



*Universidade Federal da Paraíba*

*Centro de Tecnologia*

*Programa de Pós-Graduação em Engenharia Mecânica*

*- Mestrado - Doutorado*

**UM MODELO COMPUTACIONAL PARA A OTIMIZAÇÃO  
DA EFICIÊNCIA ENERGÉTICA DE UM SISTEMA  
METROFERROVIÁRIO UTILIZANDO ALGORITMOS  
GENÉTICOS**

por

Marcelle Batista Martins

*Tese de Doutorado apresentada à Universidade Federal da Paraíba para  
obtenção do grau de Doutor*

**MARCELLE BATISTA MARTINS**

**UM MODELO COMPUTACIONAL PARA A OTIMIZAÇÃO DA  
EFICIÊNCIA ENERGÉTICA DE UM SISTEMA  
METROFERROVIÁRIO UTILIZANDO ALGORITMOS  
GENÉTICOS**

Proposta de tese apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba, em cumprimento às exigências para a obtenção do Grau de Doutor.

**Orientador: Prof. Dr. Abel Cavalcante Lima Filho**

UM MODELO COMPUTACIONAL PARA A OTIMIZAÇÃO DA  
EFICIÊNCIA ENERGÉTICA DE UM SISTEMA METROFERROVIÁRIO  
UTILIZANDO ALGORITMOS GENÉTICOS

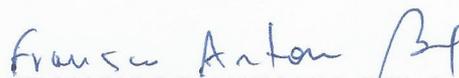
*por*

**MARCELLE BATISTA MARTINS**

*Tese aprovada em 31 de agosto de 2018*



Prof. Dr. ABEL CAVALCANTE LIMA FILHO  
Orientador – UFPB



Prof. Dr. FRANCISCO ANTONIO BELO  
Examinador Interno - UFPB



Prof. Dr. CARLOS ANTONIO CABRAL DOS SANTOS  
Examinador Interno - UFPB



Profa. Dra. NATASHA CORREIA QUEIROZ LINO  
Examinador Externo - UFPB



Profa. Dra. ANDREA SAMARA SANTOS DE OLIVEIRA GOMES  
Examinador Externo - IFPB

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

M379m Martins, Marcelle Batista.

Um modelo computacional para a otimização da eficiência energética de um sistema metroferroviário utilizando algoritmos genéticos / Marcelle Batista Martins. - João Pessoa, 2018.

139 f. : il.

Orientação: Abel Cavalcante Lima Filho.

Tese (Doutorado) - UFPB/CT.

1. Sistema metroferroviário. 2. Eficiência energética. 3. Modelagem matemática. 4. Modelagem computacional. 5. Algoritmo genético. I. Lima Filho, Abel Cavalcante. II. Título.

UFPB/BC

## **DEDICATÓRIA**

Dedico este trabalho à minha mãe, Constance Lygia de Vasconcelos Batista, e ao meu pai, Marcel Paiva Martins, pelo apoio incondicional.

Dedico também ao meu marido, Williams Pessoa dos Santos, pelo incentivo, compreensão e carinho nesta caminhada.

## AGRADECIMENTOS

Gostaria de agradecer primeiramente a Deus, que tem abençoado a minha vida com muito aprendizado e que me deu forças para que eu chegasse até aqui.

À minha família e amigos, em especial ao meu marido, Williams, por compreenderem em inúmeros momentos o motivo da minha ausência e por me incentivarem para que eu seguisse firme em meus objetivos.

Ao meu orientador, Prof. Dr. Abel Cavalcante, por ter aceitado me orientar quando a pesquisa já havia começado, mesmo tendo alguns percalços a serem superados. Agradeço a ele pelas contribuições e empenho nas viagens ao METROREC.

Ao Prof. Dr. Rômulo Araújo, pois através dele pude ter o contato com o METROREC e firmar uma parceria para a coleta de dados utilizada neste trabalho.

Ao Prof. Francisco Antônio Belo e aos colegas do Grupo de Pesquisa em Instrumentação e Controle em Estudo de Energia e Meio Ambiente (GPICEEMA), por terem me acolhido neste curso de Pós-Graduação, onde pude trocar conhecimentos durante os estudos das disciplinas.

À Profa. Dra. Natasha Lino, por todas as sugestões e contribuições prestadas através da criação do grupo de pesquisa Smart Cities, pertencente ao LIAA (Laboratório de Inteligência Artificial) do Centro de Informática (UFPB), no qual foi possível compartilhar o avanço desta pesquisa e realizar um mapeamento sistemático sobre o tema.

Agradeço muito a todos do grupo de pesquisa Smart Cities, em especial a Mayrton Dias de Queiroz, pela sua participação fundamental, sugestões e apoio no desenvolvimento do software, cujo modelo aqui proposto foi implementado.

Por fim, agradeço à Capes, por financiar este trabalho e a todos que direta ou indiretamente contribuíram de alguma forma.

# **GENETICBEE - UM MODELO COMPUTACIONAL PARA A OTIMIZAÇÃO DA EFICIÊNCIA ENERGÉTICA DE UM SISTEMA METROFERROVIÁRIO UTILIZANDO ALGORITMOS GENÉTICOS**

## **RESUMO**

Os motores elétricos dos trens e vagões de um Sistema Metroferroviário são alimentados pela energia elétrica, necessitando de uma demanda elevada de energia. Além disso, este sistema de transporte sobre trilhos tem crescido cada dia mais e, com isto, atualmente buscam-se soluções para otimizar o consumo da energia elétrica. Este trabalho tem como objetivo apresentar uma análise da condução manual dos TUEs (Trens Unidade Elétricos) da CBTU (Companhia Brasileira de Trens Urbanos) - Recife, bem como demonstrar uma análise sobre a utilização da energia elétrica disponibilizada pelos motores nos processos de aceleração e frenagem. Para este fim será proposto um modelo geral que engloba a análise dos perfis de velocidade, que chamamos aqui também de Modelo para a Otimização de *Speed Profile*. Este modelo inclui simulações empíricas com os dados reais colhidos através de sensores nas estações do METROREC e demonstração do desenvolvimento de um Algoritmo Genético da Inteligência Artificial apropriado para o contexto. Assim, após apresentação deste modelo, o mesmo será validado com o auxílio de um software onde o modelo proposto foi implementado, utilizando a linguagem de programação *Java*. Através das simulações com os dados reais, pretende-se demonstrar que controlando os perfis de velocidade dos trens, considerando alguns limites, restrições e parâmetros, ocorrerá a redução do consumo de energia na malha metroferroviária, o que irá favorecer um transporte mais sustentável e uma redução monetária dos gastos. O modelo pode ser adaptado para outras malhas metroferroviárias, como também pode servir de protótipo para a academia e indústria.

Palavras-chave: Sistema Metroferroviário, Eficiência Energética, Modelagem Matemática, Modelagem Computacional, Algoritmo Genético.

# **GENETICBEE - A COMPUTING MODEL FOR THE OPTIMIZATION OF ENERGY EFFICIENCY OF A METROFERROVAL SYSTEM USING GENETIC ALGORITHMS**

## **ABSTRACT**

The electric motors of the trains and wagons of a Metroferroviário System are fed by the electric energy, necessitating a high energy demand. In addition, this rail transport system has grown every day and with this, currently seek solutions to optimize the consumption of electricity. This work aims to present an analysis of the manual conduction of the TUEs (Electric Unit Trains) of the CBTU (Brazilian Company of Urban Trains) - Recife, as well as to demonstrate an analysis on the use of electric energy provided by the engines in the processes of acceleration and braking . To this end, a general model will be proposed that includes the analysis of speed profiles, where we also call the Speed Profile Optimization Model. This model includes empirical simulations with real data collected through sensors at METROREC stations and demonstration of the development of a Genetic Algorithm of Artificial Intelligence appropriate for the context. Thus, after presentation of this model, it will be validated with the help of software where the proposed model was implemented using the Java programming language. By simulating the real data, it is intended to demonstrate that controlling the speed profiles of trains, considering some limits, restrictions and parameters, will reduce the energy consumption in the metro-rail network, which will favor a more sustainable transport and a reduction of expenditure. The model can be adapted to other metro rail networks, but can also serve as a prototype for academia and industry.

Keywords: Metroferroviário System, Energy Efficiency, Mathematical Modeling, Computational Modeling, Genetic Algorithm.

## SUMÁRIO

<b>INTRODUÇÃO</b> .....	1
1.1 OBJETIVOS .....	2
1.1.1 Objetivos Gerais .....	2
1.1.2 Objetivos Específicos .....	2
1.2 ORGANIZAÇÃO DA TESE .....	3
<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	4
2.1 SISTEMAS DE TRANSPORTE .....	4
2.1.1 Sistemas de Transporte Inteligentes (STI) .....	4
2.1.1.1 Trabalhos Relacionados .....	6
2.2 ALGORITMOS GENÉTICOS .....	7
2.3 EFICIÊNCIA ENERGÉTICA EM FERROVIAS .....	9
2.3.1 Trabalhos Relacionados .....	10
2.3.1.1 Trabalhos sobre Otimização de <i>Schedule</i> .....	11
2.3.1.2 Trabalhos sobre Otimização de <i>Speed Profile</i> .....	11
<b>CONTEXTUALIZAÇÃO: METROREC E RAILBEE</b> .....	13
3.1 METROREC .....	13
3.1.1 Elicitação Dos Requisitos .....	15
3.1.1 Tipos e operação dos Trens .....	15
3.1.1.1 TUES ATC Alstom .....	15
3.1.1.2 TUES CAF .....	15
3.1.1.3 Demanda Contratada e Consumo .....	16
3.1.1.4 Problemas na gestão de energia .....	16
3.1.1.5 Relatos para melhoria da eficiência energética .....	17
3.2 O PROJETO RAILBEE .....	17
3.2.1 Descrição do Projeto Railbee .....	19

<b>MATERIAIS E MÉTODOS</b> .....	23
4.1 METODOLOGIA ADOTADA .....	23
4.1.1 Input – Dados de Entrada .....	25
4.1.2 Modelo de Otimização do <i>Speed Profile</i> .....	25
4.1.2.1 Simulação Empírica .....	25
4.1.2.2 Otimização utilizando Algoritmos Genéticos .....	26
4.1.2.2.1 Representação Cromossomial Adotada .....	27
4.1.2.2.2 Inicialização da População .....	28
4.1.2.2.3 Aplicação de Conforto .....	29
4.1.2.2.4 Função de Avaliação .....	29
4.1.2.2.5. Seleção dos Pais .....	31
4.1.2.2.6. Tipos de Crossover .....	33
4.1.2.2.7 Mutação Uniforme e Limite .....	35
4.2. RESUMO SOBRE O FUNCIONAMENTO DO AG .....	36
<b>APRESENTAÇÃO E ANÁLISE DOS RESULTADOS</b> .....	37
5.1 PROJETO DO EXPERIMENTO .....	37
5.2 ANÁLISES DO EXPERIMENTO - COQUEIRAL À RODOVIÁRIA (07/10/2016) ..	40
5.3 RESULTADOS ENCONTRADOS .....	45
5.3.1 Trecho 1 - Coqueiral a Alto do Céu .....	45
5.3.1.1 Resultado I - Simulação Empírica .....	45
5.3.1.2 Resultados II – Comparações dos Operadores e Módulo da População .....	47
5.3.1.3 Resultados III – Comparações da Aplicabilidade do Conforto .....	50
5.3.1.4 Resultados Finais .....	52
5.4.1 Trecho 2 – Alto do Céu a Curado .....	54
5.4.1.1 Resultado I - Simulação Empírica .....	54
5.4.1.2 Resultados Finais .....	57
5.5.1 Trecho 3 – Curado à Rodoviária .....	59
5.5.1.1 Resultado I - Simulação Empírica .....	59
5.5.1.2 Resultados Finais .....	62
5.6 AVALIAÇÃO FINAL DO DIA (07/10/2016) .....	64
<b>CONCLUSÕES E CONSIDERAÇÕES FINAIS</b> .....	66
6.1 CONTRIBUIÇÕES ALCANÇADAS .....	68

6.2 TRABALHOS FUTUROS .....	68
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>69</b>
<b>APÊNDICE I.....</b>	<b>74</b>
<b>APÊNDICE II .....</b>	<b>84</b>
<b>APÊNDICE III.....</b>	<b>87</b>
<b>APÊNDICE IV .....</b>	<b>93</b>
<b>APÊNDICE V .....</b>	<b>112</b>
<b>APÊNDICE VI.....</b>	<b>116</b>

## LISTA DE FIGURAS

Figura 1: Esquema de Algoritmo Genético (LINDEN, 2012). .....	9
Figura 2: Mapa METROREC – linhas.....	13
Figura 3: Trem Unidade Elétrico (ARAÚJO, 2009).....	14
Figura 4: Console da Cabine de Comando do TUE (ARAÚJO, 2009) .....	14
Figura 5: Representação do Sistema RailBee para uma rede de estação de trem urbano (Araujo, 2009) .....	19
Figura 6: Arquitetura básica dos módulos remotos (ARAÚJO, 2009).....	20
Figura 7: Distribuição dos nós da rede ZigBee em um trecho da via(SANTOS, 2010)....	20
Figura 8: Mapa das linhas do MetroRec .....	21
Figura 9: Localização das redes na linha Recife-Jaboatão.....	21
Figura 10: Modelo Teórico de Eficiência Energética. ....	24
Figura 11: Simulação Empírica .....	26
Figura 12: Modelo – Algoritmo Genético.....	27
Figura 13: Codificação do cromossomo .....	28
Figura 14: Método da Roleta.....	32
Figura 15: Método do torneio .....	33
Figura 16: Exemplo operação crossover – Um ponto.....	33
Figura 17: Exemplo operação crossover – Dois pontos.....	34
Figura 18: Exemplo operação crossover – Uniforme .....	34
Figura 19: Exemplo operação crossover – Crossover Média.....	35
Figura 20: Exemplo operação mutação – Uniforme .....	35
Figura 21: Fluxo do Experimento.....	39
Figura 22: Software GeneticBee 1.0.....	40
Figura 23: Linhas METROREC – Trechos escolhidos.....	41
Figura 24: Configurações do Domínio – GeneticBee 1.0 .....	42
Figura 25: Configurações dos Operadores – GeneticBee 1.0 .....	43

Figura 26: Configurações do Domínio – Trecho 1 .....	45
Figura 27: Gráfico do Perfil de Velocidade (Real) - Trecho 1 .....	46
Figura 28: Gráfico do comportamento da energia acumulada (Real) - Trecho 1 .....	46
Figura 29: Aceleração km/h <sup>2</sup> (Real) - Trecho 1 .....	47
Figura 30: Configuração dos Operadores (Comparação) – Seleção Roleta - Trecho 1 .....	48
Figura 31: Comparação dos Experimentos – Seleção Roleta - Trecho 1 .....	48
Figura 32: Configuração dos Operadores (Comparação) – Seleção Torneio - Trecho 1 .....	49
Figura 33: Comparação dos Experimentos – Seleção Torneio - Trecho 1 .....	49
Figura 34: Configuração para Comparações da Aplicabilidade do Conforto - Trecho 1 .....	50
Figura 35: Resultado da energia com e sem conforto – Trecho 1 .....	51
Figura 36: Comparação do Perfil de Velocidade (Real x AG) - Trecho 1 .....	52
Figura 37: Comportamento da Aceleração (Real x AG) - Trecho 1 .....	52
Figura 38: Comportamento da Potência por Trecho (Real x AG) - Trecho 1 .....	53
Figura 39: Comportamento da Energia Acumulada (Real x AG) - Trecho 1 .....	53
Figura 40: Configurações do Domínio – Trecho 2 .....	55
Figura 41: Perfil de Velocidade (Real) – Trecho 2 .....	55
Figura 42: Comportamento da Energia Acumulada (Real) - Trecho 2 .....	56
Figura 43: Aceleração km/h <sup>2</sup> (Real) - Trecho 2 .....	56
Figura 44: Comparação do Perfil de Velocidade (Real x AG) - Trecho 2 .....	57
Figura 45: Comportamento da Aceleração (Real x AG) – Trecho 2 .....	57
Figura 46: Comportamento da Potência por Trecho (Real x AG) - Trecho 2 .....	58
Figura 47: Comportamento da Energia Acumulada (Real x AG) - Trecho 2 .....	58
Figura 48: Configurações do Domínio – Trecho 3 .....	60
Figura 49: Perfil de Velocidade (Real) - Trecho 3 .....	60
Figura 50: Comportamento da Energia Acumulada (Real) - Trecho 3 .....	61
Figura 51: Aceleração km/h <sup>2</sup> (Real) – Trecho 3 .....	61
Figura 52: Comparação do Perfil de Velocidade (Real x AG) - Trecho 3 .....	62
Figura 53: Comportamento da Aceleração (Real x AG) - Trecho 3 .....	62
Figura 54: Comportamento da Potência por Trecho (Real x AG) - Trecho 3 .....	63
Figura 55: Comportamento da Energia Acumulada (Real x AG) - Trecho 3 .....	63

## LISTA DE TABELAS

Tabela 1: Dados Fixos – Trecho 1 .....	45
Tabela 2: Melhores resultados da execução do AG – Trecho 1 .....	54
Tabela 3: Dados Fixos – Trecho 2 .....	54
Tabela 4: Melhores resultados da execução do AG – Trecho 2 .....	59
Tabela 5: Dados Fixos – Trecho 3 .....	59
Tabela 6: Melhores resultados da execução do AG – Trecho 3 .....	64
Tabela 7: Comparação do Gasto de Energia X Aplicação do AG .....	64

# CAPÍTULO I

## INTRODUÇÃO

Os motores elétricos dos trens e vagões de um Sistema Metroferroviário são alimentados por energia elétrica, necessitando de um suprimento elevado de energia. Além disso, este sistema de transporte sobre trilhos tem crescido cada dia mais e, com isto, atualmente, buscam-se soluções para otimizar o consumo da energia elétrica. Este trabalho tem como objetivo apresentar uma análise da condução manual dos TUEs (Trens Unidade Elétricos) da CBTU (Companhia Brasileira de Trens Urbanos) - Recife, bem como demonstrar uma análise sobre a utilização da energia elétrica disponibilizada pelos motores nos processos de aceleração e frenagem. Para este fim será proposto um modelo geral que engloba a análise dos perfis de velocidade, o qual chamamos aqui também de Modelo para a Otimização de *Speed Profile* (GeneticBee). Este modelo inclui simulações empíricas com os dados reais colhidos através de sensores nas estações do METROREC e demonstração do desenvolvimento de um Algoritmo Genético da Inteligência Artificial apropriado para o contexto. Assim, após apresentação do modelo, o mesmo será validado através do software intitulado GeneticBee, no qual o modelo proposto foi implementado, utilizando a linguagem de programação *Java*. Através das simulações com os dados reais, pretende-se demonstrar que controlando os perfis de velocidade dos trens, considerando alguns limites, restrições e parâmetros, ocorrerá a redução do consumo de energia na malha metroferroviária, o que irá favorecer um transporte mais sustentável e uma redução monetária dos gastos. O modelo pode ser adaptado para outras malhas metroferroviárias, como também pode servir de protótipo para a academia e indústria.

## 1.1 OBJETIVOS

### 1.1.1 Objetivos Gerais

A finalidade principal deste trabalho é desenvolver um Modelo Computacional para a Otimização da Eficiência Energética em sistemas de malhas metroferroviárias utilizando os Algoritmos Genéticos, sendo analisados os dados colhidos nos TUEs das estações da CBTU em Recife. Em seguida, busca-se validar o modelo proposto, demonstrando os resultados encontrados.

### 1.1.2 Objetivos Específicos

Para atingir os objetivos gerais foram elencados os seguintes objetivos específicos:

- Realizar pesquisa bibliográfica sobre Sistemas de Transporte Inteligentes (STI) e seus trabalhos relacionados;
- Realizar pesquisa bibliográfica sobre a Eficiência Energética em Ferrovias e seus trabalhos relacionados;
- Realizar pesquisa bibliográfica sobre os Algoritmos Genéticos da Inteligência Artificial;
- Contextualização com dados do METROREC e análise do Projeto RailBee no que concerne aos estudos do sistema autônomo baseado em RSSF (Redes de Sensores sem Fio) e processamento em Sistemas Embarcados para o monitoramento de trens urbanos;
- Realização de um Mapeamento Sistemático sobre o tema;
- Avaliação empírica, baseados nos dados reais captados através de sensores na linha Centro do METROREC;
- Desenvolvimento e demonstração detalhada do funcionamento de um Algoritmo Genético de acordo com contexto definido, com foco na otimização do *Speed Profile*;
- Proposta de um Modelo para Otimização do *Speed Profile*, validado através da execução de experimentos, onde o modelo proposto foi implementado, utilizando a linguagem de programação *Java*.

## 1.2 ORGANIZAÇÃO DA TESE

Este trabalho está dividido em seis (seis) capítulos. Após a Introdução, segue o Capítulo 2 (dois), que aborda a Fundamentação Teórica com os conceitos básicos das principais áreas temáticas que envolvem este trabalho: Sistemas de Transportes Inteligentes; Eficiência Energética em Ferrovias; Algoritmos Genéticos. No Capítulo 3 (três), são contextualizados os conceitos do Projeto RailBee e METROREC. O Capítulo 4 (quatro) apresenta os Materiais e Métodos adotados no desenvolvimento do trabalho, onde é definido todo o planejamento para o desenvolvimento do modelo computacional para a otimização da eficiência energética, demonstrando a metodologia adotada e seu funcionamento. O Capítulo 5 (cinco) exhibe uma Apresentação e Análise dos Resultados encontrados de acordo com o modelo proposto. O Capítulo 6 (seis) consiste nas Conclusões e Considerações Finais, seguido pelas Referências Bibliográficas.

## **CAPÍTULO II**

### **FUNDAMENTAÇÃO TEÓRICA**

#### **2.1 SISTEMAS DE TRANSPORTE**

Não se pode falar de Sistemas Inteligentes de Transporte sem primeiro contextualizar e caracterizar o conceito de Sistemas de Transporte. Os Sistemas de Transporte fazem parte de uma área bastante complexa, pois incluem o poder político, social e econômico em constante interação para proporcionar o deslocamento de pessoas ou bens de forma eficiente e rápida entre determinadas regiões demográficas. Os Transportes têm uma participação ativa em quase todas as atividades sociais (SUSSMAN, 2000).

##### **2.1.1 Sistemas de Transporte Inteligentes (STI)**

Atualmente, o grande fluxo de veículos tem aumentado consideravelmente ao longo dos anos, provocando congestionamento do tráfego nas rodovias e áreas urbanas, constituindo um dos problemas mais importantes na área dos sistemas de transportes. Além disto, nas grandes cidades do mundo o sistema metroferroviário, por exemplo, é um transporte público de alta demanda. Então, para atender tal capacidade, este sistema deve possuir um grande suporte energético que, em muitos casos, encontra-se baseado na energia elétrica. No entanto, em sistemas que possuem grandes dimensões, alguns detalhes podem resultar em menor eficiência e maiores custos (PORTO et al., 2013). Contudo, têm sido atualmente publicados na literatura alguns métodos de reaproveitamento de energia, bem como sobre a otimização da melhoria da eficiência nos sistemas de malhas

metroferroviárias. Assim, neste trabalho iremos focar na análise para otimização da eficiência energética em sistemas metroferroviários baseados em motores de tração e tensão.

Com a evolução da tecnologia, a partir dos anos 1990, passou-se a empregar sistemas e recursos eletrônicos para coletar, processar e distribuir dados do tráfego urbano. Estes sistemas, conhecidos como Sistemas de Transporte Inteligentes (STI), do inglês *Intelligent Transportation Systems*, consistem em um conjunto de tecnologias aplicadas ao gerenciamento de redes de transportes para melhorar a eficiência e a segurança viária, reduzindo os custos (MENESES, 2003).

Existem muitas definições para o conceito de Sistemas de Transportes Inteligentes (STI), um deles apresenta a seguinte definição: “Os STI englobam uma vasta área de tecnologias de informação, comunicações e controle. Estas, quando integradas nas infraestruturas dos sistemas de transporte e nos próprios veículos, ajudam a monitorar o fluxo de tráfego, reduzir congestionamentos, sugerir alternativas aos viajantes, aumentar a produtividade, salvar vidas, poupar tempo e dinheiro, reduzindo os impactos na saúde e no ambiente” (ITSA, 2014).

