



Gabriela Maia Rodrigues

# **Modelagem Computacional de Rotas de Deslocamento Pré-coloniais: Explorações a partir de Otimização por Enxame de Partículas**

Recife

2026

Gabriela Maia Rodrigues

# **Modelagem Computacional de Rotas de Deslocamento Pré-coloniais: Explorações a partir de Otimização por Enxame de Partículas**

Monografia apresentada ao Curso de Bacharelado em Ciências da Computação da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do título de Bacharel em Ciências da Computação.

Universidade Federal Rural de Pernambuco – UFRPE

Departamento de Computação

Curso de Bacharelado em Ciências da Computação

Orientador: André Câmara Alves do Nascimento

Coorientador: Lucas Bonald Pedrosa de Souza

Recife

2026



MINISTÉRIO DA EDUCAÇÃO E DO DESPORTO  
UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO (UFRPE)  
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO  
<http://www.bcc.ufrpe.br>

**FICHA DE APROVAÇÃO DO TRABALHO DE CONCLUSÃO DE CURSO**

Trabalho defendido por Gabriela Maia Rodrigues às 10:00 do dia 11/02/2026, como requisito para conclusão do curso de Bacharelado em Ciência da Computação da Universidade Federal Rural de Pernambuco, intitulado **Modelagem Computacional de Rotas de Deslocamento Pré-coloniais: Explorações a partir de Otimização por Enxame de Partículas**, orientado por André Câmara Alves do Nascimento e aprovado pela seguinte banca examinadora:

---

André Câmara Alves do Nascimento  
DC/UFRPE

---

Grégoire André Henri Marie Ghislain Van Havre  
UFPI

---

Péricles Barbosa Cunha de Miranda  
DC/UFRPE

Dados Internacionais de Catalogação na Publicação  
Sistema Integrado de Bibliotecas da UFRPE  
Bibliotecário(a): Suely Manzi – CRB-4 809

R696m Rodrigues, Gabriela Maia.  
Modelagem computacional de rotas de deslocamento pré-coloniais: explorações a partir de otimização por enxame de partículas / Gabriela Maia Rodrigues. – Recife, 2026.  
64 f.; il.

Orientador(a): André Câmara Alves do Nascimento.  
Co-orientador(a): Lucas Bonald Pedrosa de Souza.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal Rural de Pernambuco, Bacharelado em Ciência da Computação, Recife, BR-PE, 2026.

Inclui referências, apêndice(s) e anexo(s).

1. Análise espacial (Estatística). 2. Inteligência computacional. 3. Modelagem computacional. 4. Arqueologia 5. Sistemas de Informação Geográfica. I. Nascimento, André Câmara Alves do, orient. II. Souza, Lucas Bonald Pedrosa de, coorient. III. Título

CDD 004

# Agradecimentos

Agradeço primeiramente a Deus, que nunca me deixou desamparada, independentemente das circunstâncias. Durante o período da graduação, tive muitos desafios pessoais e profissionais, mas em todos eles pude ver a mão do Senhor me guiando até o final.

Agradeço aos meus pais e aos meus avós, que confiaram em mim e investiram esforço, dedicação e recursos para que eu pudesse ter uma educação de qualidade. É por eles que hoje também me esforço para retribuir tudo o que um dia fizeram por mim. Reconheço cada noite mal dormida, esperando minha volta para casa quase de madrugada nos dias de aula a noite, cada ida ao terminal para me buscar sempre que possível, todas as vezes que pude usar o carro para chegar a tempo das aulas em dias intensos de trabalho, e também cada conselho que me deu forças para continuar ou me orientou quando era necessário parar. Obrigada pelas orações, tenho certeza que nunca me ocorreu nada durante esses anos também por conta delas. Vocês são a minha base e a quem eu devo tudo o que tenho e sou.

Aos meus irmãos, Rebeca e Guilherme, também meu agradecimento por todo suporte. Como irmã mais velha pude compartilhar com vocês meus sonhos ao longo de suas vidas, e hoje poder dividir alguns deles com vocês, incluindo o amor pela ciência, se tornou uma das minhas maiores dádivas. Agradeço de forma especial à minha prima Lalay, minha melhor amiga de longa data, e ao meu namorado Law, por estarem sempre presentes, oferecendo apoio, incentivo e carinho. Amo todos vocês.

Agradeço aos meus amigos da igreja, que dividiram comigo essa jornada ao longo dos anos, e às minhas amigas da escola, que acompanharam minhas conquistas desde os primeiros passos da vida acadêmica até este momento. Aos meus colegas de curso e de faculdade: o que seria dessa caminhada sem vocês? Obrigada pelo apoio desde o primeiro semestre, pela ajuda nos momentos mais difíceis, pela convivência no RU, nos passeios de circular, nas conversas no departamento, nas aulas de educação física, no vôlei, nas caronas e em tantos outros momentos compartilhados. Sou profundamente grata por estar cercada de pessoas tão especiais.

Por fim, e não menos importante, agradeço aos meus orientadores, André e Lucas, por aceitarem esse desafio comigo. Unir arqueologia e ciência da computação sempre foi um sonho antigo, e torná-lo realidade com o apoio de vocês foi mais do que especial. Agradeço também aos professores e servidores do curso, que contribuíram para uma experiência acadêmica marcante, a Rural sempre será para mim uma segunda casa.

*“O extraordinário está no que fazemos, não em quem somos.”  
(Tomb Raider, 2013)*

# Resumo

A modelagem de caminhos antigos tem se destacado como uma abordagem relevante na arqueologia, permitindo inferir padrões de mobilidade e interação humana a partir da análise espacial. Simulações mais fiéis às condições locais podem fomentar novas descobertas e ações de preservação do patrimônio. Este trabalho investiga métodos sistemáticos para modelar a mobilidade antiga em terrenos complexos, apresentando um estudo aplicado ao Parque Nacional do Catimbau, Pernambuco. O objetivo é comparar conceitualmente o método tradicional de Caminho de Menor Custo (*Least-Cost Path* - LCP) com o uso de meta-heurísticas de otimização, com ênfase no *Particle Swarm Optimization* (PSO), para a estimativa de trajetos eficientes entre pontos de interesse arqueológico. A pesquisa utiliza três variáveis ambientais determinantes para a locomoção em relevo acidentado: declividade, visibilidade e insolação, integradas à superfície de custo. Enquanto o LCP tradicional se baseia em algoritmos determinísticos sobre matrizes de fricção, condicionados à discretização direcional da vizinhança, o PSO emprega uma busca estocástica realizada por um enxame de partículas, oferecendo maior flexibilidade para explorar soluções e potencial para evitar mínimos locais. Os experimentos indicaram comportamento convergente e estável do algoritmo PSO, com calibração consistente dos pesos associados às variáveis ambientais, evidenciando a influência persistente da insolação na definição das rotas e a maior relevância da declividade em trajetos de maior extensão, refletindo prováveis estratégias de economia de esforço em escala regional. A comparação com o método tradicional de LCP evidenciou diferenças qualitativas nos traçados, com a abordagem multicritério produzindo rotas mais equilibradas frente às restrições topográficas e ambientais da paisagem semiárida. A proposta não busca substituir os métodos consolidados de LCP em Sistemas de Informação Geográfica, mas ampliar o campo de experimentação metodológica, considerando cenários nos quais o custo do movimento pode ser inferido ou ajustado a partir de evidências arqueológicas. Espera-se que o desenvolvimento dessas abordagens contribua para os debates sobre mobilidade em paisagens do passado, indicando direções para aplicações futuras em estudos arqueológicos e históricos.

**Palavras-chave:** Least-Cost Path (LCP), Particle Swarm Optimization (PSO), superfícies de custo, arqueologia computacional, Sistemas de Informação Geográfica (SIG).

# Abstract

The modeling of ancient pathways has emerged as a relevant approach in archaeology, allowing the inference of mobility patterns and human interaction through spatial analysis. Simulations that more accurately reflect local conditions can foster new discoveries and heritage conservation efforts. This work investigates systematic methods for modeling ancient mobility in complex terrains, presenting an applied study in the Catimbau National Park, Pernambuco. The objective is to conceptually compare the traditional Least-Cost Path (LCP) method with the use of optimization metaheuristics, emphasizing Particle Swarm Optimization (PSO), for estimating efficient routes between points of archaeological interest. The research utilizes three determinant environmental variables for locomotion in rugged terrain: slope, visibility, and insolation, which are integrated into the cost surface. While the traditional LCP relies on deterministic algorithms over friction matrices, conditioned by the directional discretization of the neighborhood, the PSO employs a stochastic search performed by a particle swarm, offering greater flexibility to explore solutions and the potential to avoid local minima. The experiments indicated a convergent and stable behavior of the PSO algorithm, with a consistent calibration of the weights associated with the environmental variables, highlighting the persistent influence of insolation in route definition and the greater relevance of slope in longer trajectories, reflecting probable effort-saving strategies on a regional scale. The comparison with the traditional LCP method revealed qualitative differences in the trajectories, with the multicriteria approach producing more balanced routes against the topographic and environmental constraints of the semiarid landscape. The proposal does not seek to replace the consolidated LCP methods in Geographic Information Systems, but rather to expand the field of methodological experimentation, considering scenarios in which the cost of movement can be inferred or adjusted from archaeological evidence. It is expected that the development of these approaches will contribute to the debates on mobility in past landscapes, indicating directions for future applications in archaeological and historical studies.

**Keywords:** Least-Cost Path (LCP), Particle Swarm Optimization (PSO), cost surfaces, computational archaeology, Geographic Information Systems (GIS).

# Lista de ilustrações

Figura 1 – Análise de caminho de menor custo ( <i>Least-Cost Path</i> ) entre sítios arqueológicos romanos do entorno e o sítio de Case Nuove, representada por zonas de superfície de menor custo acumulado, indicando áreas com o mesmo esforço de deslocamento. . . . .	17
Figura 2 – Exemplo de mapa de densidade de caminhos resultante da aplicação do método <i>FETE</i> . . . . .	20
Figura 3 – Fluxograma do funcionamento do algoritmo PSO. . . . .	24
Figura 4 – Vista panorâmica do Parque Nacional do Catimbau, Pernambuco. . . . .	30
Figura 5 – Pintura rupestre mostra cena de dança na Loca das Cinzas, no Vale do Catimbau. . . . .	31
Figura 6 – Camadas ambientais utilizadas na modelagem da superfície de custo no Parque Nacional do Catimbau: (a) insolação, (b) declividade e (c) visibilidade. . . . .	37
Figura 7 – Histórico de minimização da função objetivo pelo PSO. . . . .	44
Figura 8 – Superfícies de custo normalizadas utilizadas na função objetivo. <b>(A)</b> Declividade normalizada. <b>(B)</b> Visibilidade normalizada. <b>(C)</b> Insolação normalizada. . . . .	46
Figura 9 – Superfície de Custo Total Agregada. A imagem sintetiza a impedância acumulada da paisagem, onde áreas em amarelo/verde representam zonas de baixo custo (corredores de movimento) e áreas em azul/roxo indicam barreiras de alta resistência ao deslocamento. . . . .	48
Figura 10 – Rota do Cenário A sobre a Superfície de Custo Total. As áreas em tons frios (azul/roxo) indicam alta resistência, enquanto tons quentes (amarelo/verde) representam zonas de trânsito facilitado. A rota (linha vermelha) explora um corredor natural de baixa fricção. . . . .	49
Figura 11 – Rota do Cenário B sobre a Superfície de Custo Total. Nota-se a alta fragmentação da paisagem, com barreiras de alto custo (azul escuro) bloqueando o vetor direto. O algoritmo realiza curvas acentuadas para manter-se nas zonas de menor custo (verde/amarelo). . . . .	50
Figura 12 – Perfil Altimétrico do Cenário A. A rota de $\approx 11,5$ km mantém-se predominantemente em cotas estáveis (entre 630m e 750m), caracterizando um deslocamento de meia-encosta com poucas variações abruptas. . . . .	51

Figura 13 – Perfil Altimétrico do Cenário B. Em um trajeto de longa duração ( $\approx$ 31 km), o algoritmo identificou uma rampa de ascensão constante e gradual (do km 3 ao km 24), evitando picos de esforço vertical antes da chegada ao topo da serra. . . . .	52
Figura 14 – Comparação qualitativa para o Cenário A. Em <b>(A)</b> , o algoritmo tradicional prioriza rigidamente a topografia para evitar qualquer custo vertical. Em <b>(B)</b> , o PSO propõe um trajeto com leves desvios para otimizar custos térmicos e visuais. . . . .	54
Figura 15 – Comparação qualitativa para o Cenário B. A rota tradicional <b>(A)</b> apresenta alta sinuosidade geométrica para contornar o relevo. A rota otimizada <b>(B)</b> exhibe vetores mais retilíneos em determinados trechos, balanceando o esforço da subida com a necessidade de evitar a insolação prolongada. . . . .	56

# Lista de tabelas

Tabela 1 – Variação dos pesos calibrados em função da escala do deslocamento 45

# Lista de abreviaturas e siglas

ACO	Ant Colony Optimization (Otimização por Colônia de Formigas)
AG	Algoritmos Genéticos
CLI	Command-Line Interface (Interface de Linha de Comando)
CSR	Compressed Sparse Row (Formato Esperso de Matriz)
DEM	Digital Elevation Model (Modelo Digital de Elevação)
FETE	From Everywhere To Everywhere (De Todo Lugar Para Todo Lugar)
LCP	Least-Cost Path (Caminho de Menor Custo)
MDE	Modelo Digital de Elevação
NSGA-II	Non-dominated Sorting Genetic Algorithm II
PSO	Particle Swarm Optimization (Otimização por Enxame de Partículas)
SIG	Sistemas de Informação Geográfica
SRTM	Shuttle Radar Topography Mission
UFRPE	Universidade Federal Rural de Pernambuco
USGS	United States Geological Survey (Serviço Geológico dos Estados Unidos)

# Sumário

	<b>Lista de ilustrações</b> . . . . .	<b>8</b>
<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>14</b>
<b>1.1</b>	<b>Contextualização</b> . . . . .	<b>14</b>
<b>1.2</b>	<b>Problema de pesquisa</b> . . . . .	<b>15</b>
<b>1.3</b>	<b>Objetivos da pesquisa</b> . . . . .	<b>15</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> . . . . .	<b>17</b>
<b>2.1</b>	<b>Least-Cost Path (LCP)</b> . . . . .	<b>17</b>
2.1.1	Funções de Custo . . . . .	18
2.1.2	<i>From Everywhere To Everywhere</i> . . . . .	19
2.1.3	Limitações do LCP . . . . .	21
<b>2.2</b>	<b>Metaheurísticas</b> . . . . .	<b>22</b>
2.2.1	Tipos de Metaheurísticas . . . . .	22
<b>2.3</b>	<b>Particle Swarm Optimization (PSO)</b> . . . . .	<b>23</b>
<b>3</b>	<b>TRABALHOS RELACIONADOS</b> . . . . .	<b>26</b>
<b>3.1</b>	<b>Metaheurísticas aplicadas à modelagem espacial</b> . . . . .	<b>27</b>
<b>4</b>	<b>METODOLOGIA</b> . . . . .	<b>30</b>
<b>4.1</b>	<b>Contexto e Base de Dados</b> . . . . .	<b>30</b>
<b>4.2</b>	<b>Ferramentas Utilizadas</b> . . . . .	<b>32</b>
<b>4.3</b>	<b>Arquitetura Geral do Método</b> . . . . .	<b>33</b>
<b>4.4</b>	<b>Processamento e Normalização de Dados Raster</b> . . . . .	<b>33</b>
<b>4.5</b>	<b>Variáveis Ambientais e Pesos</b> . . . . .	<b>35</b>
<b>4.6</b>	<b>Balanceamento de Custos e Função Objetivo</b> . . . . .	<b>37</b>
4.6.1	Construção do Grafo Anisotrópico . . . . .	39
4.6.2	Dinâmica do Enxame e Heurística de Busca . . . . .	39
4.6.3	Eficiência e Paralelismo . . . . .	40
4.6.4	Extração de Caminhos e Topologia . . . . .	41
4.6.5	Métricas de Avaliação de Caminhos . . . . .	41
4.6.6	Protocolo de Validação e Robustez . . . . .	42
<b>5</b>	<b>RESULTADOS</b> . . . . .	<b>43</b>
<b>5.1</b>	<b>Análise de Convergência e Robustez</b> . . . . .	<b>43</b>
<b>5.2</b>	<b>Calibração dos Pesos e Adaptação à Paisagem</b> . . . . .	<b>45</b>
<b>5.3</b>	<b>Análise das Superfícies de Custo Normalizadas</b> . . . . .	<b>46</b>

<b>5.4</b>	<b>Espacialização das Rotas sobre a Superfície de Custo . . . . .</b>	<b>48</b>
5.4.1	Cenário A . . . . .	48
5.4.2	Cenário B . . . . .	49
<b>5.5</b>	<b>Análise dos Perfis Altimétricos . . . . .</b>	<b>50</b>
<b>5.6</b>	<b>Comparação com o Método de Referência . . . . .</b>	<b>52</b>
<b>5.7</b>	<b>Análise de Complexidade Computacional . . . . .</b>	<b>57</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>59</b>
<b>6.1</b>	<b>Limitações das Abordagens . . . . .</b>	<b>59</b>
<b>6.2</b>	<b>Trabalhos Futuros . . . . .</b>	<b>60</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>62</b>

# 1 Introdução

## 1.1 Contextualização

A relação entre o ser humano e o espaço está marcada por transformações mútuas: à medida que ocupamos territórios, moldamos caminhos, e esses caminhos, por sua vez, condicionam padrões de mobilidade e ocupação. A arqueologia dedica-se ao estudo das marcas deixadas por essa constante série de transformações, investigando o passado e o legado do ser humano em diferentes lugares e contextos (TILLEY, 1994). No Brasil, os estudos voltados à cultura e ao legado dos povos originários abrangem diversas abordagens, dentre elas o estudo dos caminhos traçados e dos vestígios deixados nas terras habitadas.

