



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

JOÃO PEDRO DE SOUZA LEMOS BARRETO

**OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS APLICADA A CRUZAMENTOS
VIÁRIOS**

Recife
2025

JOÃO PEDRO DE SOUZA LEMOS BARRETO

**OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS APLICADA A CRUZAMENTOS
VIÁRIOS**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Controle e Automação da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Herbert Albérico de Sá Leitão

Recife
2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Barreto, João Pedro de Souza Lemos.

Otimização por enxame de partículas aplicada a cruzamentos viários / João Pedro de Souza Lemos Barreto. - Recife, 2025.

70 p. : il., tab.

Orientador(a): Herbert Albérico de Sá Leitão

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Engenharia de Controle e Automação - Bacharelado, 2025.

Inclui referências, apêndices, anexos.

1. Otimização. 2. Cruzamentos. 3. PSO. 4. Semáforos. 5. Tráfego. I. Leitão, Herbert Albérico de Sá. (Orientação). II. Título.

620 CDD (22.ed.)

JOÃO PEDRO DE SOUZA LEMOS BARRETO

**OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS APLICADA A CRUZAMENTOS
VIÁRIOS**

Trabalho de Conclusão de Curso apresentado ao Departamento de Engenharia Elétrica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Engenheiro João Pedro de Souza Lemos Barreto.

Aprovado em: 11/04/2025

BANCA EXAMINADORA

Prof. Dr. Herbert Albérico de Sá Leitão (Orientador)
Universidade Federal de Pernambuco

Prof. Valdemar Moreira Cavalcante Júnior (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Alex Ferreira Moreira (Examinador Interno)
Universidade Federal de Pernambuco

Este trabalho é dedicado a todos que de alguma forma contribuíram para esta construção, especialmente a todos os professores, que trilharam meu caminho até aqui, e minha família, que me deu toda a base, suporte e amor em todo o caminho.

AGRADECIMENTOS

Toda a fase de idealização para a escolha do tema deste trabalho gira em torno de duas *soft skills* identificadas pelos meus pais desde cedo: logística e raciocínio lógico. Toda a jornada desde o colégio até a graduação foi trilhada com base nesses dois pilares. Logo, um agradecimento especial é deixado para eles por todo o suporte e direcionamento ao longo de todo o caminho da graduação que trouxe à tona o presente trabalho.

Agradeço especialmente ao meu pai, que me deu suporte nos fundamentos da metodologia científica e à minha namorada que me deu o suporte emocional necessário durante todo o curso.

Agradeço à Watt Consultoria por ter me ensinado a gerir adequadamente meu tempo diante de tantos desafios simultâneos.

Agradeço também ao meu orientador, que enriqueceu o trabalho com os *feedbacks* necessários.

RESUMO

A mobilidade urbana rodoviária é a base do deslocamento em grandes centros urbanos mundiais. Uma boa administração viária possibilita um rápido deslocamento de veículos, o que reduz a emissão de poluentes. O crescente aumento, ao longo dos anos, de demanda por veículos nas ruas causa várias reações em cadeia, como os aumentos de congestionamentos, tempo médio de atraso, acidentes, e poluentes. Diversos estudos estão sendo feitos para melhorar a administração viária, grande maioria com o objetivo de definir os melhores ciclos de semáforo por meio de várias táticas, como redes bayesianas, otimização binível, e comportamento de pedestres por meio de processamento de imagem, por exemplo. O objetivo deste trabalho é introduzir um modelo de otimização por enxame de partículas ou *Particle Swarm Optimization* (PSO) para controlar os tempos de sinal verde e ciclo total de sinais em um cruzamento, de modo a aumentar o fluxo total de veículos e diminuir o tempo médio de atraso, contribuindo para a evolução contínua da mobilidade urbana e mitigando os problemas anteriormente apresentados. Para isso, foi feita uma pesquisa experimental — tipo de investigação científica caracterizada pela manipulação de variáveis e observação dos efeitos consequentes — onde foram tratados os elementos de uma base de dados de tráfego da cidade de Nova York, para que fosse explícito o histórico de fluxo de veículos por horário em três cruzamentos viários diferentes. A partir dessa base, é implementado o algoritmo PSO, para que sejam retornados os melhores valores de tempos de sinal verde e ciclo total dos semáforos de cada cruzamento. Apesar das limitações encontradas na base de dados, o modelo proposto apresentou, para certas condições de parametrização, resultados teóricos de tempos de sinais, fluxos de veículos e tempos médios de atraso satisfatórios, indicativos de que o modelo se comporta bem de acordo com a função objetivo fornecida.

Palavras-chave: Otimização; Cruzamentos; PSO; Semáforos; Tráfego.

ABSTRACT

Road mobility is the foundation of transportation in major urban centers around the world. Efficient traffic management enables faster vehicle travel, which helps reduce pollutant emissions. Over the years, the increasing demand for vehicles on the streets has led to a chain reaction of issues, such as traffic congestion, longer delays, higher accident rates, and increased pollution. Many studies have been conducted to improve traffic management, most aiming to determine optimal traffic signal cycles using various strategies, such as Bayesian networks, bi-level optimization, and pedestrian behavior analysis through image processing. This study introduces a Particle Swarm Optimization (PSO) model to control green light durations and total cycle times at intersections, aiming to increase total vehicle flow and reduce average delay time, thereby contributing to the continuous development of urban mobility and mitigating the mentioned problems. To this end, an experimental study was conducted — a type of scientific investigation characterized by variable manipulation — using traffic data from New York City, explicitly treating vehicle flow data by time intervals at three different intersections. Based on this dataset, a PSO algorithm was implemented to determine the optimal green light durations and total signal cycle times for each intersection. In spite of the limitations found in the dataset, the proposed model presented, under certain parameterization conditions, theoretical results of signal times, vehicle flows, and average delays that were satisfactory, indicating that the model performs well according to the provided objective function.

Keywords: Optimization; Intersections; PSO; Traffic signals; Traffic flow.

LISTA DE ILUSTRAÇÕES

Figura 1 – Medição de fluxo numa seção de via.	20
Figura 2 – Interseção semafórica em projeto.	21
Figura 3 – Diagrama de blocos do algoritmo PSO para cada cruzamento.....	27
Figura 4 – Base de dados inicial.	28
Figura 5 – Base de dados modificada.	31
Figura 6 – Base de dados com capacidades.....	31
Figura 7 – Verificação bem sucedida de cruzamento das ruas Broadway e Spring st.	32
Figura 8 – Lugar geométrico de possíveis posições de partículas no algoritmo PSO.	37
Figura 9.a – Iteração 1 do cruzamento 1 – simulação 1.....	39
Figura 9.b – Iteração 25 do cruzamento 1 – simulação 1.....	39
Figura 9.c – Iteração 50 do cruzamento 1 – simulação 1.....	40
Figura 9.d – Iteração 100 do cruzamento 1 – simulação 1.....	40
Figura 10 – Iteração 100 do cruzamento 1 – simulação 1 repetida.....	41
Figura 11.a – Iteração 1 do cruzamento 1 – simulação 2.....	42
Figura 11.b – Iteração 25 do cruzamento 1 – simulação 2.....	42
Figura 11.c – Iteração 50 do cruzamento 1 – simulação 2.....	42
Figura 11.d – Iteração 100 do cruzamento 1 – simulação 2.....	42
Figura 12 – Resultados do algoritmo PSO – simulação 2.	43
Figura 13.a – Iteração 1 do cruzamento 1 – simulação 3.....	44
Figura 13.b – Iteração 25 do cruzamento 1 – simulação 3.....	44
Figura 13.c – Iteração 50 do cruzamento 1 – simulação 3.....	44
Figura 13.d – Iteração 100 do cruzamento 1 – simulação 3.....	44
Figura 14 – Resultados do algoritmo PSO – simulação 3.	45
Figura 15.a – Iteração 1 do cruzamento 1 – simulação 4.....	45
Figura 15.b – Iteração 25 do cruzamento 1 – simulação 4.....	45
Figura 15.c – Iteração 50 do cruzamento 1 – simulação 4.....	46
Figura 15.d – Iteração 100 do cruzamento 1 – simulação 4.....	46
Figura 16 – Resultados do algoritmo PSO – simulação 4.	46
Figura 17.a – Iteração 1 do cruzamento 1 – simulação 5.....	48

Figura 17.b – Iteração 25 do cruzamento 1 – simulação 5.....	48
Figura 17.c – Iteração 50 do cruzamento 1 – simulação 5.....	48
Figura 17.d – Iteração 100 do cruzamento 1 – simulação 5.....	48
Figura 18 – Resultados do algoritmo PSO – simulação 5.....	49
Figura 19.a – Iteração 1 do cruzamento 1 – simulação 6.....	50
Figura 19.b – Iteração 25 do cruzamento 1 – simulação 6.....	50
Figura 19.c – Iteração 50 do cruzamento 1 – simulação 6.....	50
Figura 19.d – Iteração 100 do cruzamento 1 – simulação 6.....	50
Figura 20 – Resultados do algoritmo PSO – simulação 6.....	51
Figura 21.a – Iteração 1 do cruzamento 1 – simulação 7.....	51
Figura 21.b – Iteração 25 do cruzamento 1 – simulação 7.....	51
Figura 21.c – Iteração 50 do cruzamento 1 – simulação 7.....	52
Figura 21.d – Iteração 100 do cruzamento 1 – simulação 7.....	52
Figura 22 – Resultados do algoritmo PSO – simulação 7.....	52
Figura 23.a – Iteração 1 do cruzamento 1 – simulação 8.....	53
Figura 23.b – Iteração 8 do cruzamento 1 – simulação 8.....	53
Figura 23.c – Iteração 20 do cruzamento 1 – simulação 8.....	53
Figura 23.d – Iteração 40 do cruzamento 1 – simulação 8.....	53
Figura 24 – Resultados do algoritmo PSO – simulação 8.....	54
Figura 25 – Gráfico iteração x gbest – simulação 9.....	55
Figura 26 – Resultados obtidos – simulação 9.....	55
Figura 27.a – Resultados da otimização com $\alpha=2$ e $\beta=1$ – Cruzamentos 1 e 2.....	58
Figura 27.b – Resultados da otimização com $\alpha=2$ e $\beta=2$ – Cruzamentos 1 e 2.....	58
Figura 27.c – Resultados da otimização com $\alpha=4$ e $\beta=4$ – Cruzamentos 1 e 2.....	59
Figura 27.d – Resultados da otimização com $\alpha=2$ e $\beta=0,5$ – Cruzamentos 1 e 2.....	59
Figura 28 – Resultados de Gp e CT teóricos após a operação inversa.....	61

LISTA DE TABELAS

Tabela 1 – Exemplo de linhas da base de dados original que formam um cruzamento.....	31
Tabela 2 – Resultados de simulações de α e β – Cruzamento 1, 12:00AM – 01:00AM.....	60

LISTA DE ABREVIATURAS E SIGLAS

PSO	<i>Particle Swarm Optimization</i>
UAI	<i>Urban Artificial Intelligence</i>
NYC	<i>New York City</i>
CTB	Código de trânsito brasileiro
IA	Inteligência artificial

LISTA DE SÍMBOLOS

α	Peso do fluxo total
β	Peso do tempo médio de atraso
B	Função objetivo (<i>best</i>)
c1	Coeficiente cognitivo do algoritmo PSO
C2	Coeficiente social do algoritmo PSO
CT	Tempo de ciclo total de semáforos
g	Melhor <i>fitness value</i> global obtido
Gef	Tempo de sinal verde efetivo
Gp	Tempo de sinal verde em via principal
Gt	Tempo de sinal verde em via transversal
pi	Melhor <i>fitness value</i> individual
q	Fluxo de veículos
qp	Fluxo de veículos em rua principal
qt	Fluxo de veículos em rua transversal
qT	Fluxo total de veículos
s	Capacidade de saturação de via
sp	Capacidade de saturação da via principal
st	Capacidade de saturação da via transversal
T	Intervalo de tempo
Tr	Tempo de reação
v	Demanda de fluxo de veículos
vi	Velocidade da partícula em cada iteração no algoritmo PSO
vp	Demanda de fluxo de veículos em via principal
vt	Demanda de fluxo de veículos em via transversal
ω	Inércia do algoritmo PSO
W	Tempo médio de atraso
WT	Tempo médio de atraso total
x	Distância
X	Razão crítica
xi	Posição da partícula a cada iteração no algoritmo PSO
Xp	Razão crítica em via principal
Xt	Razão crítica em via transversal
XT	Razão crítica total

Y Tempo de sinal amarelo

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVOS	17
1.1.1	Objetivos gerais.....	17
1.1.2	Objetivos específicos.....	18
1.2	ORGANIZAÇÃO DO TRABALHO.....	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	FUNÇÃO OBJETIVO E VARIÁVEIS DE PROJETO.....	19
2.2	OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS	25
2.3	RELAÇÃO ENTRE FUNÇÃO OBJETIVO E ALGORITMO PSO	26
3	DESENVOLVIMENTO DO TRABALHO	28
3.1	DEFINIÇÃO DE BASE DE DADOS.....	28
3.2	DEFINIÇÕES DE FUNÇÃO OBJETIVO E PARÂMETROS DO ALGORITMO PSO	32
3.2.1	Coeficientes cognitivo e social (c_1 e c_2).....	33
3.2.2	Inércia.....	34
3.2.3	Número de partículas	35
3.2.4	Número de iterações	35
3.3	APLICAÇÃO DO ALGORITMO COM A BASE DE DADOS INICIAL	35
3.3.1	Inicialização das partículas.....	36
3.3.2	Atualização das partículas.....	37
3.3.3	Execução do algoritmo	38
3.4	AJUSTES FINOS DOS RESULTADOS.....	39
3.4.1	Ajustes dos parâmetros c_1 , c_2 e número de partículas.....	39
3.4.2	Ajustes dos parâmetros ω e número de iterações	49
3.4.3	Ajustes dos valores de α e β	56
3.5	COMPARAÇÃO DE RESULTADOS COM PARÂMETROS ATUAIS	60
4	CONCLUSÕES E PROPOSTAS DE CONTINUIDADE	63

1 INTRODUÇÃO

A evolução tecnológica e estrutural de áreas urbanas, além de ser uma realidade atual, é uma tendência futurista garantida, assim como o conseqüente aumento da demanda por mobilidade, fator gerador de enormes desafios logísticos para a gestão do tráfego de pessoas e veículos. Em particular, a estratégia de fluxo em cruzamentos viários é fundamental nesta missão, onde a eficiência no controle dos semáforos é essencial para a continuidade do fluxo de veículos. Uma gestão inadequada de tempos de sinais pode aumentar o tempo de deslocamento de veículos, e conseqüentemente a emissão de poluentes.

Nesse contexto, estudos comprovam que os planos de tempo fixo de ciclos de sinais prejudicam o fluxo de veículos, principalmente em horários de pico. Além disso, há uma crescente tendência de aumento de veículos em circulação, a partir do contexto da crescente evolução da tecnologia e demanda por deslocamento (GONÇALVES, SONSIM, et al., 2021). Com essas tendências, sem uma adequada preparação, os problemas de aumento de tempo de deslocamento de veículos e emissões de poluentes tendem a aumentar cada vez mais. Outro problema que deve ser atacado, causado pela inadequação dos tempos de sinais em determinado cruzamento, é a melhora excessiva do fluxo de veículos em uma das ruas do cruzamento, em detrimento da outra rua, que armazena mais veículos e forma congestionamentos.

Para buscar a solução dos problemas eminentes citados anteriormente, é necessário verificar a dimensão e quantidade de variáveis do problema. Ao longo deste trabalho, é demonstrado que os problemas de trânsito são complexos, dependem de várias variáveis e exigem interpretação de extensas bases de dados, além de definição de premissas para variáveis desconhecidas.

Quando se fala de IA, é essencial reconhecer que os dados são a base que permite aos algoritmos aprender, evoluir e gerar impactos significativos (RIBEIRO, 2024). O fator de aprendizado contínuo é a maior vantagem da inteligência artificial em relação a outros métodos. Apesar da vantagem apresentada, é necessário reconhecer também que os algoritmos de inteligência artificial, em geral, demandam esforço computacional maior que outros métodos.

Nessa perspectiva, o conceito de inteligência artificial urbana (UAI) tem sido amplamente discutido como um meio de transformar o gerenciamento de tráfego

urbano, otimizando a interação entre pedestres e veículos (SEPEHR, 2024). Em Viena, por exemplo, já existem semáforos inteligentes para pedestres que utilizam algoritmos de reconhecimento de imagem para adaptar os tempos de sinalização de acordo com a presença e comportamento desses indivíduos, promovendo uma mobilidade mais eficiente e segura (SEPEHR, 2024).

Modelos de controle de tráfego baseados em inteligência artificial e otimização incluem desde sistemas de inferência probabilística, como redes bayesianas dinâmicas, até estratégias de otimização binível (dois níveis de decisão), que visam reduzir congestionamentos e minimizar tempos de espera nos cruzamentos urbanos (ZHENGXING, 2020) (STOILOVA, 2021). Redes bayesianas permitem um ajuste em tempo real dos tempos dos semáforos com base no fluxo de veículos detectados, o que reduz significativamente os congestionamentos e melhora a fluidez no tráfego (ZHENGXING, 2020).

Modelos de otimização binível também fazem parte da realidade atual e trabalham com uma gestão integrada da duração dos tempos de ciclo e tempos de sinal verde, o que possibilita uma sincronização e monitoramento mais eficientes entre diferentes interseções viárias (STOILOVA, 2021). O fator mais interessante dessa abordagem é a análise de efeitos que um cruzamento exerce em outro, possibilitando uma visão sistêmica de como o tempo de ciclo de sinais de um cruzamento A interfere no fluxo e acúmulo de veículos em um cruzamento B, trabalhando bem o conceito de rede de tráfego. O efeito de propagação e coordenação semaforica introduzido acima é essencial para minimizar o tempo de espera dos veículos e reduzir congestionamentos, garantindo uma fluidez mais eficiente no tráfego urbano (M.B. PEREIRA, 2017).