Assim, de uma forma resumida, pode-se dizer que os STI têm como finalidade a otimização dos transportes em geral, ou seja, através de uma variada gama de tecnologias têm como objetivo otimizar toda estrutura envolvida no transporte de pessoas e bens, criando vias de comunicação, veículos e utilizadores mais inteligentes, facilitando a fluidez no transporte de pessoas e mercadorias.

O êxito no desenvolvimento e aplicação destas tecnologias poderá ser a chave para resolver muitos dos problemas de transporte dos nossos dias. As potencialidades dos STI para encontrar soluções para os transportes europeus do século XXI são apontadas no documento “*A política europeia de transportes no horizonte 2010: a hora das opções*” publicada pela Comissão Europeia em 2003 (COMISSÃO EUROPEIA, 2003). Em uma abordagem visando o aperfeiçoamento do sistema europeu de transportes, são relatadas algumas questões principais:

- **Segurança** – o transporte rodoviário é, claramente, o meio de transporte com maiores custos em termos de segurança, onde ocorrem aproximadamente 40.000 mortes por ano na Europa;

- **Poluição e saúde** – atualmente existe um grande consenso sobre o fato de a emissão de gases nocivos constituírem um perigo real para o futuro da humanidade.

Verifica-se um aumento dos problemas respiratórios nas zonas urbanas e, em um mundo em que as viagens são uma necessidade cotidiana, o congestionamento crescente do tráfego torna a vida cada vez mais estressante;

- **Congestionamentos** – os engarrafamentos que se registram nos principais itinerários internacionais continuam a ser um grande problema e o congestionamento urbano e interurbano exige uma ação imediata;

- **Transportes eficientes** – o objetivo é proporcionar a possibilidade de pôr em prática transportes mais inteligentes e aumentar a eficiência dos sistemas de investigação relativa aos transportes; integrar modos de sistemas inteligentes que permitam uma gestão eficaz das infraestruturas.

#### 2.1.1.1 Trabalhos Relacionados

Na área de STI destacam-se os seguintes trabalhos:

O SART (sigla em francês para o Sistema de Suporte para Controle de Tráfego – em metrô) (BRÉZILLON et al., 2000): Visa o desenvolvimento de um sistema de apoio à decisão inteligente capaz de ajudar o operador na tomada de decisões para resolver um incidente ocorrido em uma linha. Este sistema baseia-se na abordagem de contexto. O contexto inclui informações e conhecimentos sobre a situação que não intervêm diretamente na resolução de incidentes, mas restringe a forma em que o operador vai escolher uma estratégia em cada etapa da resolução de incidentes. O trabalho destaca como a Inteligência Artificial (IA) e suas técnicas podem contribuir na aquisição de conhecimento e representação do conhecimento relacionado com o seu contexto de utilização.

*OneBusAway* (FERRIS et al., 2010): Fornece uma gama de ferramentas desenvolvidas pela Universidade de Washington, que informa dados sobre o itinerário (chegadas e partidas) dos ônibus na cidade de Seattle. Assim, tem como finalidade auxiliar os passageiros sobre as chegadas, paradas e rotas realizadas pelos ônibus.

O projeto SIMTUR (SIMTUR, 2011): Propõe criar, modelar e implementar um sistema integrado de soluções de apoio aos usuários de transporte coletivo e privado, direcionado ao rastreamento, comunicação, controle e monitoramento do tráfego em cidades. Para os passageiros, são disponibilizados dados relativos aos itinerários e rastreamento de veículos. Já para os motoristas de veículos, são disponibilizados dados

sobre as condições das vias urbanas e tráfego, além de um serviço de comunicação segura entre veículos.

O projeto UbiBus (VIEIRA et al., 2011): Propõe um sistema de transporte público inteligente que, além de determinar as estimativas de tempo de chegada dos ônibus, oferece previsão e recomendações de melhores rotas. As informações são coletadas em tempo real com o auxílio de redes sociais e colaborativas de usuários.

O Olho Vivo (PTRANS, 2012): De forma análoga ao *OneBusAway*, tem o objetivo de demonstrar a visualização em tempo real dos ônibus na Cidade de Brasília (Brasil). Informa aos passageiros, por exemplo, sobre o tempo que o ônibus levará até chegar a sua parada de destino.

MD-UTS (FELTES et al., 2014): O modelo permite o gerenciamento de diferentes tipos de veículos, criando um registro e histórico do seu movimento. O modelo fornece informações através de Web Services que podem ser utilizados por diferentes aplicações.

Sobre os Sistemas de Transportes Inteligentes na área ferroviária, pode-se destacar ainda o Centro Global de Inovações Ferroviária da IBM (IBM, 2017), do inglês *Global Rail Innovation Center*, que tem o intuito de reunir os principais líderes ferroviários de todo o mundo para que possam colaborar na discussão dos desafios que as ferrovias enfrentam e na criação de soluções, padrões para o setor, pesquisas e liderança na busca por ferrovias mais inteligentes.

## 2.2 ALGORITMOS GENÉTICOS

Em meados dos anos 70, a técnica dos Algoritmos Genéticos (AG) começou a ter relevância quando o pesquisador John H. Holland publicou seu livro sobre o mecanismo da evolução e da genética natural intitulado *Adaptation in natural and artificial systems* (1975). O intuito de sua pesquisa é de auxiliar na projeção de sistemas artificiais com propriedades similares aos sistemas naturais através da metaheurística.

Baseado na evolução e seleção natural das espécies, proposto pelo cientista Charles Darwin, os algoritmos genéticos funcionam de forma similar, onde o *indivíduo (cromossomo)* geneticamente melhor adaptado normalmente supera o problema ao sobreviver ao meio ambiente. Na modelagem de problemas, segundo os Algoritmos Genéticos, existe um número de indivíduos (*população*), onde cada um destes é uma solução que competem entre si para sobreviver. Assim, a solução melhor adaptada

geneticamente tem uma maior probabilidade de gerar novos indivíduos, contribuindo com o aprimoramento da população. Para isto, dentro da população definida são selecionados pares de cromossomos (*pais*), onde será utilizado um *operador de cruzamento (crossover)*, que é responsável pela geração de novos indivíduos (*filhos*). Basicamente, realiza-se a troca de fragmentos entre dois indivíduos previamente selecionados, combinando características dos mesmos. Através do *operador de mutação*, são realizadas pequenas alterações em um indivíduo da população, utilizando, por exemplo, uma probabilidade.

É associado a cada indivíduo da população um determinado valor numérico para identificar a qualidade deste indivíduo, este valor numérico é chamado de *função de avaliação (fitness)* ou objetiva. Desta forma, os indivíduos com uma boa função objetiva prevalecem sobre os demais, permitindo uma melhoria crescente na qualidade da população. Uma das características mais importantes dos algoritmos genéticos é a manipulação de diversas soluções ao mesmo tempo. Com esta característica a metaheurística tem a capacidade de explorar com mais eficiência o espaço de busca, tornando o método mais robusto e encontrando uma solução de boa qualidade (GUIMARÃES, 2009).

O funcionamento de um AG é mostrado de forma gráfica na Figura 1, podendo ser resumido algorítmicamente através dos seguintes passos (LINDEN, 2012):

1. Inicialize a população;
2. Avalie cada cromossomo na população;
3. Selecione os pais para gerar novos cromossomos;
4. Aplique os operadores de recombinação e mutação a estes pais de forma a gerar os indivíduos da nova geração;
5. Apague os velhos membros da população;
6. Avalie todos os novos cromossomos e insira-os na população;
7. Se o tempo acabou e o melhor cromossomo satisfaz os requerimentos e desempenho, retorne-o; caso contrário, volte para o passo 3.

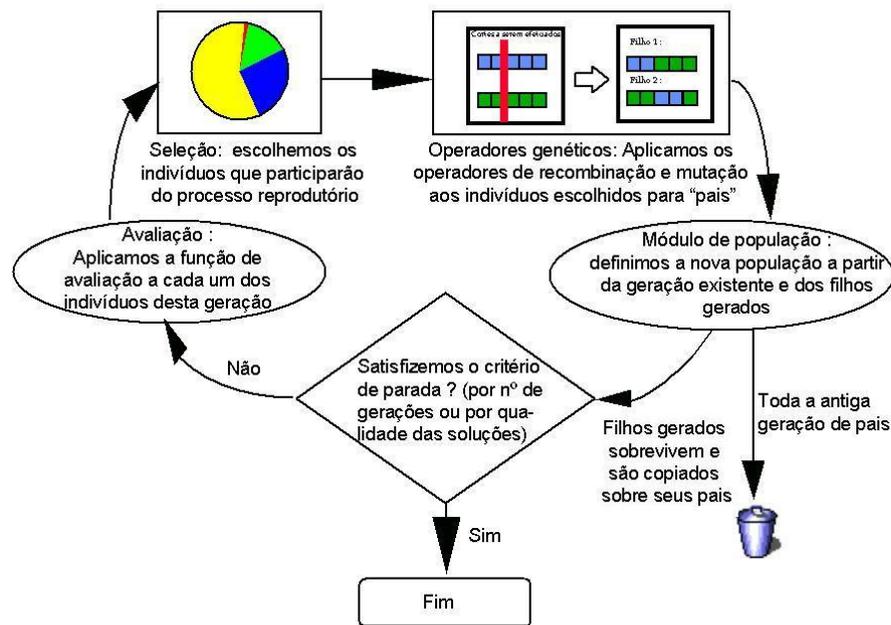


Figura 1: Esquema de Algoritmo Genético (LINDEN, 2012).

Como podemos ver nos trabalhos relacionados a seguir, no item 2.3.1, os Algoritmos Genéticos são bastante utilizados para encontrar a melhor solução para a eficiência energética em ferrovias. Por este motivo, adotaremos como um meio de validação neste trabalho e será melhor detalhado no Capítulo 5.

## 2.3 EFICIÊNCIA ENERGÉTICA EM FERROVIAS

Uma definição atual e bastante simples da palavra “energia” e que se aplica, a rigor, a certos tipos de energias, como a mecânica e a elétrica, é “a medida da capacidade de efetuar trabalho”. Infere-se, portanto, deste conceito que eficiência energética é a realização de trabalho com o menor consumo de energia possível. De uma maneira geral, pode-se afirmar que a eficiência energética aumenta quando se consegue realizar um serviço e/ou produzir um bem com uma quantidade de energia inferior à que era usualmente consumida (HADDAD, 2004).

Assim, devido às crescentes preocupações ambientais e os elevados preços da energia consumida, são avaliadas formas de otimizar a eficiência energética em sistemas de malhas metroferroviárias. A questão emergente é de como a programação dos horários de sincronização de trens, chamada na literatura de “*Schedule/Timetable*”, e o controle dos perfis de velocidade, “*Speed profile*”, podem ser aperfeiçoadas. Ou seja, no primeiro caso,

uma das alternativas é que a energia de frenagem regenerativa de um trem possa ser utilizada por outros trens em forma de aceleração e para isto deve haver um sincronismo entre os trens em uma mesma estação (programação de horários de chegadas e partidas dos trens). Estudos indicam que maximizando essa utilização da energia regenerativa pode-se levar a melhorias substanciais na eficiência energética do sistema. No segundo caso, é necessário calcular o consumo médio de energia, velocidade e potência em relação ao consumo mínimo de energia, de acordo com as limitações da carga horária, orientando os motoristas a controlar o perfil de velocidade, supervisionados por um Centro de Gestão do Tráfego.

Continuando nesta abordagem, os sistemas ferroviários são parte importante dos transportes urbanos, pois têm a tarefa de levar passageiros ao seu destino de forma eficiente, rápida e segura. Então, a programação dos horários de sincronismo dos trens, onde se determina a dimensão da frota de trens, o tempo de partida e a hora de chegada nas estações, é fundamental na operação do trem e tem uma grande influência sobre o consumo de energia. Normalmente, quanto maior o tamanho da frota, maior será o consumo de energia. Sabe-se que trens que trafegam em uma mesma estação e operam (aceleram e freiam) simultaneamente, intensificam a potência consumida naquele instante, o que irá potencializar a energia consumida. Sendo assim, os horários de chegadas e partidas que determinam a distribuição do tempo de viagem entre diferentes estações influenciam no consumo de energia de toda a viagem. Portanto, dentro dos critérios para atender a demanda de passageiros, uma excelente programação dos horários de sincronismo dos trens deve ser realizada para minimizar o custo de energia. A estratégia de condução entre as estações é outro fator importante na operação eficiente da energia. Em diferentes tempos de viagens determinados existem variadas maneiras de condução do trem e estratégias aplicáveis que podem consumir quantidades diferentes de energia.

### **2.3.1 Trabalhos Relacionados**

A utilização eficiente de energia em trens é um problema de otimização complicado e difícil, não só por questões de otimização de *Schedule/Timetable*, que deve ser bem definida para sincronizar as ações de aceleração e frenagem dos trens em uma mesma estação, mas também porque o perfil de velocidade deve ser controlado para reduzir o consumo de energia de tração sob a velocidade, tempo de viagem e distância (TUYTTENS

et al., 2013). Portanto, os estudos tradicionais normalmente dividem-se em resoluções de problemas para a otimização de *Schedule/Timetable* e problemas de otimização de *Speed Profile*.

#### 2.3.1.1 Trabalhos sobre Otimização de *Schedule*

Ramos et al. (2007) propõem um modelo de otimização de *Schedule* para maximizar o tempo entre as ações de aceleração e frenagem em trens de uma mesma estação. Nasri et al. (2010) estudaram a influência dos avanços na utilização da energia regenerativa. Eles verificaram que a utilização da energia regenerativa é eficiente se a energia mínima aceitável gerada e consumida é utilizada devido à simultaneidade da frenagem e aceleração dos trens. Pena-Alcaraz et al. (2012) desenvolveram um modelo matemático de otimização para sincronizar os trens no instante de frenagem com outros trens no instante da aceleração e, assim, melhorar a utilização da energia regenerativa. David et al. (2012) formularam um modelo de otimização para maximizar a utilização da energia regenerativa, modificando sutilmente o tempo de permanência dos vagões nas estações. Um algoritmo de programação genética e linear híbrido foi implementado para validação. Yang et al. (2013) propõem a capacitação da regra de escalonamento cooperativo para sincronizar a aceleração e frenagem nas operações sucessivas dos trens. Em seguida, eles formularam um modelo de escalonamento cooperativo para maximizar o tempo de junção entre os trens, projetado através de um algoritmo genético para encontrar a programação de *Schedule* ótima. Li e Yang (2013) propuseram um estudo estatístico para o modelo de escalonamento cooperativo com foco na aleatoriedade do atraso de partida em trens nas estações, o que comprovou que poderia poupar energia em torno de 8% em comparação com uma abordagem de agendamento cooperativo.

#### 2.3.1.2 Trabalhos sobre Otimização de *Speed Profile*

Nos anos de 1960, Ishikawa (1968) propôs o primeiro modelo de controle ótimo que determinava o perfil de velocidade mais adequado. Recentemente, alguns estudos são observados e favorecem a otimização do perfil de velocidade em relação ao consumo mínimo de energia líquida. Por exemplo, Bocharnikov et al. (2010) apresentaram um modelo de otimização perfil de velocidade de um único trem, considerando também tanto a

energia de tração quanto o consumo e a utilização da energia regenerativa. Além disso, os autores realizaram posteriormente uma simulação multi-trem para estimar os benefícios e os efeitos do perfil velocidade ideal na minimização do consumo de energia líquida. Dominguez et al. (2012) levaram em conta o armazenamento de energia regenerativa em subestações e projetaram um algoritmo genético para resolver o perfil de velocidade ideal para o consumo mínimo da energia líquida. Com base no pressuposto de que todos os trens devem obedecer a uma predeterminada programação de *Schedule*, Tuyttens et al. (2013) projetaram um algoritmo genético para determinar os perfis de velocidade para todos os vagões que circulam dentro de um período específico com a finalidade de propor uma estratégia de monitorização de tráfego em tempo real, onde modelos de condução empíricos são utilizados para a solução de perfil de velocidade ideal.

Vale ressaltar que o emprego da matemática é um dos métodos de otimização mais eficientes que busca uma estratégia com melhor desempenho energético e tem sido amplamente estudado e bem aplicado em sistemas ferroviários. Assim, associado aos estudos matemáticos, este trabalho propõe uma análise dos perfis de velocidade através de simulações experimentais através dos dados reais, coletados nas estações da CBTU na cidade de Recife.

## CAPÍTULO III

### CONTEXTUALIZAÇÃO: METROREC E RAILBEE

#### 3.1 METROREC

Conforme podemos observar na Figura 2, o Sistema de Trens Urbanos de Recife é operado em 3 linhas férreas, sendo 2 eletrificadas e 1 operada por composições diesel, com extensão total de 71 km, abrangendo 4 municípios, Recife, Jaboatão dos Guararapes, Camaragibe e Cabo de Santo Agostinho, com 37 estações, transportando cerca de 400 mil passageiros/dia. A Linha Centro, eletrificada, abrangendo 3 municípios, Recife, Jaboatão dos Guararapes e Camaragibe, com 19 estações em operação, nos trechos Recife/Jaboatão e o ramal Coqueiral/Camaragibe; a Linha Sul também eletrificada, abrangendo 2 municípios, Recife e Jaboatão dos Guararapes, com 10 estações em operação, no trecho Recife/Cajueiro Seco e a Linha Diesel (VLT) abrangendo 3 municípios, Recife, Jaboatão dos Guararapes e Cabo de Santo Agostinho, com 8 estações em operação (CBTU, 2017).



Figura 2: Mapa METROREC – linhas (CBTU, 2017)

Este trabalho irá se deter na análise de trechos da Linha Centro, onde circulam 275 mil pessoas diariamente, conforme mencionado na Figura 2.

Os modos de operação do TUE são comandos manuais controlados (ATC ativo e manual livre - ATC cancelado). Na modalidade ATC ativo, existe a supervisão de velocidade que faz o controle de frenagem do TUE, e o cabo-sinal indica a velocidade que o operador deve obedecer no console da cabine, conforme Figura. Esse tipo de comando destina-se à operação normal. Na modalidade ATC cancelado de operação, o maquinista não consta com o sistema de supervisão de velocidade, porém a velocidade máxima do trem não ultrapassa 35km/h (ARAÚJO, 2009).



Figura 3: Trem Unidade Elétrico (ARAÚJO, 2009).

Abaixo segue Figura 4 que demonstra a Console da Cabine de Comando de um TUE, visualizado pelos maquinistas.

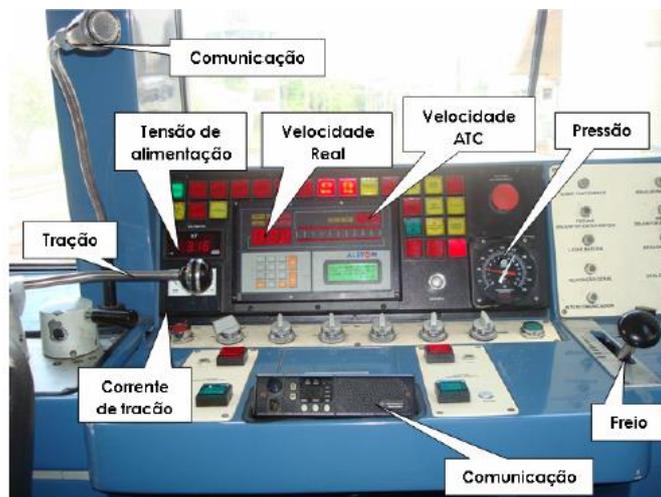


Figura 4: Console da Cabine de Comando do TUE (ARAÚJO, 2009)

### **3.1.1 Elicitação Dos Requisitos**

No dia 20 de agosto de 2015 foi realizada uma visita ao MetroRec para elicitação dos requisitos, onde foi feito um levantamento dos dados acerca do processo que envolve a gestão da energia elétrica em suas estações.

### **3.1.1 Tipos e operação dos Trens**

Ao todo, a frota contém 42 TUEs que subdividem nos tipos Alston e CAF. Toda a frota de trens não deve ultrapassar o limite máximo de velocidade de 80km/h. Todas as estações contêm um Programa Horário (Calendário) com todos os dados de chegadas, partidas e atrasos (programas realizados) dos TUEs. Todos os trens obedecem a uma planilha de sinalização de velocidade, onde a sinalização é planejada levando em conta a eficiência dos trens e a segurança dos usuários, a qual deve ser obedecida pelos maquinistas. Conforme já mencionado anteriormente, existe a sinalização automática, onde o TUE automaticamente se ajusta à velocidade recomendada (ATC Ativo), e a manual, onde o maquinista deve ajustar a velocidade recomendada para aquele trecho de via.

#### **3.1.1.1 TUES ATC Alstom**

São ao todo 27 TUES operando na linha SUL (Recife a Cajueiro Seco). Eles operam utilizando exclusivamente a Corrente Contínua (CC). Estes trens possuem uma tecnologia mais antiga e, conseqüentemente, oferecem um gasto maior de energia, pois dentre outros fatores, não possuem, por exemplo, tecnologia para utilização da energia regenerativa, o que tornaria possível obter uma melhor utilização da energia. Estes TUES possuem amparo para instalação de serviço ATO (Sistema automatizado, apenas com a supervisão do maquinista).

#### **3.1.1.2 TUES CAF**

São ao todo 15 TUES que circulam na linha Centro. A CC é convertida em Corrente Alternada (CA), assim, conseqüentemente, ocorre um melhor aproveitamento da energia. Outro fator é que eles fazem uso da energia regenerativa, retornando a energia de

frenagem para a reutilização na própria central de energia. Estes TUES também possuem amparo para instalação de serviço ATO (Sistema automatizado, apenas com a supervisão do maquinista).

### 3.1.1.3 Demanda Contratada e Consumo

Aqui foram levantadas informações sobre a Demanda Contratada de Energia com a concessionária CELPE, de tarifação, bem como dados sobre o Consumo e Gestão da Energia.

- Demanda Contratada de Energia

A Demanda contratada Fora de Ponta e Na Ponta, tem o mesmo valor - **13.090 kW** (máximo de consumo em um determinado tempo - range). Este valor não pode ser ultrapassado em cada quarto de hora, pois senão ocorre multa de um valor de R\$80.000,00 aproximadamente. Casualmente, quando se prevê que irá ultrapassar este valor (ex.: dia de festa na cidade - Galo da Madrugada) a concessionária CELPE é avisada e a ultrapassagem é justificada, sendo cobrado apenas o valor compatível ao que foi consumido pelos trens.

- Tarifa de Energia

A tarifa é variável e muda de mês a mês dependendo apenas do que foi consumido pelos trens, apenas a demanda que é fixa (13.090KW), conforme dito anteriormente.

- Consumo de Energia

Cada subestação recebe **69KV** (tensão) da concessionária (CELPE) e convertem esta tensão em várias faixas, destinando as mesmas de acordo com o propósito. Assim, para consumo dos trens, é reduzida para **3.3KV** (corrente contínua). Os demais valores KV de energia são distribuídos para a sinalização, equipamentos e iluminação. Foi questionado o valor **3.3KV** ser baixo para a utilização dos trens, mas foi justificado afirmando-se que este valor é suficiente e é o que é suportado pela central de energia.

### 3.1.1.4 Problemas na gestão de energia

Relatado que certa vez uma determinada estação que utilizava 4 trens operantes sofreu uma adição ocasional de mais um trem para testes; contudo, a central de energia daquela subestação não suportou, ocasionando um problema de parada dos trens. Foi relatado também que quando se prevê que o valor da demanda será ultrapassado em um

dado momento, normalmente em horários de pico, não é liberado trens para manobras/taxiamento naquele momento.

Foi relatado, ainda, que os trens quebram com certa frequência, inclusive os novos TUEs CAF (não foi detalhado os motivos das quebras), o que ocasiona muitas vezes transtornos com relação ao atraso dos trens e, por ventura, aumento da energia naquele momento.