Segundo Gattiglia (2025), para que os dados arqueológicos adquiram significado, é essencial o desenvolvimento de teorias e práticas narrativas. O estudo de rotas mostra-se uma peça chave para fundamentar teorias que expliquem a passagem humana por determinados locais e auxiliem na compreensão da ocupação territorial. Ao seguir trajetos antigos, é possível analisar como populações do passado interagem com o ambiente e se adaptavam às suas transformações.

Compreender rotas antigas implica não apenas reconstruir deslocamentos, mas reconhecer o valor histórico, simbólico e territorial desses caminhos. Rotas constituem marcadores de práticas culturais, estratégias de ocupação e formas de interação com a paisagem. Pesquisas como a de Dutra (2022), sobre os caminhos Guarani no sul do Brasil, demonstram que trajetos antigos expressam não apenas direções de mobilidade, mas redes de intercâmbio social, político e espiritual entre diferentes grupos.

A identificação e modelagem desses caminhos são essenciais para entender a distribuição de sítios e formas de territorialidade, e para investigar essas dinâmicas, a arqueologia moderna tem recorrido cada vez mais a métodos quantitativos e computacionais. A simulação de movimento em paisagens antigas permite testar hipóteses sobre como a topografia e o ambiente influenciavam as decisões de deslocamento. Diversos estudos indicam que estruturas arqueológicas frequentemente se alinham a rotas históricas reconstruídas por modelagem espacial, como observado por Lewis (2021).

## 1.2 Problema de pesquisa

Apesar do avanço das abordagens computacionais na modelagem de mobilidade, grande parte dos estudos ainda se apoia na atribuição manual e pré-determinada de pesos às variáveis ambientais, frequentemente limitada a poucos fatores físicos, como a declividade. Ademais, muitos desses modelos foram desenvolvidos e validados em contextos temperados presentes no hemisfério norte, o que levanta questionamentos quanto à sua adequação a paisagens semiáridas, como as do Nordeste brasileiro, onde variáveis como insolação, visibilidade e estresse térmico assumem papel central na mobilidade humana.

Outro desafio recorrente reside na dependência de fluxos de trabalho fortemente acoplados a softwares de Sistemas de Informação Geográfica (SIG) baseados em interfaces gráficas, o que dificulta a experimentação massiva, a análise estatística de múltiplos cenários e a reprodutibilidade dos resultados. A ausência de controle explícito sobre os processos algorítmicos e sobre a calibração dos parâmetros limita a transparência metodológica e a comparação entre estudos.

Diante desse cenário, este trabalho parte do seguinte problema de pesquisa: como otimizar computacionalmente o cálculo de Caminhos de Menor Custo em rotas antigas, considerando o maior número possível de variáveis do ambiente no contexto de Pernambuco?

## 1.3 Objetivos da pesquisa

O objetivo geral desta pesquisa é modelar e otimizar rotas arqueológicas no Vale do Catimbau, utilizando Caminhos de Menor Custo com múltiplas variáveis ambientais, superfícies de custo multivariadas e técnicas de otimização baseadas em metaheurísticas.

De forma a atender ao objetivo geral, estabelecem-se como objetivos específicos:

1. Integrar dados arqueológicos e ambientais relevantes para a modelagem da mobilidade em paisagens semiáridas;
2. Modelar rotas de deslocamento arqueológico por meio do cálculo de Caminhos de Menor Custo sobre grafos anisotrópicos com vizinhança estendida;
3. Calibrar automaticamente os pesos das variáveis ambientais por meio do algoritmo de Otimização por Enxame de Partículas (PSO);

4. Comparar as rotas obtidas a partir de superfícies de custo multicritério com aquelas geradas por abordagens tradicionais univariadas baseadas exclusivamente na declividade;
5. Analisar o comportamento computacional do modelo proposto em termos de convergência, estabilidade e reprodutibilidade dos resultados.

Ao adotar uma abordagem algorítmica independente de plataformas específicas de SIG, o estudo busca contribuir para o desenvolvimento de métodos mais reprodutíveis, portáteis e passíveis de generalização, ampliando o campo de experimentação metodológica na análise de rotas antigas e no apoio à formulação de hipóteses arqueológicas.

## 2 Fundamentação Teórica

### 2.1 Least-Cost Path (LCP)

Uma importante abordagem que viabiliza a identificação de rotas antigas é o cálculo de *Least-Cost Path* (LCP), ou Caminho de Menor Custo, que, de acordo com White (2017), pode ajudar a entender melhor a forma como as pessoas podem ter se movimentado em uma paisagem, tomando decisões de movimento de forma racional para minimizar os custos durante o processo de deslocamento entre locais.

Uma vez estabelecidos os pontos de origem e destino (aldeias, sítios arqueológicos ou pontos geográficos de interesse), o cálculo de LCP depende da definição de uma função de custo capaz de representar os obstáculos e facilidades da paisagem. O Modelo Digital de Elevação (MDE) é um dos recursos fundamentais nesse processo, pois, como explica Herzog (2013a), a partir dele é possível extrair a declividade (*slope*) do terreno e assim, de acordo com a metodologia tradicional, estimar a dificuldade de deslocamento. A partir da declividade é gerada uma superfície de fricção, que representa o esforço relativo necessário para atravessar cada célula da malha espacial.

O cálculo do caminho mais eficiente é realizado por algoritmos de grafos, como o de Dijkstra (1959), que utilizam essas superfícies de fricção como pesos nas arestas entre células adjacentes.

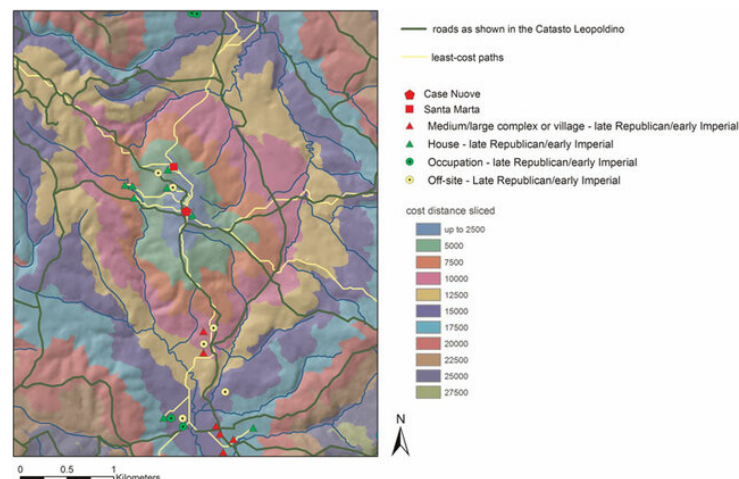


Figura 1 – Análise de caminho de menor custo (*Least-Cost Path*) entre sítios arqueológicos romanos do entorno e o sítio de Case Nuove, representada por zonas de superfície de menor custo acumulado, indicando áreas com o mesmo esforço de deslocamento.

Fonte: Adaptado de Vaccaro et al. (2013).

### 2.1.1 Funções de Custo

A função de custo constitui o componente central da análise de caminhos, atuando como a regra matemática que traduz as características da paisagem em valores quantitativos de resistência ao deslocamento. Herzog (2013a) define essa função como a espinha dorsal de qualquer análise de LCP em arqueologia, uma vez que a escolha das variáveis e a forma como seus valores são ponderados influenciam diretamente o traçado final da rota simulada.

Enquanto os algoritmos de busca (como Dijkstra) fornecem a mecânica para navegar pelo grafo, é a função de custo que define a "topografia do esforço", determinando o peso de cada aresta com base na variável utilizada.

Dentro do cálculo e análise de rotas, destacam-se dois conceitos de variáveis nas funções de custo: os custos isotrópicos e os custos anisotrópicos. Custos isotrópicos assumem resistência uniforme ao movimento independentemente da direção, enquanto custos anisotrópicos alteram o custo a depender do sentido real do deslocamento, especialmente em terrenos inclinados. Como mostram Conolly e Lake (2006), a incorporação da direção do deslocamento é importante para representar de maneira mais exata o comportamento do movimento humano sobre o terreno.

Em cenários nos quais a declividade é incluída, os custos tornam-se anisotrópicos, isto é, variam conforme a direção do deslocamento. Essa diferença direcional faz com que o custo de ir de  $A$  até  $B$  não seja igual ao de  $B$  até  $A$ , representado formalmente por:

$$\text{CustoDist}(A, B) \neq \text{CustoDist}(B, A) \quad (2.1)$$

Para lidar com essa assimetria, uma abordagem comum é calcular a bifuncionalidade (*BiCost*) do trajeto utilizando:

$$\text{BiCost}(A, B) = \text{CustoDist}(A, B) + \text{CustoDist}(B, A) \quad (2.2)$$

Esse procedimento, descrito por Herzog (2013a), permite comparar diferentes trajetos de forma mais ampla, especialmente em análises exploratórias. A escolha entre custos isotrópicos ou anisotrópicos depende dos objetivos da pesquisa e da natureza do terreno analisado, sendo a declividade geralmente o fator de maior impacto em contextos arqueológicos. Verhagen (2013) também reforçam que ela frequentemente é a variável mais sensível e dominante em análises de mobilidade.

Para além disso, White (2017) aponta que fatores como a escolha do número de vizinhos na grade e a forma de lidar com dados direcionais também são decisivos para a robustez da análise de LCP.

Além da declividade, outras variáveis podem ser integradas ao modelo, como visibilidade (MILHEIRA, 2021), áreas pantanosas (HERZOG, 2022), insolação (TOMÉ; HAVRE, 2023) e até fatores culturais, como preferências territoriais ou rituais associados a rotas específicas (ROSENSWIG; TUÑÓN, 2020). Cada variável altera a resistência ao movimento de maneiras distintas e pode ser ajustada conforme o contexto do estudo.

Uma das bases para as funções de custo modernas remonta às correções propostas por Langmuir (1984) sobre a clássica Regra de Naismith. Langmuir refinou o cálculo do tempo de caminhada ao introduzir a variável de "frenagem" para descidas: enquanto declives suaves favorecem o deslocamento, inclinações negativas acentuadas (geralmente superiores a 12 graus) voltam a aumentar o custo energético devido à necessidade fisiológica de conter o movimento para manter o equilíbrio. Atualmente, os coeficientes de Langmuir são amplamente utilizados como padrão para funções de custo anisotrópicas em softwares de SIG (como na função *r.walk* do GRASS GIS), sendo essenciais para modelar com precisão o esforço humano em relevos acidentados onde descer nem sempre é mais fácil que subir.

### 2.1.2 *From Everywhere To Everywhere*

Como método complementar e evolutivo ao cálculo tradicional de rotas, a abordagem *From Everywhere To Everywhere* (FETE) surge como uma ferramenta para analisar a conectividade potencial da paisagem. Formalizada seminalmente na arqueologia por White e Barber (2012), essa técnica propõe uma mudança de paradigma: ao invés de limitar-se a trajetórias pontuais previamente definidas, o FETE considera a conectividade entre múltiplos locais simultaneamente, calculando o custo de deslocamento entre todos os pares possíveis de células ou nós dentro de uma malha de estudo.

Essa técnica expande as capacidades analíticas da pesquisa ao superar as restrições dos modelos tradicionais de Caminho de Menor Custo (LCP), que dependem da definição prévia de pares de origem e destino. O FETE opera mediante uma lógica de fluxo acumulado baseada na conectividade integral, calculando caminhos teóricos entre todos os pontos da malha para gerar uma rede onidirecional. Essa abordagem garante a independência dos registros, permitindo inferir lógicas de movimento mesmo em áreas com vazios documentais e mitigando o viés de dependência de sítios conhecidos. O produto dessa análise transcende rotas lineares isoladas, como pode ser observado na Figura 2, resultando em mapas de densidade de fluxo que revelam corredores topográficos naturais de trânsito intenso, independentes de objetivos de deslocamento específicos.




Figura 2 – Exemplo de mapa de densidade de caminhos resultante da aplicação do método *FETE*.

Fonte: Adaptado de (WHITE; BARBER, 2012)

Além da reconstrução de mobilidade, o método tem sido empregado como ferramenta preditiva, identificando áreas de alta probabilidade arqueológica ao sobrepor sítios conhecidos com os “corredores de movimento” naturais indicados pelo modelo (WHITE; BARBER, 2012).

A relevância contemporânea e a escalabilidade do FETE são exemplificadas por Crabtree et al. (2021), que utilizaram uma variação dessa abordagem para modelar as rotas de povoamento do antigo continente Sahul (atuais Austrália e Nova Guiné). Ao processar bilhões de caminhos potenciais, o estudo identificou o que os autores denominaram “super-rodovias” humanas: corredores fundamentais de travessia que emergem naturalmente da topografia e da disponibilidade de recursos hídricos. Esses resultados validam a premissa do FETE de que a estrutura da paisagem, por si só, é capaz de prever rotas de migração de longa distância, mesmo na ausência de dados pontuais de assentamentos.

### 2.1.3 Limitações do LCP

Apesar de sua ampla aplicação, o LCP apresenta limitações metodológicas importantes. Herzog (2022) destaca que muitos algoritmos empregados nas análises de caminhos ainda se restringem a apenas oito direções de movimentação, o que pode gerar distorções conhecidas como *elongation error*, na qual o algoritmo é forçado a aproximar a trajetória através de um padrão de zigue-zague, especialmente em áreas de relevo acidentado.

A definição da função de custo também constitui um desafio. Como observa Herzog (2013b), a ampliação da área de estudo pode introduzir novas variáveis ambientais e modificar significativamente os resultados, alterando a lógica de esforço previamente aplicada. A resolução e precisão do Modelo Digital de Elevação (MDE) influenciam diretamente a estimativa de declividade e, conseqüentemente, o cálculo do custo de deslocamento, tornando-se fatores cruciais para a modelagem.