Além os trabalhos citados anteriormente, a busca por evolução da administração viária foi explorada de outras maneiras, como processamento de imagens para reconhecimento da quantidade de carros para a otimização (BARONI, 2018), e otimização para redução de atrasos e grau de saturação (COLNAGO, 2017).

Há também estudos de outros métodos aplicados ao controle de tráfego, além da inteligência artificial, que abordam o controle de ciclos de sinal utilizando outras ferramentas, como sensores e controladores lógicos programáveis. Tal método tem demonstrado benefícios significativos na adaptação do tempo de sinalização conforme densidade de tráfego, contribuindo também para a redução do consumo de

combustível e emissão de poluentes, conseqüentemente (MEI, 2017). Em Recife, a tecnologia de novos semáforos inteligentes é feita por meio de câmeras com laços virtuais, links de comunicação e *software* capaz de atualizar a programação dos semáforos em tempo real, com objetivo de aumentar a segurança e eficiência do trânsito nos semáforos aplicados (CBN RECIFE, 2024).

Para cálculos de trânsito, este trabalho aborda o tempo de resposta do algoritmo como fator importantíssimo para seu desempenho, de modo que o controle em tempo real de ciclos de semáforos possa ser feito com base nos dados mais recentes possíveis. Se o algoritmo demora muito para fazer uma simulação, é possível que a latência seja responsável pelo cálculo com variáveis desatualizadas, o que prejudica a integridade dos cálculos. Essa filosofia compromete o uso de algoritmos de inteligência artificial. Portanto, a segunda alternativa a ser analisada é o uso de algoritmos de otimização.

Diante desse cenário, foi analisado o algoritmo ***particle swarm optimization (PSO)***, proposto inicialmente por Kennedy e Eberhart, em 1995 (KENNEDY e EBERHART, 1995). O PSO é inspirado no comportamento coletivo de enxames, como movimentação de bandos de pássaros ou cardumes de peixes em busca por alimentos (KARIM, ISA e LIM, 2021).

O PSO possui a capacidade de exploração do espaço de possíveis soluções, o que é essencial em uma otimização com mais de uma variável, que é o caso do presente estudo: encontrar um ponto ótimo que agrade igualmente as duas vias que formam um cruzamento. No contexto de controle de tráfego, Saulo Matos, em 2017, cita que o uso do PSO pode minimizar tempos de espera nos semáforos e melhorar o fluxo viário por meio da adaptação dinâmica dos tempos de sinalização. Além disso, quando comparado a técnicas clássicas de programação semafórica, o PSO apresenta vantagens como menor demanda computacional e maior adaptabilidade a cenários dinâmicos, permitindo ajustes em tempo real de acordo com a demanda de veículos (MATOS, 2017). O método abordado por Saulo Matos busca otimizar o fluxo de tráfego através de seis funções objetivo. Neste trabalho, é abordado um modelo mais simples, com uma única função objetivo, para otimização de duas variáveis objetivo: fluxo de veículos e tempo médio de atraso.

Apesar das vantagens, o PSO tem desafios que podem comprometer sua eficiência, como a convergência prematura para soluções subótimas, devido à baixa

diversidade da população de partículas (KARIM, ISA e LIM, 2021). O algoritmo mostra dificuldades para escapar de pontos de mínimo/máximo locais, em detrimento de pontos de mínimo/máximo global, quando se tem uma quantidade pequena de partículas. A solução que ajuda esse problema é o aumento do número de partículas no algoritmo, aumentando a exploração de todo o espaço. Entretanto, essa solução entra em conflito com uma das vantagens do algoritmo, que é a simplicidade e baixo custo computacional.

Apesar das desvantagens apresentadas, estudos recentes, como o estudo de Saulo Matos, em 2017, apontam para o potencial dessa abordagem quando combinada com outras técnicas de inteligência artificial, como algoritmos genéticos e redes neurais, permitindo uma gestão ainda mais eficiente do tráfego urbano (MATOS, 2017). O presente trabalho não aborda as técnicas de inteligência artificial descritas, porém dá o pontapé inicial para futuras integrações com IA ao aplicar o algoritmo PSO em cruzamentos viários para controle de tempos semafóricos.

Diante das vantagens apresentadas pela otimização por enxame de partículas, esse modelo de otimização bioinspirado é utilizado neste estudo para aplicar um algoritmo PSO que recebe os fluxos de tráfego vigentes nos cruzamentos de Nova York considerados no experimento, e retorna os melhores tempos de sinal verde e de ciclo total para cada cruzamento. É escolhida pelo algoritmo a solução que melhor atende as duas ruas que compõem o cruzamento, por meio de uma única função objetivo, cujo ponto máximo definirá os melhores cenários de fluxo total de veículos e tempo de atraso total das duas ruas. Por se tratar de um modelo inicial, e pela limitação dos dados de entrada, ainda não são considerados os efeitos de interdependência entre os ciclos de sinais de cruzamentos vizinhos (STOILOVA, 2021).

1.1 Objetivos

1.1.1 Objetivos gerais

O objetivo geral deste trabalho é desenvolver uma ferramenta de otimização, baseada no PSO, aplicada em um conjunto de cruzamentos viários, para definição

dos melhores tempos de ciclo de sinais e tempos de sinal verde das duas vias que compõem cada cruzamento.

Com a otimização dos tempos de ciclo, espera-se uma redução do tempo médio de atraso dos veículos, aumento no fluxo viário, e conseqüentemente uma diminuição do tempo total de deslocamento.

1.1.2 Objetivos específicos

Diante do formato inadequado da base de dados de entrada para a aplicação do algoritmo, deve ser montada uma nova base de dados com os cruzamentos válidos, pois a base existente não explicita quais são os cruzamentos, apenas informa a via, e o trecho da via cujo fluxo de veículos foi coletado.

Outro objetivo do trabalho foi a obtenção da resposta mais satisfatória em termos de precisão, tempo de resposta e convergência de partículas, a partir de ajustes dos hiperparâmetros do algoritmo PSO, como **coeficientes cognitivo e social (c_1 e c_2)**, **inércia (ω)**, **número de partículas e número de iterações**.

1.2 Organização do Trabalho

Este trabalho está estruturado em quatro capítulos:

- No capítulo 1, apresenta-se a introdução, que descreve o atual estado da ciência acerca dos temas abordados neste trabalho, contextualização do problema, objetivos, e organização do trabalho.
- No capítulo 2, é apresentada a fundamentação teórica, que explorará os conceitos científicos fundamentais existentes sobre sinalização semafórica e algoritmo de otimização por enxame de partículas.
- No capítulo 3, é apresentado o desenvolvimento do trabalho, com toda a metodologia utilizada, todas as premissas e critérios adotados para a avaliação dos ciclos semafóricos.
- No capítulo 4, são mostrados os resultados obtidos e as análises críticas acerca dos *outputs* do desenvolvimento. Também serão apresentadas as propostas de continuidade e sugestões para futuros estudos.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, será apresentada a fundamentação teórica utilizada como base para a definição dos parâmetros e equações utilizados no presente estudo.

2.1 Função objetivo e variáveis de projeto

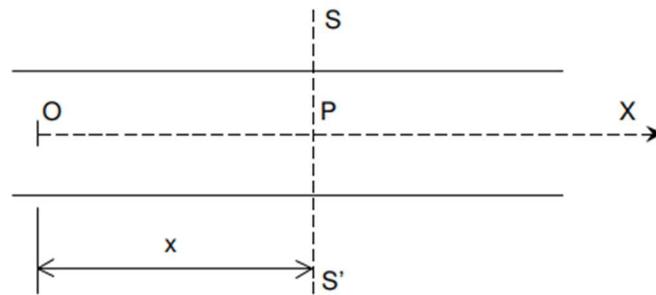
Nesta seção, é abordada a fundamentação teórica por trás da função objetivo do projeto, que é a referência que o algoritmo PSO vai utilizar para buscar os melhores valores de tempo de ciclo total e tempo de sinal verde, que também são explicados nesta seção. Quanto maior o resultado dessa função objetivo, melhor o *fitness value* — resultado da função objetivo — das partículas, de modo que o algoritmo sempre busque os valores de tempo de ciclo total e tempo de sinal verde para melhorar cada vez mais o *fitness value* dentro do lugar geométrico definido. Os detalhes do algoritmo PSO são definidos a partir da seção 2.2, enquanto esta seção define a função objetivo, que é função das variáveis objetivo fluxo de veículos e tempo médio de atraso.

O fluxo de tráfego, também chamado de volume de tráfego, é representado pela variável q . É uma variável temporal e significa o número de veículos que cruzam uma determinada seção de uma via S considerada dentro de um dado intervalo de tempo (SILVA, 1994).

Na Figura 1, por exemplo, é determinada a seção SS' que passa pelo ponto P , posicionado no eixo OX a uma distância x da origem O através da seção de via S . Durante o intervalo de tempo T são contados os $n(x)$ veículos que cruzam a seção (SILVA, 1994). O fluxo $q(x)$, em veículos/h, é então definido por:

$$q(x) = \frac{n(x)}{T} \quad (2.1)$$

Figura 1 – Medição de fluxo numa seção de via.



Fonte: (SILVA, 1994).

A variável fluxo de veículos é o parâmetro de entrada obtido da base de dados escolhida, que será detalhada posteriormente. Portanto, vista sua importância para a engenharia de tráfego, o fluxo será a primeira variável objetivo do presente trabalho, partindo da premissa que quanto maior o fluxo em um cruzamento viário, melhor é a mobilidade na via, sendo, portanto, um parâmetro (variável objetivo) de otimização.

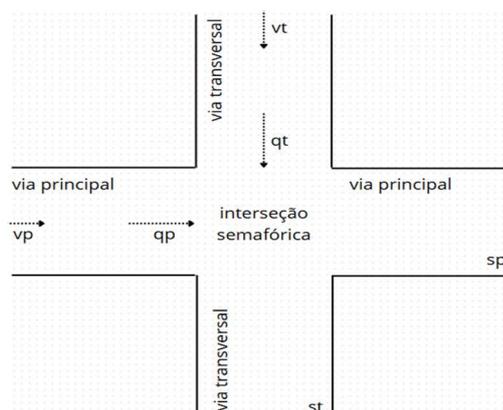
Segundo o código de trânsito brasileiro (CTB), o conceito de cruzamento se refere à interseção de duas vias no mesmo nível, enquanto interseção é todo cruzamento em nível, entroncamento ou bifurcação (REPÚBLICA FEDERATIVA DO BRASIL, 1997). Esses conceitos serão utilizados no projeto. Um exemplo de interseção semafórica válida para o projeto é apresentado na Figura 2.

Neste trabalho, o fluxo total de veículos em uma seção será outra variável objetivo que deve ser melhorada por meio do algoritmo de otimização. O fluxo total de veículos em um cruzamento ou interseção será definido como a soma dos fluxos das duas vias que o formam:

$$qT = qp + qt \quad (2.2)$$

Sendo qT o fluxo total em um cruzamento, qp o fluxo da rua principal e qt o fluxo da rua transversal, todos em veículos/h. Para prosseguimento no desenvolvimento das fórmulas, será encontrado, algumas vezes, o parâmetro descrito apenas como q para indicar que a fórmula pode ser utilizada para os dois casos, de ruas principal e transversal.

Figura 2 – Interseção semafórica em projeto.



Fonte: Autoria própria, 2025.

Além do fluxo de veículos, também serão utilizadas neste trabalho as variáveis de ajuste G_p (tempo de sinal verde da rua principal em segundos) e CT (tempo de ciclo total de sinais em segundos), que é a soma entre os tempos de sinais verde, vermelho e amarelo de um semáforo. Portanto, será desenvolvida uma fórmula que calcule o fluxo total em um cruzamento em função dessas duas variáveis. A definição correta desta fórmula é fundamental para o algoritmo, porque formará a primeira parte da função objetivo e ditará o correto funcionamento do algoritmo PSO, que será detalhado na seção 2.2.

Outra variável que influencia no estudo é o tempo de perdas, definido pelo período de reação dos motoristas, seja no início do sinal verde, quando os motoristas devem acelerar, seja no sinal amarelo, quando os motoristas devem frear seus respectivos veículos (LOPES e GIUBERTI, 2011). Isso define um parâmetro chamado tempo de sinal verde efetivo:

$$G_{ef} = G - Tr \quad (2.3)$$

Sendo G_{ef} o tempo de sinal verde efetivo, G o tempo de sinal verde real, Tr o tempo de reação dos motoristas, todos em segundos.

Portanto, o tempo de sinal verde em que a demanda de fluxo de veículos vai estar realmente fluindo é o tempo de sinal verde efetivo. Dessa forma, a porcentagem de tempo em que o fluxo de veículos realmente será efetivo é dada por:

$$\%tempo_{fluxo} = \frac{Gef}{CT} = \frac{G - Tr}{CT} \quad (2.4)$$

O fluxo de veículos em função do tempo vai ser sempre igual à demanda de fluxo ou à capacidade máxima da via, multiplicado pela porcentagem de tempo de fluxo:

$$q = \min(s, v) \cdot \frac{G - Tr}{CT} \quad (2.5)$$

Sendo s a capacidade máxima de saturação da via e v a demanda de fluxo de veículos na via, ambos em veículos/h, conceitos estabelecidos pelo *Highway Capacity Manual* (TRANSPORTATION RESEARCH BOARD ; BUREAU OF PUBLIC ROADS, 1950). Caso a demanda seja maior que a capacidade de fluxo da via, o valor será limitado a s . Caso contrário, a v .

Portanto, a partir das equações (2.2) e (2.5), obtém-se:

$$qT = \min(sp, vp) \cdot \frac{Gp - Tr}{CT} + \min(st, vt) \cdot \frac{Gt - Tr}{CT} \quad (2.6)$$

Sendo Gt , tempo de sinal verde da rua transversal, e Gp , tempo de verde da rua principal, ambos em segundos, correlacionados para a correta funcionalidade do cruzamento:

$$CT = Gp + Gt + Y \quad (2.7)$$

Sendo CT a soma dos tempos de sinais verde da rua principal (vermelho da rua transversal), verde da rua transversal (vermelho da rua principal) e tempo de sinal amarelo, definido por Y (em segundos).

Neste trabalho, os parâmetros Y e Tr serão fixos em todo o desenvolvimento, enquanto o parâmetro s será variável de acordo com cada via, e vt variável para cada horário, conforme premissas que serão adotadas na seção 3. Dessa forma obtém-se a equação final de qT apenas em função de Gp e CT :

$$qT(Gp, CT) = \min(sp, vp) \cdot \frac{Gp - Tr}{CT} + \min(st, vt) \cdot \frac{CT - Gp - Y - Tr}{CT} \quad (2.8)$$

Essa fórmula ditará o fluxo total de veículos, uma das variáveis objetivo, que deverá ser otimizada.

A partir desta etapa, será apresentada a segunda e última parte da função objetivo. Será desenvolvida uma nova fórmula, para que a função objetivo final esteja completa, levando em consideração as duas variáveis objetivo a serem otimizadas.

A segunda variável objetivo é o tempo médio de atraso (W), definido em função das mesmas variáveis existentes na fórmula de qT . W é definido como o tempo médio no qual um veículo passa esperando em um sinal vermelho antes de poder prosseguir, considerando tanto o impacto da variação na chegada dos veículos quanto o efeito da saturação do tráfego (WEBSTER, 1958).

O pesquisador britânico F.V. Webster também definiu uma fórmula para o tempo médio de atraso (WEBSTER, 1958):

$$W(G, CT) = \frac{CT \cdot \left(1 - \frac{G}{CT}\right)^2}{2 \cdot (1 - X)} \quad (2.9)$$

Onde X é a razão crítica, conceito fundamental utilizado em cruzamentos (TRANSPORTATION RESEARCH BOARD ; BUREAU OF PUBLIC ROADS, 1950). Ela representa a proporção entre a demanda de tráfego (v) e a capacidade da via (s). Uma razão crítica maior que 1, por exemplo, indica que o cruzamento está sobrecarregado. A razão crítica é o parâmetro que avalia como determinado fluxo de veículos vai se comportar em uma via de acordo com sua capacidade estrutural. A razão crítica é definida por:

$$X = \frac{v}{s} \quad (2.10)$$

Sendo assim, da mesma forma que o fluxo total, o tempo de atraso total, mostrado na equação (2.11), será a soma simples dos tempos médios de espera das duas vias, no qual são utilizadas as equações (2.7) e (2.3) para relacionar G_t a G_p e CT , além de utilizar o tempo de sinal verde efetivo para a otimização:

$$WT(Gp, CT) = \frac{CT \cdot \left(1 - \frac{Gp - Tr}{CT}\right)^2}{2 \cdot (1 - Xp)} + \frac{CT \cdot \left(1 - \frac{CT - Gp - Y - Tr}{CT}\right)^2}{2 \cdot (1 - Xt)} \quad (2.11)$$

Por fim, considerando as duas variáveis objetivos apresentadas, pode-se definir a função objetivo do estudo, ponderando-as por meio dos pesos α e β para definir qual parâmetro será mais relevante para a otimização:

$$B(Gp, CT) = \max(\alpha \cdot qT(Gp, CT) - \beta \cdot WT(Gp, CT)) \quad (2.12)$$

A função é definida de modo que os pesos possam ser alterados e os resultados serem mais balanceados. O termo qT deverá ser positivo na fórmula porque contribui diretamente com o aumento da função objetivo, enquanto a componente do termo WT deverá ser subtraída porque o aumento do tempo médio de atraso corresponderá a uma piora no resultado da função objetivo.

Também é possível calcular os parâmetros teóricos de CT e Gp em função da razão crítica total XT , de acordo com o *Highway Capacity Manual* (TRANSPORTATION RESEARCH BOARD ; BUREAU OF PUBLIC ROADS, 1950). XT é definido por:

$$XT = \sum \frac{vi}{si} \quad (2.13)$$

Sendo vi e si (em veículos/h), respectivamente, a demanda de veículos e a capacidade de cada via do cruzamento, a serem somadas para aplicabilidade da fórmula.