Há relatos que alguns trens partem em um mesmo horário utilizando a mesma Central de Energia, o que pode ocasionar um pico de energia (potência) naquele momento. Assim, seria necessário analisar o calendário para melhorá-lo.

A Subestação Ipiranga possui uma central de energia que abastece também as Subestações vizinhas (Recife e Coqueiral – que também possuem centrais elétricas próprias) e funciona como apoio uma a outra, em caso de falha.

Há em torno de 200 maquinistas, que trabalham com jornada de 6h15min (15 para descanso).

#### 3.1.1.5 Relatos para melhoria da eficiência energética

Foram sugeridos estudos sobre: a substituição ou adição de peças/instrumentos para uma melhor eficiência energética dos trens; realização de testes com os novos trens CAF e antigos para que se possa visualizar e analisar a eficiência de cada tipo de trem e, assim, sugerir a substituição dos velhos, provando que em longo prazo se terá um retorno positivo com relação à eficiência energética; análise dos perfis de condução e velocidade dos TUEs, através da coleta dos dados através dos sensores. Contudo, foi informado que qualquer trabalho que envolva melhorias em habilidades humanas (entre controladores e maquinistas) será um trabalho oneroso, mas o estudo será válido. Aconselha-se pesquisa para a adição do sistema ATO, pois há pretensão em futuramente fazer uso deste sistema, inclusive informaram que foram realizados testes *in loco* com este tipo de sistema, mas não foi ainda adotado por ser considerado caro.

## 3.2 O PROJETO RAILBEE

O projeto RailBee tem como objetivo o desenvolvimento de uma Rede de Sensores sem Fio (RSSF) para monitoramento e controle de trens urbanos. O sistema tem como

finalidade permitir o acompanhamento em tempo real de um grande conjunto de veículos que circulam em vias permanentes, permitindo o aumento na eficácia e segurança do tráfego e diminuindo custos de operação. O sistema proposto, denominado RailBee, consiste em uma RSSF (Redes de Sensores sem Fio), composta de módulos remotos embarcados nos veículos, roteadores fixos dispostos na via e módulos base para recepção dos dados a partir dos roteadores. Os módulos remotos realizarão a medida de diversos parâmetros nos trens e enviarão os valores através dos roteadores até um módulo base. Os dados recebidos nos módulos base serão então disponibilizados pela intranet para que possam ser analisados nas centrais de monitoramento. Têm-se como objetivo realizar a implantação do sistema RailBee em grande escala, contemplando uma grande quantidade de trens. Alguns estudos do Projeto RailBee já foram realizados e validados na Companhia Brasileira de Trens Urbanos – Metrô do Recife (CBTU/METROREC). Os principais estudos desenvolvidos encontram-se nos trabalhos dos pesquisadores Santos (2010) e Araújo (2009).

A arquitetura do sistema é modulada e aberta para incorporar novas tecnologias de medições. O projeto surge como uma alternativa inovadora frente aos atuais métodos de monitoramento de trens urbanos empregados no mundo, geralmente baseados em GPS, transmissão por satélite ou por rede celular, apresentando uma maior autonomia e um menor custo.

De forma resumida, o projeto tem como finalidade o desenvolvimento de um sistema de instrumentação virtual de veículos em malhas metroferroviárias, utilizando a transmissão de sinais via radiofrequência, de acordo com protocolo de comunicação de padrão internacional. Compõe-se de microprocessadores e um rádio transceptor, que, quando acoplados a sensores, captam e transmitem os dados em questão, funcionando como transdutores sem fio. Trata-se de tecnologia modular de baixo custo, baixo consumo de energia, segura e capaz de monitorar diversas variáveis simultaneamente. É uma técnica inovadora no que se refere ao monitoramento e controle de veículos que circulam em vias permanentes, avaliando em tempo real o seu desempenho. Essa avaliação, por sua vez, pode auxiliar nas ações preventivas e corretivas de operação e manutenção dos veículos rodoferroviários, a fim de melhorar a qualidade dos serviços prestados.

### 3.2.1 Descrição do Projeto Railbee

Os três subsistemas que compõem o RailBee são as Estações Móveis (EM), as Estações Base (EB) e uma Estação Central (EC). A partir da Figura 5 pode-se ter uma compreensão de tais estações e onde elas estão localizadas ao longo da via.

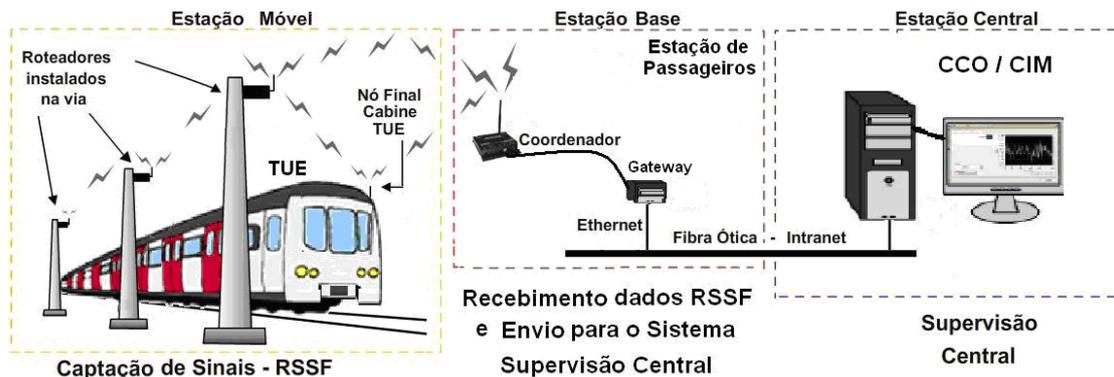


Figura 5: Representação do Sistema RailBee para uma rede de estação de trem urbano (ARAUJO, 2009)

Nas estações móveis (EM) se encontram os módulos remotos (MR) localizados nas cabines dos trens (denominados TUE - Trem Unidade Elétrica). Cada MR é composto de um nó final que terá suas entradas analógicas ligadas a diversos sensores para medição de grandezas, como: velocidade, pressão, temperatura, tensão de alimentação e corrente do motor de tração. Também, incorporado a cada MR, há saídas de sinais tipo Conversor Digital para Analógico (CDA) ou de Modulação por largura de pulso (MLP), para atuação de controle. A arquitetura básica de uma MR é composta de um microcontrolador, que recebe os sinais dos sensores, realiza o processamento dos dados e transmite as informações via rádio frequência, utilizando um transceptor (Figura 5). Os nós roteadores, localizados nas estações roteadores (ER), recebem os sinais de dados enviados pelos nós finais, os retransmitem até alcançarem um nó coordenador da rede, que ficará presente em uma estação base.

Vale salientar que as ER são instaladas nos armários de sinalização de via (cases), nas Cabines de Seccionamento e Paralelismo (CSP) e nas Subestações Retificadoras (SSR). Estas estações retransmitem os dados recebidos das EM para outras ER ou diretamente para as EB.

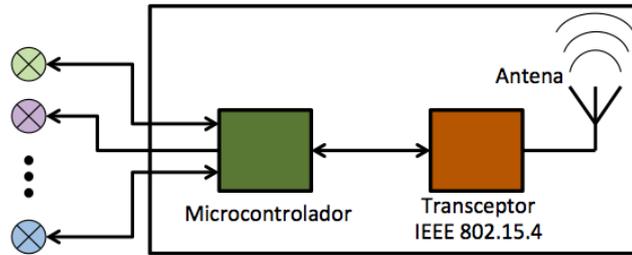


Figura 6: Arquitetura básica dos módulos remotos (ARAÚJO, 2009)

As estações base (EB) são localizadas em um ponto da via, próximo a alguma das estações de passageiros. Elas são compostas de um Nó Coordenador integrado a um *gateway* para interligação com a rede intranet. Já o *gateway* é composto por um microcontrolador de alto desempenho (ver Figura 6), responsável por decodificar os dados vindos da rede de sensores sem fio e disponibilizar esses dados utilizando o protocolo TCP/IP para a intranet, que interliga as estações base e a estação central (EC).

O Centro de Controle Operacional (CCO) é responsável pela recepção, armazenamento e visualização das medidas obtidas em tempo real. O sistema de supervisão localizado no CCO receberá os dados enviados pela intranet de todas as EB, extrairá os dados referentes às medidas obtidas e mostrará em tempo real estas informações, possibilitando ao controlador de tráfego ter a mesma visão que o operador do trem na cabine. Este sistema, através das medições enviadas pelas EM, nos testes desenvolvidos apresenta em tempo real a velocidade, posição, pressão média nas bolsas de ar, estimativa de passageiros, nível de conforto do usuário, tensão e corrente elétrica, potência elétrica consumida e torque de eixos da TUE em movimento nas vias (ARAÚJO, 2009).

A Figura abaixo demonstra um exemplo de visão de como estes componentes estarão dispostos na ferrovia.

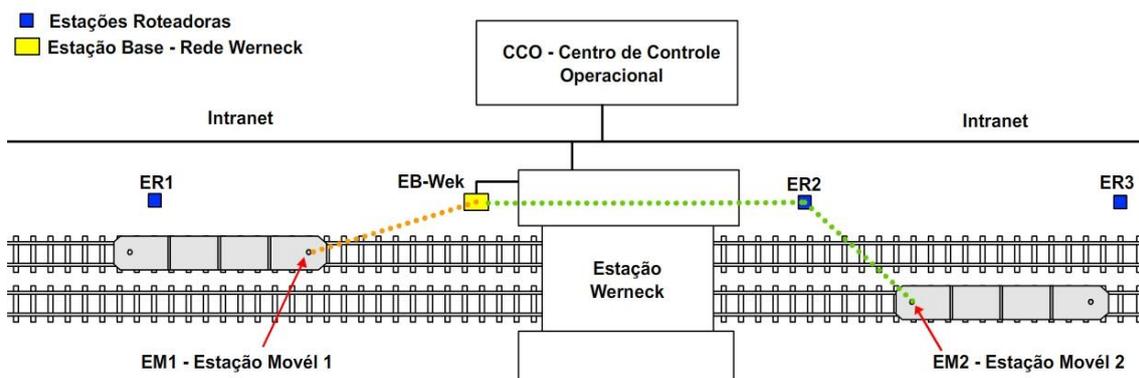


Figura 7: Distribuição dos nós da rede ZigBee em um trecho da via (SANTOS, 2010)

A Figura 7 mostra um mapa das linhas atualmente existentes no MetroRec. O sistema foi instalado inicialmente na linha vermelha mostrada na figura, que liga Recife a Jaboatão. Ao todo, são 14 estações de passageiros entre Recife e Jaboatão, separadas por uma distância de aproximadamente 1,2 km. Nesta linha, operam comercialmente das 5h às 23h, nos períodos de maior fluxo de passageiros pela manhã (5h20 às 7h50) e tarde/vespertino (17h às 19h30), 14 TUE que circulam com um intervalo mínimo de 5 minutos. No restante do dia, circulam 9 TUE com um intervalo de 7,5 minutos. São realizadas 300 viagens durante o dia, ou seja, 150 partidas da Estação Recife, 75 partidas da Estação Jaboatão e 75 partidas da Estação Camaragibe (SANTOS, 2009).

Nessa linha está localizado o Edifício Operacional Administrativo (EOA) e o Centro de Manutenção de Cavaleiro. No EOA, que está situado próximo à estação Werneck, encontra-se o CCO (Centro de Controle Operacional).

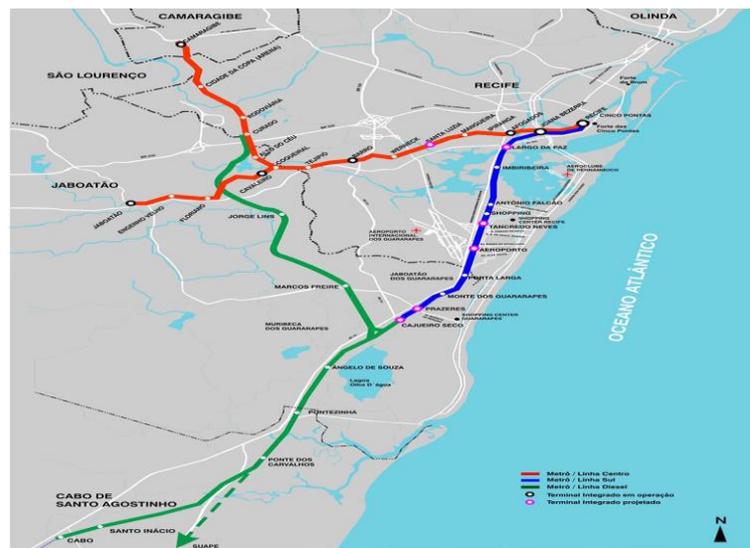


Figura 8: Mapa das linhas do MetroRec (ARAÚJO, 2009)

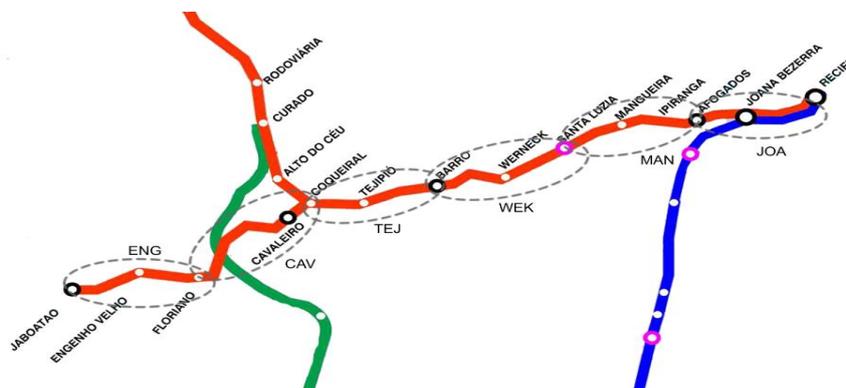


Figura 9: Localização das redes na linha Recife-Jaboatão (ARAÚJO, 2009)

Segue algumas das vantagens apresentadas por este sistema telemétrico desenvolvido (ARAÚJO et al., 2010):

- **Redução no intervalo entre trens** nos horários de pico nos trechos de maior carregamento;
- **Otimização dos trens programados** para a operação comercial, mantendo-se a mesma demanda elétrica contratada, porém com a maior produtividade do TUE;
- **Aumento na segurança para os usuários** com a redução do fluxo deles no embarque / desembarque nos horários de pico;
- **Redução no tempo de parada nas plataformas** para embarque/desembarque de passageiros nos horários de pico, **diminuindo o tempo de viagem**;
- Acompanhamento *on line* do **tempo de parada dos trens** nas plataformas e **estimativa dos usuários** no interior dos TUE, bem como o nível de **conforto** disponibilizado aos usuários;
- **Desempenho** do trem em relação à **velocidade** em tempo real;
- **Diferentes opções de interfaces** que permitam ao controlador visualizar as medidas, exibindo gráficos dos dados obtidos **em tempo real**;
- **Permissão aos engenheiros para gerarem relatórios dos dados** armazenados, a fim de serem realizados estudos que auxiliem nas tomadas das medidas preventivas e corretivas.

Assim, neste sentido, foram realizados novos levantamentos de dados através da tecnologia e sensores relatados nesta seção e proposta uma nova abordagem com a finalidade de redução do consumo da energia elétrica.

## CAPÍTULO IV

### MATERIAIS E MÉTODOS

Neste capítulo, é proposta uma metodologia com o objetivo de apresentar um modelo para a otimização do gasto energético em sistemas metroferroviários utilizando algoritmos genéticos, intitulado GeneticBee, abordando a otimização do *Speed Profile*, que consiste em melhorar o controle dos perfis de velocidade dos trens a fim de reduzir o consumo de energia, considerando os limites de velocidades permitidos, o tempo de viagem e a distância percorrida.

Para a otimização, foram analisadas estratégias para encontrar a eficiência energética em malhas metroferroviárias, onde foi avaliado um conjunto de variáveis relativas ao consumo de energia e ao comportamento de condução manual do trem. A pesquisa é relevante, visto que atualmente existem muitos incentivos governamentais visando o racionamento do uso da energia, devido às crescentes preocupações ambientais e elevados preços da energia consumida.

Assim, ao final, pretende-se que este trabalho auxilie os Centros de Controle Operacional (CCO) das companhias ferroviárias, beneficiados pela tecnologia inteligente gerada através deste trabalho. O perfil de velocidade será controlado sob a supervisão deste centro gestor do tráfego. O intuito é que futuramente possa-se cada vez mais automatizar este processo.

#### 4.1 METODOLOGIA ADOTADA

Para a otimização do *Speed Profile*, foi proposto inicialmente um Modelo Teórico de Eficiência em Trens Urbanos, com o objetivo de fornecer estratégias de condução

energeticamente eficientes, em termos de perfis de velocidade, levando em considerações metas, restrições e limites do trecho analisado.

O modelo proposto, posteriormente, foi “calibrado” com dados coletados nos trens das estações da CBTU/Recife, detalhados no decorrer deste capítulo. O objetivo foi demonstrar que o consumo é muito variável, dependendo do perfil de velocidade e comportamento do condutor. A finalidade principal foi demonstrar que os modelos devem ser capazes de demonstrar perfis de velocidade reais, como também deve sugerir as melhores estratégias de condução para cada trecho de uma determinada estação metroferroviária analisada.

Como é possível ver na Figura 10, o modelo proposto para a otimização de *Speed Profile* funciona da seguinte forma: a partir dos dados coletados, inicialmente, foram analisados os perfis de velocidade em relação determinados trens que trafegam em um trecho de uma estação à outra, e então através das *Simulações Empíricas* e *Simulações com o AG*, foram geradas algumas possíveis melhores soluções para a otimização dos perfis de velocidade.

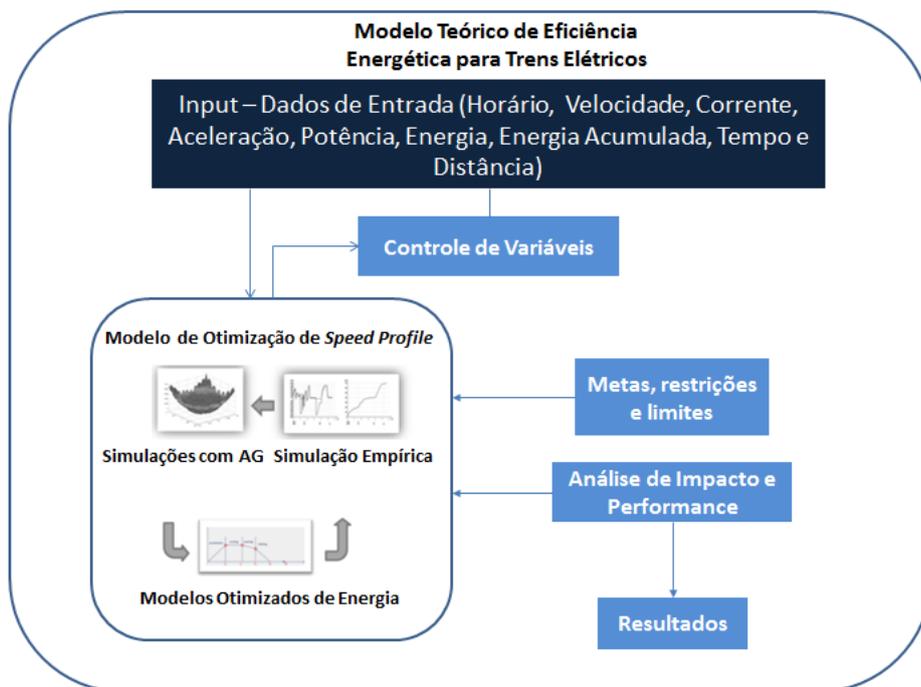


Figura 100: Modelo Teórico de Eficiência Energética (Próprio autor).

Assim, com base nos resultados, construiu-se alguns *Modelos Otimizados de Energia* relativos aos trechos analisados, onde foram avaliados seus impactos e

performances. O modelo teórico de eficiência energético proposto é especificado de modo que se encontre a melhor solução para um trecho específico da malha metroferroviária.

#### **4.1.1 Input – Dados de Entrada**

Para compor o *database*, que conterà os dados de entrada para o nosso modelo, foram coletadas através de sensores as seguintes variáveis: **horário**, **velocidade** e **corrente**. Essas são as principais variáveis necessárias para os cálculos matemáticos relacionados à eficiência energética e desenvolvimento do modelo. Também foram coletados valores da pressão das bolsas de ar do trem (suspensão), bem como valores do freio do trem. Porém, esses parâmetros serão desconsiderados neste trabalho, pois não é o objetivo da análise.

Assim, foram coletadas estas variáveis no trecho entre as estações Coqueiral, Alto do Céu, Curado e Rodoviária. A ideia é avaliar, inicialmente, as curvas de velocidade, aceleração, potência e energia gerada pelos TUEs. Neste trabalho foi sugerida a avaliação destes três trechos do Sistema de Trens METROREC, mas em uma proposta futura pode ser modificado para outros trechos que sejam adequados para a utilização e avaliação através de nosso modelo GeneticBee. Contudo, ao final com os resultados obtidos, há uma estimativa de quanto de energia pode ser poupada em toda extensão da Linha analisada. Além disso, o trabalho pode servir de protótipo para a análise de trechos de outras companhias ferroviárias que utilizem energia elétrica para locomoção dos trens.

#### **4.1.2 Modelo de Otimização do *Speed Profile***

##### **4.1.2.1 Simulação Empírica**

Tendo os dados de entrada (horário, velocidade, corrente) e através dos cálculos matemáticos, serão realizadas algumas simulações empíricas por trecho, onde serão levantados gráficos a serem analisados, conforme a Figura 11. O objetivo da simulação empírica é realizar uma simulação experimental dos dados reais, analisando todas as variáveis referentes à eficiência energética nos trechos durante o tempo determinado para a operação do trem e, assim, examinar o que pode estar impactando na energia consumida pelos trens. Abaixo, a figura exhibe todo o processo de captação dos dados até sua

simulação, onde serão retornados gráficos compostos pelas curvas de velocidade, potência, aceleração, energia, dentre outros.

Com relação aos dados, temos:

- Dados de entrada: Horário, Velocidade e Corrente;
- Dados Constantes: Tensão, Distância;
- Dados gerados: Tempo, Aceleração, Potência, Energia e Energia Acumulada.