Além dos desafios algorítmicos, há uma limitação crítica quanto à aplicabilidade ecológica dos modelos tradicionais. Grande parte das funções de custo foi desenvolvida e calibrada para ambientes temperados, ignorando variáveis críticas de regiões tropicais. Tomé e Havre (2023), ao aplicarem o LCP na Serra das Confusões (PI), demonstram que fatores climáticos locais, especificamente a intensa insolação e as altas temperaturas, impõem um custo fisiológico determinante ao movimento.

A viabilidade da análise também é frequentemente restringida por gargalos computacionais. O processamento de LCP em áreas extensas ou com DEMs de alta resolução demanda um elevado poder de processamento (CPU) e uma quantidade significativa de memória RAM. A complexidade aumenta exponencialmente quando se utilizam abordagens iterativas, nas quais o custo computacional para calcular milhares de rotas alternativas pode tornar a execução proibitiva em hardware convencional, exigindo otimizações de software ou infraestrutura de alto desempenho.

Além dessas limitações, existe uma restrição estrutural associada à dependência de ambientes GIS interativos para a condução de análises de Caminho de Menor Custo. Plataformas amplamente utilizadas na arqueologia são altamente eficientes para análises exploratórias e estudos de caso pontuais, porém apresentam limitações significativas quando o objetivo envolve experimentação massiva, otimização iterativa e avaliação estatística de um grande número de cenários. Processos como a geração automática de múltiplas superfícies de custo, a análise de convergência de algoritmos estocásticos, o teste de estabilidade dos resultados e a investigação das propriedades das redes resultantes tornam-se difíceis de implementar de forma sistemática em fluxos de trabalho predominantemente manuais ou fortemente dependentes de interfaces gráficas.

Grande parte dos estudos baseados em LCP ainda se apoia também em modelos simplificados, frequentemente limitados ao uso de uma única variável e a funções de custo com pesos fixos e não calibrados, condição essa que pode acabar por reduzir a capacidade de generalização dos resultados e dificulta a reprodução rigorosa dos experimentos. A ausência de pipelines automatizados e reproduzíveis compromete a replicação em outros contextos espaciais e limita a realização de experimentos sistemáticos em escala local, particularmente em regiões pouco representadas na literatura, como o semiárido nordestino (HERZOG, 2022).

## 2.2 Metaheurísticas

Situadas no campo de estudo da Inteligência Artificial, as metaheurísticas são definidas por Gendreau e Potvin (2019) como métodos de solução que organizam a interação entre procedimentos de melhoria local e estratégias de nível superior. Frequentemente inspiradas em fenômenos biológicos, físicos ou no comportamento social de animais, essas técnicas buscam modelar matematicamente processos naturais para resolver problemas computacionais complexos. Essa abordagem bio-inspirada permite que o algoritmo realize uma busca aprofundada, escapando de ótimos locais e encontrando soluções mais próximas ao ideal em cenários nos quais métodos exatos tradicionais se mostram inviáveis ou computacionalmente custosos.

### 2.2.1 Tipos de Metaheurísticas

As metaheurísticas são classificadas comumente entre duas categorias primárias: as baseadas em trajetória, que evoluem uma única solução ao longo do tempo, e as baseadas em população, que trabalham com um conjunto de soluções simultâneas colaborando entre si.

Dentro da categoria populacional, destacam-se algoritmos clássicos que mimetizam a evolução ou o comportamento de grupos. Os Algoritmos Genéticos (AG), propostos por Holland (1975), baseiam-se na teoria da evolução darwiniana e na genética, utilizando operadores de seleção, cruzamento e mutação. Em paralelo, a Otimização por Colônia de Formigas (ACO), introduzida por Dorigo (1992), inspira-se na comunicação indireta via feromônios de formigas reais, sendo amplamente utilizada para problemas de roteamento em domínios discretos.

Neste trabalho, utilizamos a Otimização por Enxame de Partículas (PSO). Embora também pertença à subárea da Inteligência de Enxame, assim como o ACO, o PSO diferencia-se por ter sido concebido originalmente para operar em espaços de busca contínuos e multidimensionais, característica que o torna naturalmente mais aderente à otimização de superfícies de custo contínuas.

## 2.3 Particle Swarm Optimization (PSO)

Dentre as técnicas metaheurísticas capazes de operar no cenário espacial descrito anteriormente, o *Particle Swarm Optimization* (PSO) assume papel central neste trabalho. Desenvolvido por Kennedy e Eberhart (1995), o PSO é um algoritmo de otimização baseado em população que, diferentemente dos algoritmos genéticos, não utiliza operadores de evolução (como cruzamento ou mutação), mas sim uma dinâmica de movimento cooperativo inspirada no comportamento social de bandos de pássaros ou cardumes de peixes.

A arquitetura do algoritmo apresenta características particularmente úteis para a exploração de espaços de busca geográficos. Segundo Poli, Kennedy e Blackwell (2007), o PSO opera através de um enxame de partículas que navegam pelo hiperespaço de busca, onde cada partícula representa uma solução potencial (neste caso, um caminho ou conjunto de parâmetros). O movimento de cada indivíduo não é aleatório, mas governado por uma combinação de sua própria experiência e da experiência coletiva do grupo.

Matematicamente, o algoritmo Particle Swarm Optimization (PSO) pode ser descrito como um processo iterativo de busca em um espaço vetorial contínuo, no qual cada partícula representa uma solução candidata ao problema de otimização. Neste trabalho, o espaço de busca é definido como um espaço  $\mathbb{R}^n$ , no qual cada dimensão corresponde a um peso associado às variáveis ambientais consideradas na modelagem da superfície de custo. Assim, a posição de uma partícula  $x_i$  representa um vetor de pesos que define uma configuração específica de ponderação entre declividade, visibilidade e insolação.

A dinâmica de atualização das partículas ocorre em dois passos. Inicialmente, calcula-se a nova velocidade, que determina o vetor de direção e intensidade do deslocamento da partícula no espaço de busca. Em seguida, a posição é atualizada a partir dessa velocidade. A atualização da velocidade é dada pela Equação 2.3:

$$v_i^{t+1} = w \cdot v_i^t + c_1 \cdot r_1 \cdot (pbest_i - x_i^t) + c_2 \cdot r_2 \cdot (gbest - x_i^t) \quad (2.3)$$

onde  $v_i^t$  e  $x_i^t$  representam, respectivamente, a velocidade e a posição da partícula  $i$  na iteração  $t$ . O termo  $w$  corresponde ao peso de inércia, responsável por controlar a influência do movimento anterior. Os coeficientes  $c_1$  e  $c_2$  são os fatores de aceleração associados aos componentes cognitivo e social do algoritmo. O componente cognitivo, representado por  $pbest_i$ , corresponde à melhor posição já visitada pela própria partícula, enquanto o componente social, representado por  $gbest$ , corresponde à melhor solução encontrada pelo enxame como um todo. Os vetores aleatórios  $r_1$  e  $r_2$ , com valores no intervalo  $[0, 1]$ , introduzem estocasticidade ao processo, favorecendo

a exploração do espaço de busca.

Uma vez calculada a velocidade, a posição da partícula no espaço vetorial é atualizada conforme a Equação 2.4:

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2.4)$$

Esse ciclo de atualização é repetido iterativamente até que um critério de parada seja atingido. O fluxo lógico desse processo, desde a inicialização do enxame até a convergência do algoritmo, está ilustrado na Figura 3.

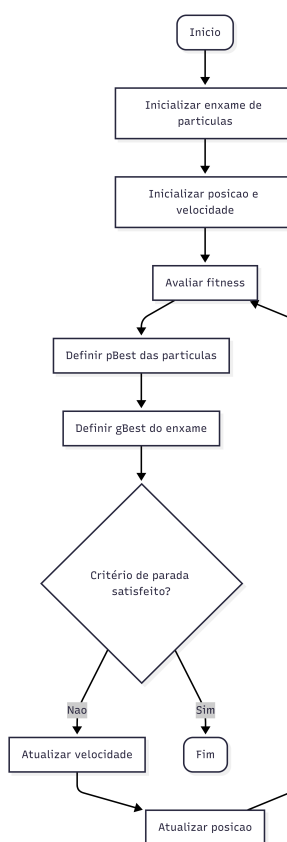


Figura 3 – Fluxograma do funcionamento do algoritmo PSO.  
Fonte: Elaborado pela autora (2026).

No que se refere à topologia de comunicação entre as partículas, este trabalho adota a configuração conhecida como *global best* (*gbest*), na qual todas as partículas compartilham informação com o melhor indivíduo global a cada iteração. Nessa topologia, o termo *gbest* representa a melhor solução encontrada pelo enxame como um todo, promovendo uma convergência mais rápida do algoritmo. Embora topologias alternativas, como *local best* (*lbest*), utilizem vizinhanças restritas para reduzir o risco de convergência prematura, a escolha da topologia global mostra-se adequada neste estudo em função da baixa dimensionalidade do espaço de busca e da necessidade de eficiência computacional (POLI; KENNEDY; BLACKWELL, 2007).

Em uma análise comparativa entre PSO e Algoritmos Genéticos, Lin e Shen (2025) demonstram que o PSO apresenta vantagem significativa em termos de velocidade de convergência, especialmente em problemas de otimização contínua. Essa eficiência decorre da mecânica direta de atualização posicional do algoritmo, que dispensa operadores como seleção, cruzamento e mutação, permitindo alcançar soluções viáveis com um menor número de iterações.

Essa característica é particularmente relevante em aplicações geográficas, nas quais a função de custo permanece fixa, porém complexa. O equilíbrio entre exploração global e refinamento local é controlado diretamente pelos parâmetros do algoritmo. Conforme discutido por Shi e Eberhart (1998), valores mais elevados de  $c_1$  favorecem a exploração do espaço de busca, enquanto valores maiores de  $c_2$  intensificam a convergência em direção às soluções globais identificadas pelo enxame, tornando o PSO adequado à calibração de superfícies de custo multivariadas em problemas de mobilidade arqueológica.

### 3 Trabalhos Relacionados

No cenário europeu, as investigações conduzidas por (VERHAGEN, 2013) na Holanda e França destacam-se pela crítica à determinação ambiental estrita em modelos preditivos. O trabalho de Verhagen enfatiza a necessidade de incorporar a incerteza e a variabilidade comportamental nas simulações arqueológicas. Suas pesquisas demonstram que a modelagem de caminhos e a predição de sítios não devem depender exclusivamente de variáveis físicas estáticas, sugerindo que a incorporação de fatores cognitivos e a análise de sensibilidade são etapas cruciais para evitar interpretações funcionalistas simplistas da paisagem.

Ainda no contexto de abordagens computacionais avançadas, (CRABTREE et al., 2021) explora a complexidade das redes de interação humana através de modelagem baseada em agentes (*Agent-Based Modeling*) e análises de custo de deslocamento. Seus estudos ilustram como algoritmos podem ser utilizados para simular a formação de redes de troca e mobilidade em ambientes de recursos dispersos. A relevância dessa abordagem reside na demonstração de que padrões emergentes de conectividade podem ser inferidos a partir de regras simples de interação local, oferecendo um paralelo metodológico para o uso de metaheurísticas na definição de rotas ótimas.

A análise da visibilidade e sua relação com a mobilidade constitui o foco das investigações de (LEWIS, 2021) na Inglaterra. Em seu estudo sobre monumentos da Idade do Bronze, o autor investiga a correlação entre caminhos de menor custo e o controle visual da paisagem, questionando se as rotas antigas priorizavam a eficiência energética ou a exposição visual de marcos territoriais. Seus resultados sugerem que, em determinados contextos monumentais, a experiência visual desempenha um papel preponderante na definição dos trajetos, o que reforça a importância de considerar múltiplas variáveis de custo, para além da declividade, na construção de superfícies de atrito.

Em uma perspectiva voltada para a arqueologia brasileira, (TOMÉ; HAVRE, 2023) desenvolve análises espaciais na Serra das Confusões (Piauí), focadas em redes de movimento e acessibilidade. O trabalho utiliza ferramentas de SIG para modelar potenciais vias de circulação entre sítios conhecidos, testando parâmetros de custo associados à adaptação humana em regiões semiáridas. A metodologia empregada por Tomé e Van Havre para validar rotas teóricas através da integração com a base de sítios fornece um referencial direto para a interpretação de redes de mobilidade em contextos de caatinga e relevo acidentado.

A arqueologia da paisagem no sul do Brasil encontra em (MILHEIRA, 2021) um expoente na análise dos construtores de cerritos (montículos). Embora focado em contextos lagunares no Pampa, o trabalho de Milheira articula dados espaciais e etno-históricos para compreender a lógica de ocupação e mobilidade dos grupos cerriteiros. Suas investigações sobre a monumentalidade e a visibilidade inter-sítios oferecem um contraponto interpretativo importante, demonstrando como a modificação intencional da paisagem e a escolha de locais de assentamento obedecem a lógicas sociais de controle visual que podem ser investigadas através de análises de distribuição espacial.

Em nível regional, e mais especificamente no contexto do Nordeste brasileiro, a tese de doutorado de (SOUZA, 2023) traz uma abordagem metodológica inovadora para a análise de padrões de assentamento na Bacia Hidrográfica do Pajeú (PE), aplicando modelos preditivos baseados em algoritmos de aprendizado de máquina (*Machine Learning*). O trabalho avança na discussão sobre a adequação de variáveis ambientais para os biomas locais e estabelece bases para a interpretação preditiva de sítios de arte rupestre.

Fora do domínio arqueológico, o uso de metaheurísticas para problemas de planejamento de trajetória (*path planning*) tem sido amplamente explorado na literatura recente de Engenharia e Ciência da Computação. Estudos como os de Ma e Chen (2022) e Sonny, Yeduri e Cenkeramaddi (2023) investigam a aplicação de variantes avançadas do PSO em cenários de veículos aéreos não tripulados (VANTs) e ambientes 3D complexos. Esses trabalhos demonstram a capacidade do algoritmo em gerar rotas eficientes e livres de colisão, lidando com desafios geométricos e restrições energéticas similares aos encontrados na modelagem de superfícies de custo em terrenos acidentados.

### 3.1 Metaheurísticas aplicadas à modelagem espacial

Problemas de modelagem espacial têm sido amplamente reconhecidos na literatura como desafiantes para abordagens determinísticas clássicas, em função da elevada dimensionalidade dos dados, da presença de variáveis contínuas e da natureza frequentemente não linear das relações entre atributos ambientais. A representação computacional do espaço geográfico envolve grandes volumes de dados derivados de características topográficas, ambientais e antrópicas, o que torna inviável a avaliação exaustiva de todas as combinações possíveis à medida que a resolução espacial aumenta.

Outro aspecto recorrente nesses problemas é a presença de múltiplos critérios potencialmente conflitantes. Em aplicações espaciais reais, fatores como eficiência de

deslocamento, custo energético, risco ambiental e adequação territorial precisam ser considerados de forma simultânea, o que frequentemente impede a identificação de uma única solução ótima. Nesse contexto, diversos estudos têm adotado estratégias de otimização capazes de explorar conjuntos de soluções viáveis, representando diferentes compromissos entre os critérios analisados.

Diante dessas características, métodos metaheurísticos têm sido empregados como alternativas eficientes para a modelagem espacial, sobretudo pela sua capacidade de operar em espaços de busca complexos, de alta dimensionalidade e com múltiplos ótimos locais. Um exemplo clássico é apresentado por Bong e Chai (2004), que propõem um modelo de zoneamento espacial baseado em Sistemas de Informação Geográfica, no qual técnicas metaheurísticas híbridas são utilizadas para gerar soluções não dominadas em um problema multiobjetivo. Os autores demonstram que a manipulação contínua de pesos e a busca heurística permitem superar limitações impostas por abordagens combinatórias tradicionais.