A partir da fórmula apresentada, é possível calcular CT e Gp teóricos:

$$CT = \frac{Tp}{1 - XT} \quad (2.14)$$

$$Gp = \frac{Xp}{XT} \cdot (CT - Tp) \quad (2.15)$$

Dessa forma, é possível calcular de maneira inversa o fluxo total e tempo médio de espera, com as equações (2.8) e (2.11).

2.2 Otimização por enxame de partículas

A otimização por enxame de partículas tem raízes em duas metodologias principais. Talvez mais óbvias sejam suas ligações com a vida artificial, em geral, e com o agrupamento de pássaros, o cardume de peixes e a teoria de enxames em particular. No entanto, também está relacionada à computação evolucionária e tem conexões tanto com algoritmos genéticos quanto com programação evolucionária (KENNEDY e EBERHART, 1995).

Assim como um grupo de pássaros, por exemplo, o algoritmo PSO utiliza o posicionamento do melhor indivíduo para guiar o posicionamento dos demais. O PSO busca soluções ótimas através de soluções candidatas apontadas por diferentes partículas.

Dentro de um lugar geométrico pré-definido, as partículas são inicializadas de forma aleatória e são analisados os *fitness values* de cada uma de acordo com uma determinada função objetivo. A partir deles, as partículas tendem a seguir a posição do melhor *fitness value* inicial obtido, além de armazenar seus próprios *fitness values* ao longo do caminho.

Essas duas premissas de armazenamento geram dois tipos de experiência: individual (experiência cognitiva) e coletiva (experiência social). As decisões de direção de cada partícula serão atualizadas de acordo com ambas as experiências, com pesos diferentes de acordo com os coeficientes c_1 e c_2 , respectivamente chamados de coeficiente cognitivo e coeficiente social (KENNEDY e EBERHART, 1995).

Os coeficientes são multiplicados por valores aleatórios entre 0 e 1, representados por r_1 e r_2 . Esses valores impõem uma condição aleatória para cada decisão de direção por partícula, diversificando a busca por resultados, ora seguindo mais a experiência cognitiva, ora a experiência social, balanceados pelos coeficientes.

No PSO, cada partícula possui uma posição e uma velocidade no espaço de busca. A posição da partícula representa uma solução potencial para o problema de otimização, enquanto a velocidade representa módulo, direção e sentido do movimento da partícula. As velocidades ($v_i(t + 1)$) são ditadas pela posição anterior ($x_i(t)$), velocidade anterior ($v_i(t)$), c_1 , c_2 , r_1 , r_2 , melhor *fitness value* obtido da partícula (p_i), melhor *fitness value* global obtido (g) e inércia (ω), que controla a influência da

velocidade anterior, assim como no conceito físico (KENNEDY e EBERHART, 1995). Sua fórmula é definida por:

$$v_i(t + 1) = \omega \cdot v_i(t) + c1 \cdot r1 \cdot (p_i - x_i(t)) + c2 \cdot r2 \cdot (g - x_i(t)) \quad (2.16)$$

Após a inicialização das partículas, a fórmula de velocidade será aplicada para cada partícula e suas novas posições serão atualizadas de acordo com a soma entre a posição anterior e a nova velocidade:

$$x_i(t + 1) = x_i(t) + v_i(t + 1) \quad (2.17)$$

Sendo $x_i(t + 1)$ a nova posição da partícula i . Fisicamente é impossível somar posição com velocidade, por se tratarem de grandezas diferentes. Entretanto, nesse caso, a velocidade representa uma variação de posição. Portanto, considerando esse contexto, isso é possível.

As velocidades e novas posições deverão ser atualizadas a cada iteração, até o limite de quantidade de iterações ser atingido. Com isso, a posição final de todas as partículas é definida. A posição da partícula com melhor *fitness value* será chamada de **gbest** (g). Esta melhor posição definirá os valores das variáveis de otimização, que resultarão no melhor resultado na função objetivo.

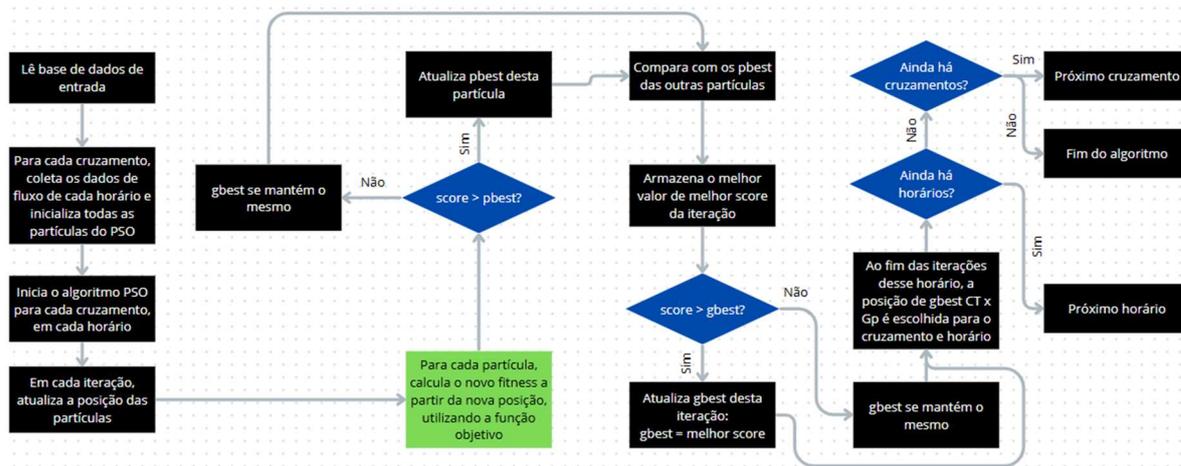
As equações e a fundamentação do algoritmo PSO exibidas nesta seção foram originalmente apresentadas no artigo *Particle Swarm Optimization* (KENNEDY e EBERHART, 1995), e será usado neste trabalho para otimizar a função B, definida na equação (2.12), em função dos parâmetros CT e Gp.

2.3 Relação entre função objetivo e algoritmo PSO

A partir dos fundamentos teóricos da função objetivo e do algoritmo PSO, a correlação entre os dois acontece nos cálculos dos *fitness values* de cada partícula em cada iteração. Em todas as iterações, a função objetivo B, definida na equação (2.12), será calculada. Caso o *fitness value* de uma determinada partícula tenha valor maior que a iteração anterior, o valor de **pbest** (p_i) será atualizado e comparado com os p_i das outras partículas. O melhor p_i da iteração será comparado com o melhor p_i

das últimas iterações, e o maior valor da comparação entre os p_i prevalecerá como valor de **gbest** (g), que será atualizado a cada iteração. A Figura 3 representa em diagrama de blocos como funcionará o algoritmo PSO, e o retângulo verde representa a utilização da função objetivo B no algoritmo PSO.

Figura 3 – Diagrama de blocos do algoritmo PSO para cada cruzamento.



Fonte: Autoria própria, 2025.

3 DESENVOLVIMENTO DO TRABALHO

Para implementação do algoritmo PSO em cruzamentos viários, foi feito um código em python utilizando a plataforma *Google Collaboratory*. Para detalhar o desenvolvimento do código, serão separadas cinco fases: base de dados, função objetivo, algoritmo PSO, ajustes finos de resultados e comparação de resultados com parâmetros atuais.

3.1 Definição de base de dados

A base de dados inicial utilizada é uma base de dados aberta com os dados de fluxo de tráfego presentes na cidade de Nova York, EUA. Em (NYC OPEN DATA, 2022), é possível acessar esta base de dados, que tem suas colunas parcialmente exibidas conforme a Figura 4.

Figura 4 – Base de dados inicial.

ID	SegmentID	Roadway	From	To	Direction	Date	12:00-1:00	1:00-2:00#	2:00-3:00#
1	15540	BEACH ST	UNION PL	VAN DUZE NB		01/09/2012	20	10	11
2	15540	BEACH ST	UNION PL	VAN DUZE NB		01/10/2012	21	16	8
3	15540	BEACH ST	UNION PL	VAN DUZE NB		01/11/2012	27	14	6
4	15540	BEACH ST	UNION PL	VAN DUZE NB		01/12/2012	22	7	7
5	15540	BEACH ST	UNION PL	VAN DUZE NB		01/13/2012	31	17	7
6	15540	BEACH ST	UNION PL	VAN DUZE NB		01/14/2012	42	27	21
7	15540	BEACH ST	UNION PL	VAN DUZE SB		01/09/2012	27	12	12
8	15540	BEACH ST	UNION PL	VAN DUZE SB		01/10/2012	26	16	11
9	15540	BEACH ST	UNION PL	VAN DUZE SB		01/11/2012	32	16	8
10	15540	BEACH ST	UNION PL	VAN DUZE SB		01/12/2012	24	12	7
11	15540	BEACH ST	UNION PL	VAN DUZE SB		01/13/2012	39	22	8
12	15540	BEACH ST	UNION PL	VAN DUZE SB		01/14/2012	45	45	28
13	12809	LITTLE CLC	NORTHER	BRISTOL A	EB	01/09/2012	21	11	2
14	12809	LITTLE CLC	NORTHER	BRISTOL A	EB	01/10/2012	20	14	5
15	12809	LITTLE CLC	NORTHER	BRISTOL A	EB	01/11/2012	16	11	3
16	12809	LITTLE CLC	NORTHER	BRISTOL A	EB	01/12/2012	26	14	7
17	12809	LITTLE CLC	NORTHER	BRISTOL A	EB	01/13/2012	29	11	10
18	12809	LITTLE CLC	NORTHER	BRISTOL A	EB	01/14/2012	32	31	17
19	12809	LITTLE CLC	NORTHER	BRISTOL A	WB	01/09/2012	18	7	7
20	12809	LITTLE CLC	NORTHER	BRISTOL A	WB	01/10/2012	21	10	9
21	12809	LITTLE CLC	NORTHER	BRISTOL A	WB	01/11/2012	19	12	6
22	12809	LITTLE CLC	NORTHER	BRISTOL A	WB	01/12/2012	32	9	4
23	12809	LITTLE CLC	NORTHER	BRISTOL A	WB	01/13/2012	37	19	8
24	12809	LITTLE CLC	NORTHER	BRISTOL A	WB	01/14/2012	29	27	15
25	14723	NARROW	HASTINGS	GARSON A	SB	01/09/2012	15	13	5
26	14723	NARROW	HASTINGS	GARSON A	SB	01/10/2012	29	20	9
27	14723	NARROW	HASTINGS	GARSON A	SB	01/11/2012	10	16	11
28	14723	NARROW	HASTINGS	GARSON A	SB	01/12/2012	26	19	17

Fonte: (NYC OPEN DATA, 2022).

A estrutura mostrada na Figura 4 apresenta as seguintes colunas:

- *ID*: Chave de cada linha;
- *SegmentID*: ID de cada trecho ou segmento de via;

- *Roadway name*: Nome da via;
- *From*: Indicador da origem do determinado trecho da via;
- *To*: Indicador do destino do determinado trecho da via;
- *Direction*: Indica o sentido de fluxo;
- *Date*: Data em que foram colhidos os dados;
- Colunas de horários: Indicam a quantidade de veículos que passaram naquele trecho e horário.

Essa base de dados contempla dados de trechos de ruas, definidos pela rua principal, rua de origem e rua de destino. Dessa maneira, é possível identificar dois cruzamentos por linha nessa base de dados:

- “*Roadway name*” e “*From*”
- “*Roadway name*” e “*To*”

Dessa forma, já é possível extrair o fluxo de veículos em um trecho entre dois cruzamentos.

O principal problema da base de dados para essa aplicação é a falta de uma coluna de cruzamentos que agrupe os dados de fluxo de veículos tanto da rua principal, quanto transversal. Sem um agrupamento por cruzamentos, seria muito complicado reunir os valores corretos de dois cruzamentos. Portanto, foi necessário o refinamento da base de dados para prosseguimento do trabalho.

Apesar de cada linha conter dois cruzamentos implícitos, apenas uma das vias contém os dados de fluxo sobre a mesma, que é a via presente na coluna “*Roadway name*”. Isso significa que a partir de uma linha, não é possível obter os dados de um cruzamento.

Portanto, a solução encontrada foi a criação de uma nova base de dados, derivada da primeira, que contivesse uma clara identificação dos cruzamentos. Isso foi feito de acordo com o seguinte passo a passo:

- Identificação da via citada na coluna “*Roadway name*” na linha A;
- Análise das vias nas colunas “*From*” e “*To*” da linha A;
- Procura de um valor na coluna “*Roadway name*” que contivesse uma das vias “*From*” ou “*To*” da linha A em uma linha B;

- Análise dos valores “From” e “To” da linha B para checar se um dos valores é o “Roadway name” da linha A;
- Analisar na plataforma *Google maps* a presença de uma interseção semafórica entre as duas ruas.

As linhas A e B, encontradas na configuração apresentada, completam os dados de um cruzamento, sendo formado por uma via principal e uma via transversal, ambas com seus dados de fluxo por horário em duas linhas diferentes. Um exemplo de linha A e linha B encontradas na base de dados pode ser visto na Tabela 1, que mostra o exemplo do cruzamento da Valentine Avenue com East Fordham Road.

Assim, foram coletados manualmente 3 conjuntos linha A + linha B, representando 3 cruzamentos diferentes em 6 linhas, que foram transferidas para uma nova base de dados de maneira mais organizada para prosseguimento do código, conforme mostrado na Figura 5. A base de dados modificada explicita as ruas principal e transversal do cruzamento, além de criar um ID de cruzamentos, para ser utilizado posteriormente no código como referência.

Ainda nesta fase de desenvolvimento, foi adotada uma premissa para a capacidade de fluxo s , necessária para cálculo da função objetivo conforme seção 2.1. De acordo com o *Highway Capacity Manual* (TRANSPORTATION RESEARCH BOARD ; BUREAU OF PUBLIC ROADS, 1950), os seguintes tipos de vias têm as seguintes capacidades de fluxo:

- Via Coletora: $s = 600$ a 1500 veículos por hora. Será utilizado 1000;
- Via local: $s = 150$ a 600 veículos por hora. Será utilizado 600
- Via arterial $s = 1800$ veículos por hora. Será utilizado 1800.

Portanto, com esses valores de referência, assumiu-se um valor para as capacidades das vias de modo que cada via tenha alguns horários de sobrecarga, para verificação de comportamento no modelo que está sendo proposto. Assim, foram definidos valores para as capacidades com base na Figura 6, pois não foram encontrados esses valores reais nas bases de dados existentes. Dessa maneira, conclui-se esta etapa de projeto com uma base de dados de entrada para o algoritmo PSO e função objetivo.

Tabela 1 – Exemplo de linhas da base de dados original que formam um cruzamento.

	Roadway name	From	To
Linha A	Valentine avenue	East 188 street	East Fordham road
Linha B	East Fordham road	Grand concourse	Valentine Avenue

Fonte: (NYC OPEN DATA, 2022).

Figura 5 – Base de dados modificada.

A	B	C	D	E	F	G	H	I	J
ID	CRUZAMENTO	PRINCIPAL	TRANSVERSAL	12:00-1:00 AM	1:00-2:00AM	2:00-3:00AM	3:00-4:00AM	4:00-5:00AM	5:00-6:00AM
1	1	BROADWAY	SPRING STREET	641	487	497	593	637	666
2	1	SPRING STREET	BROADWAY	512	440	364	307	233	174
3	2	BEACH STREET	VAN DUZER STREET	33	23	16	12	15	22
4	2	VAN DUZER STREET	BEACH STREET	122	76	54	45	50	97
5	3	VALENTINE AVENUE	EAST FORDHAM ROAD	51	39	25	16	17	24
6	3	EAST FORDHAM ROAD	VALENTINE AVENUE	375	277	203	174	182	233

Fonte: Autoria própria, 2025

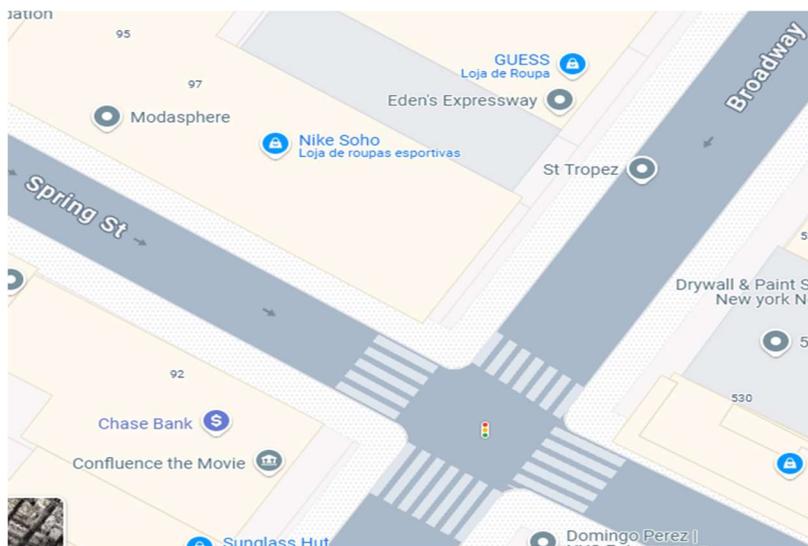
Figura 6 – Base de dados com capacidades.

ID	CRUZAMENTO	PRINCIPAL	TRANSVERSAL	Tipo_Via	Capacidade
1	1	BROADWAY	SPRING STREET	Coletora	1000
2	1	SPRING STREET	BROADWAY	Local	600
3	2	BEACH STREET	VAN DUZER STREET	Local	600
4	2	VAN DUZER STREET	BEACH STREET	Local	600
5	3	VALENTINE AVENUE	EAST FORDHAM ROAD	Local	600
6	3	EAST FORDHAM ROAD	VALENTINE AVENUE	Local	600

Fonte: Autoria própria, 2025.

A própria plataforma *Google maps* indica se um cruzamento tem semáforos ou não, o que possibilitou a verificação da existência dos cruzamentos mostrados nas Figuras Figura 5 e Figura 6. Um exemplo de verificação bem sucedida é mostrado na Figura 7, que indica o nome das ruas exemplo Broadway e Spring Street, com um indicativo de semáforo no cruzamento entre as duas.