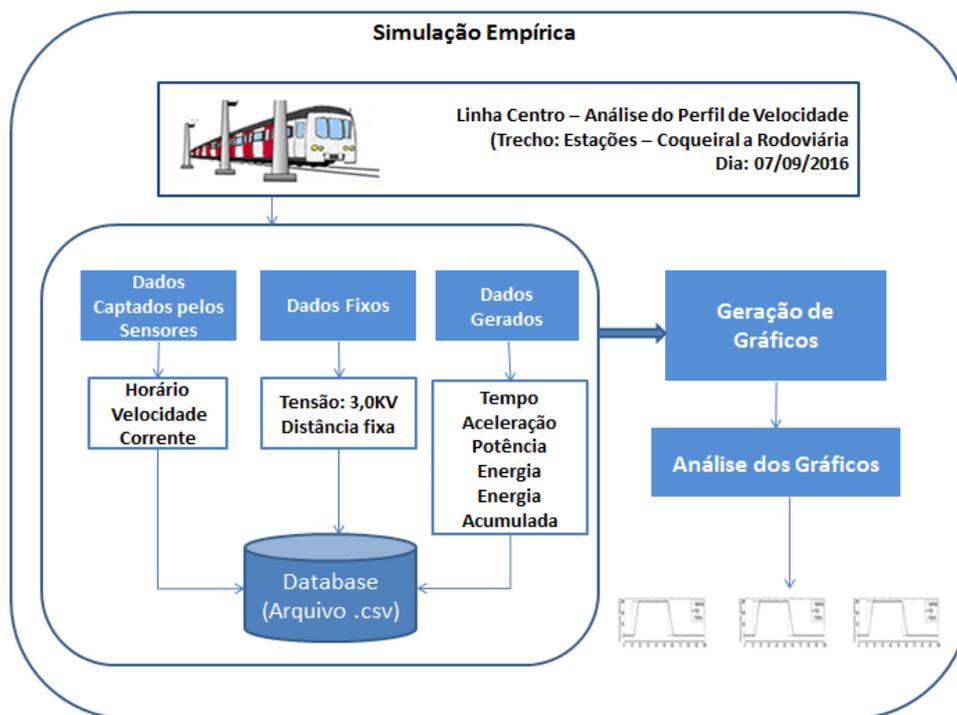


Figura 11: Simulação Empírica (Experimental)

#### 4.1.2.2 Otimização utilizando Algoritmos Genéticos

É possível afirmar que o núcleo deste trabalho está nos estudos com os Algoritmos Genéticos, no retorno satisfatório encontrado através deles para a resolução do problema. Foi necessária uma pesquisa aprofundada de todas as etapas do Algoritmo Genético básico proposto por Holland (1975), as quais foram adaptadas de acordo com as necessidades e levantamento do domínio do problema. Abaixo, segue a Figura 12 do fluxo do Algoritmos Genético desenvolvido neste trabalho. Todas as suas etapas estão detalhadas a seguir:

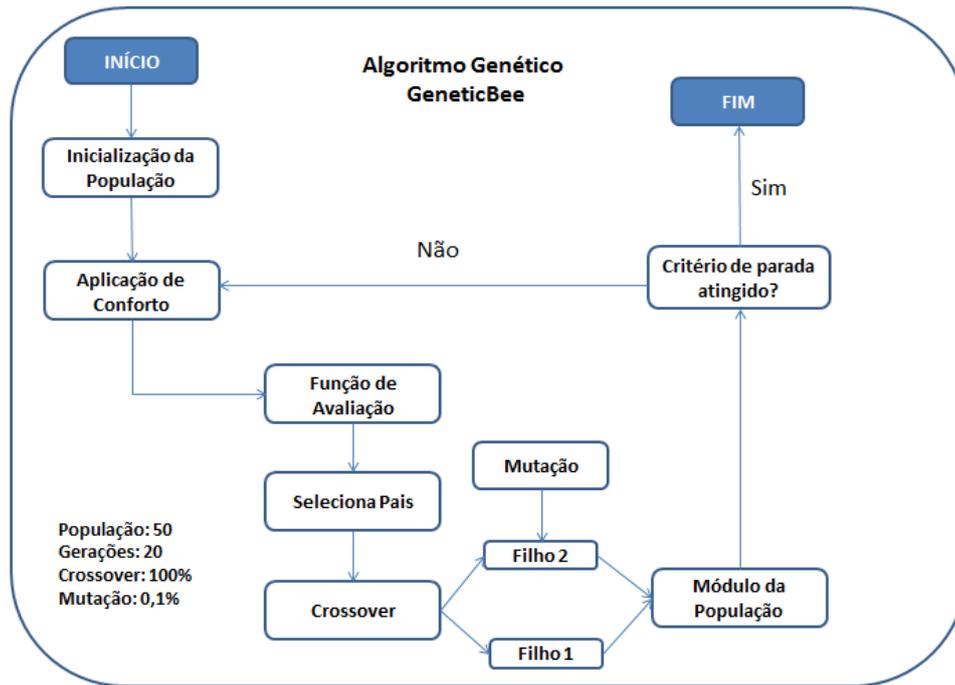


Figura 12: Modelo – Algoritmo Genético

#### 4.1.2.2.1 Representação Cromossomial Adotada

A codificação é uma das partes mais importantes no desenvolvimento de um AG, sendo essencial na tarefa de traduzir o problema real em questão em um modo a ser tratado pelo computador. Normalmente, para a representação do problema, utilizam-se valores binários, mas para o contexto deste trabalho, que é um problema que envolve variáveis e parâmetros contínuos, será adotada a representação real, onde o gene será representado por parâmetros pertencentes a uma parte do trecho de uma estação a outra, pertencente à Linha Centro do METROREC, melhor detalhado mais a frente.

Segundo Linden (2012), a representação binária de tamanho fixo tem dominado a pesquisa de algoritmos genéticos desde o seu início. Contudo, boas características dos AGs e seu bom desempenho na busca de soluções não têm relação direta com o fato de usarmos uma representação binária. Em muitos casos, o mais natural seria representar diretamente os parâmetros sendo otimizados como números reais, onde neste caso, espaços de busca contínuos são representados de forma mais direta e, conforme esperamos, de forma mais eficiente. Ele diz ainda que a representação usada tem que se adequar ao problema, e não o contrário.

Assim, há variáveis de interesse ao nosso problema os seguintes parâmetros: Horário, Tempo, Distância, Velocidade, Aceleração, Corrente, Potência e Energia. Segue a representação real de nosso cromossomo:

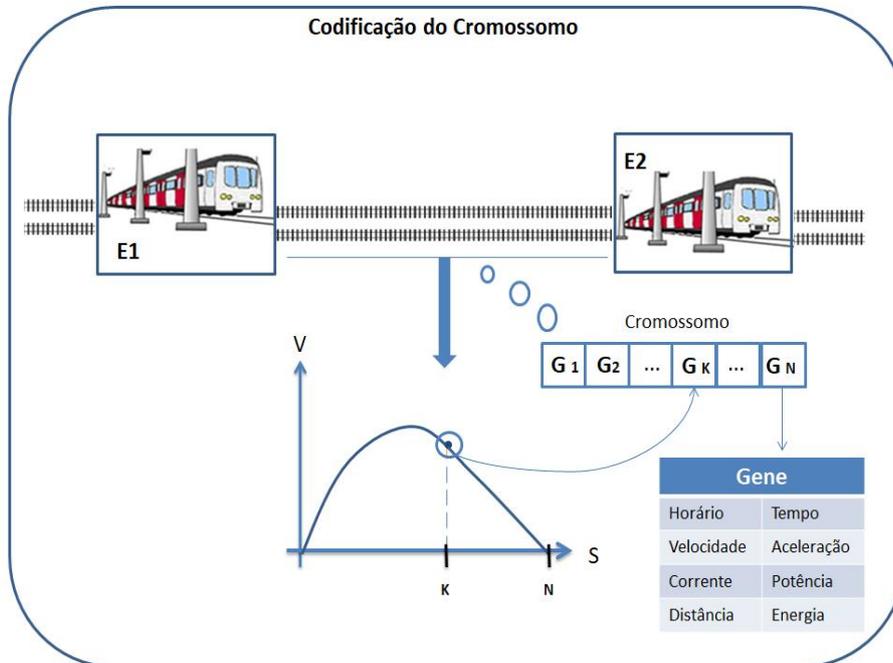


Figura 13: Codificação do cromossomo

Ou seja, há um determinado trecho entre a estação **E1** e **E2**, onde cada cromossomo significa uma estratégia de controle de tráfego a ser avaliada e está codificada como um vetor estrutural que consiste em **N** elementos, onde cada elemento é nomeado como um gene (ver Figura 13). Cada gene é parte indivisível de um cromossomo, sendo assim, neste caso cada gene conterá informações sobre todos os parâmetros definidos para o problema.

A qualidade dos indivíduos (cromossomos) gerados será qualificada através da função de avaliação, detalhada mais à frente.

#### 4.1.2.2.2 Inicialização da População

Segundo Linden (2012), a inicialização da população deve ser feita de uma das três formas descritas abaixo:

- De forma mais simples possível, fazendo-se uma escolha aleatória;

- Dividindo o espaço de busca em  $k$  espaços iguais, selecionando  $n/k$  indivíduos em cada um destes espaços;
- A inicialização da população também pode ser feita através de uma população conhecida.

Assim, neste trabalho é adotada a inicialização aleatória, contudo cada indivíduo é iniciado aleatoriamente baseado nos dados reais captados através dos sensores no METROREC, respeitando os limites e/ou restrições do trecho.

#### 4.1.2.2.3 Aplicação de Conforto

Foi observado durante o desenvolvimento da Inicialização da População que alguns genes dos cromossomos possuíam uma diferença elevada se comparados aos genes vizinhos, o que não seria interessante na prática, para a condução manual do trem, pois traria desconforto para os passageiros. E, assim, na fase de testes do modelo, quando eram executados os operadores de crossover e mutação, o problema persistia. Desta forma, foi visto que esta correção (suavização) deveria ser realizada ainda na Inicialização da População para promover um conforto e a viabilidade dos perfis de velocidade gerados.

Na aplicação do conforto, o algoritmo irá percorrer todo o cromossomo e realizar uma média entre os 5 genes adjacentes, ou seja, será realizada esta média entre todos os genes e seus vizinhos, provendo uma suavização de valores entre eles.

#### 4.1.2.2.4 Função de Avaliação

A função de avaliação é a maneira utilizada pelos AGs para determinar a qualidade de um indivíduo como solução do problema em questão. É uma nota dada ao indivíduo na resolução do problema. Será usada para a escolha dos indivíduos pelo módulo de seleção de pais, sendo a forma de diferenciar entre as boas e as más soluções para um problema (LINDEN, 2012).

Sabe-se que os Algoritmos Genéticos podem ser vistos como métodos de maximização, ou seja, a função de avaliação  $f(x)$  será maximizada. Contudo, como o objetivo deste trabalho é encontrar soluções que gastem o mínimo de energia para a operação dos trens, deve-se inverter o resultado da função de gasto de energia total, que é representada na função por  $Et(x)$ :

$$f(\mathbf{x}) = \frac{1}{Et(\mathbf{x})} \quad (\text{Equação 1})$$

Antes de dar início à demonstração de como é calculada a função de avaliação, é necessário informar que o  $\mathbf{x}$  representado nas equações se refere a um cromossomo e o  $\mathbf{y}$  a cada gene deste cromossomo.

Para se chegar ao resultado exato da função de avaliação  $f(\mathbf{x})$ , primeiramente calcula-se o tempo e aceleração em cada gene  $\mathbf{y}$  do cromossomo  $\mathbf{x}$ , como segue:

$$t_{x,y} = \frac{d_{x,y}}{v_{x,y}}, \quad (\text{Equação 2})$$

$$a_{x,y} = \frac{v_{x,y}}{t_{x,y}}, \quad (\text{Equação 3})$$

Em seguida, tendo o valor da aceleração, encontra-se a corrente  $I_{x,y}$  baseada na função de regressão linear gerada para o trecho através do MATLAB (mais informações esta função no item do próximo capítulo):

$$I_{x,y} = p_1(a_{x,y}) + p_2 \quad (\text{Equação 4})$$

Feito isto, encontramos o valor da Potência  $P_{x,y}$ :

$$P_{x,y} = I_{x,y} * U \quad (\text{Equação 5})$$

O valor da energia consumida  $Ec_{x,y}$  em um gene de um cromossomo  $\mathbf{x}$  é calculada através da integral da variação da potência no tempo:

$$Ec_{x,y} = \int P_{x,y} dt \quad (\text{Equação 6})$$

Ao final, tem-se a Energia Total  $Et(x)$  gasta pelos genes em um cromossomo, onde o valor encontrado é invertido na função  $f(x)$ , trazendo finalmente o resultado da função de avaliação daquele cromossomo:

$$Et(x) = \sum_{y=1}^N (Ec_{x,y}) \quad \rightarrow \quad f(x) = \frac{1}{Et(x)}$$

Temos:

$f(x)$  = função que o algoritmo deseja maximizar;

$t$  = tempo do trem no gene  $y$ ;

$a$  = aceleração do trem no gene  $y$ ;

$I$  = corrente do trem no gene  $y$ ;

$p1$  e  $p2$  são as constantes encontradas através dos dados reais de aceleração e corrente calculados através do MATLAB;

$P$  = potência do trem no gene  $y$ ;

$Ec$  = energia consumida no gene  $y$ ;

$Et$  = energia total do cromossomo  $x$ ;

$N$  = quantidade de genes.

Em resumo, a função de avaliação irá percorrer todos os genes de um cromossomo e ao final retornará um valor final de  $F(x)$ . Desta forma, aqueles cromossomos com as melhores notas em sua avaliação estarão mais aptos a permanecerem na população no decorrer das gerações, sendo um forte candidato a melhor solução, enquanto os que obtiveram piores notas poderão ser descartados posteriormente. É importante ressaltar ainda que, caso um cromossomo possua um valor de tempo que não esteja dentro intervalo definido para o trecho, ele sofrerá uma penalidade. Assim, o valor da  $Et$  será multiplicado por dois ( $f(x) = \frac{1}{2 * Et(x)}$ ), fazendo com que a probabilidade que ela seja escolhido posteriormente diminua.

#### 4.1.2.2.5. Seleção dos Pais

A técnica para a seleção dos pais reproduz o método de seleção natural das espécies, onde os indivíduos com o valor da função de avaliação alta são privilegiados se

comparados aos indivíduos menos aptos, ou seja, com função de avaliação muito baixa. Contudo, mesmo assim, os indivíduos menos aptos podem ter algumas características boas e favoráveis à geração de indivíduos ótimos e por isso poderão ser selecionados.

- Método da Roleta:

Uma roleta (virtual) é criada, onde cada cromossomo recebe um pedaço proporcional à sua avaliação (a soma dos pedaços corresponde a 100%). Após a roleta ser rodada, será selecionado o indivíduo sobre o qual ela parar. Normalmente, a probabilidade do indivíduo com maior aptidão ser selecionado é maior em detrimento aos indivíduos com menor aptidão, visto que os indivíduos com melhores resultados no cálculo *fitness* (função de avaliação) tendem a ocupar um espaço maior na roleta.

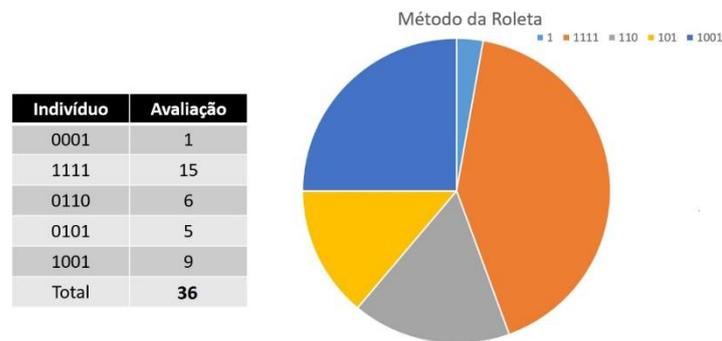


Figura 14: Método da Roleta

- Método do Torneio:

São escolhidos aleatoriamente dois ou mais indivíduos e comparadas suas aptidões através dos valores “fitness” da função de aptidão, onde o que obtiver o melhor valor será selecionado como o melhor. Inicialmente, há que se determinar o valor do atributo K, pois é ele que irá definir qual a quantidade de indivíduos que deve ser escolhida aleatoriamente para competir. Na Figura 15, é possível verificar duas tabelas, na primeira tabela temos a relação entre os indivíduos e sua avaliação. Já na segunda, pode-se verificar os 3 indivíduos escolhidos em cada linha e qual obteve a maior avaliação entre eles.

Em nosso método do AG, serão utilizados tanto a técnica da Roleta quanto o Torneio, onde será avaliado experimentalmente o comportamento e o retorno dos resultados. Com isso, será aprimorado o Algoritmo Genético através de experimentos, experiência e do domínio do conhecimento quanto à modelagem e funcionamento dos

perfis de condução. O AG proposto será aprimorado gradativamente, após os testes e variadas técnicas serem utilizadas, podendo, até mesmo, ocorrer uma junção de mais uma técnica a fim que o retorno do algoritmo seja o melhor possível para a solução.

**Método do Torneio para k = 3**

Indivíduo	Avaliação	1	2	3	
x1	1	x2	x1	x4	x2
x2	15	x4	x3	x1	x3
x3	6	x5	x3	x3	x5
x4	5	x1	x3	x4	x3
x5	9	x4	x4	x4	x4

Figura 15: Método do torneio

#### 4.1.2.2.6. Tipos de Crossover

- Um ponto

Depois de selecionados dois pais pelo módulo de seleção de pais, um ponto de corte é selecionado. Um ponto de corte constitui uma posição entre dois genes de um cromossomo. Depois de sorteado o ponto de corte, separou-se os pais em duas partes: uma à esquerda do ponto de corte e outra à direita. É importante notar que não necessariamente estas duas partes têm o mesmo tamanho. O primeiro filho é composto através da concatenação da parte esquerda do primeiro pai com a parte direita do segundo pai. O segundo filho é composto através da concatenação das partes que sobraram (a metade esquerda do segundo pai com a metade à direita do primeiro pai) (LINDEN, 2012).

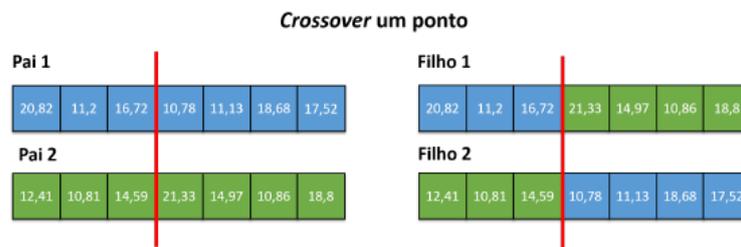


Figura 16: Exemplo operação crossover – Um ponto

- Dois pontos

Segundo Coppin (2004), nesse crossover, dois pontos são escolhidos para dividir os cromossomos em duas seções, com as seções externas juntando-se para transformar o cromossomo em um anel. As duas seções são trocadas como mostrado na Figura abaixo:

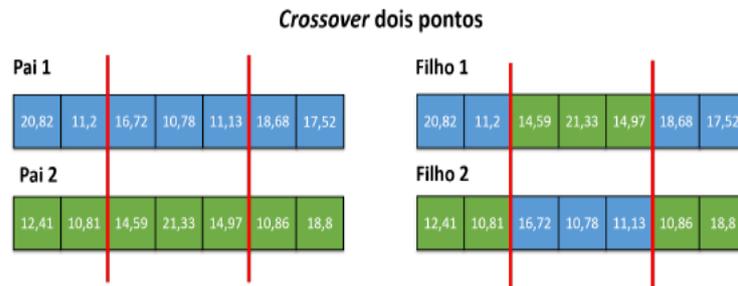


Figura 17: Exemplo operação crossover – Dois pontos

- Uniforme

Linden (2012) afirma que no crossover uniforme ou crossover discreto, faz-se um sorteio para escolher em cada posição um elemento pertencente ao conjunto dado por  $\{c_i^1, c_i^2\}$  e o segundo filho recebe o elemento não sorteado para o primeiro. Um exemplo do funcionamento deste operador pode ser visto na Figura 18. Este operador é mais eficiente quando a função de avaliação é linear, não havendo termos cruzados entre os valores armazenados.

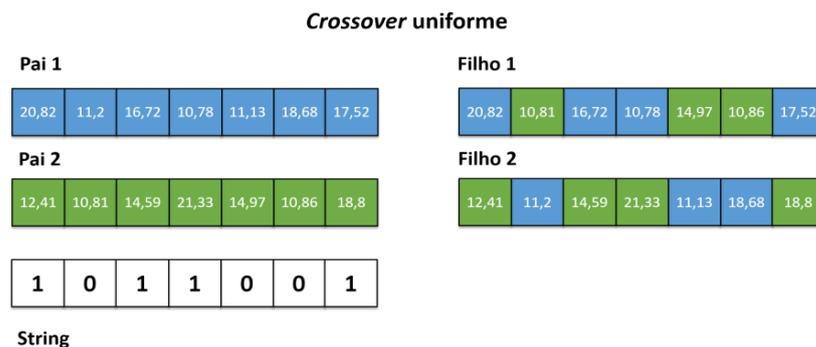


Figura 18: Exemplo operação crossover – Uniforme

- Média Aritmética

Nesse crossover é realizada a média entre os valores dos genes de cada pai, ou seja, será feita a média com o primeiro gene do primeiro pai e o primeiro gene do segundo pai, esse processo continua até que seja feita a média entre o último gene do primeiro pai com o

último gene do segundo pai, gerando assim um novo valor (caso os genes não sejam os mesmos) para o filho como mostrado na Figura 19. Assim sendo,  $p_i^1$  e  $p_i^2$  são os cromossomos pais,  $c$  o cromossomo filho e  $i$  um gene do cromossomo. Para a média aritmética é expressa na equação abaixo (SOUZA, 2014).

$$c_i = \frac{(p_i^1 + p_i^2)}{2}$$

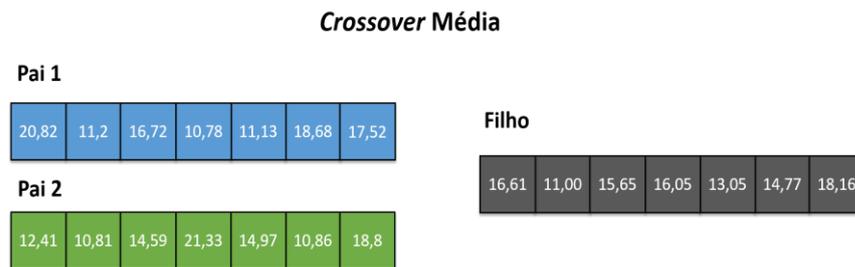


Figura 19: Exemplo operação crossover – Crossover Média

#### 4.1.2.2.7 Mutação Uniforme e Limite

A operação de mutação uniforme é realizada após o processo de reprodução ou crossover, onde é modificado um ou mais números do cromossomo com uma probabilidade baixa que varia de 0,1% a 5% de forma aleatória e dentro dos limites do intervalo permitido. Já na mutação limite um ou mais números do cromossomo é substituído pelo valor de um dos limites do intervalo permitido.

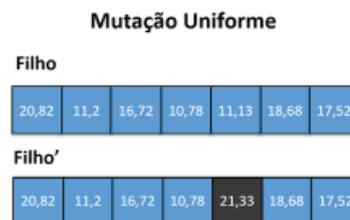


Figura 20: Exemplo operação mutação – Uniforme

O operador de mutação é importante dentro de um AG, pois quando ocorre, tende-se a uma diversificação maior de indivíduos, encontrando novas soluções no espaço de busca.

#### 4.1.2.2.8 Módulo da População

O tamanho da população está diretamente relacionado com o desempenho global e com a eficiência dos Algoritmos Genéticos (HAUPT, HAUPT, 1998). Assim, o módulo da população é gerada aleatoriamente e por simplicidade. Nos estudos de Holland (1975) foi definido que a população não pode crescer. Ou seja, ela será armazenada em um vetor de tamanho constante, desta forma os pais serão substituídos conforme os filhos forem nascendo.

Assim, sabe-se que a cada aplicação dos operadores genéticos do tipo crossover, criam-se filhos que serão armazenados neste vetor até que o número de filhos criados contenha a quantidade igual ao tamanho da população já pré-definida. Sabe-se que a cada atuação do operador genético cria-se filhos. Os pais então serão substituídos por seus filhos, ficando em seu lugar nas posições de memórias. Esses novos filhos serão os pais da nova geração.

Importante ressaltar que a cada geração tem-se a possibilidade de guardar o melhor pai para a população seguinte ou descartá-lo.

## 4.2. RESUMO SOBRE O FUNCIONAMENTO DO AG

Para este problema, define-se a Inicialização da População aleatoriamente, contudo eles serão baseados nas informações dos dados reais captados pelos sensores. É definido que nossa população conterà 50 indivíduos e que passará por no máximo 20 gerações. A função de avaliação (auxiliada pela função de regressão) foi definida para o problema aqui proposto com a finalidade de atribuir a cada cromossomo ou indivíduo um valor que o qualificará quanto a mais ou menos aptos dentro da atual geração. Assim, tendo estes valores, realizar-se-á o teste de seleção utilizando o método da Roleta ou Torneio, onde serão selecionados os pais. Através da técnica do crossover, os pais sofrerão Crossover e gerarão seus filhos, os quais podem ou não sofrer mutação, visto que o índice disto ocorrer foi definido em 0,1%. Este processo de seleção ocorrerá até que todos os pais tenham sido substituídos por seus filhos, criando uma nova população com 50 indivíduos. Este ciclo de gerações de novas populações se repetirá até 20 gerações. Mais detalhes sobre o funcionamento do AG e análise dos resultados serão apresentados no próximo capítulo.