Além de aplicações em zoneamento, metaheurísticas também têm sido utilizadas como ferramentas para a calibração de modelos espaciais multivariados. Nesse sentido, Chen, Panahi e Pourghasemi (2017) aplicam algoritmos como PSO, algoritmos genéticos e evolução diferencial na otimização de parâmetros de modelos preditivos voltados à suscetibilidade a deslizamentos. Os resultados indicam ganhos significativos de desempenho em relação a configurações definidas manualmente, reforçando o papel dessas técnicas na redução da subjetividade associada à parametrização de modelos espaciais.

Abordagens mais recentes apontam para uma integração crescente entre modelagem espacial, aprendizado de máquina e metaheurísticas, especialmente em problemas que envolvem múltiplas camadas ambientais e grandes conjuntos de dados. O estudo de Bordbar et al. (2022) exemplifica essa tendência ao empregar algoritmos metaheurísticos para a otimização de pesos em modelos espaciais aplicados à análise de múltiplos riscos naturais. Esses trabalhos evidenciam que o principal papel das metaheurísticas na modelagem espacial não reside na substituição de modelos geográficos ou estatísticos consolidados, mas na otimização de seus parâmetros e na exploração eficiente do espaço de soluções, ampliando a capacidade de generalização e análise dos modelos.

A leitura conjunta dessas produções indica uma oportunidade de integração metodológica, visto que enquanto as análises arqueológicas tem avançado na discussão teórica sobre quais fatores influenciam o movimento, os métodos computacionais têm refinado algoritmos capazes de processar essas variáveis de forma automatizada. Este trabalho insere-se nesse ponto de convergência, propondo um exercício experimental ao utilizar o PSO não apenas para traçar caminhos, mas para auxiliar na calibração

dos pesos das variáveis ambientais. A proposta é verificar em que medida essa abordagem computacional pode complementar os métodos tradicionais, oferecendo uma ferramenta adicional para interpretar a relação entre os sítios arqueológicos e a paisagem do Catimbau.

## 4 Metodologia

### 4.1 Contexto e Base de Dados

A área de estudo corresponde ao Parque Nacional do Catimbau, localizado no semiárido pernambucano e instituído pelo Decreto de 13 de dezembro de 2002, que estabelece como finalidade a preservação dos ecossistemas naturais da região, além de incentivar pesquisas científicas, educação ambiental e atividades de turismo ecológico (BRASIL, 2002). Trata-se de um território de elevada relevância ambiental, histórica e cultural para o entendimento dos processos de ocupação humana no Nordeste brasileiro.



Figura 4 – Vista panorâmica do Parque Nacional do Catimbau, Pernambuco.

Fonte: Instituto Chico Mendes de Conservação da Biodiversidade (s.d.)

O Catimbau abriga um dos mais importantes complexos arqueológicos do país, com mais de 60 sítios de arte rupestre documentados. Essa concentração faz do parque uma área de importância comparável a outros grandes polos arqueológicos do semiárido, como o Parque Nacional da Serra da Capivara (PI) e a região do Seridó (RN). Os registros gráficos rupestres locais apresentam uma diversidade estilística notável, sendo objeto de investigações sistemáticas iniciadas ainda na década de 1970 por pesquisadoras como Gabriela Martin e Anne-Marie Aguiar (MARTIN, 1975). As datações para as ocupações humanas na área recuam ao Holoceno Médio, com registros

de cerca de 6.640 anos B.P. (antes do presente) (ALBUQUERQUE; LUCENA, 1987), evidenciando uma longa persistência de grupos caçadores-coletores na paisagem.

Entre os locais de maior destaque encontra-se o sítio "Loca das Cinzas". Este abrigo sob rocha exemplifica a riqueza iconográfica da região, apresentando painéis atribuídos predominantemente à Tradição Nordeste, caracterizada pelo dinamismo das figuras antropomorfas e pela representação de cenas coletivas, como rituais e danças (Figura 5). A disposição das pinturas e a escolha dos suportes rochosos sugerem que a visibilidade e a acústica podem ter sido fatores determinantes na seleção destes locais, variáveis estas que dialogam diretamente com os parâmetros de análise espacial propostos neste trabalho.



Figura 5 – Pintura rupestre mostra cena de dança na Loca das Cinzas, no Vale do Catimbau.

Fonte: Fellipe Abreu (s.d.).

A região também é marcada por significativa heterogeneidade geomorfológica, incluindo afloramentos areníticos, vales encaixados e formas residuais, além de abrigar uma grande concentração de sítios arqueológicos com registros rupestres. Esses vestígios, produzidos por grupos pré-coloniais em diferentes períodos, tornam o Catimbau um cenário particularmente adequado para a investigação de modelos que buscam compreender padrões de circulação e fatores ambientais associados à mobilidade humana ao longo do tempo (MATOS, 2019).

Com base nas características ambientais e arqueológicas da área, foram selecionados e processados os conjuntos de dados necessários à modelagem espacial. O

dado primário utilizado foi o Modelo Digital de Elevação (MDE) proveniente da missão SRTM (*Shuttle Radar Topography Mission*), com resolução espacial de 30 metros (1 arco-segundo), disponibilizado pelo Serviço Geológico dos Estados Unidos (USGS). Este dado matricial (*raster*) possui natureza contínua, com os valores altimétricos locais expressos em metros.

A partir deste MDE base, foram derivadas, por meio de ferramentas computacionais dos softwares QGIS e módulos do GRASS GIS, as variáveis de custo da paisagem, garantindo a reprodutibilidade e a transparência metodológica. Para assegurar a correta calibração do modelo e a integração no algoritmo de otimização estocástica, mapeou-se a natureza espacial e os intervalos físicos reais de cada dado derivado:

- Declividade: variável de natureza contínua que representa a inclinação topográfica do terreno. Os dados foram extraídos com resolução espacial coerente ao MDE base, assumindo valores no intervalo de  $0^\circ$  (terrenos planos) a um pico máximo de  $44.16^\circ$ .
- Visibilidade: variável de natureza contínua (*Float32*), indicando bacias visuais ou índices de destaque visual na paisagem. Diferente de uma abordagem binária simples, os resultados da análise espacial retornaram um índice de alcance e conectividade visual que varia em um espectro de 0 (áreas ocultas) a 0.84 (zonas de alta visibilidade cumulativa).
- Insolação: variável de natureza contínua que quantifica a exposição do relevo à radiação solar global e o consequente estresse térmico, fator crítico em ambientes semiáridos. O processamento da variável resultou em valores flutuantes distribuídos em um intervalo de 0 a 4.65.

## 4.2 Ferramentas Utilizadas

A execução do cálculo tradicional de Caminho de Menor Custo baseou-se nas lógicas implementadas pelo GRASS GIS (módulos *r.cost*, *r.drain* e *r.walk*), ferramenta consolidada para análises de custo anisotrópico. Paralelamente, a etapa de calibração das superfícies de custo foi desenvolvida em um ambiente independente em Python.

Este ambiente permitiu a implementação de algoritmos de otimização estocástica sem as dependências de motor dos softwares de SIG comerciais. A arquitetura do código inspira-se em bibliotecas de código aberto dedicadas à análise de caminhos, como o pacote *pycda* (CLAIR, 2021) e implementações de planejamento de trajetória com inteligência de enxame (ASLANSEFAT, 2020). Essa abordagem facilita a experimentação modular de variáveis ambientais e a futura encapsulação do fluxo em ferramentas acessíveis a pesquisadores não habituados a linguagens de programação.

Com vistas à transparência metodológica e à reprodutibilidade dos experimentos, todo o pipeline computacional desenvolvido neste trabalho foi disponibilizado em repositório público. O código-fonte, bem como as instruções de execução e a organização dos dados, encontram-se disponíveis no repositório do projeto no GitHub.

### 4.3 Arquitetura Geral do Método

A operacionalização do método baseia-se em uma arquitetura computacional modular desenvolvida em linguagem Python, desenhada para processar dados espaciais de forma independente de softwares de SIG comerciais. O sistema estrutura-se como um *pipeline* de processamento contínuo, onde a saída de um módulo alimenta o subsequente, retroalimentado pelo algoritmo de otimização estocástica.

A estrutura lógica do *software* foi organizada em quatro macromódulos sequenciais:

1. Pré-processamento e Auditoria: Responsável pela ingestão, higienização estatística e transformação matemática das variáveis ambientais brutas (MDE, Declividade, Insolação e Visibilidade);
2. Modelagem de Superfície de Custo: Módulo que integra as variáveis normalizadas em uma única matriz de impedância, aplicando restrições físicas (áreas intransponíveis);
3. Análise de Caminhos em Grafo: Motor vetorial que converte a matriz raster em um grafo anisotrópico e calcula as rotas de menor custo;
4. Otimização via PSO: Camada de inteligência que gerencia o enxame de partículas para calibrar iterativamente os pesos das variáveis até a convergência do modelo.

As seções a seguir detalham a implementação algorítmica e as decisões de projeto adotadas para cada um destes componentes.

### 4.4 Processamento e Normalização de Dados Raster

A etapa inicial consistiu na padronização das camadas ambientais base: MDE, Declividade, Visibilidade e Insolação, processadas via biblioteca *Rasterio* em Python. Análises preliminares das variáveis ambientais revelaram distribuições heterogêneas e escalas díspares. A variável de Declividade apresentou forte assimetria positiva (*skewness* > 0,5), onde a predominância de áreas planas comprimia a variância útil dos

dados. A variável de Insolação, devido às extensas áreas de sombra projetada pelos afloramentos rochosos, exibiu distribuição com forte caráter binário, concentrando valores em dois intervalos extremos.

Para mitigar essas distorções antes da normalização final, aplicou-se um protocolo de estabilização de variância. A Declividade recebeu uma transformação de raiz quadrada ( $S_{trans} = \sqrt{S_{raw}}$ ), que comprime os valores extremos e expande a variância nas inclinações suaves, aumentando a sensibilidade do modelo a pequenas alterações no relevo. A Insolação passou por análise de distribuição implementada no módulo `AdvancedPreprocessor`, que detecta padrões multimodais e aplica tratamentos adaptativos.

Em contrapartida, a variável de Visibilidade apresentou uma distribuição estatística mais estável e contínua nas análises exploratórias, dispensando a aplicação de transformações de estabilização de variância prévias. Optou-se, portanto, por submetê-la diretamente ao processo de normalização, preservando a integridade dos valores brutos de visualização acumulada (*viewshed*)

Após essas transformações de estabilização, adotou-se o protocolo de *Rank Normalization* (Normalização por Postos) para garantir a uniformidade da escala de custo. Diferente de métodos lineares que apenas reescalonam os valores, esta técnica substitui o valor bruto de cada pixel pela sua posição relativa na distribuição acumulada dos dados (HYNDMAN; FAN, 1996). Matematicamente, a transformação aplicada segue a equação:

$$v_{norm} = \frac{\text{rank}(v_{raw}) - 1}{N - 1} \quad (4.1)$$

onde  $N$  representa o número total de pixels válidos na matriz. Esse procedimento força a distribuição dos custos normalizados a assumir um comportamento uniforme no intervalo  $[0, 1]$ , garantindo que o contraste local entre áreas de baixo e alto custo seja preservado, independentemente da presença de *outliers* estatísticos ou ruídos de sensor.

A escolha pela normalização por postos foi motivada pelo caráter relacional da função de custo adotada neste trabalho. Diferente de técnicas como a normalização min-max ou a padronização estatística (Z-score), a transformação por postos elimina a influência da escala absoluta dos valores, preservando exclusivamente a hierarquia relativa entre os pixels. Essa característica é particularmente adequada para superfícies de custo, nas quais o interesse analítico reside nas relações comparativas de impedância entre regiões do espaço, e não nos valores métricos absolutos das variáveis ambientais.

Após a normalização estatística, aplicou-se uma restrição de custo mínimo ope-

racional, denominada fricção basal ( $f_{\text{base}}$ ), definida em 0,1 (10%). A superfície final de cada variável ( $v_{\text{final}}$ ) foi calculada como:

$$v_{\text{final}} = f_{\text{base}} + (1 - f_{\text{base}}) \cdot v_{\text{norm}} \quad (4.2)$$

resultando em uma distribuição uniforme no intervalo  $[f_{\text{base}}, 1] = [0,1, 1,0]$ . A introdução deste termo aditivo assegura que nenhuma célula do raster, por mais favorável que seja (ex: terreno plano e sombreado), apresente custo zero de deslocamento, representando o custo metabólico basal inerente ao movimento humano. O valor de 10% foi definido empiricamente de modo a preservar a contribuição mínima de todas as variáveis durante o processo de otimização.

Lacunas de dados (*NoData*) foram tratadas através da substituição pela média global da variável correspondente, mantendo a continuidade matemática da superfície necessária para a navegação do algoritmo de otimização.

## 4.5 Variáveis Ambientais e Pesos

As variáveis ambientais integradas ao modelo (declividade, visibilidade e insolação) compõem as camadas de impedância que representam, numericamente, a resistência ao deslocamento na paisagem. Na lógica computacional adotada, cada variável foi normalizada para operar em uma escala de custo direta, na qual valores próximos a 1,0 indicam máxima resistência (alto custo energético ou risco), e valores próximos a 0,0 indicam zonas de trânsito facilitado. A combinação dessas camadas gera a superfície de custo acumulada, cuja topologia final é modulada pelos pesos calibrados durante a otimização.

A inclusão dessas variáveis específicas não é arbitrária, mas traduz para a linguagem algorítmica condicionantes físicos e culturais apontados pela literatura. A declividade atua como o vetor primário de custo físico, balizada pelas funções de movimento pedestre de Tobler (1993) e revisadas por Herzog (2013a). A visibilidade foi incorporada para representar o controle visual e a estruturação social do espaço, seguindo a premissa de Milheira (2021) sobre a importância da comunicação visual em paisagens arqueológicas. A insolação modela o estresse térmico característico do ambiente de Caatinga; baseando-se em Tomé e Havre (2023), assume-se que a alta exposição à radiação solar atua como um agente ativo de repulsão em horários críticos, moldando rotas que buscam conforto térmico.

As três variáveis distinguem-se pelo tratamento algorítmico, as camadas de visibilidade e insolação comportam-se como campos de fricção isotrópicos: seu custo é intrínseco à localização da célula (pixel) e independe da direção de onde o agente vem.

A declividade opera de forma dual e anisotrópica. Primeiramente, impõe uma barreira física rígida (*hard constraint*), onde inclinações superiores a  $30^\circ$  recebem custo infinito, simulando limites de segurança biomecânica (TOBLER, 1993). Abaixo desse limiar, o algoritmo aplica uma penalidade dinâmica, diferenciando o custo de aclive (subida) do custo de declive (descida) ou caminhada em nível, mimetizando a fisiologia do esforço humano.

Os pesos funcionam como coeficientes de calibração que traduzem a importância relativa de cada fator na decisão de movimento. Matematicamente, o custo basal de uma célula ( $C_{base}$ ) foi definido pela combinação linear convexa das variáveis normalizadas:

$$C_{base} = w_{declividade} \cdot V_{dec} + w_{visibilidade} \cdot V_{vis} + w_{insolao} \cdot V_{ins} \quad (4.3)$$

Onde  $V$  representa o valor normalizado da variável e  $w$  o peso atribuído. O algoritmo PSO opera sob a restrição rígida de que o somatório dos pesos deve ser igual à unidade ( $\sum w_i = 1,0$ ). Essa restrição é fundamental para garantir a consistência de escala da superfície de custo, impedindo que a simples inflação dos valores dos pesos altere a lógica topológica do terreno.