Figura 7 – Verificação bem sucedida de cruzamento das ruas Broadway e Spring st.



Fonte: Google maps (GOOGLE), 2025.

3.2 Definições de função objetivo e parâmetros do algoritmo PSO

Na segunda etapa do desenvolvimento, foi idealizado e escrito o código da função objetivo, de acordo com as equações definidas na seção 2.1, além da inicialização das variáveis de projeto.

Para a análise inicial, foram definidos os valores de peso da função objetivo conforme equação (2.12), com base em resultados de teste iniciais do algoritmo: $\alpha=2$ e $\beta=1$. Os valores dessas variáveis serão revisados posteriormente com a verificação dos resultados.

A função objetivo está presente na função em python chamada *funcao_objetivo*, apresentada no **apêndice B**, e implementa a função objetivo que será utilizada posteriormente para cálculo de otimização pelo algoritmo PSO.

Os parâmetros do algoritmo PSO a serem definidos, conforme fundamentação científica na seção 2.2, são:

- $c1$
- $c2$
- ω
- Número de partículas
- Número de iterações

Cada um desses parâmetros iniciais altera uma característica diferente da otimização por enxame de partículas. Seus efeitos no código e valores iniciais utilizados serão mostrados nos subitens a seguir.

3.2.1 Coeficientes cognitivo e social (c_1 e c_2)

Os coeficientes determinam qual tipo de experiência da partícula será mais influente na sua “tomada de decisão” de direção, ao influenciar diretamente a equação de velocidade do PSO (2.16).

Quanto maior for c_1 em relação a c_2 , mais a partícula vai seguir sua própria experiência, pois estabelece um peso maior na equação de velocidades para a diferença de posição entre a partícula e a posição de melhor *fitness value* registrada por ela (p_i). Isso pode gerar comportamentos indesejados porque gera mais dificuldade na convergência das partículas em direção à posição de melhor *fitness value* global (g).

Por outro lado, quanto maior for c_2 em relação a c_1 , mais a partícula vai seguir a experiência da melhor partícula, pois o peso maior é estabelecido sobre a diferença entre a posição da partícula (p_i) e a posição de melhor *fitness value* global (g). A condição apresentada também pode gerar comportamentos indesejados, pois as partículas vão convergir rápido demais, deixando de explorar todo o lugar geométrico de possíveis soluções e podendo convergir para um ponto de máximo local, em detrimento do ponto de máximo global buscado.

Assim, a solução apresentada para esse problema neste trabalho é o equilíbrio entre c_1 e c_2 , estabelecidos por valores iguais. Será definido inicialmente o valor **1,2** para cada coeficiente. Conforme explícito na equação (2.16), quanto maior o módulo desses dois coeficientes, maior o módulo das velocidades. O comportamento da convergência das partículas será avaliado para diferentes valores iguais de c_1 e c_2 na seção 3.4.1.

3.2.2 Inércia

O fator de inércia no algoritmo PSO determina a magnitude da velocidade, amplificando seu módulo de acordo com a equação (2.16). Assim como os coeficientes cognitivo e social, foi necessário encontrar um meio termo para o fator de inércia.

Uma inércia muito pequena gera dificuldade nas velocidades iniciais das partículas, sendo necessária uma maior quantidade de iterações e memória computacional para aguardar a convergência. Já uma inércia muito grande pode dificultar convergências no ponto de máximo global, pois a partícula terá mais dificuldade para desacelerar.

A partir dos princípios apresentados, conclui-se que é desejado um fator de inércia maior nas iterações iniciais, para que as partículas tenham melhor movimentação e a quantidade de iterações diminua, assim como é desejada uma inércia menor nas iterações finais, facilitando a convergência das partículas na melhor posição global.

Dessa maneira, foi adotada uma premissa de inércia variável para este trabalho: o fator de inércia inicial deverá ser multiplicado por um valor diferente a cada iteração de modo que a inércia diminua linearmente. Dessa forma, foi idealizada a seguinte equação:

$$\omega = \omega_{inicial} - (\omega_{inicial} - \omega_{final}) \cdot \frac{iteração}{num_{iterações}} \quad (3.18)$$

Sendo ω o valor de inércia. Assim, os valores de inércia devem alcançar os valores desejados para cada fase da iteração. Foram escolhidos inicialmente, após testes iniciais, **0,9** e **0,4** como $\omega_{inicial}$ e ω_{final} . Esses valores serão testados e reavaliados na seção 3.4.2.

3.2.3 Número de partículas

Há dois fatores relacionados ao número de partículas do algoritmo PSO: a memória computacional e a precisão do algoritmo. Quanto maior o número de partículas no algoritmo, mais tempo vai levar para realizar todas as iterações e obter os melhores valores. Entretanto, o algoritmo se torna mais preciso porque uma maior quantidade de soluções vai ser explorada por compilação, podendo esse ser um fator determinante para o problema da convergência prematura apontada na seção 1, pois mais espaços serão explorados, e conseqüentemente, mais soluções serão exploradas. Portanto, foi escolhido o valor inicial de **50 partículas** que é 25 vezes a quantidade de variáveis, e é reavaliado na seção 3.4.1.

3.2.4 Número de iterações

O número de iterações é responsável por determinar quantas vezes as partículas aplicarão a função objetivo para alcançar o melhor resultado.

Em teoria, quanto maior a quantidade de iterações, mais precisa vai ser a solução. Entretanto, para essa aplicação, não é necessário um valor preciso a partir da segunda casa decimal, visto que o número será desprezível em relação aos valores totais. Portanto, o número de iterações será escolhido de acordo com uma estratégia de parada forçada do algoritmo, assim que a diferença entre *gbest* atual e *gbest* anterior for menor que uma unidade centesimal. A partir desse ponto, não é mais necessário o acréscimo de iterações. Inicialmente, foi escolhido o valor **100** como número máximo de iterações, mas será reavaliado na seção 3.4.2.

3.3 Aplicação do algoritmo com a base de dados inicial

Considerando as premissas apresentadas anteriormente, a aplicação do algoritmo PSO foi separada em três funções:

- Inicialização das partículas
- Atualização das partículas

- Execução do algoritmo

Estas funções serão abordadas nas próximas subseções.

3.3.1 Inicialização das partículas

Para a inicialização das partículas, foi utilizada a função ***inicializar_particulas***, que define os valores iniciais aleatórios das partículas e velocidades. O lugar geométrico possível das partículas também é definido nessa função:

- CT deve estar entre CT mínimo e CT máximo, definido na inicialização do código, conforme seção 3.2:

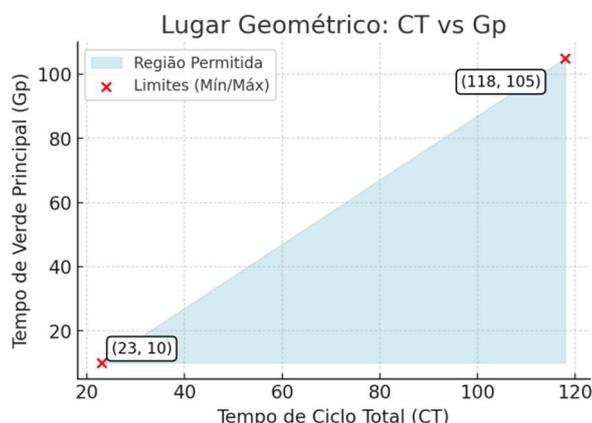
$$CT_{minimo} \leq CT \leq CT_{maximo} \quad (3.19)$$

- Gp deve ser maior que Gp mínimo e maior ou igual que o limite estabelecido pela equação (2.7):

$$Gp_{minimo} \leq Gp \leq CT - Gp_{minimo} - Y \quad (3.20)$$

Essas premissas também são aplicadas em Gt. O lugar geométrico está representado na Figura 8.

Figura 8 – Lugar geométrico de possíveis posições de partículas no algoritmo PSO.



Fonte: Autoria própria, 2025.

Dessa forma, o código construído para inicializar as partículas está apresentado na função ***inicializar_particulas***, disponível no **apêndice B**.

3.3.2 Atualização das partículas

De maneira análoga à seção 3.3.1, o lugar geométrico do algoritmo PSO para essa aplicação também deve ser o mesmo para todas as novas posições de partículas.

Assim, as equações apresentadas na seção 2.2 foram utilizadas em código na função de atualização de partículas, chamada ***atualizar_particulas***.

Esta função recebe como parâmetros:

- A lista de partículas da iteração anterior
- A matriz de velocidades da iteração anterior
- O melhor *fitness value* individual **pi** para cada iteração
- O melhor *fitness value* global **g** para cada iteração
- O número da iteração

E retorna:

- O vetor de partículas da atual iteração

- A matriz de velocidades da atual iteração

A função ***atualizar_particulas*** garantirá que todas as partículas sejam corretamente atualizadas ao longo de todas as iterações. A função está apresentada no código disponível no **apêndice B**.

3.3.3 Execução do algoritmo

Por fim, para obtenção dos resultados, a função *executar_pso* lê a base de dados e realiza a lógica de identificação dos cruzamentos com base na coluna “cruzamento”. A função também define as variáveis v_p e v_t , como os valores por horário de fluxo da base de dados inicial, considerando esses parâmetros como demanda de veículos naquele conjunto de via e horário.

A função, disponibilizada no **apêndice B**:

- Inicializa os parâmetros de melhores posições individual e global;
- Inicializa os melhores *fitness values*;
- itera sobre cada horário;
- atualiza os valores de g e p_i para cada partícula de acordo com a fundamentação teórica na seção 2.2
- chama corretamente e ordenadamente as funções *funcao_objetivo*, *inicializar_particulas* e *atualizar_particulas*.

A função *plotar_particulas*, apresentada também no código disponível no **apêndice B**, formata e plota o gráfico para serem exibidas posteriormente as posições das partículas no lugar geométrico definido previamente.

3.4 Ajustes finos dos resultados

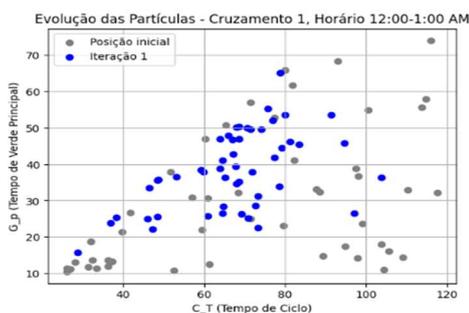
3.4.1 Ajustes dos parâmetros $c1$, $c2$ e número de partículas

Nesta fase de trabalho, serão observados os primeiros resultados da otimização PSO para a realização dos ajustes finos dos parâmetros. Conforme descrito na seção 3.2, os parâmetros da simulação 1 iniciais são:

- $c1 = 1,2$
- $c2 = 1,2$
- $\omega_{\text{inicial}} = 0,9$
- $\omega_{\text{final}} = 0,4$
- $\text{num_particulas} = 50$
- $\text{num_iterações} = 100$

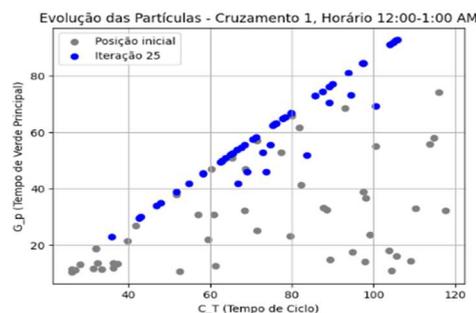
A partir da Figura 9.a, é possível observar os resultados da simulação 1 para um exemplo de cruzamento ao longo das iterações, no horário exemplo 00:00 a 01:00.

Figura 9.a – Iteração 1 do cruzamento 1 – simulação 1.



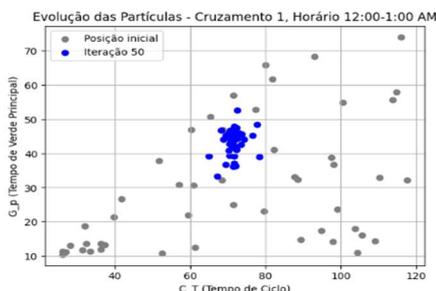
Fonte: Autoria própria, 2025.

Figura 9.b – Iteração 25 do cruzamento 1 – simulação 1.



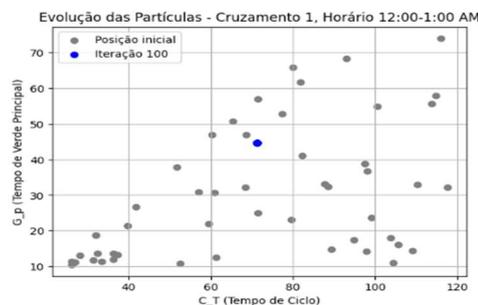
Fonte: Autoria própria, 2025.

Figura 9.c – Iteração 50 do cruzamento 1 – simulação 1.



Fonte: Autoria própria, 2025.

Figura 9.d – Iteração 100 do cruzamento 1 – simulação 1.



Fonte: Autoria própria, 2025.

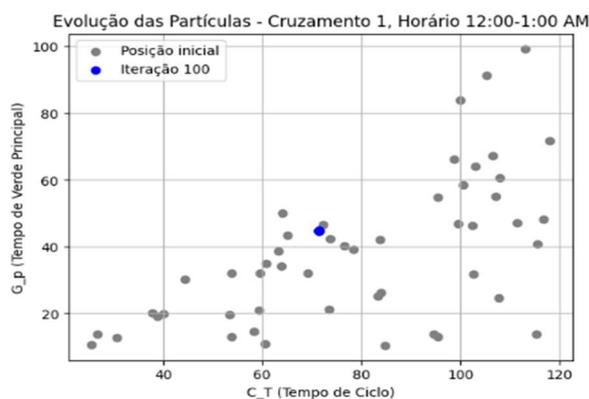
Uma estratégia que será utilizada neste documento é mostrar o exemplo de um cruzamento por simulação, para evitar um documento excessivamente extenso, facilitando também a análise das mudanças de parâmetros. Entretanto, também serão verificados os resultados dos demais cruzamentos para validação dos resultados.

Na primeira simulação, percebe-se que a convergência completa aconteceu de maneira adequada, pois todas as partículas convergiram para um único ponto, aproximadamente na posição $CT = 71$ s, e $G_p = 44$ s. A simulação foi repetida para confirmação da convergência e o resultado final foi o mesmo, conforme Figura 10.

É possível verificar que nas duas simulações, os resultados de CT e G_p foram os mesmos: indicativo de correta convergência para a posição de melhor *fitness value* dentro do lugar geométrico definido e uma escolha adequada de número de partículas, evitando pontos de máximo locais a favor do máximo global.

Além disso, há uma convergência das partículas com o passar das iterações em direção a um ponto ótimo, o que aponta o correto funcionamento da premissa de diminuição de ω ao longo das iterações. Tal critério será melhor avaliado na seção 3.4.2.

Figura 10 – Iteração 100 do cruzamento 1 – simulação 1 repetida.



Fonte: Autoria própria, 2025.

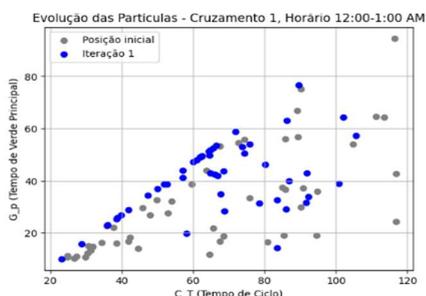
Ao longo das simulações, buscou-se tempos de resposta cada vez menores, visando à resposta mais rápida possível sem prejudicar os resultados favoráveis.

A primeira tentativa para isso verificou os efeitos do aumento dos parâmetros c_1 e c_2 , mantendo a igualdade entre eles. Esse efeito visa favorecer a experiência geral das partículas em detrimento da sua velocidade anterior. Assim, foi feito um ensaio com $c_1 = c_2 = 2,5$, sem alterar os demais parâmetros.

Essa tentativa não tende a resultar em tempos de simulação menores, mas o aumento dos coeficientes pode ser determinante na velocidade de convergência, com maiores velocidades. Caso essa hipótese se comprove, o número de iterações pode ser diminuído, gerando assim a melhora no tempo de resposta.

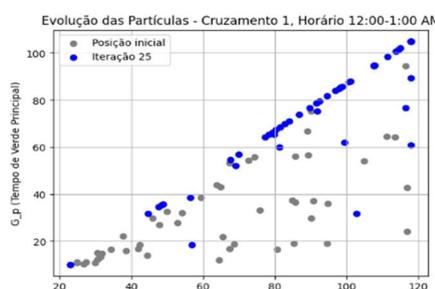
As respostas da simulação 2 podem ser verificadas a partir da Figura 11.a:

Figura 11.a – Iteração 1 do cruzamento 1 – simulação 2.



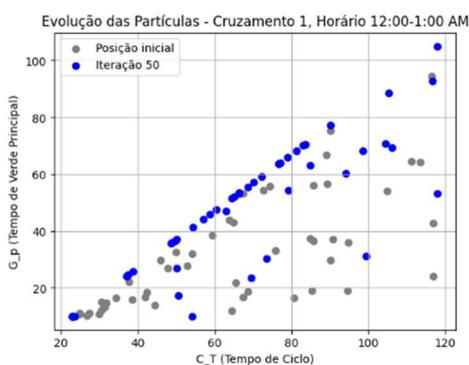
Fonte: Autoria própria, 2025.

Figura 11.b – Iteração 25 do cruzamento 1 – simulação 2.



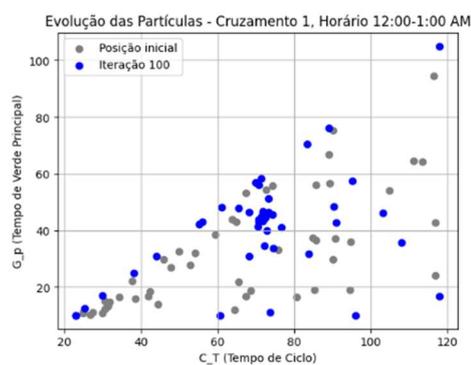
Fonte: Autoria própria, 2025.