## CAPÍTULO V

### APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

#### 5.1 PROJETO DO EXPERIMENTO

Os dados para o experimento foram colhidos na linha centro do METROREC no dia 07/10/2016. Foram analisados três trechos sequenciais, sendo eles: Trecho 1 - Estação Coqueiral a Alto do Céu; Trecho 2 – Estação Alto do Céu a Curado; Trecho 2 – Estação Curado à Rodoviária. Não foi possível analisar todas as estações, devido a problemas na coleta dos dados, contudo nesta amostra foi possível levantar resultados relevantes.

A Figura 21 representa o fluxo do experimento, dividido em Simulação Empírica e Simulação com AG. Na Simulação Empírica foi realizado o seguinte processo:

- **Dados Capturados:** os dados foram recebidos em formato excel (.csv), são eles: **horário** (formato hh:mm:ss), **velocidade** (km/h), **pressão** das bolsas de ar (pmi), **corrente** do motor (ampère) e **freio** (fr). Para o estudo, foi desconsiderado o valor da pressão das bolsas de ar do trem, pois os vagões estavam vazios e não variaram significativamente. Também foram desconsiderados os valores do freio requerido no AG, já que também não foi levado em consideração o atrito, apenas a desaceleração do trem.
- **Limpeza dos dados:** tendo a posse dos dados reais, foi necessário realizar uma limpeza dos dados, no que se refere à quantidade de captações por segundo. Foram realizadas de 5 a 7 captações por segundo, assim, para manter uma constância, os dados foram padronizados para 6 captações por segundo. Desta forma, foi possível realizar os cálculos de forma precisa.

- Conversões e Cálculos: tendo as variáveis principais: **horário**, **velocidade**, **corrente** e tensão fixa (3KV), foi possível então calcular a **distância** (m), **tempo** (s), **aceleração** (km/h<sup>2</sup>), **potência** (KW), a **energia real** (KWh) e a **energia acumulada** (KWh), fazendo as devidas conversões.
- Geração de Gráficos Reais: Com todos os dados relativos à análise da eficiência energética nos trechos, foram gerados 5 tipos de gráficos diferentes, são eles: gráfico do perfil de velocidade, aceleração, potência, energia e energia acumulada. As análises dos gráficos estão descritas no próximo Capítulo, sobre os resultados encontrados.

Na Simulação com AG foi realizado o seguinte processo:

- MATLAB (Geração de Função de Avaliação): Através dos dados reais de aceleração e corrente do trem, foi gerada uma função de regressão polinomial linear. Esta função foi gerada no intuito de ser utilizada como função de avaliação no Algoritmo Genético aqui proposto. Segue o formato da função encontrada, onde o  $I_{x,y}$  representa a corrente a ser encontrada baseada na aceleração, denominada  $a_{x,y}$  e  $p1$  e  $p2$  são as constantes encontradas. Na exemplificação da execução do Algoritmo Genético no capítulo anterior, está detalhado seu funcionamento e importância para a Função de Avaliação adotada neste trabalho.

Segue a Função Polinomial Linear encontrada através dos dados reais entre Coqueiral a Alto do Céu, que norteará o nosso trabalho:

$$I_{x,y} = p_1(a_{x,y}) + p_2$$

- Configuração do Domínio: de acordo com cada trecho a ser analisado, foi levantado várias informações sobre o domínio, suas variáveis e limites. São eles: Tamanho do trecho, máximo e mínimo de todas as variáveis a serem analisadas, etc.
- Configurações dos Operadores: aqui entram definições clássicas dos AG, como tamanho da população, quantidade de gerações, escolha dos operadores de mutação e crossover, criação do módulo da população e escolha da aplicação do conforto nos resultados.

- Execução do AG: configurados todos os parâmetros, conforme itens anteriores, o AG está pronto para ser executado. Os AGs, por utilizarem a metaheurística, não dão garantias de bons resultados sempre que forem executados. Desta forma, o mais apropriado é tentar bons resultados a cada experimento, variando as configurações dos operadores, a fim de encontrar o resultado mais satisfatório possível. Todo o processo de execução de AG está descrito a seguir.
- Resultados: após executar o AG de variadas formas, com configurações distintas, chegou-se a um melhor resultado com relação ao perfil de velocidade, comparando sempre com os dados reais. Os gráficos gerados e o novo perfil de velocidade sugerido estão demonstrados no Capítulo de Resultados.

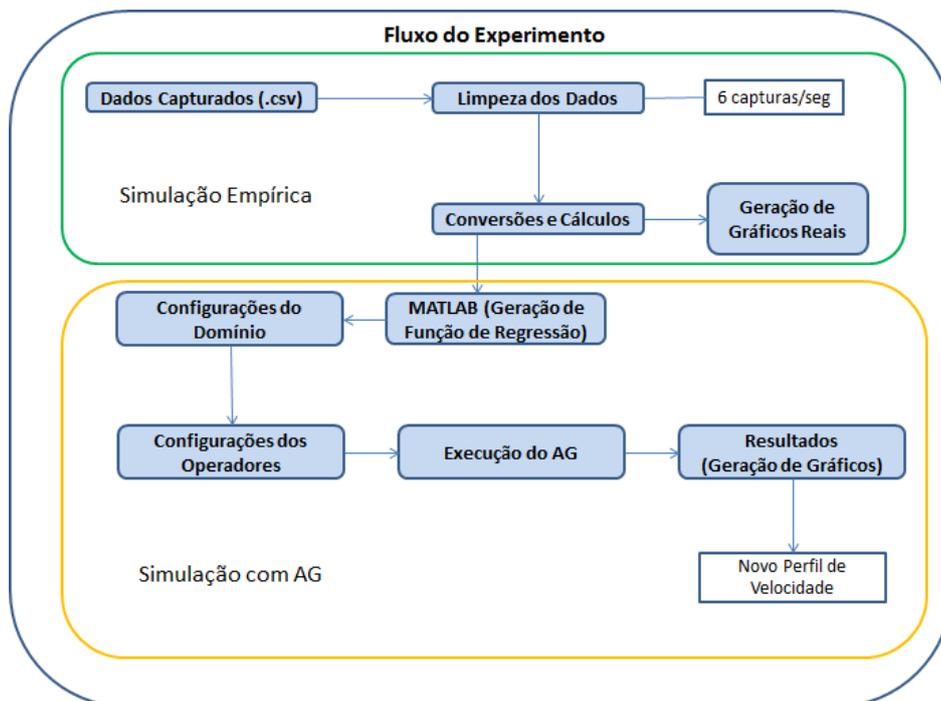


Figura 21: Fluxo do Experimento

Como prova de conceito do modelo foi desenvolvido um software intitulado “GeneticBee” em parceria com o grupo de pesquisa “Smart Cities” do Laboratório de Inteligência Artificial – LIAA, no Centro de Informática, UFPB (ver Figura 22). Nos itens posteriores, será detalhado o passo a passo de como foram executados os experimentos

neste software referentes ao modelo proposto, nos quais foram utilizados dados reais do METROREC.



Figura 16: Software GeneticBee 1.0

## 5.2 ANÁLISES DO EXPERIMENTO - COQUEIRAL À RODOVIÁRIA (07/10/2016)

Recapitulando, foram analisados os seguintes trechos do METROREC, com dados captados no dia 07/10/2016, são eles:

**Trecho 1: Coqueiral a Alto do Céu** onde o tamanho do trecho é de aproximadamente 1118m;

**Trecho 2: Alto do Céu a Curado**, onde o tamanho do trecho é de aproximadamente 852m;

**Trecho 3: Curado à Rodoviária**, onde o tamanho do trecho é de aproximadamente 1040m;

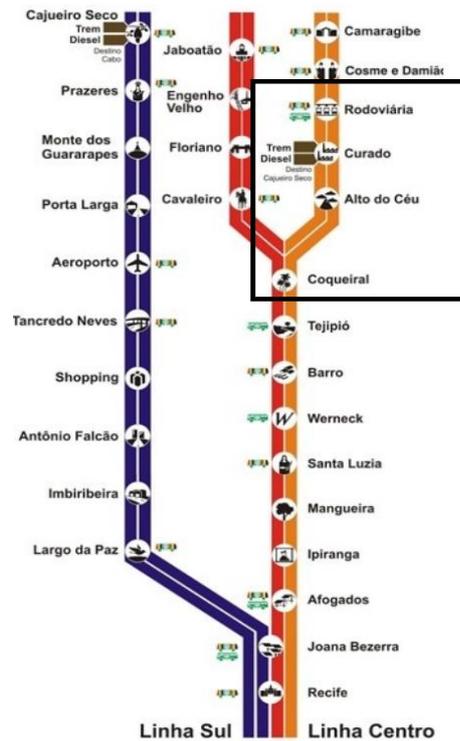


Figura 17: Linhas METROREC – Trechos escolhidos (CBTU, 2017)

Assim, a partir dos dados coletados pelos sensores foi definido o Perfil de Velocidade baseado na condução manual do trem. Além disto, foi definida a base para criar a população inicial do AG e também foi proposta uma configuração do domínio, que nos fornece os limites reais máximos de velocidade, aceleração, dentre outras variáveis, por trecho.

Após a execução do software GeneticBee, foram investigadas variadas formas de parametrizar as configurações do domínio e operadores, inclusive porque o software é facilmente editável, nos trazendo resultados que variam conforme o uso da plataforma.

Com relação ao uso do software, é importante destacar ainda quais parâmetros são editáveis e quais foram escolhidos, por trazer os melhores resultados e perfil de velocidade com um menor gasto energético. Por isso, segue a análise a seguir:

Com relação às “Configurações do Domínio”, todos os campos são editáveis, conforme Figura 24. Contudo, o Tamanho do Trecho, o Tempo e os valores das variáveis foram preenchidas automaticamente baseadas nos dados reais e, assim, optou-se por não modificar tais valores.

A folga com relação ao Tempo na execução do AG foi variável em 10 segundos para que o AG pudesse variar este tempo para encontrar a melhor solução, sem que impactasse muito no Timetable já pré-definido pelo METROREC.

A variação da velocidade fixamos em 3Km/h para mais ou para menos, para que também o AG pudesse fazer uma melhor varredura no espaço de busca e, assim, encontrar uma melhor solução.

The screenshot shows the 'Configurações do Domínio' window in the GeneticBee 1.0 application. The window has a menu bar at the top with options: 'Página Inicial', 'Arquivos', 'Análise dos Dados Reais', 'Configuração Domínio', 'Configuração Operadores', 'Resultados', 'Ajuda', and 'Sobre'. Below the menu bar, there is a 'Validar' button with a green checkmark icon. The main content area is divided into several sections:

- Configurações do Domínio:** This section contains four input fields:
  - Tamanho do trecho (m.): 950
  - Tempo (seg.): 109
  - Folga (seg.): 10
  - Variação da Velocidade: 3
- Função Fitness:** This section contains a radio button labeled 'Função Regressão' which is currently selected.
- Variáveis:** This section contains a table with two columns: 'Máximo' and 'Mínimo'. The rows are:
 

	Máximo	Mínimo
Velocidade	60.176	0.0
Aceleração	20260	-20260
Pressão	44.477	42.717
Corrente	245.845	0.0
Freio	12.64	0.0
Potência	726	1

Figura 18: Configurações do Domínio – GeneticBee 1.0

Com relação à “Configuração dos Operadores” (ver Figura 25), através de vários testes experimentais, foi constatado experimentalmente que a População com tamanho 50 e o número de Geração 20 e Mutação 0.1, trazia um melhor resultado, conforme será demonstrado nos próximos itens.

The screenshot shows the 'Configuração Operadores' window of GeneticBee 1.0. The interface is divided into several sections:

- Configurações Gerais:** Population (50), Generation (10), Mutation (0.1).
- Configurações dos Operadores:** K (3), Lambda (0.3), Alfa (0.5), R (0.7).
- Criação da População:**  Dados.
- Conforto:**  Com Conforto (Média),  Sem Conforto.
- Operadores:**
  - Seleção:**  Roleta,  Torneio.
  - Crossover:**  Um Ponto,  Dois Pontos,  Uniforme,  Heurístico,  Flat,  Aritmético,  Linear,  Média Aritmética,  Média Geométrica,  SBX.
  - Mutação:**  Uniforme,  Limite.
  - Módulo da População:**  Descartar todos os pais,  Melhor pai.

An 'Iniciar' button is located at the bottom right of the configuration area.

Figura 19: Configurações dos Operadores – GeneticBee 1.0

Assim, o experimento foi configurado da seguinte forma:

- Geração
  - Aleatória (baseada em dados reais)
- Seleção
  - Método da Roleta
  - Método Torneio
- Crossover
  - Um Ponto
  - Dois Pontos
  - Uniforme
  - Média Aritmética
- Mutação
  - Uniforme
  - Limite
- Módulo da População
  - Descarta Pais
  - Melhor Pai
- Aplicabilidade do Conforto

- Com Conforto (Média)
- Sem Conforto

Valores utilizados em todos os experimentos:

- População: 50 indivíduos;
- Gerações: 20;
- Taxa de Crossover: 100;
- Taxa de Mutação: 0,1;

Sobre os operadores:

- $K=3$  no parâmetro de seleção por Torneio.

Execuções do experimento:

Primeiramente, será executado o experimento no Trecho 1, conforme configuração relatada acima e os resultados serão expostos da seguinte forma, considerando os seguintes experimentos:

**Resultados I:** Demonstração da Simulação Empírica dos dados reais coletados nos trechos, onde foram realizados os cálculos e conversões necessárias para a demonstração do perfil de velocidade, energia acumulada, aceleração e limites máximos encontrados;

**Resultados II:** Comparação dos operadores - Seleção, Crossover, Mutação e Módulo da População (simulação apenas no Trecho 1);

**Resultados III:** Comparação da Aplicabilidade do Conforto (simulação apenas no Trecho 1);

**Resultados Finais:** Análise dos gráficos antes e após execução do AG – Gráficos sobre o Perfil de Velocidade, Aceleração, Potência e Energia Acumulada.

## 5.3 RESULTADOS ENCONTRADOS

### 5.3.1 Trecho 1 - Coqueiral a Alto do Céu

#### 5.3.1.1 Resultado I - Simulação Empírica

- **Dados Fixos:**

Tabela 1: Dados Fixos – Trecho 1

Tamanho do Trecho	Tempo	Velocidade Máxima	Energia Total Consumida
1148m	100s	65.455Km/h	9,36KWh

Função de regressão gerada através do MATLAB:

*Linear model Poly1:*

$$f(x) = p1 * x + p2$$

*Coefficients:*

$$p1 = 0.006275 (0.005329, 0.007221)$$

$$p2 = 111.2 (105.3, 117.1)$$

Foram encontrados os valores máximos das seguintes variáveis no trecho analisado, antes da execução do Algoritmo Genético:

**Configurações do Domínio**

Tamanho do trecho (m.):

Tempo (seg.):

Folga (seg.):

Variação da Velocidade:

**Função Fitness**

Função Regressão

**Variáveis**

	Máximo	Mínimo
Velocidade	<input type="text" value="65.455"/>	<input type="text" value="0.0"/>
Aceleração	<input type="text" value="27863"/>	<input type="text" value="-17733"/>
Pressão	<input type="text" value="44.281"/>	<input type="text" value="38.025"/>
Corrente	<input type="text" value="245.356"/>	<input type="text" value="0.488"/>
Freio	<input type="text" value="12.188"/>	<input type="text" value="0.0"/>
Potência	<input type="text" value="726"/>	<input type="text" value="1"/>

Figura 20: Configurações do Domínio – Trecho 1

- **Perfil de Velocidade**

Este é o perfil de velocidade antes da execução do AG, onde a velocidade máxima atingida foi de **65,455Km/h**.

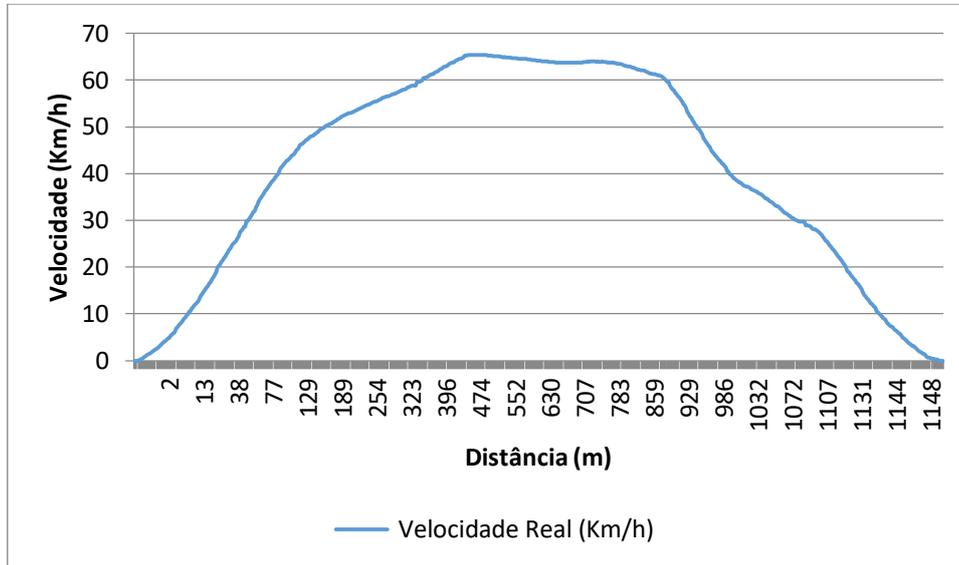


Figura 27: Gráfico do Perfil de Velocidade (Real) - Trecho 1

- **Energia Total Consumida:**

A Energia Total Consumida antes da execução do AG foi de **9,36KWh**.

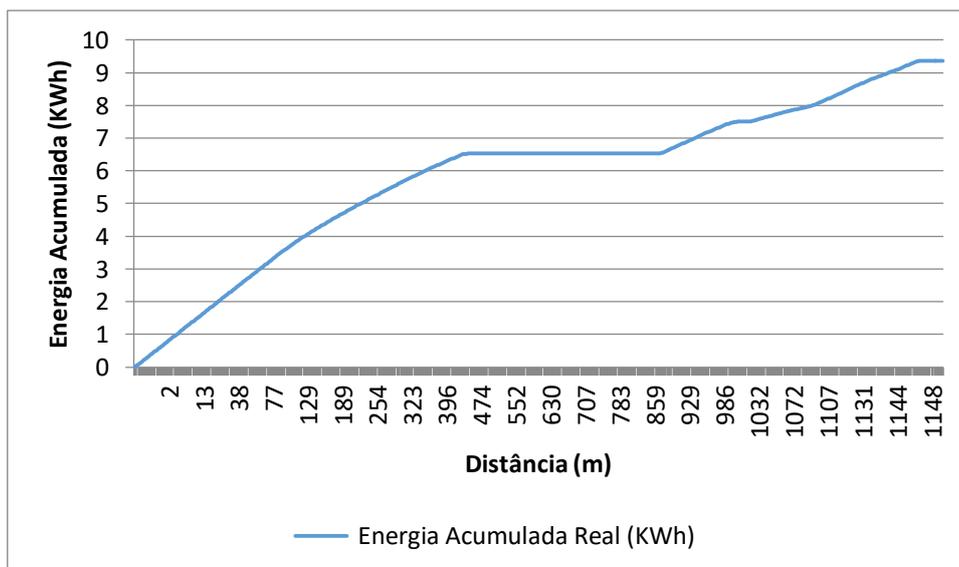


Figura 28: Gráfico do comportamento da energia acumulada (Real) - Trecho 1

- **Análise da Simulação Empírica**

Analisando os gráficos de velocidade, energia e aceleração, percebe-se que o condutor acelera gradativamente até atingir um pico de 27863km/h<sup>2</sup> em 40m percorridos e em seguida começa a desacelerar gradativamente e, em aproximadamente 470m percorridos, ele estabiliza a aceleração, o que faz com que neste momento não ocorra gasto de energia significativo e a velocidade se mantenha relativamente estável até 880m. Após essa distância percorrida, o condutor vai desacelerando cada vez mais, gastando uma energia na frenagem, até o trem parar ao atingir 1148m percorridos.

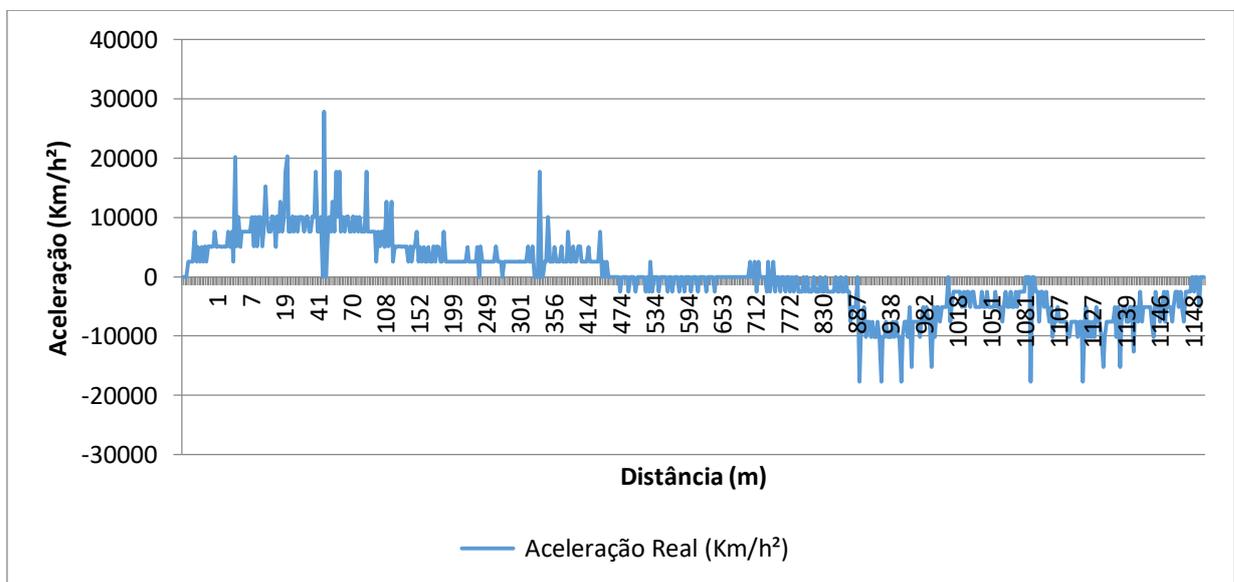


Figura 29: Aceleração km/h (Real) - Trecho 1

### 5.3.1.2 Resultados II – Comparações dos Operadores e Módulo da População

Em seguida, executou-se o AG conforme configurações pré-definidas do experimento, que trouxe os resultados a seguir:

- Segue a avaliação do método de seleção (**roleta**), crossover (um, ponto, dois pontos, uniforme e média), mutação (mutação, limite) e módulo da população (descartar todos os pais, melhor pai).