A penalidade anisotrópica da declividade opera através de um sistema de fatores multiplicativos que modula o custo basal. Para aclives, a penalidade segue a função  $A_{subida} = 1 + (k_{up} \cdot \theta_{norm})^2$ , onde  $\theta_{norm}$  representa a inclinação normalizada pelo limiar crítico de  $30^\circ$  e  $k_{up} = 4,0$ . Esse fator quadrático reflete o aumento exponencial do custo metabólico observado em subidas acentuadas. Em declives moderados (entre  $-5^\circ$  e  $-15^\circ$ ), o modelo implementa um fator de alívio linear que reduz o custo em até 10%, simulando a economia energética observada em descidas controladas onde a gravidade facilita o movimento. Declives acentuados (abaixo de  $-15^\circ$ ) retornam gradualmente à penalização, seguindo  $A_{descida} = 1 + (k_{down} \cdot \delta_{norm})^2$ , com  $k_{down} = 2,0$ , refletindo o aumento do risco de queda e a necessidade de frenagem muscular excêntrica. Todos os fatores de anisotropia são limitados inferiormente em 0,7 para evitar valores irrealistas de facilitação.




Figura 6 – Camadas ambientais utilizadas na modelagem da superfície de custo no Parque Nacional do Catimbau: (a) insolação, (b) declividade e (c) visibilidade.

Fonte: Fonte: Dados da pesquisa (2026).

## 4.6 Balanceamento de Custos e Função Objetivo

Uma vez modelada a superfície de fricção, o foco recai sobre o custo acumulado. A adoção da abordagem linear visa garantir a inteligibilidade do modelo, permitindo a leitura direta da influência de cada variável. Tal estratégia é fundamental para a análise arqueológica, pois oferece uma alternativa transparente e validável em contraposição a arquiteturas complexas de difícil interpretação semântica.

O problema foi tratado como uma otimização com restrições, na qual cada partícula do algoritmo PSO representa um vetor de pesos  $\mathbf{w} = [w_1, w_2, \dots, w_n]$  associado às variáveis ambientais utilizadas na modelagem da superfície de custo. Cada componente  $w_i$  expressa a relevância relativa da variável correspondente no cálculo do custo do deslocamento, de modo que valores próximos de zero indicam contribuição desprezível da variável, enquanto valores próximos de um indicam predominância quase absoluta sobre as demais. A condição de normalização  $\sum w_i = 1$  garante que os pesos sejam interpretados como proporções relativas de influência, impedindo a amplificação artificial do custo total por simples escalonamento numérico.

Embora o limite teórico  $w_i \rightarrow 1$  represente um cenário no qual uma única variável domina integralmente o processo decisório, tal configuração é indesejável neste estudo, pois implicaria a exclusão prática das demais variáveis ambientais e a redução do modelo a uma abordagem univariada. Da mesma forma, valores  $w_i \rightarrow 0$  correspondem à anulação da influência da variável, eliminando sua contribuição para a superfície de custo. O objetivo da otimização, portanto, não é maximizar ou minimizar isoladamente um peso específico, mas identificar combinações equilibradas que representem compromissos plausíveis entre os diferentes fatores ambientais considerados.

Para garantir a consistência dessas interpretações, a implementação adotou uma estratégia de Normalização Forçada (*Hard Constraint*), na qual o vetor de pesos de cada partícula é matematicamente normalizado antes da avaliação da função ob-

jetivo. Especificamente, dado um vetor candidato  $\mathbf{w}'$  gerado pela dinâmica do PSO, o algoritmo calcula os pesos efetivos  $\mathbf{w}$  por meio da divisão pela soma de seus componentes:

$$\mathbf{w} = \frac{\mathbf{w}'}{\sum_{i=1}^n w'_i} \quad (4.4)$$

Esse procedimento garante que todas as soluções avaliadas sejam válidas ( $\sum w_i = 1, 0$ ) sem a necessidade de introduzir termos de penalidade por violação de restrição na função objetivo. Isso aumenta a eficiência da busca, pois evita o desperdício de recursos computacionais na avaliação de partículas inviáveis.

A função de aptidão global  $F(\mathbf{w})$ , que o algoritmo busca minimizar, é definida pela combinação do custo do caminho com um termo de regularização multiplicativo. Matematicamente, a função implementada é dada por:

$$F(\mathbf{w}) = \alpha \cdot C_{total}(\mathbf{w}) \cdot (1 + R(\mathbf{w})) \quad (4.5)$$

onde  $C_{total}(\mathbf{w})$  é o custo acumulado do Caminho de Menor Custo gerado pelos pesos  $\mathbf{w}$ ,  $\alpha$  é um coeficiente de escala do custo (definido como 1, 0 na implementação padrão) e  $R(\mathbf{w})$  é o termo de regularização baseado na entropia.

A estabilidade numérica da superfície de custo constitui uma preocupação central. Para evitar que o algoritmo convirja prematuramente para soluções degeneradas (onde um único peso concentra 100% da influência, anulando as outras variáveis), aplicou-se a *Regularização por Entropia* baseada na Divergência de Kullback-Leibler (KULLBACK; LEIBLER, 1951). O termo  $R(\mathbf{w})$  penaliza configurações de pesos que se desviem excessivamente de uma distribuição uniforme, conforme a equação:

$$R(\mathbf{w}) = \lambda \sum_{i=1}^n w_i \log(n \cdot w_i) \quad (4.6)$$

onde  $\lambda$  é a força da regularização (definida como 3, 0 nos experimentos) e  $n$  é o número de variáveis. A estrutura multiplicativa da função objetivo assegura que a penalidade de entropia atue como um fator de escala sobre o custo físico: soluções desequilibradas têm seu custo artificialmente inflado, incentivando o algoritmo a explorar combinações de variáveis, salvo quando a topografia impõe uma especialização funcional estrita que justifique o desequilíbrio.

Complementarmente, o sistema monitora a diversidade espacial do enxame através da distância euclidiana média entre partículas no espaço de pesos. Quando essa métrica cai abaixo de um limiar crítico ( $\bar{d} < 0, 1$ ), o algoritmo diagnostica convergência prematura e aciona mecanismos de reinicialização parcial.

### 4.6.1 Construção do Grafo Anisotrópico

A representação computacional do terreno como grafo direcionado exigiu a vetorização completa da topologia de vizinhança. Diferente de implementações tradicionais que constroem arestas iterativamente, a arquitetura desenvolvida pré-computa todas as conexões possíveis através de operações matriciais usando `numpy.indices`. Para um raster de dimensões  $M \times N$ , isso resulta em aproximadamente  $16 \times M \times N$  arestas válidas, armazenadas em formato esparso CSR (*Compressed Sparse Row*) da biblioteca SciPy.

Cada aresta  $(u, v)$  possui um custo calculado como  $C_{aresta} = C_{base}^{uv} \cdot A_{aniso}(\theta_{uv}) \cdot d_{eucl}(u, v)$ , onde  $C_{base}^{uv}$  representa a média dos custos basais dos nós terminal e inicial,  $A_{aniso}$  é o fator de anisotropia derivado da diferença de elevação, e  $d_{eucl}$  é a distância euclidiana corrigida metricamente. Para movimentos do tipo “Knight”, o custo basal é estimado por meio de interpolação dos pixels intermediários do trajeto, seguindo abordagens utilizadas em algoritmos de custo acumulado em ambientes SIG, com o objetivo de evitar saltos artificiais sobre regiões de alta impedância (WHITE; BARBER, 2012; HERZOG, 2013a).

A construção vetorizada do grafo consome aproximadamente 2 – 3 segundos para matrizes de  $1000 \times 1000$  pixels em hardware convencional (processador Intel i7, 16GB RAM), contra os 30 – 45 segundos de implementações baseadas em loops. Essa eficiência pode contribuir para viabilizar as diversas avaliações necessárias durante a otimização PSO. O algoritmo de caminho mínimo utilizado é o de Dijkstra implementado em `scipy.sparse.csgraph`, com complexidade  $O((V + E) \log V)$  otimizada para grafos esparsos.

### 4.6.2 Dinâmica do Enxame e Heurística de Busca

A calibração dos pesos utiliza uma estratégia de inicialização estratificada para garantir uma cobertura robusta do espaço de busca e evitar mínimos locais prematuros. Diferente de abordagens puramente aleatórias, o enxame inicial ( $N = 40$  partículas para o protocolo de robustez) foi distribuído em grupos funcionais baseados em heurísticas de conhecimento de domínio. Aproximadamente 33% das partículas foram iniciadas com pesos distribuídos uniformemente via distribuição Dirichlet com parâmetros  $\alpha = [1, 1, 1]$ , formando o grupo equilibrado que explora soluções generalistas. Outros 20% receberam viés para declividade usando  $\alpha = [3, 1, 1]$ , forçando a exploração de soluções que priorizam o custo topográfico. Uma proporção similar foi iniciada com  $\alpha = [1, 3, 1]$ , explorando configurações que enfatizam controle visual. Os 27% restantes foram iniciados aleatoriamente para manter a estocasticidade do sistema. Essa arquitetura híbrida assegura que o algoritmo investigue tanto soluções generalistas quanto especializadas desde as primeiras iterações, evitando convergência prematura para

configurações subótimas.

Os coeficientes dinâmicos do PSO seguem a parametrização clássica de Shi e Eberhart (1998): coeficiente de inércia  $\omega = 0,5$  (fixo), aceleração cognitiva  $c_1 = 2,0$  e aceleração social  $c_2 = 2,0$ . Essa configuração balanceia a exploração individual (memória da partícula) com a exploração coletiva (influência do líder global).

O mecanismo de reinicialização parcial monitora a melhoria relativa do líder global. Quando o custo de  $g_{best}$  não reduz em mais de 5% comparado à média da população durante 10 iterações consecutivas, o algoritmo diagnostica estagnação prematura. As 30% piores partículas são então reinicializadas usando a distribuição Dirichlet estratificada, mantendo a diversidade funcional do enxame. Esse ciclo adaptativo é complementado por uma perturbação estocástica global a cada 10 iterações ( $\epsilon \sim \mathcal{N}(0, 0.01)$ ), que injeta ruído gaussiano nas posições para escapar de bacias de atração rasas.

#### 4.6.3 Eficiência e Paralelismo

Dado o elevado custo computacional da simulação estocástica, que envolve milhares de cálculos de caminho mínimo, a implementação adotou técnicas de computação de alto desempenho. A construção do grafo de adjacência, etapa crítica em análises de Least Cost Path (LCP), foi otimizada por meio de operações matriciais vetorizadas, reduzindo o tempo de geração das arestas.

Foi implementada uma correção métrica automática baseada na latitude média da cena. Distâncias originalmente expressas em graus foram convertidas para unidades métricas. Essa correção reduz distorções associadas ao uso de coordenadas geográficas e garante maior consistência nos cálculos de custo acumulado.

A avaliação da função de aptidão no algoritmo Particle Swarm Optimization (PSO) foi paralelizada utilizando a arquitetura `multiprocessing.Pool`. As partículas foram distribuídas simultaneamente entre os núcleos disponíveis da CPU. Essa estratégia viabilizou a execução do modelo com 15 partículas e a realização de testes de robustez com 40 partículas. Em testes de desempenho, a paralelização reduziu o tempo total de execução em aproximadamente 60% em relação à versão sequencial.

A adoção de uma vizinhança estendida de 16 conexões (*Knight's move*) aumentou o número de arestas do grafo, proporcionalmente ao número de células do raster. Essa configuração eleva o custo computacional quando comparada a abordagens baseadas em vizinhança de 8 conexões. A escolha reduz distorções geométricas associadas ao *elongation error*.

Quando integrado ao processo de otimização por enxame de partículas, o cálculo do LCP é reavaliado a cada iteração do algoritmo. O custo computacional global do método depende do número de partículas, do número de iterações e da topologia do

grafo utilizada. Esses fatores condicionam a viabilidade computacional da abordagem proposta.

#### 4.6.4 Extração de Caminhos e Topologia

A cada avaliação, o algoritmo calcula o Caminho de Menor Custo sobre um grafo de vizinhança estendida (16 conexões ou *Knight's move*). Essa topologia conecta a célula central não apenas aos seus 8 vizinhos imediatos (Vizinhança de Moore), mas também aos vizinhos correspondentes ao movimento do cavalo no xadrez (distância  $\sqrt{5} \approx 2,23$  células).

A escolha por essa topologia estendida visa mitigar o erro de alongamento (*elongation error*) e a tendenciosidade angular típicos de grafos 8-conexos, onde o caminho tende a se fixar artificialmente em direções de 45 ou 90 graus. Conforme demonstrado por Herzog (2022), a vizinhança de 16 conexões permite a geração de curvas organicamente plausíveis e metricamente precisas, essenciais para simular trajetórias humanas em terrenos naturais complexos como o do Catimbau. A precisão angular efetiva dessa topologia é de aproximadamente  $11,25^\circ$  (versus  $45^\circ$  para grafos 8-conexos), permitindo representação fidedigna de curvas suaves.

Como mecanismo de contingência, o sistema implementa um modo de *fallback* que reverte para o algoritmo `route_through_array` da biblioteca `scikit-image` caso o grafo anisotrópico não consiga encontrar um caminho válido (situação rara que pode ocorrer quando há isolamento topológico por barreiras de custo infinito). Esse modo secundário garante a robustez operacional do sistema.

#### 4.6.5 Métricas de Avaliação de Caminhos

Para cada solução candidata, o algoritmo extrai automaticamente quatro métricas descritivas do caminho gerado através da classe `PathAnalyzer`. O custo acumulado ( $C_{total}$ ) representa o esforço total demandado, calculado pela soma das impedâncias de todas as arestas percorridas no grafo anisotrópico. A extensão métrica ( $L$ ) determina o comprimento real do trajeto em quilômetros, corrigindo as distorções de projeção geográfica através do ajuste dimensional dos pixels pela latitude média.

A curvatura média ( $\kappa$ ) quantifica a sinuosidade do percurso calculando a média aritmética dos ângulos de deflexão entre segmentos consecutivos do trajeto. Esta métrica oferece uma medida da complexidade geométrica independente da escala, onde valores mais altos indicam rotas com mudanças de direção frequentes ou abruptas.

A eficiência direcional ( $\eta$ ) normaliza o comprimento do caminho pela distância euclidiana direta entre a origem e o destino ( $\eta = d_{eucl}/L$ ). Valores de  $\eta$  próximos a 1,0 indicam trajetórias quase retilíneas, enquanto valores baixos (ex:  $< 0,7$ ) denotam

alta tortuosidade imposta pelo terreno. O cálculo das rotas base utiliza o algoritmo de Dijkstra (`scipy.sparse`) sobre a grade de 16 vizinhos para garantir a naturalidade dos movimentos.

#### 4.6.6 Protocolo de Validação e Robustez

Para verificar a estabilidade da convergência e validar estatisticamente os pesos encontrados, aplicou-se um protocolo de robustez automatizado, implementado no script de teste de sensibilidade. Nesse protocolo, o PSO foi configurado com população  $P = 40$  partículas e  $I = 50$  iterações, com regularização entrópica fixada em  $\lambda = 3,0$ . Cada partícula codifica um vetor de pesos  $\mathbf{w} = [w_1, \dots, w_n]$  associado às variáveis ambientais, e a busca ocorre em um espaço vetorial de dimensão  $n = 3$  (declividade, visibilidade e insolação), sujeito às restrições  $w_i \geq 0$  e  $\sum_{i=1}^n w_i = 1$ . Assim, o espaço de busca corresponde ao simplex 2-dimensional embutido em  $\mathbb{R}^3$ , no qual cada ponto representa uma combinação convexa de importância relativa entre as variáveis.

Em termos operacionais, a cada iteração o algoritmo avalia  $P$  soluções candidatas (uma por partícula), totalizando  $P \times I$  avaliações da função objetivo por execução do PSO. Como a função objetivo envolve o cálculo de um Caminho de Menor Custo a partir da superfície de custo gerada pelos pesos  $\mathbf{w}$ , cada avaliação corresponde a uma execução completa do módulo de caminho mínimo sob aquela configuração de pesos. Para reduzir a influência da estocasticidade inerente à inicialização do enxame, o experimento foi repetido cinco vezes com sementes aleatórias fixas  $S = \{42, 100, 2026, 7, 999\}$ . Dessa forma, o protocolo de robustez totaliza  $5 \times P \times I = 5 \times 40 \times 30 = 6000$  avaliações da função objetivo, permitindo estimar a variabilidade dos pesos obtidos entre diferentes inicializações.