Figura 11.c – Iteração 50 do cruzamento 1 – simulação 2.



Fonte: Autoria própria, 2025.

Figura 11.d – Iteração 100 do cruzamento 1 – simulação 2.



Fonte: Autoria própria, 2025.

A partir dos resultados exibidos da simulação 2, é notável a tendência da não convergência completa entre as partículas, fator que prejudica a procura precisa da posição de melhor *fitness value* ao redor do **gbest** (g), o que pode gerar resultados imprecisos.

Entretanto, é possível observar que uma boa quantidade de partículas converge para o mesmo ponto: os mesmos valores de CT e Gp observados na primeira iteração.

Comparando os resultados das duas simulações, percebe-se que os resultados da otimização são muito parecidos, apesar da convergência incompleta, o que indica que a segunda simulação também retorna resultados favoráveis. A dispersão das partículas pode gerar uma melhor exploração do lugar geométrico como um todo.

Apesar disso, em teoria, caso se diminua a quantidade de partículas, a simulação 2 apresenta um cenário mais desafiador para o PSO que o cenário da simulação 1, porque as partículas mais dispersas terão mais dificuldade em achar o ponto ótimo. Seus resultados são mostrados na Figura 12. Nas simulações 3 e 4, serão diminuídos o número de partículas igualmente para **30**, e serão mantidos os respectivos valores de c_1 e c_2 de cada simulação: **1,2** na simulação 3 e **2,5** na simulação 4.

A diminuição de partículas pode gerar um efeito negativo de exploração inefetiva do lugar geométrico, mas economiza tempo de resposta, como lado positivo. Os resultados das simulações 3 e 4 são mostrados a partir da Figura 13.a.

Figura 12 – Resultados do algoritmo PSO – simulação 2.

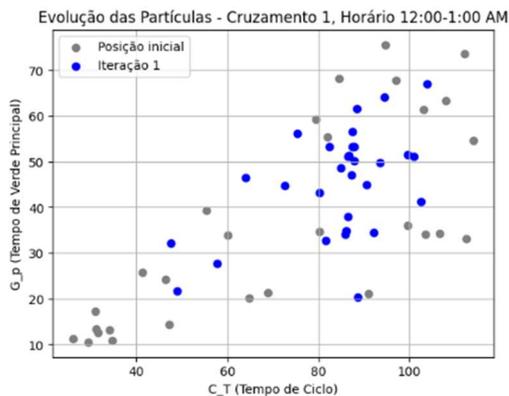
```
Otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'
Cruzamento Horário C_T G_p G_t Função Objetivo \
0 1 12:00-1:00 AM 71.3 44.6 23.8 943.9
1 1 1:00-2:00AM 95.5 46.5 46.0 780.7
2 1 2:00-3:00AM 86.0 73.0 10.0 795.8
3 1 3:00-4:00AM 113.6 100.6 10.0 969.7
4 1 4:00-5:00AM 118.0 105.0 10.0 1057.2
.. ... ..
67 3 7:00-8:00PM 118.0 10.0 105.0 904.3
68 3 8:00-9:00PM 118.0 10.0 105.0 904.3
69 3 9:00-10:00PM 118.0 10.0 105.0 904.0
70 3 10:00-11:00PM 118.0 10.0 105.0 828.7
71 3 11:00-12:00AM 118.0 10.0 105.0 655.1

Fluxo Total Tempo Médio de Atraso Total
0 538.8 133.6
1 429.6 78.6
2 444.1 92.5
3 536.3 103.0
4 571.8 86.4
.. ... ..
67 532.8 161.4
68 531.9 159.4
69 530.0 155.9
70 446.4 64.1
71 357.2 59.4

[72 rows x 8 columns]
```

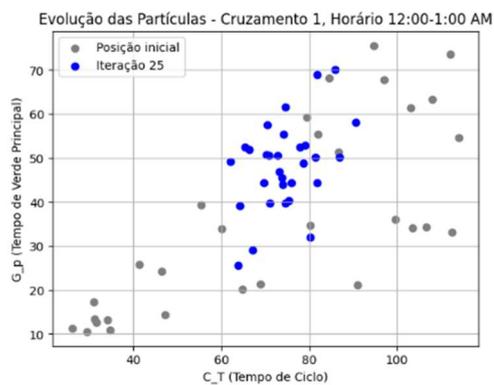
Fonte: Autoria própria, 2025.

Figura 13.a – Iteração 1 do cruzamento 1 – simulação 3.



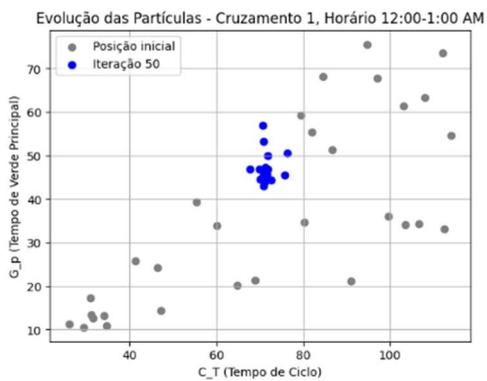
Fonte: Autoria própria, 2025.

Figura 13.b – Iteração 25 do cruzamento 1 – simulação 3.



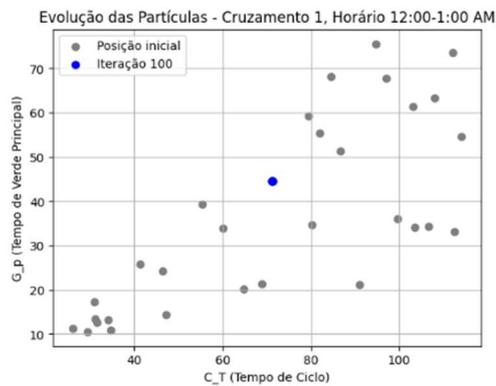
Fonte: Autoria própria, 2025.

Figura 13.c – Iteração 50 do cruzamento 1 – simulação 3.



Fonte: Autoria própria, 2025.

Figura 13.d – Iteração 100 do cruzamento 1 – simulação 3.



Fonte: Autoria própria, 2025.

Figura 14 – Resultados do algoritmo PSO – simulação 3.

Otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'

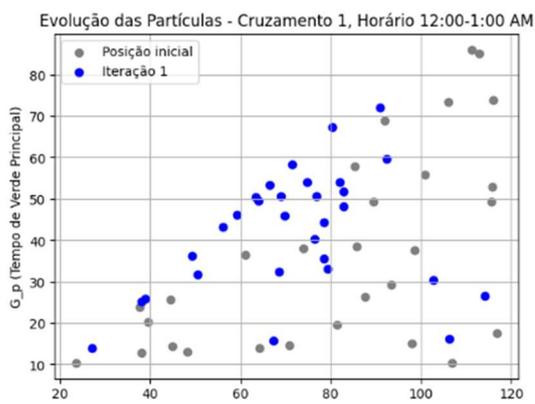
	Cruzamento	Horário	C_T	G_p	G_t	Função Objetivo \
0	1	12:00-1:00 AM	71.3	44.6	23.8	943.9
1	1	1:00-2:00AM	95.5	46.6	46.0	780.7
2	1	2:00-3:00AM	86.0	73.0	10.0	795.8
3	1	3:00-4:00AM	113.6	100.6	10.0	969.7
4	1	4:00-5:00AM	118.0	105.0	10.0	1057.2
..
67	3	7:00-8:00PM	118.0	10.0	105.0	904.3
68	3	8:00-9:00PM	118.0	10.0	105.0	904.3
69	3	9:00-10:00PM	118.0	10.0	105.0	904.0
70	3	10:00-11:00PM	118.0	10.0	105.0	828.7
71	3	11:00-12:00AM	118.0	10.0	105.0	655.1

	Fluxo Total	Tempo Médio de Atraso	Total
0	538.8		133.6
1	429.7		78.7
2	444.1		92.5
3	536.3		103.0
4	571.8		86.4
..
67	532.8		161.4
68	531.9		159.4
69	530.0		155.9
70	446.4		64.1
71	357.2		59.4

[72 rows x 8 columns]

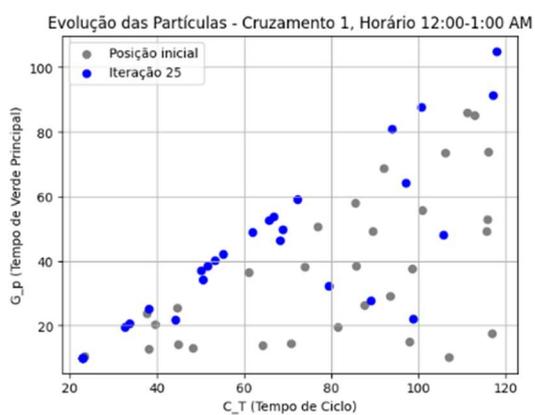
Fonte: Autoria própria, 2025.

Figura 15.a – Iteração 1 do cruzamento 1 – simulação 4.



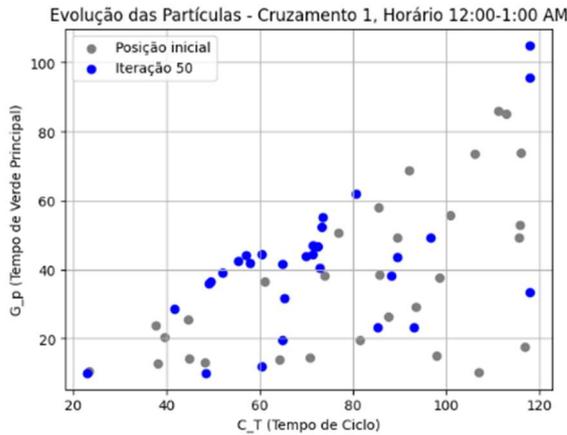
Fonte: Autoria própria, 2025.

Figura 15.b – Iteração 25 do cruzamento 1 – simulação 4.



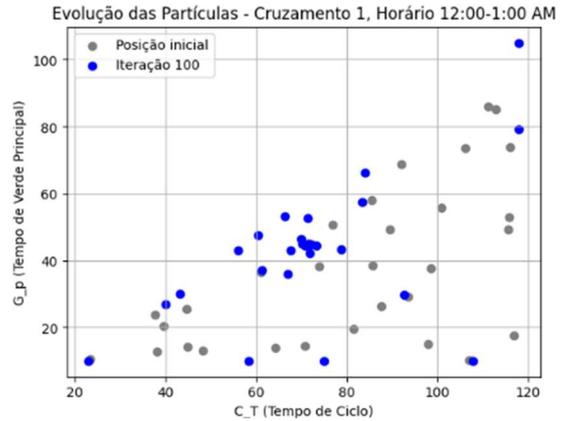
Fonte: Autoria própria, 2025.

Figura 15.c – Iteração 50 do cruzamento 1 – simulação 4.



Fonte: Autoria própria, 2025.

Figura 15.d – Iteração 100 do cruzamento 1 – simulação 4.



Fonte: Autoria própria, 2025.

Figura 16 – Resultados do algoritmo PSO – simulação 4.

```

otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'
Cruzamento Horário C_T G_p G_t Função Objetivo \
0 1 12:00-1:00 AM 71.3 44.6 23.7 943.9
1 1 1:00-2:00AM 95.5 46.6 46.0 780.7
2 1 2:00-3:00AM 85.9 72.9 10.0 795.8
3 1 3:00-4:00AM 113.6 100.6 10.0 969.7
4 1 4:00-5:00AM 118.0 105.0 10.0 1057.2
.. ... ..
67 3 7:00-8:00PM 118.0 10.0 105.0 904.3
68 3 8:00-9:00PM 118.0 10.0 105.0 904.3
69 3 9:00-10:00PM 118.0 10.0 105.0 904.0
70 3 10:00-11:00PM 118.0 10.0 105.0 828.7
71 3 11:00-12:00AM 118.0 10.0 105.0 655.1

Fluxo Total Tempo Médio de Atraso Total
0 538.8 133.6
1 429.7 78.7
2 444.1 92.4
3 536.3 103.0
4 571.8 86.4
.. ...
67 532.8 161.4
68 531.9 159.4
69 530.0 155.9
70 446.4 64.1
71 357.2 59.4

[72 rows x 8 columns]
    
```

Fonte: Autoria própria, 2025.

A partir dos resultados das simulações 3 e 4, os gráficos apresentados indicam conclusões parecidas com as simulações 1 e 2: simulação 1 converge completamente

e simulação 2 converge de maneira incompleta. Apesar do tempo de resposta menor, é notório que com **30 partículas**, existem muitas lacunas no lugar geométrico de possíveis soluções que indicam regiões inexploradas, como os gráficos da simulação 3, por exemplo (Figura 13.a), onde o espaço inferior direito da figura não foi explorado por partículas.

Portanto, para o prosseguimento deste trabalho, será descartada a diminuição de partículas e será mantido o valor `num_particulas = 50`. Quando o número de partículas diminuiu, a convergência também diminuiu na simulação 4 (Figura 16). Por exemplo, a simulação 4 demonstrou um resultado diferente de CT no cruzamento 1, de 01:00 até 02:00, em aproximadamente 1 segundo de diferença.

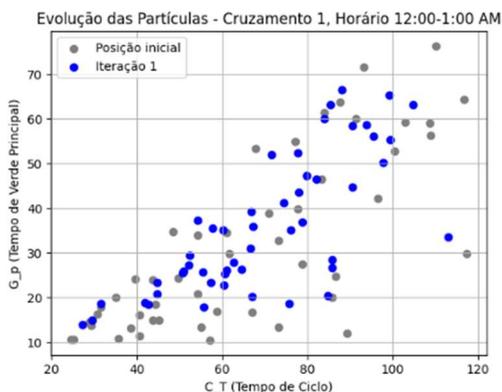
Dessa forma, as premissas da simulação 1 serão seguidas porque demonstraram mais estabilidade em relação à mudança do número de partículas que a simulação 2. Portanto, foram mantidos os valores:

- $c1 = c2 = 1,2$
- `num_particulas = 50`

A utilização de **50 partículas** demonstrou um bom resultado em tempo de resposta e preenchimento do lugar geométrico de possíveis soluções, respeitando o tempo de resposta de **23 segundos**, que é exatamente o valor mínimo de ciclo total de sinais. Portanto, em uma situação de aplicação, o algoritmo conseguiria obter uma resposta mais atualizada para todos os ciclos de sinais. Aumentar o número de partículas melhora a exploração do lugar geométrico em detrimento do tempo. Portanto, a **quantidade de partículas será mantida em 50**.

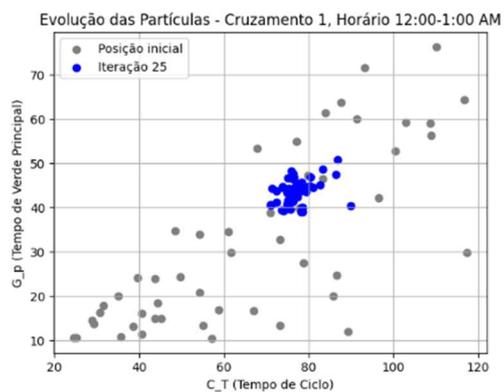
A última simulação desta seção será a verificação da diminuição dos coeficientes cognitivo e social. Com a diminuição desses parâmetros, o efeito inverso tende a acontecer: o valor da inércia ser dominante em relação à experiência. Portanto, a simulação 5 será apresentada a partir da Figura 17.a e mostrará o que acontece quando $c1 = c2 = 0,5$.

Figura 17.a – Iteração 1 do cruzamento 1 – simulação 5.



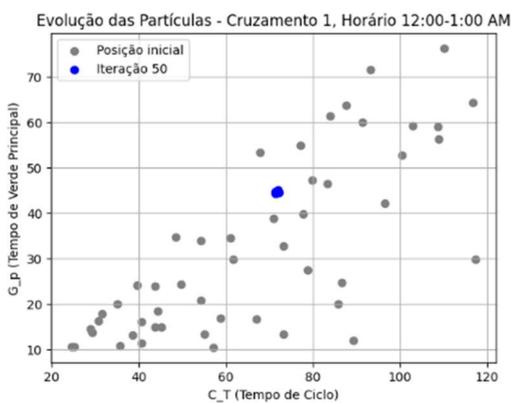
Fonte: Autoria própria, 2025.

Figura 17.b – Iteração 25 do cruzamento 1 – simulação 5.



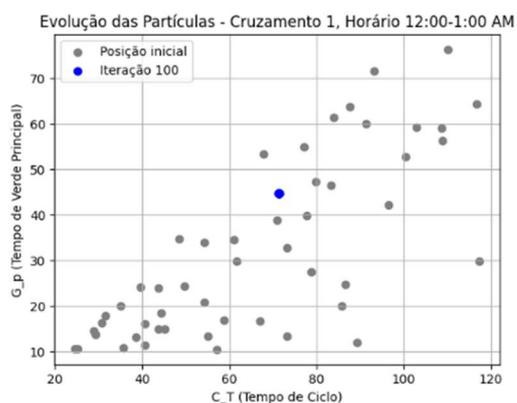
Fonte: Autoria própria, 2025.

Figura 17.c – Iteração 50 do cruzamento 1 – simulação 5.



Fonte: Autoria própria, 2025.

Figura 17.d – Iteração 100 do cruzamento 1 – simulação 5.



Fonte: Autoria própria, 2025.

Figura 18 – Resultados do algoritmo PSO – simulação 5.

```

Otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'
Cruzamento Horário C_T G_p G_t Função Objetivo \
0 1 12:00-1:00 AM 71.3 44.6 23.8 943.9
1 1 1:00-2:00AM 95.5 46.6 46.0 780.7
2 1 2:00-3:00AM 86.0 73.0 10.0 795.8
3 1 3:00-4:00AM 113.6 100.6 10.0 969.7
4 1 4:00-5:00AM 118.0 105.0 10.0 1057.2
.. ... ..
67 3 7:00-8:00PM 118.0 10.0 105.0 904.3
68 3 8:00-9:00PM 118.0 10.0 105.0 904.3
69 3 9:00-10:00PM 118.0 10.0 105.0 904.0
70 3 10:00-11:00PM 118.0 10.0 105.0 828.7
71 3 11:00-12:00AM 118.0 10.0 105.0 655.1

Fluxo Total Tempo Médio de Atraso Total
0 538.8 133.6
1 429.7 78.7
2 444.1 92.5
3 536.3 103.0
4 571.8 86.4
.. ...
67 532.8 161.4
68 531.9 159.4
69 530.0 155.9
70 446.4 64.1
71 357.2 59.4

```

Fonte: Autoria própria, 2025.