<b>Configurações Gerais</b> População: <input type="text" value="50"/> Geração: <input type="text" value="20"/> Mutação: <input type="text" value="0.1"/>	<b>Configurações dos Operadores</b> K: <input type="text" value="3"/> Lambda: <input type="text" value="0.3"/> Alfa: <input type="text" value="0.5"/> R: <input type="text" value="0.7"/>	<b>Criação da População</b> <input checked="" type="checkbox"/> Dados	<b>Conforto</b> <input checked="" type="checkbox"/> Com Conforto (Média) <input type="checkbox"/> Sem Conforto
<b>Operadores</b>			
<b>Seleção</b> <input checked="" type="checkbox"/> Roleta <input type="checkbox"/> Torneio	<b>Crossover</b> <input checked="" type="checkbox"/> Um Ponto <input checked="" type="checkbox"/> Dois Pontos <input checked="" type="checkbox"/> Uniforme <input type="checkbox"/> Heurístico <input type="checkbox"/> Flat <input type="checkbox"/> Aritmético <input type="checkbox"/> Linear <input checked="" type="checkbox"/> Média Arimética <input type="checkbox"/> Média Geométrica <input type="checkbox"/> SBX	<b>Mutação</b> <input checked="" type="checkbox"/> Uniforme <input checked="" type="checkbox"/> Limite	<b>Módulo da População</b> <input checked="" type="checkbox"/> Descartar todos os pais <input checked="" type="checkbox"/> Melhor pai
<input type="button" value="Iniciar"/>			

Figura 30: Configuração dos Operadores (Comparação) – Seleção Roleta - Trecho 1

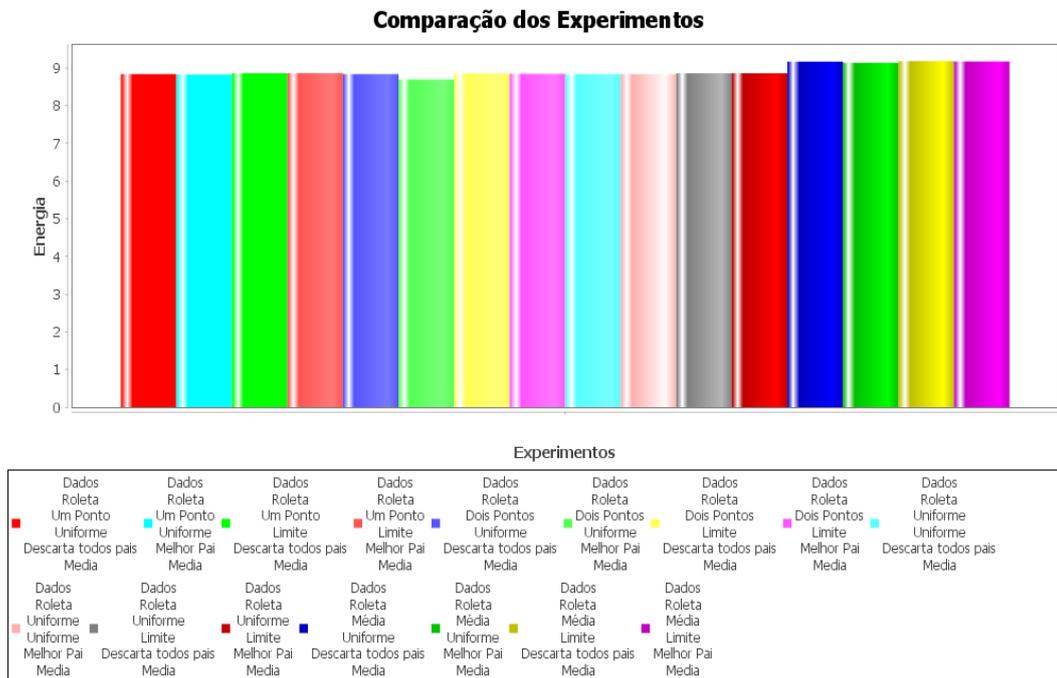


Figura 31: Comparação dos Experimentos – Seleção Roleta - Trecho 1

- Agora, segue a avaliação do método de seleção (**torneio**), crossover (um, ponto, dois pontos, uniforme e média), mutação (mutação, limite) e módulo da população (descartar todos os pais, melhor pai).

**Configurações Gerais**

População:

Geração:

Mutação:

**Configurações dos Operadores**

K:

Lambda:

Alfa:

R:

**Criação da População**

Dados

**Conforto**

Com Conforto (Média)

Sem Conforto

**Operadores**

**Seleção**

Roleta

Torneio

**Crossover**

Um Ponto

Dois Pontos

Uniforme

Heurístico

Flat

Aritmético

Linear

Média Aritmética

Média Geométrica

SBX

**Mutação**

Uniforme

Limite

**Módulo da População**

Descarta todos os pais

Melhor pai

Figura 21: Configuração dos Operadores (Comparação) – Seleção Torneio - Trecho 1

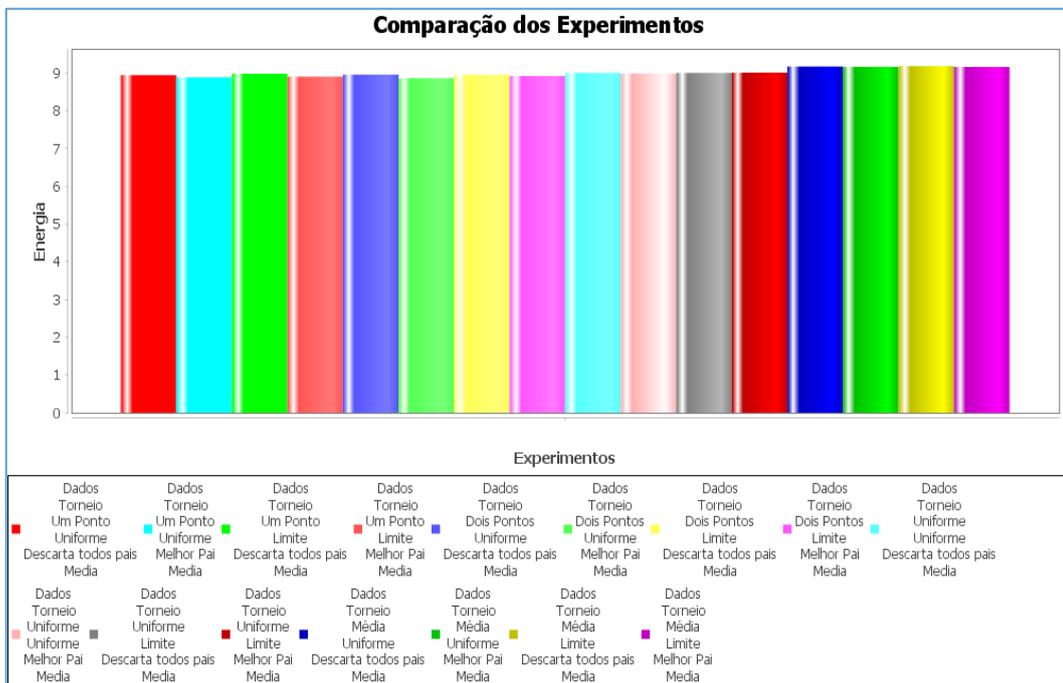


Figura 223: Comparação dos Experimentos – Seleção Torneio - Trecho 1

É possível perceber através do gráfico de barras que, em ambos os testes, os resultados envolvendo os tipos crossover um ponto, dois pontos e uniforme trouxeram resultados com valores próximos e com gasto menor de energia se comparado ao tipo de

crossover média. Os demais tipos de crossover foram estudados, mas não foram detalhados nesta seção de resultados, porque suas análises já foram discutidas no artigo do Enucomp (ENUCOMP, 2016), onde foi demonstrado que não trouxeram bons resultados neste contexto estudado.

Apenas no Trecho 1 foi demonstrada esta análise, no intuito de nortear o leitor, quanto à escolha dos operadores e resultados encontrados. Os resultados nos próximos dois trechos se restringirão à análise da Simulação Empírica e Resultados Finais após execução do AG.

### 5.3.1.3 Resultados III – Comparações da Aplicabilidade do Conforto

Para avaliação do conforto, que é a suavização do perfil de velocidade, segue as configurações utilizadas:

The image shows a configuration window for a genetic algorithm. It is organized into several panels:

- Configurações Gerais:**
  - População: 50
  - Geração: 20
  - Mutação: 0.1
- Configurações dos Operadores:**
  - K: 3
  - Lambda: 0.3
  - Alfa: 0.5
  - R: 0.7
- Criação da População:**
  - Dados
- Conforto:**
  - Com Conforto (Média)
  - Sem Conforto
- Operadores:**
  - Seleção:**
    - Roleta
    - Torneio
  - Crossover:**
    - Um Ponto
    - Dois Pontos
    - Uniforme
    - Heurístico
    - Flat
    - Aritmético
    - Linear
    - Média Aritmética
    - Média Geométrica
    - SBX
  - Mutação:**
    - Uniforme
    - Limite
  - Módulo da População:**
    - Descartar todos os pais
    - Melhor pai

At the bottom right, there is an 'Iniciar' button.

Figura 34: Configuração para Comparações da Aplicabilidade do Conforto - Trecho 1

Demonstração da avaliação e do resultado na energia com e sem conforto:

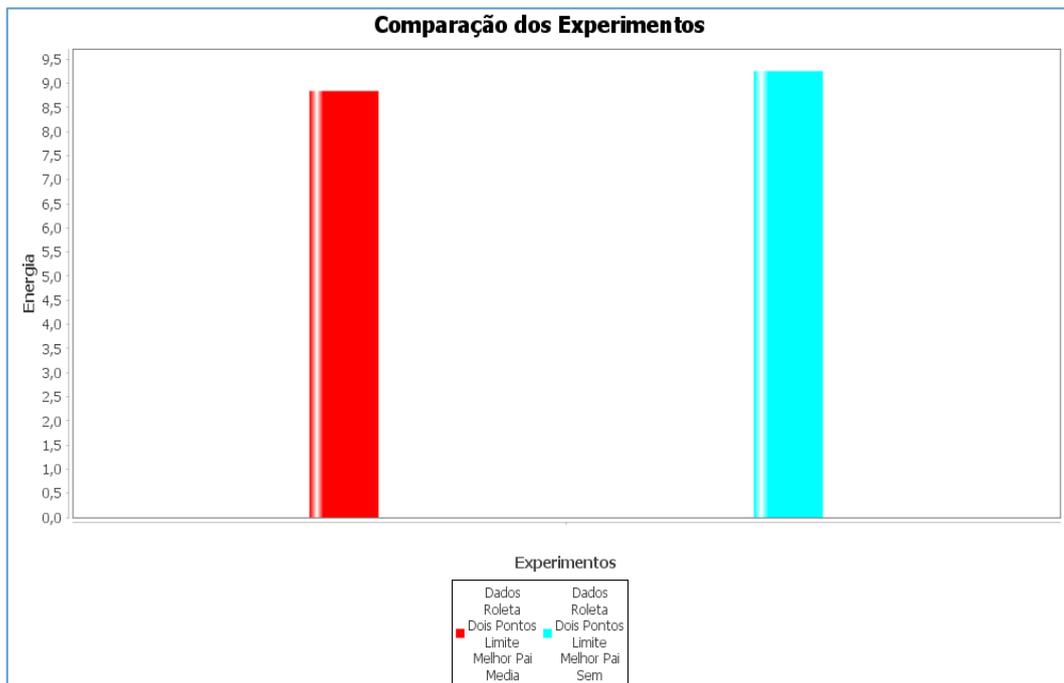


Figura 23: Resultado da energia com e sem conforto – Trecho 1

Com conforto:

Experimento: 1

**Avaliação: 0.11986273630047241**

**Energia: 8.342876450719395**

Geração: Dados

Seleção: Roleta

Crossover: Dois Pontos

Mutação: Limite

Módulo: Melhor Pai

Suavização: Media

Sem conforto:

Experimento: 2

**Avaliação: 0.10809319643381987**

**Energia: 9.211276056141522**

Geração: Dados

Seleção: Roleta

Crossover: Dois Pontos

Mutação: Limite

Módulo: Melhor Pai

Suavização: Sem

Assim, percebe-se que a suavização das curvas através do conforto aplicado, explicado no capítulo anterior, faz com que a execução do algoritmo se torne mais eficaz, já que os valores são ajustados desde a inicialização da população.

Por esta razão, apenas no Trecho 1 está demonstrada esta funcionalidade, nos Trechos 2 e 3 considerar-se-á nos experimentos e resultados, a Aplicabilidade de Conforto.

### 5.3.1.4 Resultados Finais

- Perfil de Velocidade antes e após aplicação do AG:

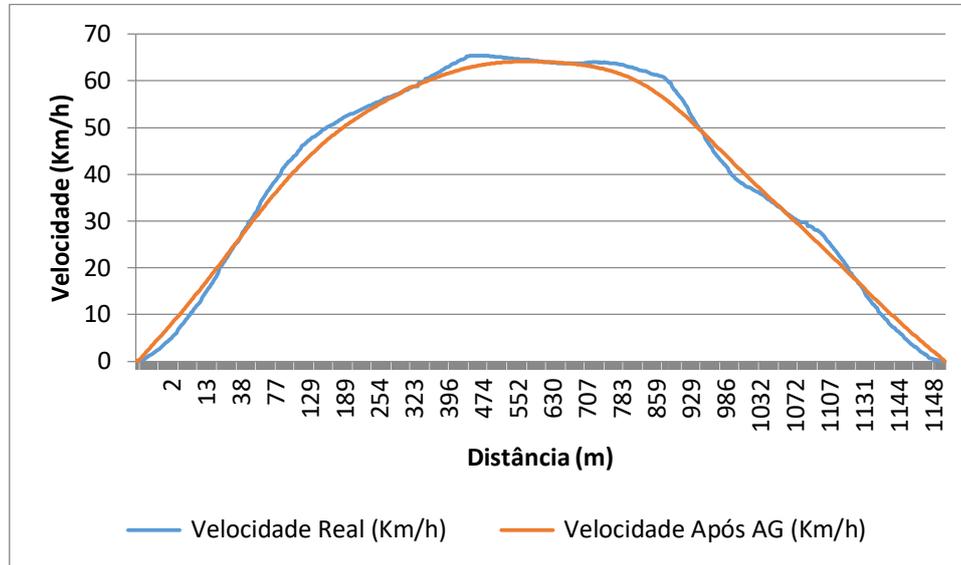


Figura 36: Comparação do Perfil de Velocidade (Real x AG) - Trecho 1

A figura 36 mostra que o Perfil de Velocidade foi ajustado através da aplicação do AG, contudo não se percebe grande diferença na curva de velocidade e, sim, nas curvas de aceleração, o que conseqüentemente afeta a curva/gasto de energia, como será visto a seguir. Segue gráfico do comportamento da Aceleração antes e após aplicação do AG:

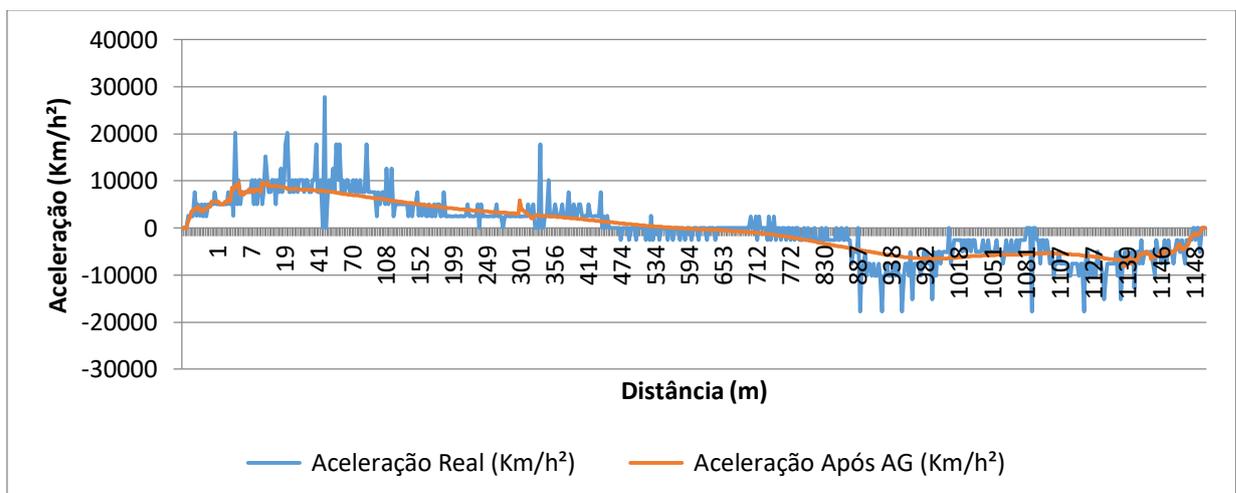


Figura 37: Comportamento da Aceleração (Real x AG) - Trecho 1

O AG sugere que o condutor acelere inicialmente até por 10000Km/h<sup>2</sup> e depois gradativamente desacelere sem se preocupar em manter uma aceleração constante, contudo, percebe-se que os picos de aceleração são menores, o que favorece um menor gasto de energia, como é possível perceber no gráfico a seguir.

No gráfico sobre a Potência, percebe-se que após a execução do AG não há uma variação drástica/brusca nos resultados, a potência inicialmente sobe até meados de 500KW e gradativamente vai diminuindo. Mesmo tendo algumas variações, percebe-se que existe uma constância, o que faz com que a energia acumulada seja menor que antes da execução.

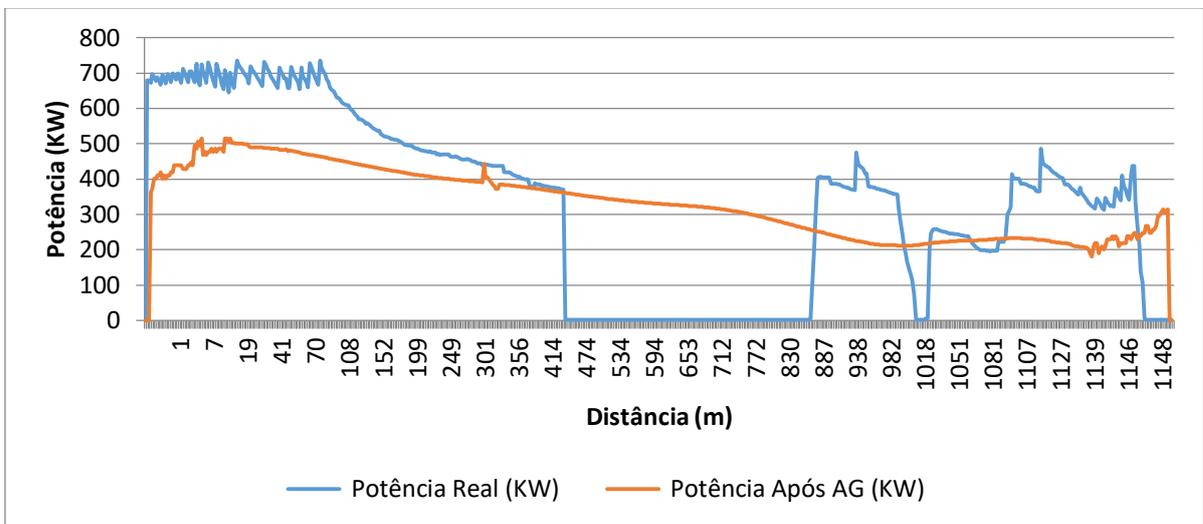


Figura 38: Comportamento da Potência por trecho (Real x AG) – Trecho 1

Segue gráfico do comportamento da Energia Acumulada antes e após AG:

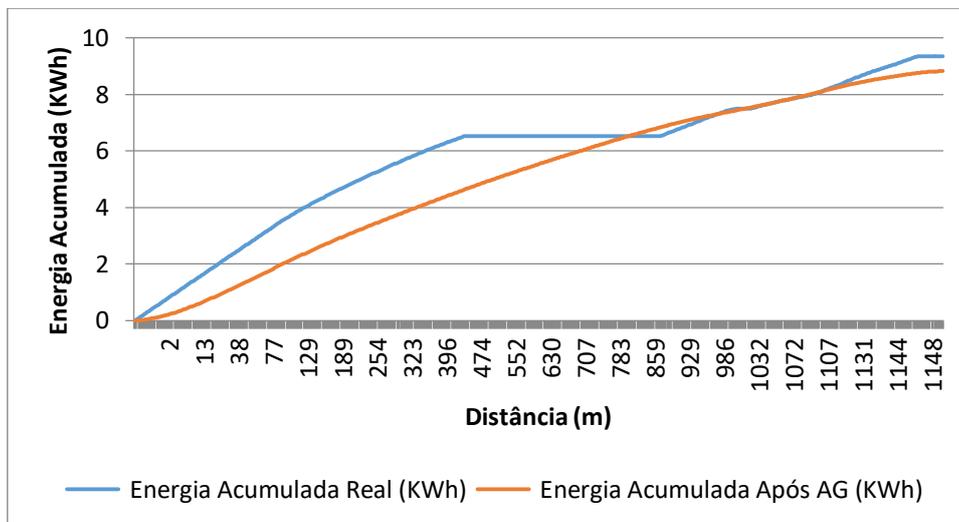


Figura 39: Comportamento da Energia Acumulada (Real x AG) - Trecho 1

O software foi executado conforme configuração do domínio e configuração dos operadores já demonstradas, trazendo os seguintes melhores resultados:

Tabela 2: Melhores resultados da execução do AG – Trecho 1

	Aval.	Energia	Seleção	Crossover	Mutação	População
Exp 4	0.11848	8.4395	Roleta	Um Ponto	Limite	Melhor Pai
<b>Exp 8</b>	<b>0.11954</b>	<b>8.3650</b>	<b>Roleta</b>	<b>Dois Pontos</b>	<b>Limite</b>	<b>Melhor Pai</b>
Exp 12	0.11817	8.4855	Roleta	Uniforme	Limite	Melhor Pai

Ou seja, ao executar o Experimento neste Trecho 1, constata-se que o método de seleção **Roleta** prevaleceu, mutação **Limite** e guardando o **Melhor Pai** no Módulo de População. Contudo, o operador Crossover variou entre **Um Ponto**, **Dois Pontos** e **Uniforme**, mas trouxeram resultados aproximados quanto à diminuição da energia, sendo o de **Dois Pontos** o de menor resultado. Os resultados das execuções, os resultados de todos os experimentos, podem ser encontrados detalhados no Apêndice VI.

Pode-se concluir que o gasto energético inicial antes da execução do AG no Trecho 1 q era de **9,36KWh** e, após execução, resultou em um gasto considerável de **8.36KWh**.

#### 5.4.1 Trecho 2 – Alto do Céu a Curado

##### 5.4.1.1 Resultado I - Simulação Empírica

- **Dados Fixos:**

Tabela 3: Dados Fixos – Trecho 2

Tamanho do Trecho	Tempo	Velocidade Máxima	Energia Total Consumida
852m	90s	65.572Km/h	9,88KWh

Função de regressão gerada através do MATLAB:

*Linear model Poly1:*

$$f(x) = p1*x + p2$$

*Coefficients:*

$$p1 = 0.004445 (0.003598, 0.005291)$$

$$p2 = 130.8 (125.4, 136.2)$$

Foram encontrados os valores máximos das seguintes variáveis no trecho analisado, antes da execução do Algoritmo Genético:

Configurações do Domínio		
Tamanho do trecho (m.):	<input type="text" value="852"/>	
Tempo (seg.):	<input type="text" value="90"/>	
Folga (seg.):	<input type="text" value="10"/>	
Variação da Velocidade:	<input type="text" value="3"/>	
<b>Função Fitness</b>		
<input checked="" type="radio"/> Função Regressão		
<b>Variáveis</b>		
	Máximo	Mínimo
Velocidade	<input type="text" value="65.572"/>	<input type="text" value="0.0"/>
Aceleração	<input type="text" value="17755"/>	<input type="text" value="-22809"/>
Pressão	<input type="text" value="39.882"/>	<input type="text" value="33.822"/>
Corrente	<input type="text" value="246.334"/>	<input type="text" value="0.488"/>
Freio	<input type="text" value="12.152"/>	<input type="text" value="0.0"/>
Potência	<input type="text" value="726"/>	<input type="text" value="1"/>

Figura 40: Configurações do Domínio – Trecho 2

- **Perfil de Velocidade**

Este é o perfil de velocidade antes da execução do AG, onde a velocidade máxima atingida foi de **65.572Km/h**

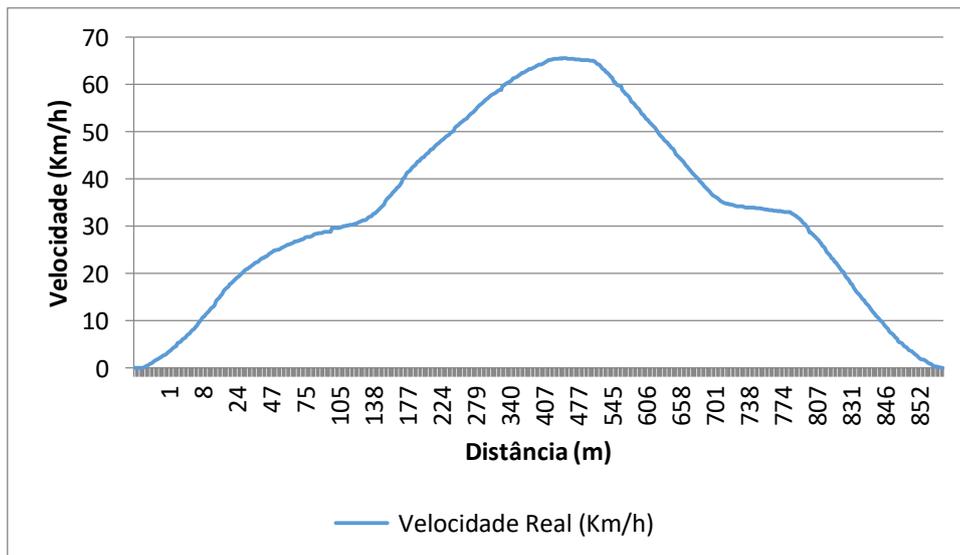


Figura 24: Perfil de Velocidade (Real) – Trecho 2

- **Energia Total Consumida:**

A Energia Total Consumida antes da execução do AG foi de **9,88KWh**.