A análise dos pesos resultantes foi realizada por meio do cálculo da média e do desvio padrão das configurações finais, adotando-se como critério de estabilidade  $\sigma_{\text{pesos}} < 0,05$ . Para selecionar a execução representativa utilizada na geração dos produtos cartográficos, adotou-se o menor valor do custo acumulado normalizado, definido como  $\hat{C} = C_{\text{total}}/d_{\text{euclidiana}}$ , onde  $d_{\text{euclidiana}}$  representa a distância em linha reta entre origem e destino. Esse índice penaliza trajetos excessivamente longos e tortuosos quando não justificados pela topografia, combinando custo e eficiência geométrica.

Em contraste, a execução principal utilizada para a produção dos resultados do estudo de caso foi realizada em modo de execução única (seed fixa), com  $P = 15$  partículas e  $I = 30$  iterações por par de coordenadas, mantendo  $\lambda = 3,0$ . Nesse caso, cada cenário executa  $P \times I = 450$  avaliações da função objetivo, priorizando a geração eficiente dos mapas finais e das métricas do caminho.

## 5 Resultados

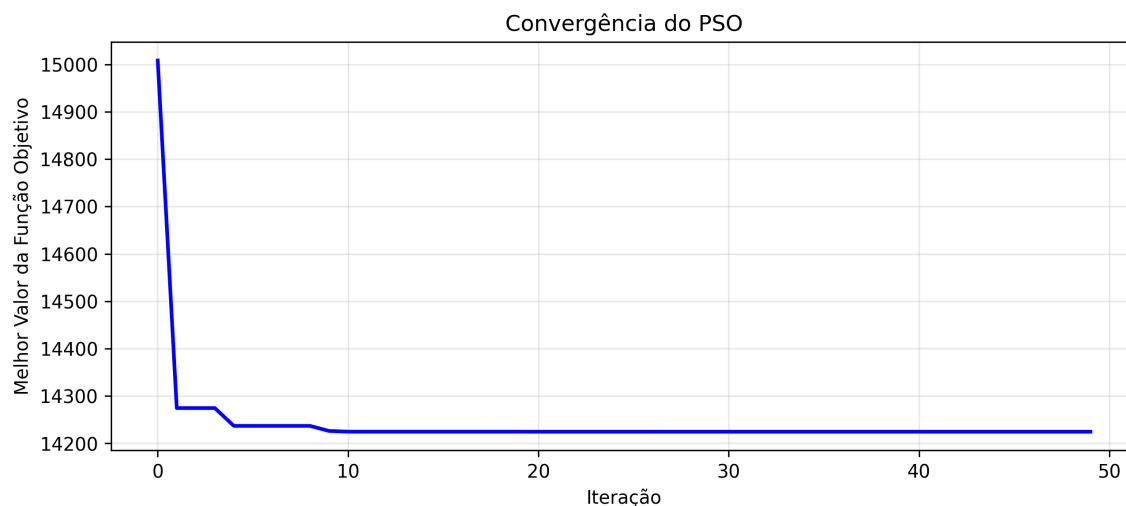
Com o objetivo de avaliar a eficácia da calibração automática de pesos via PSO frente à diversidade ambiental do Parque Nacional do Catimbau, o experimento foi estruturado em dois cenários distintos. Para a geração das rotas de Caminho de Menor Custo (LCP), foram selecionados pares de coordenadas correspondentes a sítios arqueológicos documentados e utilizados como nós de origem e destino.

Essa divisão visa garantir a confiabilidade estatística e verificar a adaptabilidade do modelo em diferentes escalas e contextos geomorfológicos:


1. **Cenário A:** Simula um deslocamento de curta distância entre sítios com características geomorfológicas similares.
  - **Origem:** Sítio *Prateado*. Caracteriza-se como um abrigo sob rocha em baixa vertente, contendo pinturas rupestres nos setores oeste e noroeste.
  - **Destino:** Sítio *da Escada*. Também situado em baixa vertente, é um abrigo sob rocha com pinturas no setor sudoeste.
2. **Cenário B:** Simula uma rota de longa distância, atravessando zonas de alta complexidade topográfica e diferentes compartimentos da paisagem.
  - **Origem:** *Toca do Gato*. Abrigo sob rocha em baixa vertente com pinturas no setor nordeste.
  - **Destino:** *Dedos de Deus II*. Diferencia-se por estar localizado em média vertente, contendo tanto pinturas quanto gravuras rupestres.

### 5.1 Análise de Convergência e Robustez

O comportamento do otimizador foi avaliado através das curvas de minimização da função objetivo, apresentadas de forma comparativa na Figura 7. Os gráficos ilustram o histórico de busca, evidenciando a rápida estabilização do enxame tanto no Cenário A quanto no Cenário B.



(A) Convergência no Cenário A



(B) Convergência no Cenário B

Figura 7 – Histórico de minimização da função objetivo pelo PSO.

Fonte: Dados da Pesquisa (2026).

Dada a natureza estocástica do algoritmo PSO, a análise de convergência torna-se essencial para verificar que os resultados obtidos não decorrem de flutuações aleatórias do processo de busca. O objetivo é demonstrar que o modelo apresenta comportamento convergente consistente, conduzindo sistematicamente a soluções semelhantes, e que os pesos calibrados são reprodutíveis do ponto de vista científico, independentemente das condições iniciais de distribuição das partículas.

Em ambos os casos, observa-se um perfil de convergência acelerada (formato em “L”). Isso indica que a superfície de custo gerada possui gradientes bem definidos (bacias de atração), permitindo que o enxame identifique a solução ótima rapidamente. A rápida estabilização do algoritmo decorre de dois fatores arquiteturais: a estratégia de

inicialização estratificada, que distribui as partículas em grupos funcionais especializados (equilibradas, com viés em declividade, com viés em visibilidade) desde a primeira iteração, garantindo cobertura efetiva do espaço de busca; e a restrição rígida de normalização de pesos ( $\sum w_i = 1, 0$ ), aplicada matematicamente antes de cada avaliação, que impede que as partículas explorem configurações inválidas ou numericamente instáveis. A ausência de ruído excessivo nas iterações finais indica que o coeficiente de inércia fixo ( $\omega = 0,5$ ) foi adequado para balancear exploração e refinamento.

A eficiência do algoritmo também se manteve estável mesmo com o aumento da complexidade espacial. Enquanto o Cenário A (trajeto curto) demandou um tempo de execução de aproximadamente 729 segundos, o Cenário B, apesar de triplicar a extensão física do percurso e atravessar uma topografia mais acidentada, convergiu em 798 segundos (aumento de apenas  $\approx 9,4\%$  no tempo de processamento), demonstrando que o custo computacional do PSO, nesta implementação, foi dominado pelo tamanho da população e número de iterações, e não pela complexidade geométrica do terreno.

Para avaliar se a estabilidade observada não decorre de uma inicialização específica do algoritmo, foi conduzido um teste de robustez com cinco execuções independentes, utilizando sementes aleatórias distintas (*seeds*: 42, 100, 2026, 7, 999). Em todas as execuções, o desvio padrão dos pesos calibrados permaneceu inferior a  $\sigma < 0,0006$ . Esse comportamento sugere um grau elevado de consistência estatística nas soluções obtidas, indicando que o processo de otimização apresenta baixa sensibilidade às condições iniciais e tende a produzir configurações de pesos semelhantes ao final da busca.

## 5.2 Calibração dos Pesos e Adaptação à Paisagem

A Tabela 1 sintetiza os parâmetros ótimos identificados (o centróide do enxame na última iteração) para a conexão entre os sítios arqueológicos nas duas escalas avaliadas.

Tabela 1 – Variação dos pesos calibrados em função da escala do deslocamento

Parâmetro	Cenário A	Cenário B
Custo Total ( <i>Score</i> )	4.538,32	12.475,60
Peso Declividade ( $w_s$ )	0,282	0,316
Peso Visibilidade ( $w_v$ )	0,356	0,317
Peso Insolação ( $w_i$ )	0,363	0,368

Fonte: Dados da Pesquisa (2026).

A análise comparativa entre os dois cenários evidencia uma dinâmica distinta na atribuição de importância às variáveis ambientais conforme a extensão do trajeto

aumenta. A variável de insolação apresentou o comportamento mais estável entre os testes, mantendo valores próximos a 0,36 em ambas as situações. Essa constância numérica indica que, dentro do modelo computacional proposto, a minimização da exposição à radiação solar atua como um fator de custo basal e permanente. Para o caminhante no semiárido, a necessidade de evitar o estresse térmico revela-se uma prioridade constante, exercendo influência similar independentemente se o destino é um sítio vizinho ou distante.

Em contrapartida, nota-se um ajuste sensível na variável de declividade para o Cenário B. O aumento do peso atribuído a este parâmetro (de 0,281 para 0,316) sugere que, em trajetos de maior extensão, o acúmulo de custos associados à movimentação vertical torna-se o fator crítico. O algoritmo indicou que, para rotas longas, é matematicamente vantajoso sacrificar parcialmente a ocultação visual (reduzindo o peso da visibilidade de 0,356 para 0,315) em troca de um caminho topograficamente mais suave. Essa compensação demonstra uma estratégia de economia de energia metabólica a longo prazo, onde a topografia assume preponderância sobre a visibilidade em escalas regionais.

### 5.3 Análise das Superfícies de Custo Normalizadas

A Figura 8 apresenta as três superfícies de custo normalizadas utilizadas na composição da função objetivo: declividade, visibilidade e insolação. Todas as camadas foram reescaladas para o intervalo  $[f_{base}, 1] = [0,1, 1,0]$  através da aplicação de fricção basal ( $f_{base} = 0,1$ ), garantindo comparabilidade numérica entre variáveis originalmente heterogêneas e eliminando a possibilidade de movimento gratuito (custo zero) em qualquer região da paisagem. Essa restrição assegura que o custo metabólico basal do deslocamento humano esteja sempre presente, mesmo em terrenos planos e sombreados.




Figura 8 – Superfícies de custo normalizadas utilizadas na função objetivo. **(A)** Declividade normalizada. **(B)** Visibilidade normalizada. **(C)** Insolação normalizada.

Fonte:Dados da Pesquisa (2026).

A superfície de declividade evidencia a forte compartimentação topográfica do Parque Nacional do Catimbau, com extensas zonas de alto custo associadas a escarpas, vales encaixados e interflúvios abruptos. Essas áreas configuram barreiras físicas claras ao deslocamento humano, enquanto corredores de baixo custo acompanham fundos de vale e rampas suaves, sugerindo caminhos energeticamente mais eficientes. Essa estrutura gera gradientes bem definidos na superfície de custo, favorecendo a rápida convergência do algoritmo observada nos testes.

A superfície de visibilidade apresenta um padrão espacial mais fragmentado e heterogêneo, refletindo a complexidade geométrica da paisagem e a alternância entre áreas de controle visual amplo e zonas de ocultação. Diferentemente da declividade, os custos associados à visibilidade não formam barreiras contínuas, mas mosaicos locais que podem influenciar decisões de microescala no traçado das rotas, especialmente em contextos onde o controle visual da paisagem possui relevância simbólica ou estratégica.

Já a superfície de insolação revela extensas áreas de alto custo associadas a encostas expostas e platôs abertos, típicos do relevo semiárido da Caatinga. A distribuição espacial relativamente contínua dessas zonas indica que a radiação solar atua como um fator ambiental difuso, penalizando amplas porções da paisagem de forma sistemática. Essa característica explica a estabilidade do peso da insolação nos diferentes cenários testados, uma vez que a exposição térmica impõe um custo fisiológico persistente ao movimento humano, independentemente da escala do deslocamento.

A análise conjunta das três superfícies sugere que o espaço de busca explorado pelo PSO não é arbitrário, mas estruturado por gradientes ambientais coerentes com a geomorfologia local. A presença de bacias de atração bem definidas e a complementaridade entre barreiras físicas (declividade), condicionantes térmicos (insolação) e fatores perceptivos (visibilidade) fornecem a base espacial sobre a qual as rotas ótimas são posteriormente derivadas.

A materialização dessa síntese resulta na Superfície de Custo Total, apresentada na Figura 9. Esta imagem representa a "paisagem de atrito" final sobre a qual as partículas do PSO navegam, calculada através da combinação linear ponderada das três variáveis normalizadas ( $C_{total} = w_s \cdot S + w_v \cdot V + w_i \cdot I$ ).




Figura 9 – Superfície de Custo Total Agregada. A imagem sintetiza a impedância acumulada da paisagem, onde áreas em amarelo/verde representam zonas de baixo custo (corredores de movimento) e áreas em azul/roxo indicam barreiras de alta resistência ao deslocamento.

Fonte: Dados da Pesquisa (2026).

## 5.4 Espacialização das Rotas sobre a Superfície de Custo

### 5.4.1 Cenário A

A Figura 10 apresenta o traçado otimizado para o deslocamento curto entre o Sítio Prateado e o Sítio da Escada sobre a superfície de custo total.

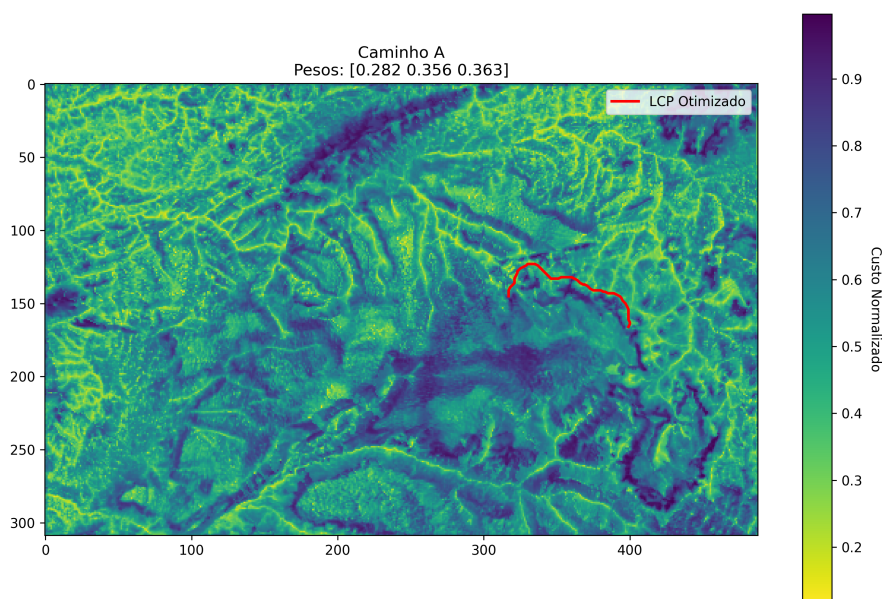


Figura 10 – Rota do Cenário A sobre a Superfície de Custo Total. As áreas em tons frios (azul/roxo) indicam alta resistência, enquanto tons quentes (amarelo/verde) representam zonas de trânsito facilitado. A rota (linha vermelha) explora um corredor natural de baixa fricção.

Fonte: Dados da Pesquisa (2026).

A análise da espacialização revela uma alta linearidade na rota gerada ( $\eta \approx 0,84$ ). O algoritmo identificou com sucesso um "corredor de permeabilidade" (representado pelas faixas verdes no mapa) que conecta a origem ao destino sem a necessidade de desvios significativos. Isso indica que, nesta escala local, os pesos atribuídos às variáveis ( $w_s = 0,281$ ;  $w_v = 0,356$ ;  $w_i = 0,363$ ) não geraram conflitos espaciais graves; ou seja, o caminho topograficamente eficiente coincidiu, em grande parte, com zonas de conforto térmico e visual aceitáveis, permitindo uma trajetória direta e econômica.