A simulação 5 demonstrou maior velocidade na convergência das partículas. é possível observar a igualdade operacional dos resultados, pois alguns apresentam diferenças apenas a partir da quarta casa decimal.

Dessa forma, a simulação 5 permitirá posteriormente uma retirada maior de quantidade de iterações que a simulação 1, economizando memória computacional e acelerando o tempo de resposta. Assim, os valores finais de c_1 , c_2 e $num_particulas$ serão:

- $c_1 = c_2 = 0,5$
- $num_particulas = 50$

3.4.2 Ajustes dos parâmetros ω e número de iterações

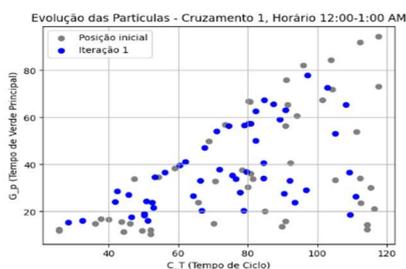
As próximas simulações analisam o comportamento do algoritmo com a variação do parâmetro inércia. Conforme mostrado na equação (2.16) e experimentado nas simulações 2 e 4 da seção 3.4.1, a diminuição de ω causará um efeito de divergência. Essa conclusão é obtida por dedução, pois nas simulações citadas, a proporção desbalanceada com inércia menor que coeficientes gerou um resultado de divergência entre os resultados, fator indesejado para o algoritmo PSO.

Portanto, a simulação 6 analisa o aumento dos parâmetros de inércias inicial e final. De acordo com a equação (2.16), o aumento de inércia indica uma maior

influência do valor da velocidade anterior da partícula, em relação à experiência obtida.

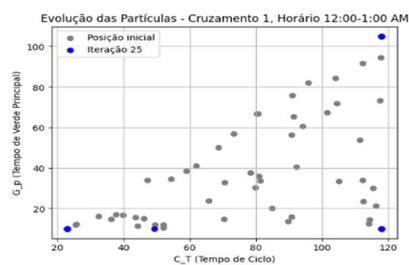
Dessa forma, são analisados os valores inicial e final **1,5** e **1,0**, mantendo a premissa de abaixar a inércia de acordo com a iteração conforme descrito na seção (3.18). Os resultados são mostrados a partir da Figura 19.a.

Figura 19.a – Iteração 1 do cruzamento 1 – simulação 6.



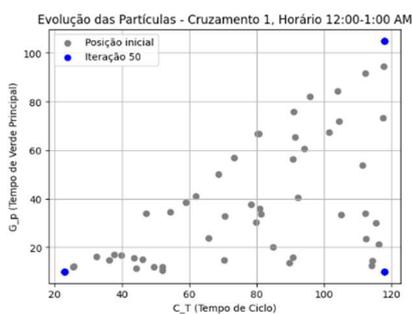
Fonte: Autoria própria, 2025.

Figura 19.b – Iteração 25 do cruzamento 1 – simulação 6.



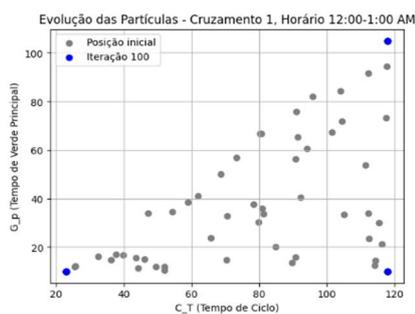
Fonte: Autoria própria, 2025.

Figura 19.c – Iteração 50 do cruzamento 1 – simulação 6.



Fonte: Autoria própria, 2025.

Figura 19.d – Iteração 100 do cruzamento 1 – simulação 6.



Fonte: Autoria própria, 2025.

Figura 20 – Resultados do algoritmo PSO – simulação 6.

```

Otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'
Cruzamento Horário C_T G_p G_t Função Objetivo \
0 1 12:00-1:00 AM 23.0 10.0 10.0 943.9
1 1 1:00-2:00AM 118.0 105.0 10.0 780.6
2 1 2:00-3:00AM 118.0 105.0 10.0 795.8
3 1 3:00-4:00AM 118.0 105.0 10.0 969.7
4 1 4:00-5:00AM 118.0 105.0 10.0 1057.2
.. ..
67 3 7:00-8:00PM 118.0 10.0 105.0 904.3
68 3 8:00-9:00PM 118.0 10.0 105.0 904.3
69 3 9:00-10:00PM 118.0 10.0 105.0 904.0
70 3 10:00-11:00PM 118.0 10.0 105.0 828.7
71 3 11:00-12:00AM 118.0 10.0 105.0 655.1

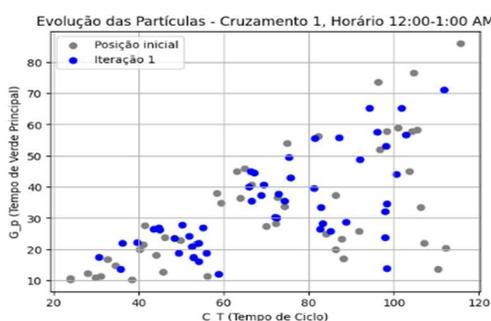
Fluxo Total Tempo Médio de Atraso Total
0 401.0 47.0
1 454.9 194.1
2 458.5 132.2
3 538.4 107.3
4 571.8 86.4
.. ..
67 532.8 161.4
68 531.9 159.4
69 530.0 155.9
70 446.4 64.1
71 357.2 59.4

```

Fonte: Autoria própria, 2025.

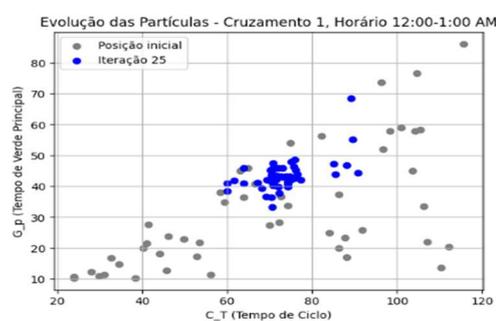
A partir da análise, é possível identificar a divergência entre as partículas. O aumento de inércia inicial é o grande causador desse comportamento, uma vez que as partículas partiram para longe do lugar geométrico aplicável antes de convergirem. A partir desse princípio, não é estratégico aumentar o valor de inércia inicial. Para análise de comportamento, as simulações 7 e 8 utilizam os valores **0,9** e **0,4**, respectivamente escolhidos inicialmente para as inércias final e inicial, como valores fixos da inércia, para verificação do comportamento do algoritmo PSO. Os resultados da simulação 7 são apresentados a partir da Figura 21.a, e os resultados da simulação 8 são apresentados a partir da Figura 23.a.

Figura 21.a – Iteração 1 do cruzamento 1 – simulação 7.



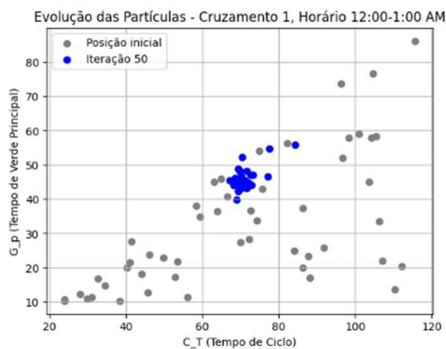
Fonte: Autoria própria, 2025.

Figura 21.b – Iteração 25 do cruzamento 1 – simulação 7.



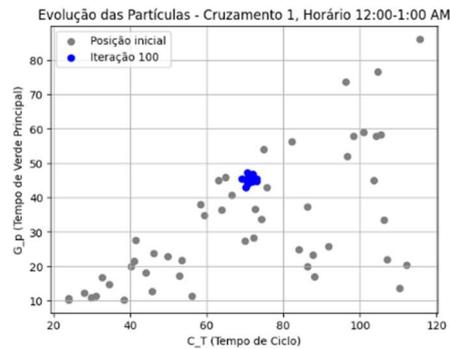
Fonte: Autoria própria, 2025.

Figura 21.c – Iteração 50 do cruzamento 1 – simulação 7.



Fonte: Autoria própria, 2025.

Figura 21.d – Iteração 100 do cruzamento 1 – simulação 7.



Fonte: Autoria própria, 2025.

Figura 22 – Resultados do algoritmo PSO – simulação 7.

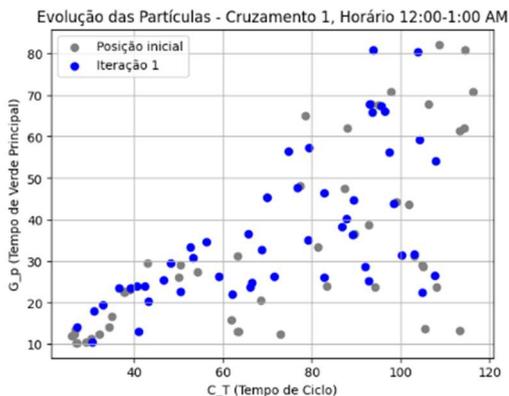
Otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'

	Cruzamento	Horário	C_T	G_p	G_t	Função	Objetivo \
0	1	12:00-1:00 AM	75.2	44.7	27.5		943.9
1	1	1:00-2:00AM	95.5	46.6	45.9		780.7
2	1	2:00-3:00AM	88.9	75.9	10.0		795.8
3	1	3:00-4:00AM	113.0	100.0	10.0		969.7
4	1	4:00-5:00AM	118.0	105.0	10.0		1057.2
..
67	3	7:00-8:00PM	118.0	10.0	105.0		904.3
68	3	8:00-9:00PM	118.0	10.0	105.0		904.3
69	3	9:00-10:00PM	118.0	10.0	105.0		904.0
70	3	10:00-11:00PM	118.0	10.0	105.0		828.7
71	3	11:00-12:00AM	118.0	10.0	105.0		655.1

	Fluxo Total	Tempo Médio de Atraso	Total
0	537.6		131.5
1	429.7		78.7
2	445.9		96.1
3	536.0		102.4
4	571.8		86.4
..
67	532.8		161.4
68	531.9		159.4
69	530.0		155.9
70	446.4		64.1
71	357.2		59.4

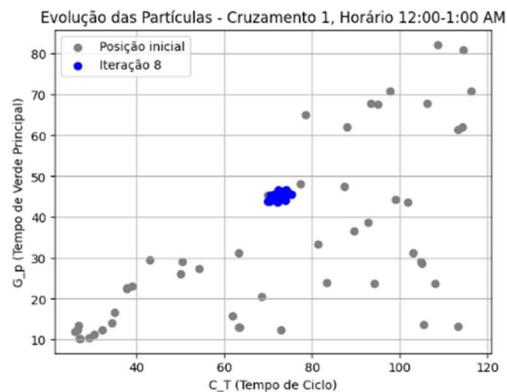
Fonte: Autoria própria, 2025.

Figura 23.a – Iteração 1 do cruzamento 1 – simulação 8.



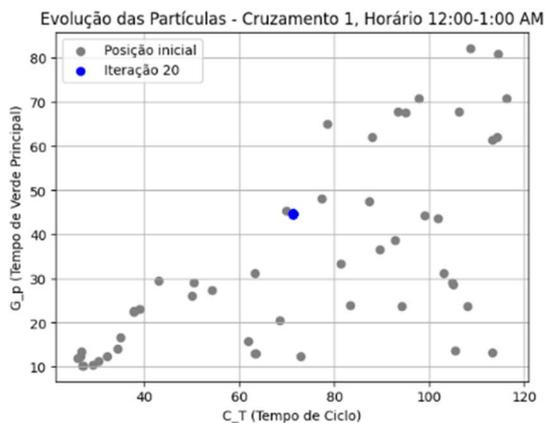
Fonte: Autoria própria, 2025.

Figura 23.b – Iteração 8 do cruzamento 1 – simulação 8.



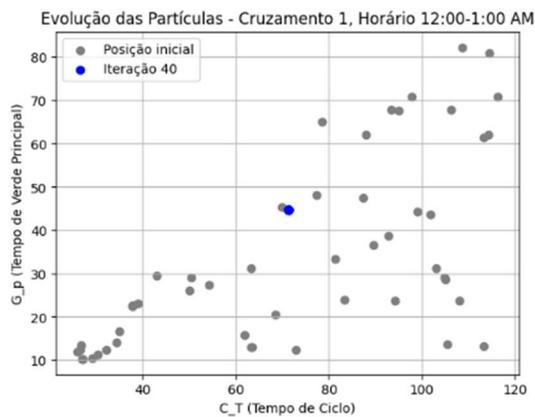
Fonte: Autoria própria, 2025.

Figura 23.c – Iteração 20 do cruzamento 1 – simulação 8.



Fonte: Autoria própria, 2025.

Figura 23.d – Iteração 40 do cruzamento 1 – simulação 8.



Fonte: Autoria própria, 2025.

Figura 24 – Resultados do algoritmo PSO – simulação 8.

Otimização concluída. Resultados salvos em 'Resultados_Otimização_PSO.csv'

	Cruzamento	Horário	C_T	G_p	G_t	Função Objetivo \
0	1	12:00-1:00 AM	71.3	44.6	23.8	943.9
1	1	1:00-2:00AM	95.5	46.6	46.0	780.7
2	1	2:00-3:00AM	86.0	73.0	10.0	795.8
3	1	3:00-4:00AM	93.8	80.8	10.0	965.4
4	1	4:00-5:00AM	118.0	105.0	10.0	1057.2
..
67	3	7:00-8:00PM	102.2	10.0	89.2	878.8
68	3	8:00-9:00PM	118.0	10.0	105.0	904.2
69	3	9:00-10:00PM	98.0	10.0	85.0	867.7
70	3	10:00-11:00PM	118.0	10.0	105.0	828.7
71	3	11:00-12:00AM	88.6	10.0	75.6	638.5

	Fluxo Total	Tempo Médio de Atraso	Total
0	538.8		133.6
1	429.7		78.7
2	444.1		92.5
3	524.4		83.3
4	571.8		86.4
..
67	522.4		166.0
68	531.8		159.4
69	515.7		163.6
70	446.4		64.1
71	341.4		44.3

Fonte: Autoria própria, 2025.

Conforme pode ser observado nos resultados das simulações 7 e 8, ambos os valores de inércia **0,9** e **0,4**, resultam em convergência das partículas para a posição de melhor *fitness value*.

Entretanto, a simulação 7 não converge completamente dentro das **100 iterações** e precisa de mais memória computacional para as partículas convergirem para o melhor valor. Isso acontece porque quando as partículas chegam perto do ponto ótimo, elas não conseguem desacelerar a tempo, por conta da inércia alta, fator que descarta esta solução.

Por outro lado, a simulação 8 obteve os melhores resultados em termos de precisão e velocidade de convergência das partículas. O cruzamento 1, mostrado na Figura , consegue convergir em aproximadamente **20 iterações** para o ponto ótimo. Dessa forma, como as posições de ponto ótimo foram mantidas, a inércia fixa de **0,4** será utilizada, o que contraria a hipótese anteriormente adotada na seção 3.2.2.

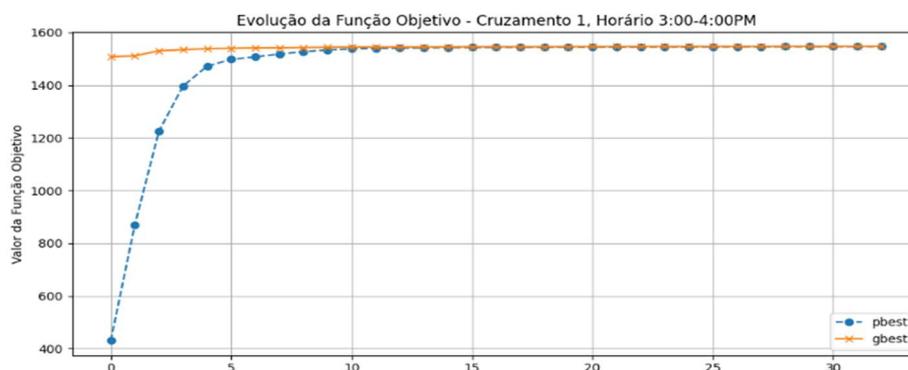
A nona e última simulação tem objetivo de minimizar o tempo de resposta a partir da diminuição da quantidade total de iterações. Para isso, foram feitas duas alterações no algoritmo:

- Inclusão de critério de parada: Agora, o algoritmo analisa a diferença entre os *gbests* entre uma iteração e outra. Se o valor absoluto da diferença for menor que **0,01**, o algoritmo sofre uma parada forçada, indicando que já convergiu;

- O algoritmo também analisa qual foi o cruzamento e horário que demorou mais iterações para ativar o critério de parada definido. Para esse cruzamento e horário, foi impresso um gráfico de **iteração x gbest**

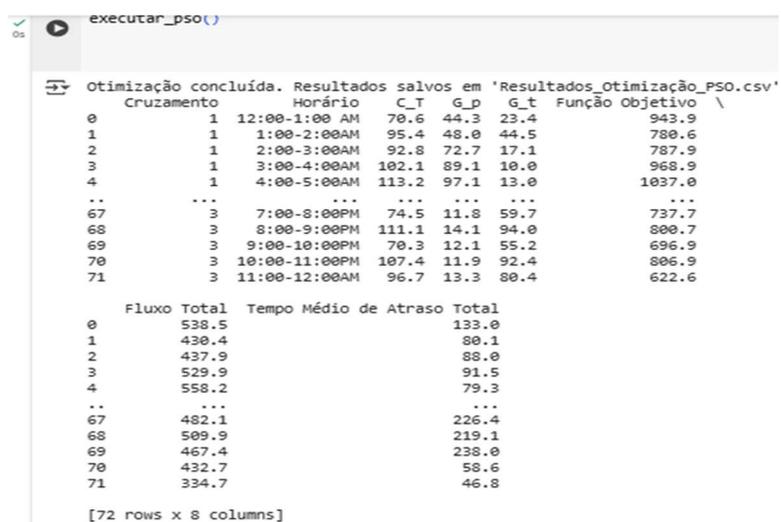
Enquanto o gráfico com maior quantidade de iterações obtida é mostrado na Figura 25, o resultado de tempo e funções objetivas é mostrado na Figura 26.