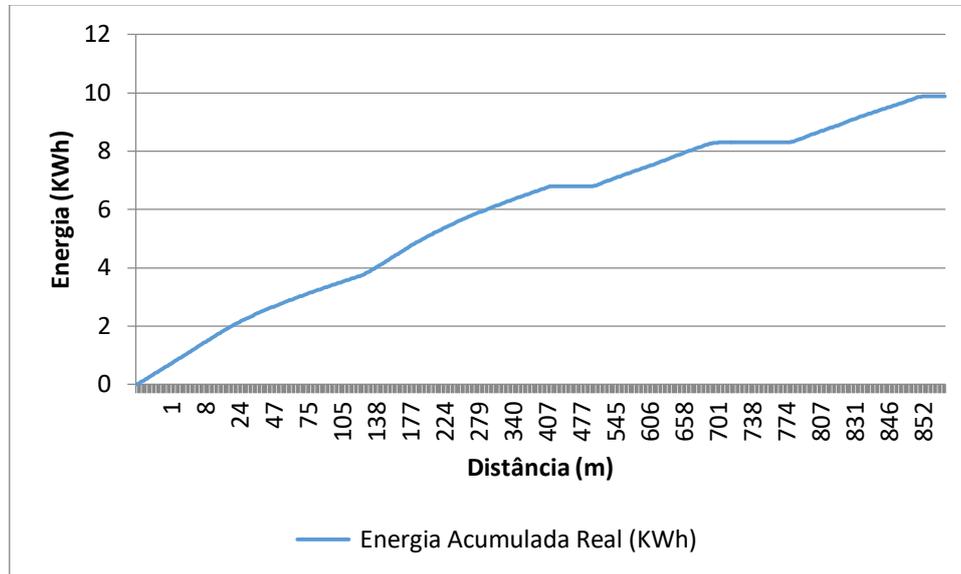


Figura 25: Comportamento da Energia Acumulada (Real) - Trecho 2

- **Análise da Simulação Empírica**

Analisando os gráficos de velocidade, energia e aceleração, percebe-se que o condutor acelera gradativamente até atingir um pico de 17755 km/h<sup>2</sup> em 15m percorridos e em seguida começa a desacelerar gradativamente e em seguida acelera novamente. Em aproximadamente 440m percorridos ele desacelera, gastando uma energia de frenagem e até a parada em 852m.

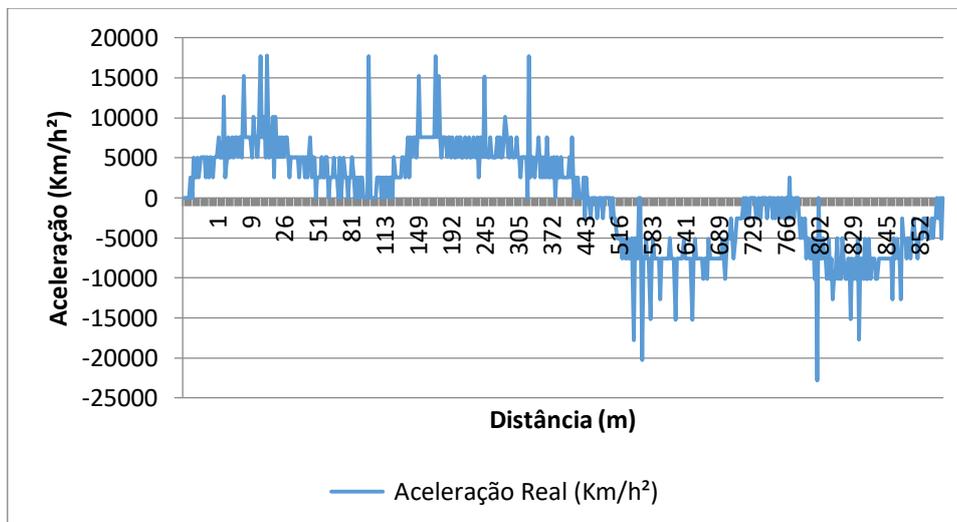


Figura 26: Aceleração km/h<sup>2</sup> (Real) - Trecho 2

## 5.4.1.2 Resultados Finais

- Perfil de Velocidade antes e após aplicação do AG:

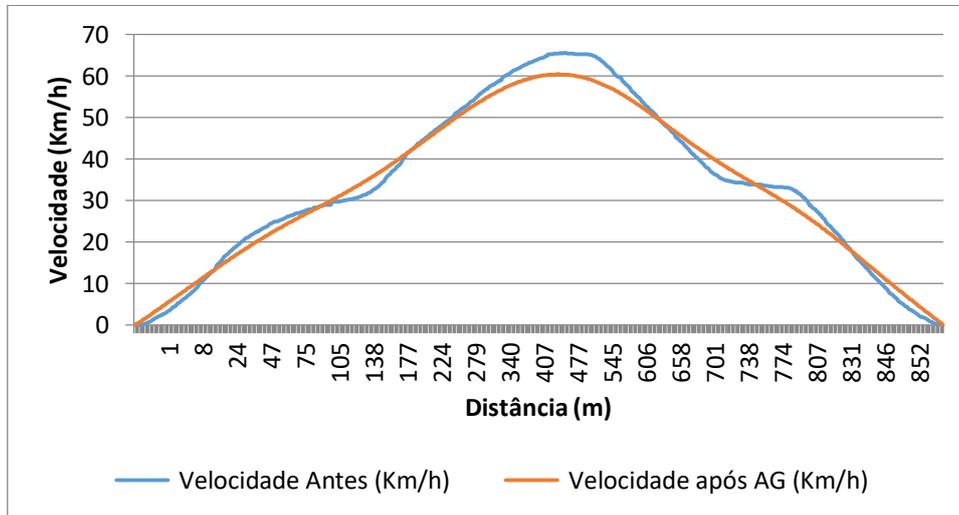


Figura 27: Comparação do Perfil de Velocidade (Real x AG) -Trecho 2

A figura 44 mostra que o Perfil de Velocidade foi ajustado através da aplicação do AG, contudo não se percebe grande diferença na curva de velocidade e, sim, nas curvas de aceleração e potência, o que conseqüentemente afeta a curva/gasto de energia, como iremos ver a seguir.

Segue gráfico do comportamento da Aceleração antes e após aplicação do AG:

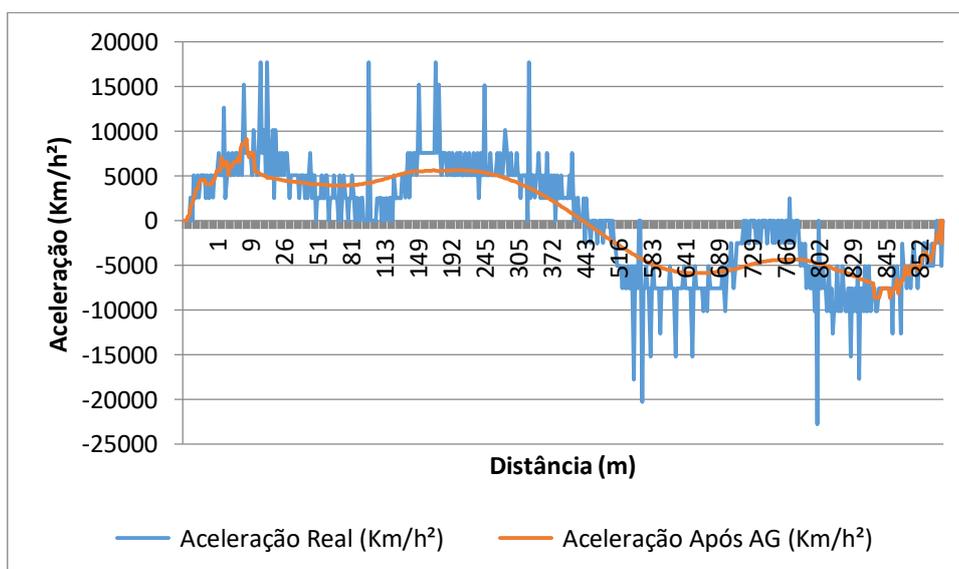


Figura 28: Comportamento da Aceleração (Real x AG) – Trecho 2

O AG sugere que o condutor acelere inicialmente até por 10000Km/h<sup>2</sup> e depois gradativamente desacelere sem se preocupar em manter uma aceleração constante, contudo, podemos perceber que os picos de aceleração são menores, o que favorece um menor gasto de energia, como podemos perceber no gráfico a seguir.

No gráfico sobre a Potência, percebe-se que após a execução do AG não há uma variação drástica/brusca nos resultados, a potência inicialmente sobe até meados de 500KW e gradativamente vai diminuindo. Mesmo tendo algumas variações, percebe-se que existe uma constância, o que faz com que a energia acumulada seja menor que antes da execução.

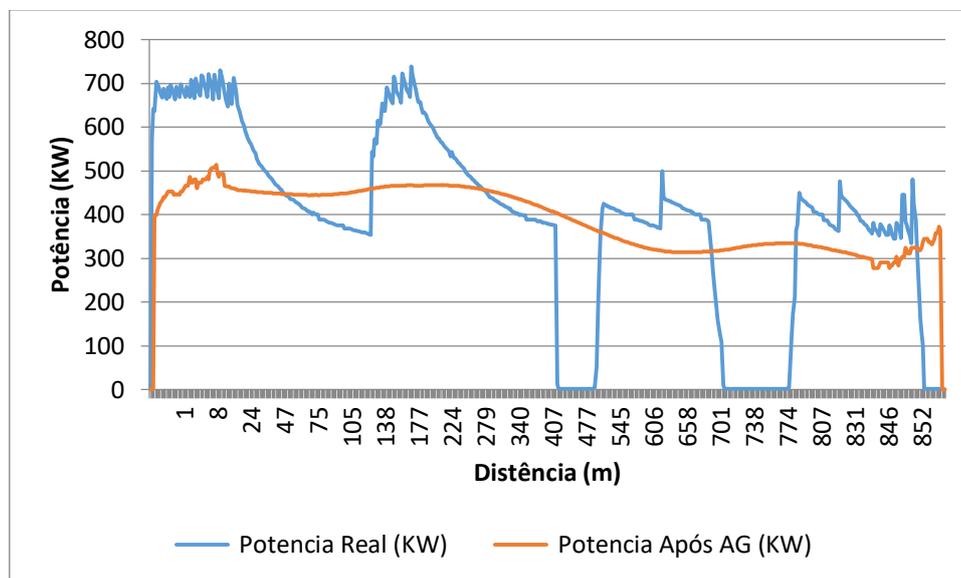


Figura 29: Comportamento da potência por Trecho (Real x AG) - Trecho 2

Segue gráfico do comportamento da Energia Acumulada antes e após AG:

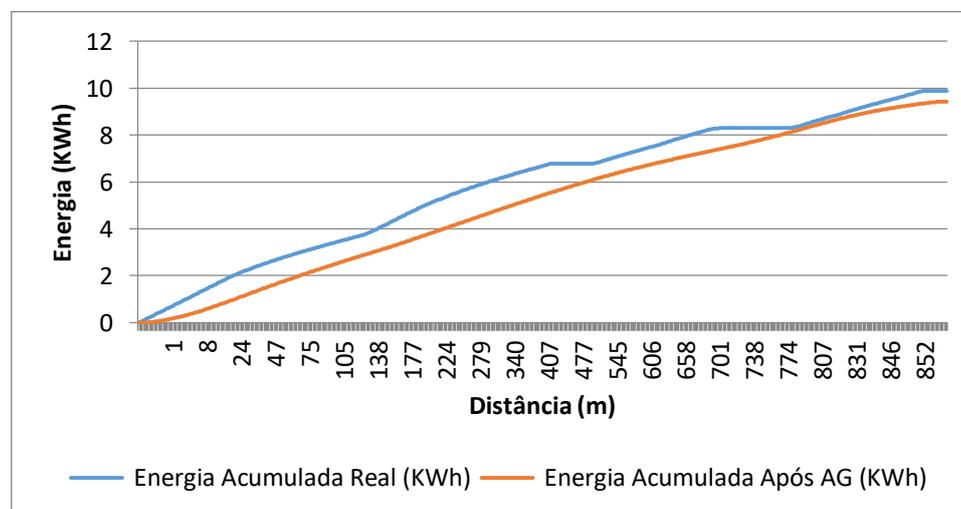


Figura 47: Comportamento da Energia Acumulada (Real x AG) - Trecho 2

O software foi executado conforme configuração do domínio e configuração dos operadores já demonstradas, trazendo os seguintes melhores resultados:

Tabela 4: Melhores resultados da execução do AG – Trecho 2

	Aval.	Energia	Seleção	Crossover	Mutação	População
Exp 04	0.10982	9.1056	Roleta	Um Ponto	Limite	Melhor Pai
<b>Exp 8</b>	<b>0.1105</b>	<b>9.0465</b>	<b>Roleta</b>	<b>Dois Pontos</b>	<b>Limite</b>	<b>Melhor Pai</b>
Exp 20	0.11035	9.0616	Torneio	Um Ponto	Limite	Melhor Pai

Assim, ao executar o Experimento neste Trecho 2, foi constatado que o método de seleção **Roleta** prevaleceu, crossover de **Dois Pontos**, mutação **Limite** e guardando o **Melhor Pai** no Módulo de População. Os resultados das execuções podem ser encontradas detalhadas no Apêndice VI. Sendo possível concluir que o gasto energético inicial antes da execução do AG no Trecho 2 era de **9,88KWh** e, após execução, resultou em um gasto considerável de **9,05KWh**.

### 5.5.1 Trecho 3 – Curado à Rodoviária

#### 5.5.1.1 Resultado I - Simulação Empírica

- **Dados Fixos:**

Tabela 5: Dados Fixos – Trecho 3

Tamanho do Trecho	Tempo	Velocidade Máxima	Energia Total Consumida
1040m	113 seg	64.047Km/h	11,32KWh

Função de regressão gerada através do MATLAB:

*Linear model Poly1:*

$$f(x) = p1*x + p2$$

*Coefficients:*

$$p1 = 0.004298 (0.005329, 0.007221)$$

$$p2 = 119.8 (105.3, 117.1)$$

Foram encontrados os valores máximos das seguintes variáveis no trecho analisado, antes da execução do Algoritmo Genético:

**Configurações do Domínio**

Tamanho do trecho (m.):

Tempo (seg.):

Folga (seg.):

Variação da Velocidade:

**Função Fitness**

Função Regressão

**Variáveis**

	Máximo	Mínimo
Velocidade	<input type="text" value="64.047"/>	<input type="text" value="0.0"/>
Aceleração	<input type="text" value="20260"/>	<input type="text" value="-25336"/>
Pressão	<input type="text" value="40.078"/>	<input type="text" value="34.213"/>
Corrente	<input type="text" value="241.935"/>	<input type="text" value="0.488"/>
Freio	<input type="text" value="12.116"/>	<input type="text" value="0.0"/>
Potência	<input type="text" value="726"/>	<input type="text" value="1"/>

Figura 48: Configurações do Domínio – Trecho 3

- **Perfil de Velocidade**

Este é o perfil de velocidade antes da execução do AG, onde a velocidade máxima atingida foi de **64.047Km/h**.

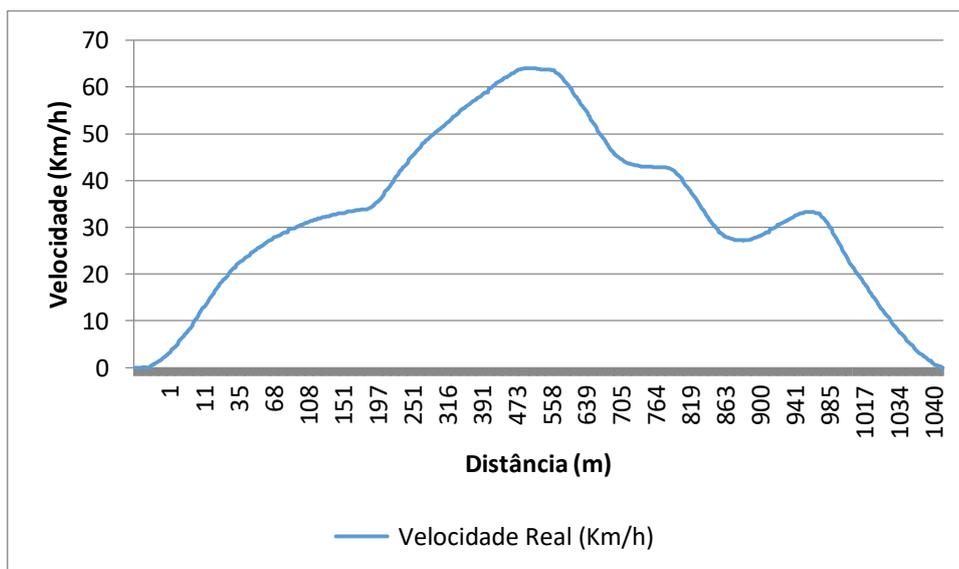


Figura 49: Perfil de Velocidade (Real) - Trecho 3

- **Energia Total Consumida:**

A Energia Total Consumida antes da execução do AG foi de **11,32KWh**.

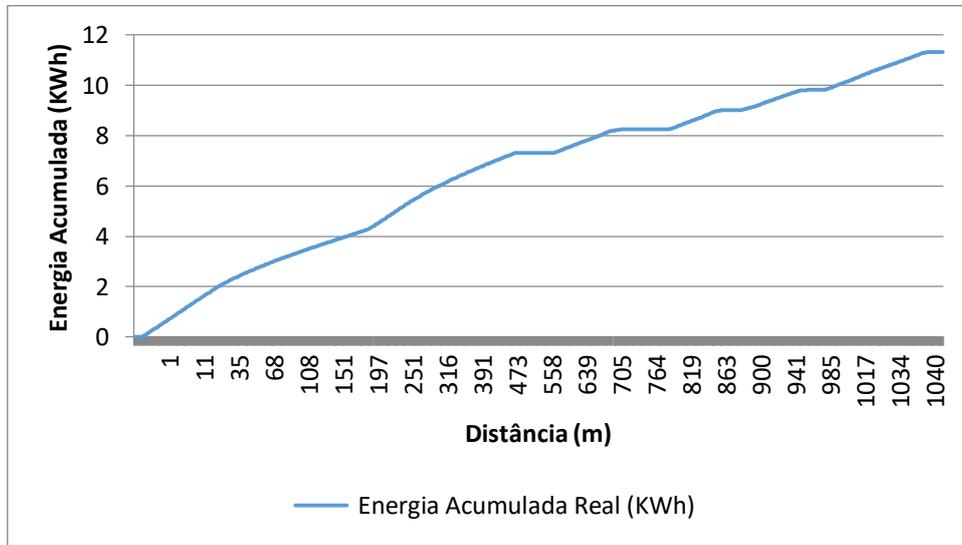


Figura 30: Comportamento da Energia Acumulada (Real) - Trecho 3

- **Análise da Simulação Empírica**

Analisando os gráficos de velocidade, energia e aceleração, percebe-se que o condutor acelera e desacelera em alguns momentos, atingindo um pico máximo de 20260km/h<sup>2</sup>. Percebe-se que neste trecho o condutor não se preocupa em manter uma aceleração ou desaceleração gradativa por muito tempo, o que pode sinalizar alguma subida, declive ou curva mais acentuada no trecho.

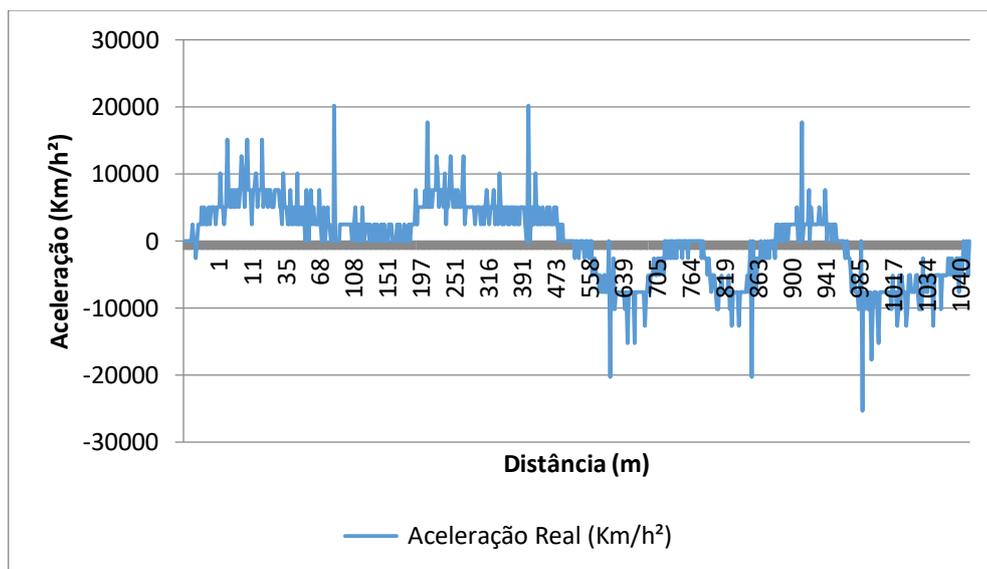


Figura 31: Aceleração km/h (Real) – Trecho 3

### 5.5.1.2 Resultados Finais

- Perfil de Velocidade antes e após aplicação do AG:

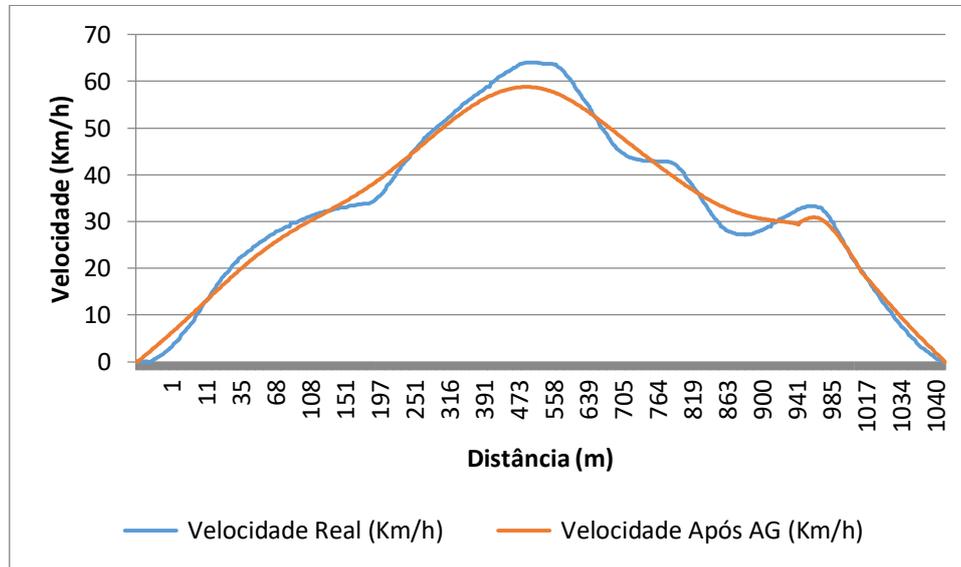


Figura 32: Comparação do Perfil de Velocidade (Real x AG) - Trecho 3

A figura 52 mostra que o Perfil de Velocidade foi ajustado através da aplicação do AG, contudo não percebemos grande diferença na curva de velocidade e, sim, nas curvas de aceleração, o que conseqüentemente afeta a curva/gasto de energia, como iremos ver a seguir.