#### 5.4.2 Cenário B

No cenário regional (B), a distribuição espacial dos custos apresenta-se fragmentada, impondo desafios de navegação mais severos ao algoritmo PSO, conforme ilustrado na Figura 11.




Figura 11 – Rota do Cenário B sobre a Superfície de Custo Total. Nota-se a alta fragmentação da paisagem, com barreiras de alto custo (azul escuro) bloqueando o vetor direto. O algoritmo realiza curvas acentuadas para manter-se nas zonas de menor custo (verde/amarelo).

Fonte: Dados da Pesquisa (2026).

Diferentemente do cenário anterior, a rota de longa distância exibe um índice de linearidade reduzido ( $\eta \approx 0,61$ ), caracterizando um trajeto sinuoso. A sobreposição com a superfície de custo explica matematicamente esse comportamento: o vetor direto entre origem e destino é interceptado por extensas zonas de custo máximo (áreas em azul escuro e roxo), que representam barreiras onde a soma ponderada de inclinação íngreme e alta insolação torna o movimento proibitivo.

A eficiência do algoritmo é demonstrada pela sua capacidade de contornar essas "ilhas de resistência". O traçado adere rigorosamente às faixas de custo intermediário (tons de verde claro), funcionando como um fluido que busca o caminho de menor pressão.

## 5.5 Análise dos Perfis Altimétricos

A validação das rotas geradas não se encerra na análise planimétrica (2D). Para verificar a viabilidade física do deslocamento, é necessário analisar o comportamento vertical dos trajetos através de seus perfis altimétricos. Esta etapa permite inferir o

custo metabólico acumulado e observar como a ponderação da declividade ( $w_s$ ) influenciou a escolha de rampas e passagens de nível.

As Figuras 12 e 13 apresentam a variação de elevação ao longo da distância acumulada para os dois cenários.

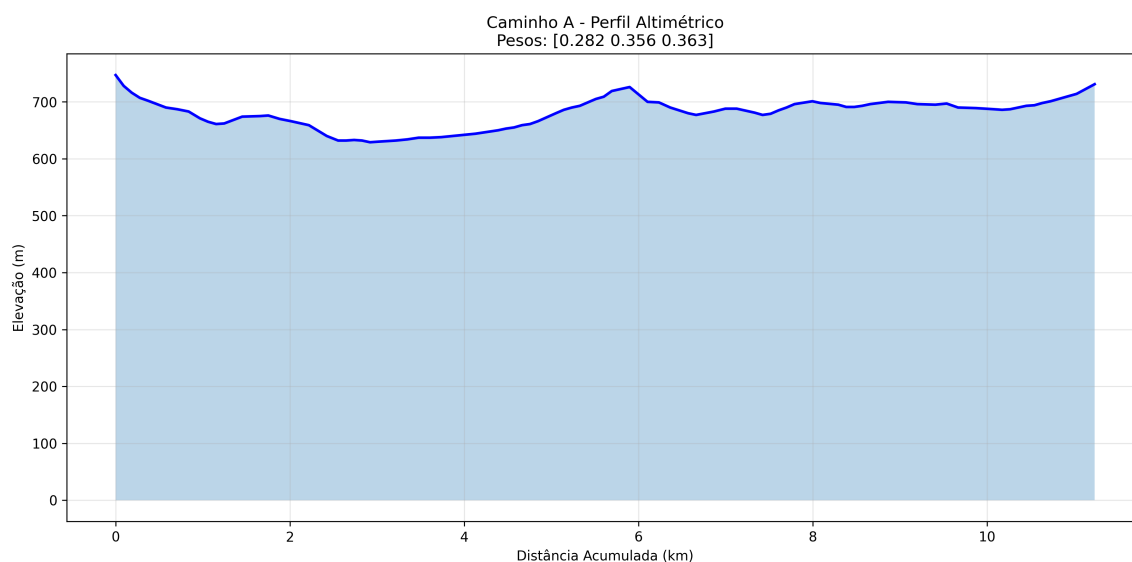


Figura 12 – Perfil Altimétrico do Cenário A. A rota de  $\approx 11,5$  km mantém-se predominantemente em cotas estáveis (entre 630m e 750m), caracterizando um deslocamento de meia-encosta com poucas variações abruptas.

Fonte: Dados da Pesquisa (2026).

No Cenário A (Figura 12), observa-se um perfil relativamente suave. O algoritmo optou por iniciar o trajeto em cota elevada ( $\approx 750$ m), realizar uma descida gradual até o quilômetro 3 e, posteriormente, manter uma cota média de navegação estável até o destino. A ausência de "dentes de serra" (subidas e descidas repetitivas e curtas) sugere que o peso da declividade ( $w_s = 0,282$ ) foi eficaz em penalizar variações locais desnecessárias, gerando uma rota que economiza energia ao manter o caminhante em curvas de nível sempre que possível.

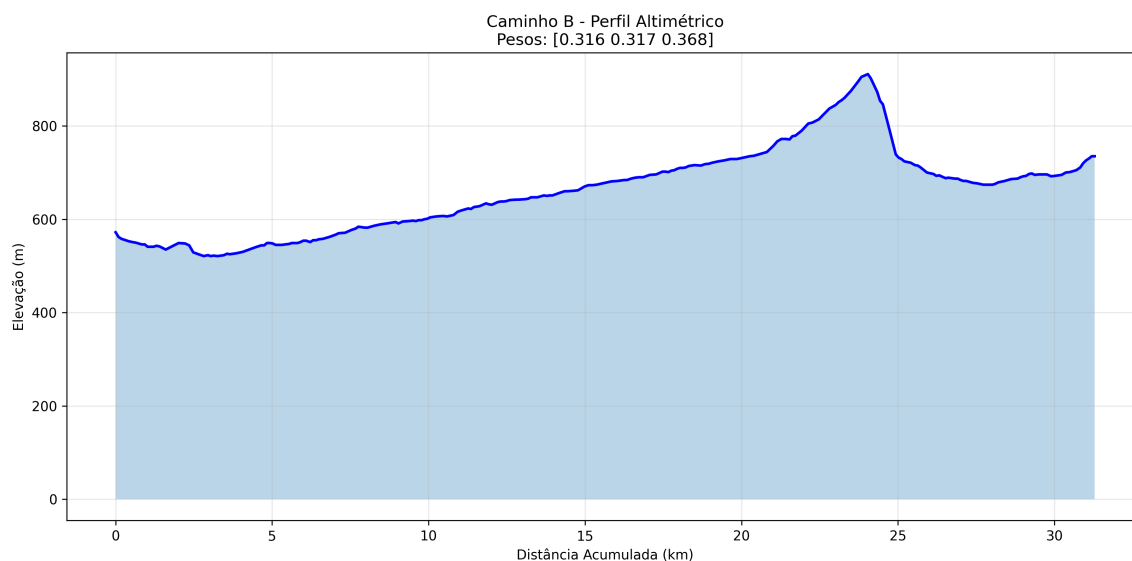


Figura 13 – Perfil Altimétrico do Cenário B. Em um trajeto de longa duração ( $\approx 31$  km), o algoritmo identificou uma rampa de ascensão constante e gradual (do km 3 ao km 24), evitando picos de esforço vertical antes da chegada ao topo da serra.

Fonte: Dados da Pesquisa (2026).

O Cenário B (Figura 13) apresenta um desafio topográfico muito mais complexo, conectando o fundo do vale ( $\approx 520$ m) ao topo ( $\approx 900$ m). Aqui, a atuação do otimizador torna-se evidente na gestão do esforço a longo prazo. Do quilômetro 5 ao 24, a rota descreve uma longa rampa ascendente. Em vez de atacar a encosta diretamente (o que geraria uma curva muito íngreme e curta), o algoritmo estendeu o caminho para diluir o ganho de elevação ao longo de quase 20 km. O perfil é notavelmente contínuo: o peso majorado da declividade neste cenário ( $w_s = 0,316$ , comparado a  $0,282$  do cenário A) forçou o PSO a rejeitar caminhos que subissem e descessem vales intermediários, preferindo uma rota de crista ou de flanco contínuo.


## 5.6 Comparação com o Método de Referência

Para contextualizar os resultados obtidos pela calibração automática via PSO, esta seção apresenta uma análise comparativa entre a estratégia proposta e uma abordagem de controle, denominada aqui como Método de Referência (Baseline). Este cenário representa a aplicação convencional de algoritmos de Caminho de Menor Custo (LCP) em arqueologia, frequentemente executados em ambientes SIG (como QGIS ou GRASS) utilizando configurações padrão.


O Método de Referência adotado utiliza a função de custo de Langmuir (1984) aplicada exclusivamente sobre o Modelo Digital de Elevação (MDE) e utilizando a declividade. Nesta abordagem univariada, assume-se que o deslocamento humano é

regido estritamente pela minimização do esforço metabólico físico ( $w_s = 1, 0$ ), desconsiderando variáveis ambientais secundárias como a exposição solar ou o controle visual da paisagem.

As Figuras 14 e 15 apresentam a sobreposição das rotas geradas pelos dois métodos. A linha laranja representa o traçado obtido pela abordagem tradicional (apenas topográfica), enquanto a linha vermelha indica a solução gerada pelo PSO (multicritério).



(A) Referência (Univariado: Apenas Declividade).




(B) Proposta (Multicritério: Declividade + Insolação + Visibilidade).

Figura 14 – Comparação qualitativa para o Cenário A. Em **(A)**, o algoritmo tradicional prioriza rigidamente a topografia para evitar qualquer custo vertical. Em **(B)**, o PSO propõe um trajeto com leves desvios para otimizar custos térmicos e visuais.


Fonte: Dados da Pesquisa (2026).

No Cenário A (Figura 14), observa-se que o Método de Referência tende a aderir estritamente às curvas de nível e fundos de vale, gerando uma rota que busca a "planicidade perfeita". Em contraste, a rota otimizada pelo PSO, ao ponderar também a insolação ( $w_i \approx 0,36$ ) e a visibilidade ( $w_v \approx 0,35$ ), aceita pequenos incrementos no esforço físico (cortando trechos de baixa vertente) para evitar zonas de exposição solar excessiva ou para manter um campo de visão mais estratégico.

Essa divergência metodológica torna-se mais evidente no Cenário B (Figura 15), onde a complexidade do relevo exige decisões de compromisso (trade-offs).



(A) Referência (Univariado: Apenas Declividade).



(B) Proposta (Multicritério: Declividade + Insolação + Visibilidade).

Figura 15 – Comparação qualitativa para o Cenário B. A rota tradicional (A) apresenta alta sinuosidade geométrica para contornar o relevo. A rota otimizada (B) exhibe vetores mais retílineos em determinados trechos, balanceando o esforço da subida com a necessidade de evitar a insolação prolongada.

Fonte: Dados da Pesquisa (2026).

No Cenário B (Figura 15), a comparação visual entre as rotas sobre o Modelo Digital de Elevação (MDE) mostra estratégias opostas de navegação. O trajeto gerado pelo Método de Referência (Langmuir) atravessa diretamente as áreas mais claras do mapa, indicando que o algoritmo priorizou uma linha mais reta entre a origem e o destino. Ao fazer isso, o modelo aceitou enfrentar grandes desniveis e subidas íngremes apenas para encurtar a distância geométrica.

Em contrapartida, a rota otimizada pelo PSO concentra-se nas áreas escuras do MDE. Essas zonas correspondem aos fundos de vale e às partes mais baixas do relevo. O comportamento do traçado sugere que o algoritmo optou por contornar as elevações, mantendo-se no nível do terreno, indetificando um corredor natural de passagem. O resultado sugere que caminhar uma distância maior pelo vale pode ser mais vantajoso do que tentar cortar caminho pelas serras, aproximando-se mais de uma decisão humana real de poupar energia.

## 5.7 Análise de Complexidade Computacional

Além da avaliação da convergência e da robustez do método, é fundamental analisar o custo computacional associado à abordagem proposta, especialmente considerando a adoção de vizinhança ampliada e a integração com um algoritmo de otimização iterativa. A modelagem do Caminho de Menor Custo (LCP) baseia-se no cálculo de uma superfície de custo raster e na aplicação de um algoritmo de busca global, conceitualmente equivalente ao algoritmo de Dijkstra.

Considerando um raster composto por  $V$  células, cada uma conectada a uma vizinhança de 16 direções, o número de arestas do grafo subjacente pode ser aproximado por  $E \approx 16V$ . Nesse contexto, o custo assintótico do algoritmo de Dijkstra é dado por  $O(E + V \log V)$ , o que implica um aumento significativo no tempo de execução quando comparado a abordagens baseadas em vizinhanças mais restritas, como a conectividade de 8 direções. Essa escolha, no entanto, é justificada pela redução de distorções geométricas e pela maior fidelidade espacial das rotas geradas.

Na abordagem proposta, o cálculo do LCP não é executado de forma isolada, mas repetidamente dentro do ciclo de otimização do algoritmo Particle Swarm Optimization (PSO). Assim, considerando uma população de  $P$  partículas e um total de  $I$  iterações, a complexidade computacional global do processo pode ser expressa de forma aproximada como:

$$O(P \cdot I \cdot (E + V \log V))$$

Esse resultado sugere que o custo computacional total é dominado pelo número

de avaliações da função objetivo realizadas pelo PSO, e não exclusivamente pela complexidade geométrica do terreno ou pela dimensionalidade das variáveis ambientais. Em termos práticos, isso significa que o aumento do número de variáveis ambientais incorporadas à função de custo impacta marginalmente o custo assintótico, desde que a resolução espacial do raster permaneça constante.

Portanto, embora a utilização de vizinhança de 16 direções e a calibração automática de pesos introduzam um custo computacional adicional em relação a modelos tradicionais de LCP, esse custo é previsível, controlável e compensado pelo ganho em realismo geométrico, estabilidade numérica e capacidade de experimentação sistemática em larga escala.

## 6 Considerações Finais

Neste trabalho, investigou-se a aplicação de técnicas de Inteligência Computacional, especificamente a Otimização por Enxame de Partículas (PSO), na modelagem de mobilidade humana em paisagens arqueológicas. O foco central recaiu sobre o Parque Nacional do Catimbau, um cenário de alta complexidade geomorfológica que desafia métodos determinísticos tradicionais. A pesquisa buscou superar a subjetividade inerente à atribuição manual de pesos em análises de Caminho de Menor Custo (LCP), propondo e validando uma abordagem automatizada capaz de calibrar os parâmetros de impedância a partir da própria configuração espacial dos sítios.

A metodologia desenvolvida integrou variáveis ambientais relevantes (declividade, visibilidade e insolação) em uma função de custo otimizada estocasticamente. Os experimentos demonstraram que o algoritmo é capaz de convergir para soluções estáveis e reproduzíveis, revelando uma hierarquia de importância na qual a radiação solar e o controle visual assumem relevância estatística equiparável ao esforço físico. Esse equilíbrio entre as variáveis valida a eficácia do mecanismo de Regularização por Entropia implementado, que permitiu ao algoritmo explorar composições complexas de custos sem convergir prematuramente para soluções degeneradas ou monovariáveis.

### 6.1 Limitações das Abordagens

A interpretação dos resultados deve considerar as restrições inerentes à modelagem computacional adotada. No que tange à geometria do movimento, a utilização de uma topologia de grafo com vizinhança estendida de 16 conexões (*Knight's move*) foi adotada especificamente para mitigar o erro de alongamento (*elongation error*) comum em abordagens 8-conexas. Contudo, a resolução espacial dos dados de entrada (aproximadamente 30 metros), embora compatível com bases globais, ainda impõe barreiras à representação de microtopografias. Processos de reamostragem e interpolação, necessários para a harmonização das camadas raster, tendem a suavizar obstáculos naturais pontuais que, na escala humana, poderiam representar impedimentos físicos não captados pelo sensor remoto.