Figura 25 – Gráfico iteração x gbest – simulação 9.



Fonte: Autoria própria, 2025.

Figura 26 – Resultados obtidos – simulação 9.



Fonte: Autoria própria, 2025

Conforme apresentado nas Figuras 25 e 26, os 24 horários em 10 cruzamentos tiveram suas simulações concluídas em **menos de 1 segundo**, com a precisão dos resultados sendo mantida. As simulações anteriores demoravam entre 6 e 7 segundos. Dessa maneira, conclui-se que o número de **32 iterações** é suficiente para garantir o melhor valor de ciclos de sinais em todos os cruzamentos e horários. Assim, será escolhido para o algoritmo o valor máximo de **40 iterações**, para que haja uma garantia maior de convergência em todas as simulações.

Dessa maneira, os parâmetros do algoritmo PSO para simulação e análise dos valores finais de ciclos de sinais serão:

- $c1 = 0,5$
- $c2 = 0,5$
- $\omega = 0,4$
- $\text{num_particulas} = 50$
- $\text{num_iterações} = 40$, com parada forçada caso a diferença entre os gbests seja menor que 0,01 em uma iteração.

Todos os tempos de simulação foram obtidos com um computador com as seguintes configurações:

- CPU: Intel(R) Core(TM) i7-8565U CPU @ 1.80GHz
- Memória RAM: 8GB
- SSD: 256GB

3.4.3 Ajustes dos valores de α e β

O objetivo desta seção é avaliar os efeitos das mudanças dos parâmetros α e β nos resultados finais de fluxo total e tempo médio de atraso total. Para isso, a primeira simulação foi concluída com os valores $\alpha=2$ e $\beta=1$, e os resultados serão mostrados na Figura 27.a.

Em teoria, de acordo com a equação (2.12), os valores de α e β são responsáveis pela definição de importância e balanceamento nas respostas do código. Um α maior impõe mais peso ao fluxo total em detrimento do tempo médio de atraso, e vice-versa.

Dessa forma, será avaliada a aplicabilidade dessa teoria e seus efeitos nos tempos de ciclos de sinais.

A primeira mudança em código a ser feita é o aumento de β em relação α , o que deverá diminuir o tempo médio de atraso total (resultado desejado) e diminuir o fluxo total (resultado indesejado). Os resultados dessa simulação são apresentados na Figura 27.b, com $\alpha=2$ e $\beta=2$.

Teoricamente, os resultados da otimização devem se manter para valores de α e β proporcionais. Dessa maneira, serão avaliados os tempos de sinal verde e ciclo total de sinais para $\alpha=4$ e $\beta=4$. Os resultados dessa simulação são apresentados na Figura 27.c.

Por último, é avaliado o efeito da diminuição de β em relação α , o que deverá impactar no aumento do fluxo total (resultado desejado) e aumento do tempo médio de atraso (resultado indesejado). Os resultados dessa simulação são apresentados na Figura 27.d, com $\alpha=2$ e $\beta=0,5$.

Os resultados apresentados devem ser comparados aos valores existentes para verificação de qual combinação de pesos α e β resultará no melhor resultado em relação à melhoria dos resultados existentes.

Para todos os resultados, foram mostrados apenas os cruzamentos 1 e 2 como exemplos para funcionalidade do código.

Nas 27.a a 27.d, cujos valores podem ser melhor visualizados na Tabela 2, é possível verificar a coerência dos resultados de acordo com a teoria: com o aumento de β , houve uma melhora no tempo médio de atraso, e uma piora no fluxo total de veículos, assim como sua diminuição causou o efeito contrário.

Com α e β iguais, houve uma mudança nos resultados apenas no valor da função objetivo, que aumenta conforme o aumento dos dois. Entretanto, os parâmetros de otimização se mantiveram os mesmos, pois o peso relativo não mudou para as duas variáveis de otimização.

Figura 27.a – Resultados da otimização com $\alpha=2$ e $\beta=1$ – Cruzamentos 1 e 2.

Cruzamento	Horário	C_T	G_p	G_t	Função Objetivo	Fluxo Total	Tempo Médio de Atraso Total
1	12:00-1:00 AM	71.3	44.6	23.8	943.9	538.8	133.6
1	1:00-2:00AM	95.5	46.6	46.0	780.7	429.7	78.7
1	2:00-3:00AM	86.0	73.0	10.0	795.8	444.1	92.5
1	3:00-4:00AM	106.0	93.0	10.0	969.1	532.2	95.4
1	4:00-5:00AM	109.0	96.0	10.0	1053.5	566.4	79.3
1	5:00-6:00AM	88.5	75.5	10.0	1082.3	568.8	55.4
1	6:00-7:00AM	109.9	96.9	10.0	1177.2	626.6	76.0
1	7:00-8:00AM	94.4	81.4	10.0	1252.0	665.2	78.4
1	8:00-9:00AM	77.8	64.8	10.0	1362.9	719.6	76.3
1	9:00-10:00AM	93.4	80.4	10.0	1435.4	775.0	114.6
1	10:00-11:00AM	109.9	96.9	10.0	1315.0	729.0	143.1
1	11:00-12:00PM	107.3	94.3	10.0	1290.5	720.4	150.4
1	12:00-1:00PM	115.1	102.1	10.0	1377.6	765.0	152.3
1	1:00-2:00PM	110.5	97.5	10.0	1386.6	770.0	153.5
1	2:00-3:00PM	111.2	98.2	10.0	1551.4	855.0	158.6
1	3:00-4:00PM	117.7	104.7	10.0	1556.0	899.2	242.4
1	4:00-5:00PM	118.0	105.0	10.0	1562.1	898.6	235.2
1	5:00-6:00PM	118.0	105.0	10.0	1550.8	900.0	249.2
1	6:00-7:00PM	109.2	96.2	10.0	1522.2	893.9	265.7
1	7:00-8:00PM	94.1	81.1	10.0	1453.3	881.0	308.6
1	8:00-9:00PM	97.6	84.6	10.0	1374.7	888.5	402.3
1	9:00-10:00PM	87.4	74.4	10.0	1347.4	865.5	383.7
1	10:00-11:00PM	71.7	58.7	10.0	1129.4	652.0	174.6
1	11:00-12:00AM	84.8	31.9	49.9	914.8	513.6	112.5
2	12:00-1:00 AM	118.0	105.0	10.0	1191.4	631.5	71.5
2	1:00-2:00AM	105.2	92.2	10.0	819.3	437.8	56.2
2	2:00-3:00AM	95.1	82.1	10.0	578.6	312.8	47.0
2	3:00-4:00AM	117.5	104.5	10.0	449.4	253.8	58.2
2	4:00-5:00AM	90.4	77.4	10.0	552.6	298.5	44.4
2	5:00-6:00AM	118.0	105.0	10.0	804.4	433.6	62.7
2	6:00-7:00AM	99.0	86.0	10.0	1805.9	938.5	71.2
2	7:00-8:00AM	118.0	105.0	10.0	2952.9	1597.7	242.5
2	8:00-9:00AM	81.3	68.3	10.0	2772.1	1508.8	245.5
2	9:00-10:00AM	118.0	105.0	10.0	2764.9	1467.8	170.8
2	10:00-11:00AM	118.0	105.0	10.0	2637.9	1414.6	191.2
2	11:00-12:00PM	118.0	105.0	10.0	2753.9	1500.8	247.7
2	12:00-1:00PM	91.7	78.7	10.0	2689.3	1534.5	379.8
2	1:00-2:00PM	63.1	50.1	10.0	2025.4	1445.6	865.8
2	2:00-3:00PM	34.3	21.3	10.0	969.3	1152.9	1336.6
2	3:00-4:00PM	34.3	21.3	10.0	969.3	1152.9	1336.6
2	4:00-5:00PM	34.3	21.3	10.0	969.3	1152.9	1336.6
2	5:00-6:00PM	34.3	21.3	10.0	969.3	1152.9	1336.6
2	6:00-7:00PM	34.3	21.3	10.0	969.3	1152.9	1336.6
2	7:00-8:00PM	118.0	105.0	10.0	2794.9	1605.4	415.8
2	8:00-9:00PM	118.0	105.0	10.0	2727.8	1441.2	154.7
2	9:00-10:00PM	100.3	87.3	10.0	2202.0	1143.8	85.6
2	10:00-11:00PM	112.3	99.3	10.0	1812.1	947.7	83.2
2	11:00-12:00AM	109.5	96.5	10.0	1479.0	776.1	73.1

Fonte: Autoria própria, 2025.

Figura 27.b – Resultados da otimização com $\alpha=2$ e $\beta=2$ – Cruzamentos 1 e 2.

Cruzamento	Horário	C_T	G_p	G_t	Função Objetivo	Fluxo Total	Tempo Médio de Atraso Total
1	12:00-1:00 AM	58.7	27.5	28.2	839.0	507.0	87.5
1	1:00-2:00AM	69.9	29.6	37.4	714.9	414.5	57.0
1	2:00-3:00AM	61.8	48.8	10.0	720.7	423.4	63.1
1	3:00-4:00AM	81.4	68.4	10.0	885.5	513.9	71.1
1	4:00-5:00AM	99.3	86.3	10.0	975.6	559.5	71.7
1	5:00-6:00AM	109.4	96.4	10.0	1036.3	587.4	69.3
1	6:00-7:00AM	66.6	53.6	10.0	1056.6	573.7	45.3
1	7:00-8:00AM	81.0	68.0	10.0	1164.2	649.1	67.0
1	8:00-9:00AM	101.9	88.9	10.0	1302.5	750.7	99.5
1	9:00-10:00AM	92.2	79.2	10.0	1320.8	773.6	113.2
1	10:00-11:00AM	81.6	68.6	10.0	1193.2	700.6	104.0
1	11:00-12:00PM	77.2	64.2	10.0	1166.7	688.7	105.4
1	12:00-1:00PM	84.3	71.3	10.0	1249.5	734.6	109.8
1	1:00-2:00PM	82.6	69.6	10.0	1254.8	740.6	113.2
1	2:00-3:00PM	99.1	86.1	10.0	1396.6	842.6	144.3
1	3:00-4:00PM	117.0	104.0	10.0	1313.2	898.5	241.9
1	4:00-5:00PM	118.0	105.0	10.0	1326.9	898.6	235.2
1	5:00-6:00PM	118.0	105.0	10.0	1301.7	900.0	249.2
1	6:00-7:00PM	115.0	102.0	10.0	1257.6	899.3	270.5
1	7:00-8:00PM	95.1	82.1	10.0	1145.0	882.3	309.8
1	8:00-9:00PM	80.1	67.1	10.0	994.5	864.0	366.8
1	9:00-10:00PM	70.3	57.3	10.0	990.0	836.1	341.1
1	10:00-11:00PM	51.8	38.8	10.0	987.8	612.7	118.8
1	11:00-12:00AM	62.8	19.1	40.7	820.9	491.7	81.2
2	12:00-1:00 AM	117.3	104.3	10.0	1119.9	631.0	71.1
2	1:00-2:00AM	104.1	91.1	10.0	763.0	437.1	55.6
2	2:00-3:00AM	89.1	76.1	10.0	531.4	309.4	43.7
2	3:00-4:00AM	84.0	71.0	10.0	401.9	241.0	40.1
2	4:00-5:00AM	73.1	60.1	10.0	502.7	286.4	35.1
2	5:00-6:00AM	98.5	85.5	10.0	742.4	422.6	51.4
2	6:00-7:00AM	106.1	93.1	10.0	1743.0	948.3	76.8
2	7:00-8:00AM	116.0	103.0	10.0	2705.9	1594.3	241.3
2	8:00-9:00AM	99.4	86.4	10.0	2624.5	1561.7	249.5
2	9:00-10:00AM	112.5	99.5	10.0	2592.1	1459.0	162.9
2	10:00-11:00AM	104.5	91.5	10.0	2448.1	1392.2	168.1
2	11:00-12:00PM	101.0	88.0	10.0	2516.7	1470.1	211.8
2	12:00-1:00PM	82.1	69.1	10.0	2290.4	1505.7	360.5
2	1:00-2:00PM	49.2	36.2	10.0	1247.7	1345.0	721.2
2	2:00-3:00PM	27.1	14.1	10.0	-214.8	980.0	1087.4
2	3:00-4:00PM	27.1	14.1	10.0	-214.8	980.0	1087.4
2	4:00-5:00PM	27.1	14.1	10.0	-214.8	980.0	1087.4
2	5:00-6:00PM	27.1	14.1	10.0	-214.8	980.0	1087.4
2	6:00-7:00PM	27.1	14.1	10.0	-214.8	980.0	1087.4
2	7:00-8:00PM	95.5	82.5	10.0	2382.4	1559.6	368.4
2	8:00-9:00PM	86.7	73.7	10.0	2524.4	1376.3	114.1
2	9:00-10:00PM	117.3	104.3	10.0	2135.6	1169.0	101.2
2	10:00-11:00PM	111.3	98.3	10.0	1728.2	946.5	82.4
2	11:00-12:00AM	98.5	85.5	10.0	1398.2	764.2	65.1

Fonte: Autoria própria, 2025.

Figura 27.c – Resultados da otimização com $\alpha=4$ e $\beta=4$ – Cruzamentos 1 e 2.

Cruzamento	Horário	C_T	G_p	G_t	Função Objetivo	Fluxo Total	Tempo Médio de Atraso Total
1	12:00-1:00 AM	58.7	27.5	28.2	1677.9	507.0	87.5
1	1:00-2:00AM	69.9	29.6	37.4	1429.7	414.5	57.0
1	2:00-3:00AM	61.8	48.8	10.0	1441.3	423.4	63.1
1	3:00-4:00AM	81.4	68.4	10.0	1770.9	513.9	71.1
1	4:00-5:00AM	88.9	75.9	10.0	1947.3	550.5	63.7
1	5:00-6:00AM	90.7	77.7	10.0	2057.6	571.2	56.8
1	6:00-7:00AM	86.0	73.0	10.0	2180.8	604.0	58.8
1	7:00-8:00AM	102.5	89.5	10.0	2349.6	673.0	85.6
1	8:00-9:00AM	83.6	70.6	10.0	2587.9	728.7	81.7
1	9:00-10:00AM	87.1	74.1	10.0	2640.1	767.0	107.0
1	10:00-11:00AM	81.6	68.6	10.0	2386.3	700.6	104.0
1	11:00-12:00PM	77.2	64.2	10.0	2333.4	688.7	105.4
1	12:00-1:00PM	84.3	71.3	10.0	2499.0	734.6	109.8
1	1:00-2:00PM	82.6	69.6	10.0	2509.7	740.6	113.2
1	2:00-3:00PM	87.8	74.8	10.0	2785.1	828.0	131.7
1	3:00-4:00PM	93.5	80.5	10.0	2562.1	873.1	232.6
1	4:00-5:00PM	62.9	49.9	10.0	2262.2	809.8	244.2
1	5:00-6:00PM	92.2	79.2	10.0	2538.4	871.9	237.4
1	6:00-7:00PM	94.5	81.5	10.0	2484.4	877.5	256.4
1	7:00-8:00PM	85.2	72.2	10.0	2274.5	868.5	299.9
1	8:00-9:00PM	80.1	67.1	10.0	1988.9	864.0	366.8
1	9:00-10:00PM	70.3	57.3	10.0	1980.0	836.1	341.1
1	10:00-11:00PM	51.8	38.8	10.0	1975.6	612.7	118.8
1	11:00-12:00AM	62.8	19.1	40.7	1641.9	491.7	81.2
2	12:00-1:00 AM	101.8	88.8	10.0	2232.2	618.8	60.8
2	1:00-2:00AM	91.4	78.4	10.0	1520.5	428.2	48.1
2	2:00-3:00AM	94.1	81.1	10.0	1063.4	312.2	46.4
2	3:00-4:00AM	84.0	71.0	10.0	803.8	241.0	40.1
2	4:00-5:00AM	91.9	78.9	10.0	1016.5	299.4	45.3
2	5:00-6:00AM	90.6	77.6	10.0	1479.9	416.8	46.8
2	6:00-7:00AM	113.6	100.6	10.0	3498.2	957.3	82.7
2	7:00-8:00AM	118.0	105.0	10.0	5420.7	1597.7	242.5
2	8:00-9:00AM	94.7	81.7	10.0	5209.7	1549.9	247.5
2	9:00-10:00AM	97.5	84.5	10.0	5152.0	1429.6	141.6
2	10:00-11:00AM	108.4	95.4	10.0	4897.8	1399.3	174.9
2	11:00-12:00PM	101.4	88.4	10.0	5033.5	1471.0	212.6
2	12:00-1:00PM	83.6	70.6	10.0	4589.3	1510.6	363.3
2	1:00-2:00PM	49.2	36.2	10.0	2495.4	1345.0	721.2
2	2:00-3:00PM	27.1	14.1	10.0	-429.6	980.0	1087.4
2	3:00-4:00PM	27.1	14.1	10.0	-429.6	980.0	1087.4
2	4:00-5:00PM	27.1	14.1	10.0	-429.6	980.0	1087.4
2	5:00-6:00PM	27.1	14.1	10.0	-429.6	980.0	1087.4
2	6:00-7:00PM	27.1	14.1	10.0	-429.6	980.0	1087.4
2	7:00-8:00PM	95.5	82.5	10.0	4764.6	1559.5	368.3
2	8:00-9:00PM	80.7	67.7	10.0	5005.5	1358.0	106.6
2	9:00-10:00PM	103.1	90.1	10.0	4241.4	1148.5	88.1
2	10:00-11:00PM	103.0	90.0	10.0	3442.1	936.3	75.7
2	11:00-12:00AM	96.4	83.4	10.0	2792.3	761.6	63.6

Fonte: Autoria própria, 2025.

Figura 27.d – Resultados da otimização com $\alpha=2$ e $\beta=0,5$ – Cruzamentos 1 e 2.

Cruzamento	Horário	C_T	G_p	G_t	Função Objetivo	Fluxo Total	Tempo Médio de Atraso Total
1	12:00-1:00 AM	81.4	68.4	10.0	1031.7	573.2	229.6
1	1:00-2:00AM	118.0	70.7	44.3	827.0	441.3	111.2
1	2:00-3:00AM	115.8	102.8	10.0	850.8	457.8	129.5
1	3:00-4:00AM	100.2	87.2	10.0	1012.7	528.8	89.7
1	4:00-5:00AM	118.0	105.0	10.0	1100.4	571.8	86.4
1	5:00-6:00AM	97.6	84.6	10.0	1125.2	577.9	61.4
1	6:00-7:00AM	118.0	105.0	10.0	1223.4	632.2	81.9
1	7:00-8:00AM	118.0	105.0	10.0	1319.9	684.8	99.3
1	8:00-9:00AM	85.2	72.2	10.0	1420.3	731.0	83.2
1	9:00-10:00AM	106.0	93.0	10.0	1511.1	788.0	130.0
1	10:00-11:00AM	108.2	95.2	10.0	1385.1	727.7	140.7
1	11:00-12:00PM	115.5	102.5	10.0	1371.0	726.2	162.9
1	12:00-1:00PM	113.3	100.3	10.0	1452.4	763.6	149.8
1	1:00-2:00PM	114.6	101.6	10.0	1466.5	773.1	159.4
1	2:00-3:00PM	95.1	82.1	10.0	1605.9	837.9	139.8
1	3:00-4:00PM	111.2	98.2	10.0	1667.1	893.2	238.6
1	4:00-5:00PM	108.8	95.8	10.0	1664.7	890.0	230.7
1	5:00-6:00PM	86.3	73.3	10.0	1608.1	863.3	236.9
1	6:00-7:00PM	118.0	105.0	10.0	1667.1	901.8	273.2
1	7:00-8:00PM	104.3	91.3	10.0	1624.7	892.7	321.3
1	8:00-9:00PM	118.0	105.0	10.0	1588.9	907.7	453.0
1	9:00-10:00PM	92.9	79.9	10.0	1545.8	872.7	399.3
1	10:00-11:00PM	100.4	87.4	10.0	1233.7	681.1	257.0
1	11:00-12:00AM	108.5	52.7	52.8	981.7	532.7	167.3
2	12:00-1:00 AM	105.7	92.7	10.0	1212.7	622.2	63.3
2	1:00-2:00AM	112.4	99.4	10.0	853.4	441.8	60.5
2	2:00-3:00AM	116.5	103.5	10.0	615.0	322.2	58.9
2	3:00-4:00AM	115.4	102.4	10.0	478.0	253.3	57.1
2	4:00-5:00AM	110.3	97.3	10.0	588.0	307.9	55.5
2	5:00-6:00AM	107.9	94.9	10.0	828.3	428.4	56.8
2	6:00-7:00AM	112.7	99.7	10.0	1871.6	956.3	82.0
2	7:00-8:00AM	114.4	101.4	10.0	3062.6	1591.4	240.4
2	8:00-9:00AM	110.9	97.9	10.0	3044.8	1586.4	256.3
2	9:00-10:00AM	114.1	101.1	10.0	2840.7	1461.7	165.2
2	10:00-11:00AM	117.3	104.3	10.0	2732.0	1413.5	189.9
2	11:00-12:00PM	113.3	100.3	10.0	2867.7	1493.3	237.8
2	12:00-1:00PM	117.7	104.7	10.0	2956.2	1588.9	443.1
2	1:00-2:00PM	84.3	71.3	10.0	2509.3	1534.8	1120.6
2	2:00-3:00PM	45.4	32.4	10.0	1727.9	1311.5	1790.1
2	3:00-4:00PM	45.4	32.4	10.0	1727.9	1311.5	1790.1
2	4:00-5:00PM	45.4	32.4	10.0	1727.9	1311.5	1790.1
2	5:00-6:00PM	45.4	32.4	10.0	1727.9	1311.5	1790.1
2	6:00-7:00PM	45.4	32.4	10.0	1727.9	1311.5	1790.1
2	7:00-8:00PM	110.6	97.6	10.0	2985.2	1592.4	399.2
2	8:00-9:00PM	98.2	85.2	10.0	2745.5	1405.0	128.7
2	9:00-10:00PM	107.8	94.8	10.0	2265.5	1155.9	92.4
2	10:00-11:00PM	109.8	96.8	10.0	1849.0	944.8	81.2
2	11:00-12:00AM	118.0	105.0	10.0	1527.6	783.6	79.4

Fonte: Autoria própria, 2025.

Tabela 2 – Resultados de simulações de α e β – Cruzamento 1, 12:00AM – 01:00AM.

α	β	CT (s)	Gp (s)	Gt (s)	qT (veíc./h)	WT (s)
2	1	71,3	44,6	23,8	538,8	133,6
2	2	58,7	27,5	28,2	507,0	87,5
4	4	58,7	27,5	28,2	507,0	87,5
2	0,5	81,4	68,4	10,0	573,2	229,6

Fonte: Autoria própria, 2025.

3.5 Comparação de resultados com parâmetros atuais

Após a conclusão das premissas do algoritmo PSO, foi feita uma tentativa de operação inversa com os valores de fluxo existentes para tentativa de simulação de tempos de ciclo de sinais existentes nos cruzamentos escolhidos para análise.

Em teoria, adotadas as devidas premissas, os dados de fluxo por horário são suficientes para esta simulação, e são os únicos dados que a base de dados disponibiliza. De acordo com as equações (2.13) a (2.15), os cálculos teóricos de tempo de ciclo total e tempo de sinal verde podem ser obtidos com os dados de tempo perdido, demanda de veículos e capacidade da via. Para verificação da aplicabilidade dessas fórmulas, foi definida uma base de dados com todos os valores de Gp e CT teóricos calculados. Os resultados da Figura 28 indicam alguns valores da base de dados de saída do código disponível no **apêndice C**.

Figura 28 – Resultados de Gp e CT teóricos após a operação inversa.

G_p_teorico	C_T_teorico
48	118
45	118
50	118
60	118
70	118
75	113
75	118
70	118
69	118
66	118
62	118
61	118
63	118
63	118
67	118
70	118
73	118
73	118
70	118
67	118
65	118
59	118
53	118
46	118
5	14

2	9
1	7
1	6
1	7
2	8
318	529
68	118
67	118
64	118
62	118
61	118
60	118
58	118
57	118
59	118
58	118
58	118
60	118
62	118
65	118
68	118
895	15
14	29
4	13
2	8
1	7

Fonte: Autoria própria, 2025.

Esses resultados não são satisfatórios, pois valores como $G_p < 5 \text{ s}$ e $CT > 500 \text{ s}$ indicam valores irrealistas na prática para ciclos de sinais. Um dos valores inclusive indica um tempo de sinal verde igual a **895 segundos** enquanto o tempo de ciclo total é **15 segundos**, o que é impossível.

Esses resultados impossibilitam a continuação da verificação a partir da base de dados de entrada escolhida para o presente projeto, pois não foi possível analisar o comportamento dos tempos de ciclo de sinais disponível a partir apenas dos dados de fluxo.

Duas possíveis causas são consideradas a partir dos resultados inconsistentes:

- Os valores tomados como premissas de demanda (v_p e v_t) e saturação (s_p e s_t) não condizem com a realidade;
- As fórmulas presentes nas equações (2.13) a (2.15) são incoerentes ou não aplicáveis ao escopo apresentado neste trabalho.

Por fim, o código final foi atualizado após as mudanças ao longo das seções 3.2, 3.3 e 3.4 para obtenção de resultados finais, presentes na seção 3.4.3. O código final está disponível no **apêndice B** com todos os parâmetros atualizados.

O trecho de geração de gráficos foi comentado como *docstring*, para observação do tempo de resposta.

Os valores ideais de α e β são inconclusivos, por conta da falta de referência de valores reais atuais de fluxos e tempos médios de atraso totais, fator que impossibilita uma correta referência desses pesos.

4 CONCLUSÕES E PROPOSTAS DE CONTINUIDADE

A partir do desenvolvimento do trabalho, observa-se que o modelo de otimização por enxame de partículas pode ser utilizado para controle de sinais de trânsito, e que o modelo desenvolvido para o estudo reproduz as fórmulas teóricas de tráfego corretamente de acordo com as devidas referências científicas. O tempo de execução do algoritmo de menos de 1 segundo foi obtido em uma simulação com 3 cruzamentos. Isso indica que mais cruzamentos poderiam ser adicionados na base de entrada, e, ainda assim, o tempo de execução duraria menos que um período de ciclo total, em uma análise feita sem interdependência entre os cruzamentos. Esse fator é importantíssimo para um controle em tempo real, visto que a cada ciclo de sinais, o tempo de resposta do algoritmo o permite ser atualizado, e o próximo ciclo já otimizado de acordo com a demanda atual de tráfego, o que possibilita um controle em tempo real dos ciclos semaforicos.

Entretanto, essa conclusão é apenas baseada em referências teóricas, pois no presente trabalho, não foi possível verificar os resultados na prática pela incoerência dos resultados ao aplicarem-se as equações (2.13) a (2.15).

Ao longo do trabalho, não foi possível realizar a verificação com os dados disponibilizados pela base de dados de trânsito de Nova York, porque os únicos dados disponibilizados foram os fluxos de veículos para cada horário. Para uma análise mais precisa, seriam necessários os dados em operação atual de CT , G_p , G_t e Y por cruzamento, além de valores estabelecidos ao longo do trabalho, como v_p , v_t , s_p e s_t . Dessa forma, seria possível uma verificação teórica mais robusta e confiável, além dos testes práticos para confiabilidade de melhora a partir do algoritmo desenvolvido.

Uma tentativa para superar essas dificuldades foi o cálculo de G_p e CT teóricos por operação inversa de acordo com as equações (2.13) a (2.15). A partir desses valores, seria possível calcular os atuais fluxos totais e tempos médios de atraso dos cruzamentos viários por horário e simular uma comparação, mas conforme evidenciado na Figura 28, os resultados obtidos são operacionalmente inviáveis.

Outro fator de influência no trânsito é que não foi considerada no presente trabalho a influência que um cruzamento pode ter em outros, pois as filas geradas em um ciclo de sinal vermelho podem afetar o cruzamento anterior. A base de dados

utilizada não oferece opções explícitas de cruzamentos, tampouco cruzamentos adjacentes, o que impossibilita a análise coletiva.

Apesar das dificuldades encontradas por limitação de dados, os resultados do comportamento do algoritmo PSO evidenciam a coerência dos valores diante dos parâmetros adotados e referências citadas, de modo que o algoritmo possa servir como base para futuras pesquisas, com dados mais completos. Os resultados da simulação 8 da seção 3.4.2, por exemplo, evidenciam o bom comportamento de convergência do enxame de partículas, além da velocidade de processamento.

Dessa maneira, o código final, apresentado no **apêndice B**, está pronto para futuros refinamentos das variáveis citadas neste trabalho, para que seus resultados possam ser comparados com situações reais, e posteriormente praticados com um real cruzamento. O código necessita apenas de uma melhor alimentação de dados.

Portanto, o presente trabalho propõe sua continuidade com um estudo estatístico para coleta de dados de:

- Cruzamentos
- Fluxos de veículos na rua A de cada horário e cruzamento
- Fluxos de veículos na rua B de cada horário e cruzamento
- Tempo de verde de ambas as ruas
- Tempo de sinal amarelo de ambas as ruas
- Tempos de sinal vermelho em ambas as ruas
- Demanda de veículos por horário e cruzamento
- Capacidade de veículos em ambas as ruas.

Com esses dados concretos, o algoritmo será alimentado com variáveis reais, obtendo mais confiabilidade nas suas respostas.

A partir desses dados coletados e estudo dos dados aplicados no presente algoritmo, é proposto um experimento no mesmo cruzamento, sendo abastecido pelos novos dados de entrada, e aplicando o ciclo de sinais, analisando os resultados antes e depois de sua implementação.

Caso o experimento seja bem sucedido, o estudo pode ser ampliado para uma quantidade maior de cruzamentos para aprimoramento do código de modo que considere corretamente o efeito coletivo da mudança de ciclos de sinais, representando cada vez melhor a realidade atual.

REFERÊNCIAS

- ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. Medição de resistência de aterramento e de potenciais na superfície do solo em sistemas de aterramento. **ABNT NBR 15749**, p. 49, set. 2009.
- ALMEIDA, Daniella D.; BATISTA, Tatiana F. M. Tratamento de interferência com Sinalização Semafórica, Caso da Rodovia ES-010 em Serra-ES, 2022.
- BARONI, Rafael B. Metodologia para controle de semáforos utilizando processamento de imagens para reconhecimento da quantidade de carros, 2018.
- CBN RECIFE. CBN Recife, 2024. Disponível em: <<https://www.cbnrecife.com/artigo/com-investimento-de-r-1-07-milhao-primeiros-semaforos-inteligentes-passam-a-operar-no-recife>>. Acesso em: 06 mar. 2025.
- COLNAGO, Glauber R. Otimização semafórica de cruzamentos da cidade de Santos-SP: Redução de atrasos e grau de saturação, Cubatão, 2017.
- GONÇALVES, Cristiane C. et al. Análise de desempenho de uma interseção semaforizada da cidade de Jacareí no estado de São Paulo por meio do software Sidra Intersection utilizando o método do Highway Capacity Manual 2010, 2021.
- GOOGLE. **Google maps**. Disponível em: <<https://www.google.com.br/maps/place/Dorothy+Zeidman+at+The+Corcoran+Group/@40.7231904,-73.9990161,20z/data=!3m1!5s0x89c2598e7ed4d5dd:0xdc5e1d7a7e8afe9b!4m15!1m8!3m7!1s0x89c2598c74796b0b:0x5e7aba8d9d7e19fd!2sSpring+St,+New+York,+NY,+EUA!3b1!8m2!3d40.72436>>. Acesso em: 05 mar. 2025.
- GOOGLE. **Google Collaboratory**, 2024. Disponível em: <<https://colab.research.google.com/>>. Acesso em: 15 jan. 2025.
- KARIM, AASAM A.; ISA, NOR A. M.; LIM, WEI H. **Hovering Swarm Particle Swarm Optimization**. [S.l.]: [s.n.]. 2021.
- KENNEDY, J.; EBERHART, R. **Particle swarm optimization**. [S.l.]: [s.n.]. 1995.
- LOPES, BRENO C.; GIUBERTI, HEITOR. **APLICAÇÃO DAS TÉCNICAS DE ENGENHARIA DE TRÁFEGO PARA ANÁLISE E MELHORIA DE UMA INTERSEÇÃO SEMAFORIZADA**. [S.l.]: [s.n.]. 2011.
- M.B. PEREIRA, D.L. P. **Simulação e Otimização de Sistemas de Sinalização**. Lavras – MG – Brasil: [s.n.]. 2017.
- MATOS, Saulo A. D. L. **Sincronização de Semáforos como um Problema de Otimização com Muitos Objetivos**. [S.l.]: [s.n.]. 2017.
- MEI, Lin. **Intelligent Traffic Light Based on PLC Control**. [S.l.]: [s.n.]. 2017.
- NYC OPEN DATA. **NYC open data**, 2022. Disponível em: <https://data.cityofnewyork.us/Transportation/Traffic-Volume-Counts/btm5-ppia/about_data>. Acesso em: 15 jan. 2025.
- REPÚBLICA FEDERATIVA DO BRASIL. **Código de Trânsito Brasileiro**. [S.l.]: [s.n.]. 1997.
- RIBEIRO, Eliéser D. F. Medium. **medium.com**, 2024. Disponível em: <https://medium.com/%40elieser_ribeiro/a-pot%C3%Aancia-dos-dados-para-a-intelig%C3%Aancia-artificial-703f1c05750f>. Acesso em: 04 mar. 2025.
- SEPEHR, Pouya. **Mundane Urban Governance and AI Oversight**. [S.l.]: [s.n.]. 2024.

SILVA, Paulo C. M. D. **TEORIA DO FLUXO DE TRÁFEGO**. [S.l.]: [s.n.]. 1994.

STOILOVA, Krasimira. **Bi-Level Optimization Model for Urban Traffic Control**. [S.l.]: [s.n.]. 2021.

TRANSPORTATION RESEARCH BOARD ; BUREAU OF PUBLIC ROADS. **Highway Capacity Manual**.

WEBSTER, F. V. **Traffic Signal Settings**. [S.l.]: [s.n.]. 1958.

ZHENGXING, Xiao. **Research on intelligent traffic light control system based on dynamic Bayesian reasoning**. [S.l.]: [s.n.]. 2020.

APÊNDICES

APÊNDICE A – BASE DE DADOS MODIFICADA

Disponível em: https://drive.google.com/file/d/1aS5JT0BUHi-whtYUYaqO_gL8gy8ITigQ/view?usp=sharing

APÊNDICE B – CÓDIGO PARA OTIMIZAÇÃO COM ALGORITMO PSO

Disponível em:
https://colab.research.google.com/drive/16Gc_7YBHUpGzDvRmRvtaSVbTvOduwhZ5?usp=sharing

APÊNDICE C – CÓDIGO PARA VERIFICAÇÃO DOS RESULTADOS

Disponível em:
https://colab.research.google.com/drive/1JoNd3UstDZBMDYw_QKFFIB2kuywAOG4?usp=sharing

ANEXOS

ANEXO A – BASE DE DADOS PRINCIPAL

Disponível em:

<https://docs.google.com/spreadsheets/d/1B1QCdzOPdO0MFuulYaqqAXg3lv3SZ8u-/edit?usp=sharing&oid=101435240209422097966&rtpof=true&sd=true>