Outra restrição metodológica refere-se à natureza estática da superfície de custo. O modelo atual trata as variáveis ambientais como constantes temporais, desconsiderando a sazonalidade marcante do bioma. A densidade da vegetação (que afeta a visibilidade) e a biomassa sofrem variações drásticas entre os períodos seco e chuvoso na Caatinga, conforme detalhado na análise de sensoriamento remoto de Junior (2024). Essas dinâmicas, somadas à temperatura do solo que intensifica a insolação, deman-

dariam séries temporais para serem plenamente capturadas pela função de custo.

Uma restrição teórica reside na premissa do “agente racional” implícita nos algoritmos de custo mínimo, que tende a reduzir a mobilidade à estrita economia de energia. Autores da arqueologia da paisagem, como Tilley (1994), argumentam que o movimento é frequentemente motivado por fatores simbólicos e sociais que transcendem a lógica econômica. Ao não incorporar variáveis subjetivas, o modelo gera rotas de viabilidade fisiológica, mas não captura necessariamente a complexidade cultural da navegação antiga.

Finalmente, deve-se atentar para o escopo da calibração realizada. Embora os resultados tenham demonstrado uma consistência estatística notável, com pesos equilibrados entre as variáveis (Insolação  $\approx 0,36$ , Declividade e Visibilidade  $\approx 0,31$ ), essa configuração reflete as particularidades geomorfológicas dos pares de sítios testados no Vale do Catimbau. Não se deve extrapolar esses coeficientes, sem validação adicional, como um “padrão universal” de mobilidade para todo o complexo arqueológico, uma vez que diferentes zonas da paisagem podem impor restrições distintas que alterariam a hierarquia de importância das variáveis.

A viabilidade do experimento esteve condicionada às otimizações implementadas ao longo do pipeline computacional. A aplicação de um protocolo de robustez com múltiplas sementes permitiu avaliar a sensibilidade do otimizador à estocasticidade da inicialização, indicando um comportamento consistente dos resultados dentro das condições testadas. A vetorização da construção do grafo anisotrópico e a paralelização da avaliação das partículas também contribuíram de forma significativa para a redução do tempo de execução, atenuando o impacto do aumento da complexidade topológica decorrente da vizinhança estendida. Esses resultados sugerem que, com estratégias adequadas de implementação em software, é possível tornar viável o processamento de superfícies de custo geometricamente complexas em contextos arqueológicos, mesmo sob restrições computacionais moderadas.

## 6.2 Trabalhos Futuros

A metodologia desenvolvida permite extensões que ampliam a aplicabilidade do modelo em cenários complexos. Uma linha de investigação crucial reside na validação externa dos modelos através do confronto com dados empíricos independentes. O mapeamento etnográfico de trilhas históricas ainda utilizadas pelas comunidades locais e a correlação espacial com sítios de arte rupestre não incluídos no treinamento serviriam como *ground truth* (dados reais para validação). Essa triangulação entre a predição algorítmica e a realidade etnográfica é fundamental para refinar a função de aptidão do PSO, garantindo que a inteligência de enxame convirja para padrões de

movimento antropologicamente plausíveis.

Um desdobramento futuro consiste no empacotamento do pipeline computacional em uma ferramenta executável com interface de linha de comando (CLI), permitindo a execução completa do método sem a necessidade de modificação do código-fonte. Nessa configuração, o usuário poderia informar, via terminal, os caminhos para os dados de entrada, os parâmetros do modelo e as coordenadas de origem e destino, viabilizando a aplicação do algoritmo em diferentes contextos espaciais e computacionais. Essa estratégia amplia a acessibilidade da metodologia para pesquisadores sem formação em programação e favorece a reprodutibilidade e portabilidade dos experimentos, preservando a transparência do fluxo de modelagem.

A transição da abordagem mono-objetivo para a otimização multiobjetivo baseada em Pareto representa outro avanço metodológico relevante. Diferentemente dos métodos que combinam múltiplos critérios em uma única função agregada, algoritmos como o NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) (DEB et al., 2002) tratam cada objetivo de forma independente, evitando a imposição prévia de pesos arbitrários. O algoritmo organiza a população de soluções em frentes de não-dominância, nas quais uma solução é considerada superior apenas se apresentar desempenho igual ou melhor em todos os objetivos e estritamente melhor em pelo menos um deles.

Além disso, o NSGA-II incorpora um mecanismo de preservação de diversidade baseado na distância de aglomeração (*crowding distance*), garantindo que as soluções se distribuam de forma homogênea ao longo da fronteira de Pareto. Como resultado, o método não retorna um único caminho ótimo, mas um conjunto de trajetórias eficientes que expressam diferentes compromissos entre esforço físico, visibilidade e outros fatores ambientais. No contexto arqueológico, essa característica é particularmente relevante, pois permite ao pesquisador explorar múltiplas estratégias plausíveis de mobilidade, variando desde rotas energeticamente econômicas até percursos que privilegiam controle visual e vigilância territorial.

Do ponto de vista da Inteligência Artificial, um desdobramento promissor seria a calibração dos hiperparâmetros da própria função de custo anisotrópica. Na presente pesquisa, os coeficientes de penalidade para subida ( $k_{up}$ ) e descida ( $k_{down}$ ) foram fixados com base na literatura; trabalhos futuros poderiam incluir esses parâmetros no vetor de posição das partículas do PSO. Isso permitiria que o algoritmo descobrisse não apenas o peso das camadas, mas a própria fisiologia do movimento (o quão difícil é subir uma encosta) que melhor explica os dados observados.

## Referências

- ALBUQUERQUE, M.; LUCENA, V. Caçadores-coletores no agreste pernambucano: Ocupação e ambiente holocênico. *Clio – Revista do Curso de Mestrado em História (Anais do I Simpósio de Pré-História do Nordeste)*, Universidade Federal de Pernambuco, Recife, v. 4, p. 73–75, 1987. Citado na página 31.
- ASLANSEFAT, K. *UAV Path Planning with PSO*. 2020. Kaggle Notebook. Acessado em: 13 jan. 2026. Disponível em: <<https://www.kaggle.com/code/kooaslansefat/uav-path-planning-with-pso>>. Citado na página 32.
- BONG, C. W.; CHAI, W. Y. A multiobjective hybrid metaheuristic approach for gis-based spatial zoning model. *Journal of Mathematical Modelling and Algorithms*, Springer, v. 3, n. 3, p. 245–261, 2004. Citado na página 28.
- BORDBAR, M. et al. Multi-hazard spatial modeling via ensembles of machine learning and meta-heuristic techniques. *Scientific Reports*, Nature Publishing Group, v. 12, n. 1, p. 1451, 2022. Citado na página 28.
- BRASIL. *Decreto de 13 de dezembro de 2002: Cria o Parque Nacional do Catimbau*. 2002. <[https://www.planalto.gov.br/ccivil\\_03/dnn/2002/dnn9771.htm](https://www.planalto.gov.br/ccivil_03/dnn/2002/dnn9771.htm)>. Acesso em: 26 nov. 2025. Citado na página 30.
- CHEN, W.; PANAHI, M.; POURGHASEMI, H. R. Performance evaluation of gis-based new ensemble data mining techniques of adaptive neuro-fuzzy inference system with genetic algorithm, differential evolution, and particle swarm optimization for landslide spatial modelling. *Catena*, v. 157, p. 382–397, 2017. Citado na página 28.
- CLAIR, M. S. *PyCDA: Python Crater Detection Algorithm*. GitHub, 2021. Acessado em: 28 jan. 2026. Disponível em: <<https://github.com/avkoehl/pycda>>. Citado na página 32.
- CONOLLY, J.; LAKE, M. *Geographical Information Systems in Archaeology*. Cambridge: Cambridge University Press, 2006. Citado na página 18.
- CRABTREE, S. A. et al. Landscape rules predict optimal superhighways for the first peopling of sahal. *Nature Human Behaviour*, Nature Publishing Group, v. 5, n. 10, p. 1303–1313, 2021. Citado 2 vezes nas páginas 20 e 26.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, IEEE, v. 6, n. 2, p. 182–197, 2002. Citado na página 61.
- DIJKSTRA, E. W. A note on two problems in connexion with graphs. *Numerische Mathematik*, v. 1, n. 1, p. 269–271, 1959. Citado na página 17.
- DORIGO, M. *Optimization, Learning and Natural Algorithms*. Tese (Doutorado) — Politecnico di Milano, Italy, 1992. Citado na página 22.

DUTRA, Y. D. *Arqueologia dos Caminhos Guarani Através da Utilização de Ferramentas SIG*. Dissertação (Dissertação de Mestrado) — Universidade Federal de Pelotas, Pelotas, 2022. Programa de Pós-Graduação em Antropologia. Citado na página 14.

GATTIGLIA, G. Managing artificial intelligence in archaeology: An overview. *Journal of Cultural Heritage*, v. 71, p. 183–190, 2025. Citado na página 14.

GENDREAU, M.; POTVIN, J.-Y. (Ed.). *Handbook of Metaheuristics*. 3rd. ed. Cham: Springer International Publishing, 2019. Citado na página 22.

HERZOG, I. The potential and limits of optimal path analysis. In: BEVAN, A.; LAKE, M. (Ed.). *Computational Approaches to Archaeological Spaces*. Walnut Creek, CA: Left Coast Press, 2013. p. 179–211. Citado 4 vezes nas páginas 17, 18, 35 e 39.

HERZOG, I. Theory and practice of cost functions. In: CONTRERAS, F.; FARJAS, M.; MELERO, F. J. (Ed.). *Fusion of Cultures. Proceedings of the 38th Annual Conference on Computer Applications and Quantitative Methods in Archaeology, CAA 2010*. Oxford: Archaeopress, 2013. p. 431–434. Citado na página 21.

HERZOG, I. Issues in replication and stability of least-cost path calculations. *Studies in Digital Heritage*, v. 5, n. 2, p. 131–155, 2022. Citado 4 vezes nas páginas 19, 21, 22 e 41.

HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press, 1975. Citado na página 22.

HYNDMAN, R. J.; FAN, Y. Sample quantiles in statistical packages. *The American Statistician*, v. 50, n. 4, p. 361–365, 1996. Citado na página 34.

Instituto Chico Mendes de Conservação da Biodiversidade. *Parque Nacional do Catimbau*. s.d. Imagem fotográfica. Acesso em: 19 jan. 2026. Disponível em: <<https://www.gov.br/icmbio/pt-br/assuntos/biodiversidade/unidade-de-conservacao/unidades-de-biomas/caatinga/lista-de-ucs/parna-do-catimbau/parna-do-catimbau>>. Citado na página 30.

JUNIOR, J. J. M. *Efeito das mudanças no padrão de precipitação na área total e biomassa da Mata Atlântica e Caatinga*. Dissertação (Dissertação (Mestrado em Recursos Florestais)) — Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2024. Citado na página 59.

KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: IEEE. *Proceedings of ICNN'95 - International Conference on Neural Networks*. Perth, WA, Australia, 1995. v. 4, p. 1942–1948. Citado na página 23.

KULLBACK, S.; LEIBLER, R. A. On information and sufficiency. *Annals of Mathematical Statistics*, v. 22, n. 1, p. 79–86, 1951. Citado na página 38.

LANGMUIR, E. *Mountaineering and Leadership: A Handbook for Mountaineers and Hillwalking Leaders in the British Isles*. 1st edition. ed. Edinburgh: Scottish Sports Council, 1984. ISBN 978-0903908757. Citado 2 vezes nas páginas 19 e 52.

- LEWIS, J. *The Suitability of Using Least Cost Path Analysis in the Prediction of Roman Roads in the Highland and Lowland Zones of Roman Britain*. Dissertação (Dissertation) — University of Plymouth, 2021. Citado 2 vezes nas páginas 14 e 26.
- LIN, C.; SHEN, M. Analysis of PSO algorithm and GA. *Biology and Medical Engineering*, Wisdom Academic Press, v. 1, n. 3, p. 146, 2025. Citado na página 25.
- MA, Z.; CHEN, J. Adaptive path planning method for uavs in complex environments. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 115, p. 103133, 2022. Citado na página 27.
- MARTIN, G. Estudo para uma desmitificação dos petroglifos brasileiros: A pedra lavrada do ingá (paraíba). *Revista de História*, Universidade de São Paulo, São Paulo, n. 102, p. 509–537, 1975. Citado na página 30.
- MATOS, F. d. A. S. d. *Entre semelhanças gráficas e ambientais: as recorrências das representações antropomórficas pintadas pré-históricas entre as regiões do Cariri Ocidental-PB, Parque Nacional do Catimbau-PE e Seridó Oriental-RN*. Tese (Tese (Doutorado em Arqueologia)) — Universidade Federal de Pernambuco, Recife, 2019. Citado na página 31.
- MILHEIRA, R. G. Visibilidade, comunicação e movimento entre os cerriteiros na paisagem aquática da laguna dos patos, sul do brasil. *Boletim do Museu Paraense Emílio Goeldi. Ciências Humanas*, SciELO Brasil, v. 16, n. 1, p. e20200048, 2021. Citado 3 vezes nas páginas 19, 27 e 35.
- POLI, R.; KENNEDY, J.; BLACKWELL, T. Particle swarm optimization: An overview. *Swarm Intelligence*, Springer, v. 1, n. 1, p. 33–57, 2007. Citado 2 vezes nas páginas 23 e 24.
- ROSENSWIG, R. M.; TUÑÓN, A. M. Changing olmec trade routes understood through least cost path analysis. *Journal of Archaeological Science*, v. 118, p. 105146, 2020. Citado na página 19.
- SHI, Y.; EBERHART, R. A modified particle swarm optimizer. In: IEEE. *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence*. Anchorage, AK, USA, 1998. p. 69–73. Citado 2 vezes nas páginas 25 e 40.
- SONNY, A.; YEDURI, S. R.; CENKERAMADDI, L. R. Autonomous uav path planning using modified pso for uav-assisted wireless networks. *IEEE Access*, IEEE, v. 11, p. 70353–70367, 2023. Citado na página 27.
- SOUZA, L. B. P. d. *Distribuição espacial dos sítios arqueológicos com grafismos rupestres na bacia hidrográfica do Pajeú, PE: um estudo de caso para aplicação de modelos preditivos baseados em algoritmos de aprendizagem de máquina*. Tese (Tese (Doutorado em Arqueologia)) — Universidade Federal de Pernambuco, Recife, 2023. Citado na página 27.
- TILLEY, C. *A Phenomenology of Landscape: Places, Paths and Monuments*. Oxford: Berg, 1994. Citado 2 vezes nas páginas 14 e 60.

TOBLER, W. R. *Three presentations on geographical analysis and modeling: Non-isotropic geographic modeling, speculations on the geometry of geography, and global spatial analysis*. Santa Barbara, CA, 1993. Citado 2 vezes nas páginas 35 e 36.

TOMÉ, T.; HAVRE, G. V. Redes de movimento: Acessibilidades em uma paisagem arqueológica na serra das confusões, piauí. *Tessituras: Revista de Antropologia e Arqueologia*, v. 11, n. 2, p. 71–89, 2023. Citado 4 vezes nas páginas 19, 21, 26 e 35.

VERHAGEN, P. On the road to nowhere? least cost paths, accessibility and the predictive modelling perspective. In: EARL, G. et al. (Ed.). *Archaeology in the Digital Era: Papers from the 40th Annual Conference of Computer Applications and Quantitative Methods in Archaeology (CAA), Southampton, 26-29 March 2012*. Amsterdam: Amsterdam University Press, 2013. p. 383–389. Citado 2 vezes nas páginas 18 e 26.

WHITE, D. A. *The Basics of Least Cost Analysis for Archaeological Applications*. Cambridge: Cambridge University Press, 2017. Citado 2 vezes nas páginas 17 e 18.

WHITE, D. A.; BARBER, S. B. Geospatial modeling of pedestrian transportation networks: A case study from precolumbian Oaxaca, Mexico. *Journal of Archaeological Science*, v. 39, n. 8, p. 2684–2696, 2012. Citado 3 vezes nas páginas 19, 20 e 39.