Segue gráfico do comportamento da Aceleração antes e após aplicação do AG:

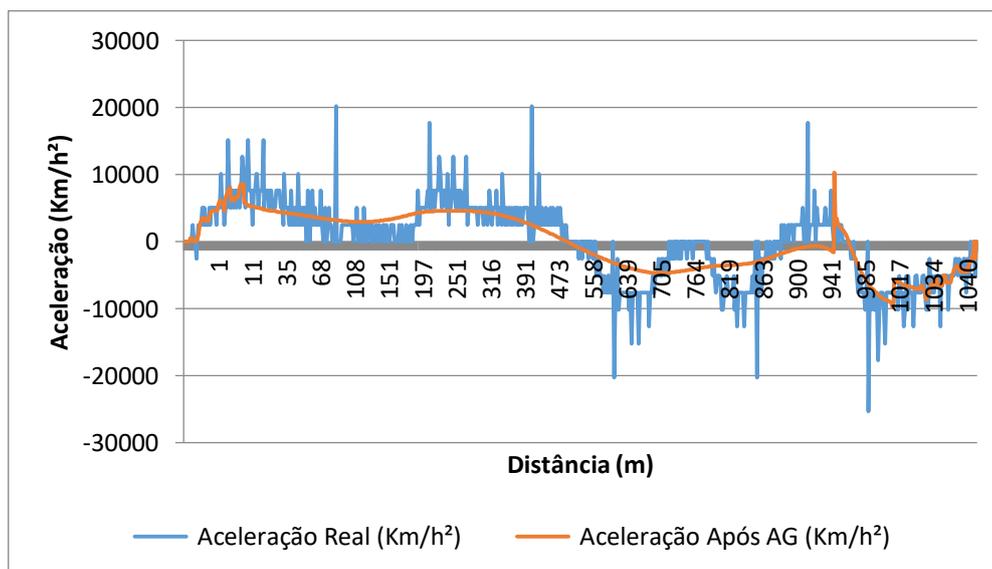


Figura 33: Comportamento da Aceleração (Real x AG) - Trecho 3

O AG sugere que o condutor acelere inicialmente até por 9000Km/h<sup>2</sup> e depois gradativamente desacelere sem se preocupar em manter uma aceleração constante, contudo, podemos perceber que os picos de aceleração são menores, o que favorece um menor gasto de energia, como podemos perceber no gráfico a seguir.

No gráfico sobre a Potência, percebe-se que após a execução do AG não há uma variação drástica/brusca nos resultados, a potência inicialmente sobe até meados de 480KW e gradativamente vai diminuindo. Mesmo tendo algumas variações, percebe-se que existe uma constância, o que faz com que a energia acumulada seja menor que antes da execução.

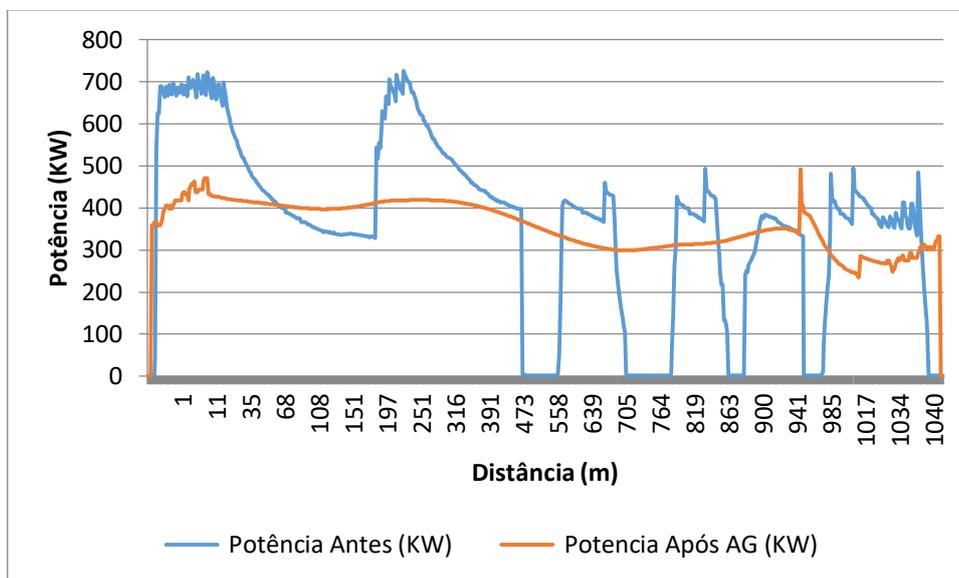


Figura 34: Comportamento da potência por trecho (Real x AG) - Trecho 3

Segue gráfico do comportamento da Energia Acumulada antes e após AG:

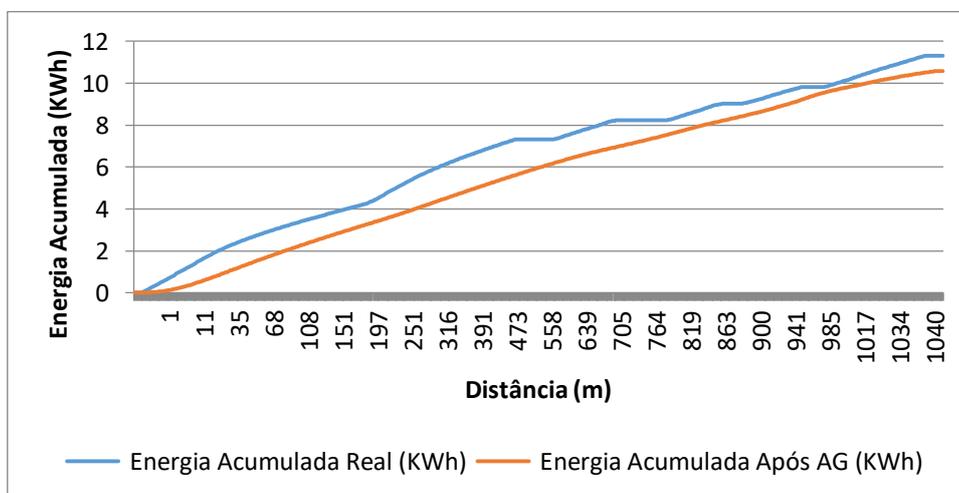


Figura 35: Comportamento da Energia Acumulada (Real x AG) - Trecho 3

O software foi executado conforme configuração do domínio e configuração dos operadores já demonstradas, trazendo os seguintes melhores resultados:

Tabela 6: Melhores resultados da execução do AG – Trecho 3

	Aval.	Energia	Seleção	Crossover	Mutação	População
<b>Exp 4</b>	<b>0.0967</b>	<b>10.3340</b>	<b>Roleta</b>	<b>Um Ponto</b>	<b>Limite</b>	<b>Melhor Pai</b>
Exp 8	0.09607	10.4081	Roleta	Dois Pontos	Limite	Melhor Pai
Exp 20	0.09601	10.4155	Torneio	Um Ponto	Limite	Melhor Pai

Ou seja, ao executar o Experimento neste Trecho 3, foi constatado que o operador de mutação **Limite** e guardando o **Melhor Pai** no Módulo de População prevaleceu. Contudo, o operador seleção variou entre **Roleta** e **Torneio** e o crossover variou entre **Um Ponto** e **Dois Pontos**, trazendo resultados aproximados quanto a diminuição da energia, sendo o de **Roleta** e **Um Ponto** o de menor resultado. Os resultados das execuções podem ser encontradas detalhadas no Apêndice VI.

Pode-se concluir que o gasto energético inicial antes da execução do AG no Trecho 1 q era de **11,32KWh** e, após execução, resultou em um gasto considerável de **10.35KWh**.

## 5.6 AVALIAÇÃO FINAL DO DIA (07/10/2016)

Conforme demonstrado na tabela a seguir, pode-se concluir que este estudo garante uma média de 9,1% a menos de gasto de energia, o que é considerável já que normalmente o valor médio pago à concessionária de energia gira em torno de alguns milhões mensais.

Tabela 7: Comparação do Gasto de Energia X Aplicação do AG

Comparação do Gasto de Energia X Aplicação do AG			Redução de Energia (%)
	Total da Energia Consumida (Antes)	Total da Energia Consumida (Depois)	
<b>Trecho 1</b>	9,36KWh	8,36KWh	10,6%
<b>Trecho 2</b>	9,88KWh	9.0465KWh	8,4%
<b>Trecho 3</b>	11,32KWh	10.33KWh	8,5%
<b>Total de Energia Gasta</b>	<b>30,56KWh</b>	<b>27,76KWh</b>	<b>9,1%</b>

Assim, supondo que o METROREC faça 400 viagens ao dia, sendo 12.000 viagens por mês, tem-se uma conta aproximada de R\$2.000.000,00 por mês em média. Assim, este trabalho propõe uma economia de R\$182.000,00 ao mês e de R\$2.184.000,00 ao ano. Os cálculos foram feitos apenas levando em consideração a redução média de 9,1% no total dos gastos, contudo, este cálculo poderá ser feito pela empresa de trens, junto aos valores repassados pela concessionária.

## CAPÍTULO VI

### CONCLUSÕES E CONSIDERAÇÕES FINAIS

Este trabalho demonstrou o desenvolvimento de um Modelo para a Otimização da Eficiência Energética de um Sistema Metroferroviário utilizando Algoritmos Genéticos, intitulado GeneticBee. Foi realizado um estudo através dos dados reais sobre o Perfil de Velocidade e energia gasta no METROREC, levando em consideração os limites e as restrições dos trechos analisados.

Inicialmente, foi realizado um levantamento bibliográfico, abordando conceitos básicos das principais áreas temáticas que envolvem esta dissertação: Sistemas de Transporte Inteligentes, Algoritmos Genéticos e Eficiência Energética em Ferrovias. Também foi realizada uma análise sobre o METROREC e o projeto Railbee. Em seguida, foi descrito um Mapeamento Sistemático, localizado no Apêndice I e II, que envolve especificidades sobre o tema de trabalho, com a finalidade de nortear e aplicar da melhor forma o conhecimento sobre os Algoritmos Genéticos na redução do consumo de energia em Trens Elétricos no caso estudado. Ainda sobre o Mapeamento Sistemático, é importante ressaltar que este trabalho destaca-se dos demais por ter o apoio de uma interface gráfica para a modelagem do domínio e por utilizar uma modelagem matemática própria para a função de avaliação.

Posteriormente, foi realizado um detalhamento da metodologia utilizada no que concerne à Simulação Empírica e às Simulações utilizando os Algoritmos Genéticos, como também foi descrito um passo a passo de como foi desenvolvido o Modelo de Otimização e sua validação através dos experimentos demonstrados, simulados pelo Software GeneticBee, no qual foi implementado o modelo, utilizando a linguagem de programação Java.

Ao final, foram escolhidos três trechos do METROREC, aplicado o modelo e demonstrado os resultados obtidos com os experimentos. Desta forma, foi possível realizar comparações sobre os dados antes do processo e depois da aplicação do modelo que utiliza os Algoritmos Genéticos.

Em suma, o modelo proposto para otimização da eficiência energética utilizando Algoritmos Genéticos demonstra que seguindo o Perfil de Velocidade proposto ocorrerá uma redução em média de 9,1% da energia consumida em trens elétricos manuais. Já em trens elétricos automáticos, que utilizam o sistema ATO, é possível propor uma estratégia de implantação de um “filtro de linha” com os valores limites encontrados da nova corrente. No contexto do estudo, através do mapeamento sistemático, verificamos que não foram encontrados trabalhos relevantes no Brasil sobre o tema, que utilizem os Algoritmos Genéticos para o controle do perfil de velocidade em trens elétricos, o que foi constatado através do mapeamento sistemático descrito nos Apêndice I e II. O trabalho já obteve três publicações na área (verificar Apêndices III, IV e V):

- MARTINS, M. B.; LINO, N. C. Q; LIMA FILHO, A. C.. GeneticBee: A Theoretic and Evolutionary Formulation for the Energy Efficiency Problem of Urban Trains. In: 2016 IEEE ANDESCON, 2016, Arequipa, Peru. 2016 IEEE ANDESCON, 2016.
- QUEIROZ, M. D. ; MARTINS, M. B. ; Daniel, R. G. ; LINO, N. C. Q. Um estudo exploratório sobre o uso de algoritmos genéticos para o problema de eficiência energética em trens urbanos. In: ENUCOMP 2016 - Encontro Unificado de Computação, 2016, Teresina, Piauí. Anais Eletrônicos Enucomp 2016. Teresina, Piauí: FUESPI, 2016. p. 229.
- MARTINS, M. B.; QUEIROZ, M. D. ; LINO, N. C. Q.; LIMA FILHO, A. C. Uma Metodologia para a Otimização da Energia Elétrica em Sistemas Metroferroviários. In: Expotec 2016, 2016, João Pessoa. Expotec 2016, 2016.

É importante levar em consideração a complexidade no desenvolvimento de um modelo que utiliza os Algoritmos Genéticos para prover uma redução no gasto energético em malhas metroferroviárias.

## 6.1 CONTRIBUIÇÕES ALCANÇADAS

Seguem descritas algumas contribuições alcançadas:

- Análise in loco do funcionamento dos TUEs no Metro de Recife, análise do domínio e levantamento de requisitos;
- Criação de um modelo para otimização da eficiência energética em trens elétricos, que contempla um Módulo Empírico e Utilizando os AGs;
- Análise de dados reais sobre o comportamento da energia e suas variáveis, definindo os limites mínimos e máximos de todos os parâmetros envolvidos no Sistema;
- Fornecimento de um modelo (protótipo) que pode ser adaptável para outras malhas metroferroviárias, auxiliando, assim, a academia e a indústria nos avanços de tecnologias para a redução de energia elétrica.
- Avanços no estado da arte relativos à construção de um modelo que utiliza um Algoritmo Evolucionário para redução de energia em malhas metroferroviárias, com relação à Inicialização da População, Aplicação de Conforto e Função de Avaliação sugeridas;
- Inovação do projeto iniciado, através da pouca quantidade de trabalhos específicos na área da AGs, constatados no mapeamento sistemático;
- Validação do trabalho através de dados reais captados no Metro de Recife.

## 6.2 TRABALHOS FUTUROS

Seguem algumas propostas de trabalhos futuros:

- Levantar dados acerca da topologia da região e curvas, melhorando, assim, a configuração do domínio da malha a ser analisada;
- Com isto, tendo esses dados, propor uma função de avaliação de forma mais genérica, modelada matematicamente;
- Simular os resultados obtidos de modo real no METROREC ou adaptá-los para outras malhas metroferroviárias;
- Propor um sistema de controle de corrente para trens automáticos (ATO) com os resultados encontrados.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ARAÚJO, R. C. C., 2009, *Sistema Telemétrico Dinâmico sem Fio Aplicado aos Veículos Rodoferroviários em Malhas Metroferroviárias*. Tese de Doutorado, UFPB.
- ARAÚJO, R. C., SANTOS J. L. A., ANJOS, E. G., LIMA FILHO, A. C., BELO, F. A., LIMA, J. A. G, 2009, “RailBee”, *Sistema de instrumentação virtual de veículos em malhas metroferroviárias, Seminário Negócios nos Trilhos*. Prêmio Alston de Tecnologia, Revista Ferroviária.
- ARAÚJO, R. C., SANTOS, J. L. A., BELO, F. A., LIMA, J. A. G, 2010, *Utilização do Sistema Telemétrico Dinâmico RailBee para estimativa em tempo real do número de passageiros e análise do desempenho do TUE*. Prêmio Alston de Tecnologia, Revista Ferroviária.
- ARAÚJO, R. C., SANTOS, J. L. A., MORAIS, B. M., BELO, F. A., LIMA, J. A. G., 2009, *Telemetria dinâmica de veículos rodoferrviários em malhas metroferroviárias*, 17º Congresso Brasileiro de Transportes e Trânsito, Curitiba – PR.
- BOCHARNIKOV, Y.V., TOBIAS, A.M., ROBE, C., 2010. “Reduction of train and net energy consumption using genetic algorithms for trajectory optimization”. *In: Proceedings of IET Conference on Railway Traction Systems*, IEEE Publisher, Birmingham, UK, pp. 32–36.
- BRÉZILLON P., NAVEIRO, M. CAVALCANTI, J.-CH., 2000. *Pomerol; Sart: An Intelligent Assistant System For Subway Control* - Rio de Janeiro.
- CARVAJAL-CARRENO, W., CUCALA, A., FERNANDEZ-CARDADOR, A. Fuzzy train tracking algorithm for the energy efficient operation of CBTC equipped metro lines. *Engineering Applications of Artificial Intelligence*, 53, pp. 19-31, Agosto, 2016.
- CHEVRIER, R., PELLEGRINI, P., RODRIGUEZ, J. Energy saving in railway timetabling: A bi-objective evolutionary approach for computing alternative running times. *Transportation Research Part C: Emerging Technologies*, v.37, p. 20-41, Dezembro, 2013.

- CBTU, 2017, *Companhia Brasileira de Trens Urbanos - Superintendencia de Trens Urbanos - Recife - Metrô Recife (METROREC)*. Acessível através do link: <https://www.cbtu.gov.br/index.php/pt/sistemas-cbtu/recife> (em 05/06/2017)
- CHEN, H., FELLAH, S., BISHR, Y, 2005, *Rules for geospatial semantic web applications*. W3C workshop on rule languages for interoperability, Washington, D.C., USA, The World Wide Web Consortium (W3C).
- COMISSÃO EUROPEIA, 2003. *A política europeia de transportes no horizonte 2010: a hora das opções*.
- DAVID, F., DENIS, M., FRANCOIS, F., 2012. Energy optimization of metro timetables: a hybrid approach. In: *Proceedings of the 18th International Conference on Principles and Practice of Constraint Programming, Lecture Notes in Computer Science*, vol. 7514, Springer Publisher, Quebec City, Canada, pp. 7–12.
- DOMINGUEZ, M., FERNANDEZ-CARDADOR, A., CUCALA, A.P., PECHARROMAN, R.R., 2012. “Energy savings in metropolitan railway substations through regenerative energy recovery and optimal design of ATO speed profiles”. *IEEE Transactions on Automation Science and Engineering* 9 (3), 496–504.
- FELTES L. H. AND J. L. V. BARBOSA, 2014, "A Model for Ubiquitous Transport Systems Support", *IEEE LATIN AMERICA TRANSACTIONS*, VOL. 12, NO. 6.
- FERRISB., K. WATKINS, A. BORNING, 2010, “Location-Aware Tools for Improving Public Transit Usability,” in *IEEE Pervasive Computing*, pp. 2–9.
- GONG, C., ZHANG, S., ZHANG, F., JIANG, J. and WANG, X., An integrated energy-efficient operation methodology for metro systems based on a real case of Shanghai metro line one. *Energies*, 7(11), p.7305-7329. Novembro, 2014
- GUIMARÃES, M. A. N.; LORENZETI, J. F. C.; CASTRO C. A., 2004c, “Reconfiguration of distribution system for voltage stability margin enhancement using Tabu Search”. In: CONFERENCE ON POWER SYSTEM TECHNOLOGY - POWERCON, 2004, Singapore. *Proceedings...* New york: IEEE, p. 1556-1561.
- GUPTA, S., TOBIN, J., PAVEL, L. A two-step linear programming model for energy-efficient timetables in metro railway networks. *Transportation Research Part B: Methodological*, 93, 57-74, Nov, 2016.
- HADDAD, J, 2004, *Energia Elétrica: Conceitos, Qualidade e Tarifação* – Rio de Janeiro.

- HOLLAND, J. H. 1975, *Adaptation in natural and artificial systems*. Michigan: Ann Arbor.
- ITS America, INTELLIGENT TRANSPORTATION SOCIETY OF AMERICA, 1991.
- IBM, 2017. *Global Rail Innovation Center* . Acessível através do link: <https://www-03.ibm.com/press/us/en/pressrelease/27686.wss> (em 05/06/2017)
- KAZA, N., HOPKINS, L.D, 2007, *Ontologies for Urban Development*. Springer Berlin/Heidelberg: Studies in Computational Intelligence, Volume 61, p. 47-59.
- KITCHENHAM, B. Guidelines for performing Systematic Literature Reviews in Software Engineering. Volume 2.3 EBSB Technical Report, EBSE-2007-01, 2007.
- LI, X., YANG, X., 2013. “A stochastic timetable optimization model in subway systems”. *International Journal of Uncertainty, Fuzziness & Knowledge-Based*. p. 1–15.
- LU, S., HILLMANSEN, S., HO, T., ROBERTS, C. Single-train trajectory optimization. *IEEE Transactions on Intelligent Transportation Systems*, v. 14, n. 2, pp.743-750, Jun, 2013.
- MARTINIS, V., GALLO, M., 2012, *Models and methods to optimize train speed profiles with and without energy recovery systems: a suburban test case*.
- MENESES, H. B., 2003, *Interface lógica em ambiente SIG para base de dados de sistemas centralizadores do controle do tráfego urbano em tempo real*. Fortaleza, 2003. Dissertação (Mestrado em Engenharia de Transportes). Universidade Federal do Ceará, Fortaleza.
- NASRI, A., FEKRI MOGHADAM, M., MOKHTARI, H., 2010. “Timetable optimization for maximum usage of regenerative energy of braking in electrical railwaysystems”. In: *Proceedings of the International Symposium on Power Electronics, Electrical Drives, Automation and Motion*, IEEE Publisher, Pisa, Italy, pp.1218–1221.
- OLIVEIRA, M. B. C.; 2011, *Reconfiguração de Alimentadores em Sistemas de Distribuição Usando a Metaheurística Grasp*. Dissertação de Mestrado, Unesp.
- PENA-ALCARAZ, M., FERNANDEZ, A., CUCALA, A., RAMOS, A., PECHARROMAN, R., 2012. “Optimal underground timetable design based on power flow for maximizing the use of regenerative-braking energy”. *Journal of Rail and Rapid Transit* 226 (4), 397–408.
- PORTO, C. C.; MATOS, C. A. S.; OLIVEIRA, F. S., 2013, *Estudo de Potenciais Tecnologias de Regeneração e Otimização de Energia Para os Trens Da Cptm – Unicamp*.

- RAMOS, A., PENA, M., FERNNDEZ-CARDADOR, A., CUCALA, A.P., 2007. “Mathematical programming approach to underground timetabling problem for maximizing time synchronization”. In: *Proceedings of the International Conference on Industrial Engineering and Industrial Management*, IEEE Publisher, Madrid, Spain, pp. 88–95.
- RUSCONI G., M. BRUGNOLI, P. DOSSO, K. KRETZSCHMAR, P. BOUGIA, D.FOTIADIS, L. SALGADO, AND F. JAUREGUIZAR, 2007, “I-WAY - intelligent cooperative system for road safety,” in *IEEE Intelligent Vehicles Symposium*, pp. 1056–1061.
- SANTOS, A. H. M., et al., 2001, *Conservação de Energia, Eficiência Energética de Instalações e Equipamentos*, Itajubá, Editora da EFEI.
- SANTOS, J. L. A, 2010, *Sistema Telemétrico para Monitoramento de Trens através de Rdes de Sensores sem Fio e Processamento em Sistema Embarcado*. Dissertação de Mestrado, UFPB.
- SCHEVERS, H.A.J., TRINIDAD, G.; DROGEMULLER, R.M. “Towards Integrated Assessments for Urban Development. Journal of Information Technology.” In: *Construction (ITcon)*, Vol. 11, Special Issue Decision Support Systems for Infrastructure Management, pg. 225-236.
- SPTRANS, 2012, *Olho Vivo - Sistema de monitoramento do transporte*.
- SUSSMAN, J, 2000, *Introduction to transportation Systems*, Artec House, Intelligent transportation systems library, London.
- TOULMINET G., J. BOUSSUGE, AND C. LAURGEAU, 2008, “Comparative synthesis of the 3 main European projects dealing with Cooperative Systems (CVIS, SAFESPOT and COOPERS) and description of COOPERS Demonstration Site 4,” in *11th International IEEE Conference on Intelligent Transportation Systems*, pp. 809–814.
- TUYTTENS, D., FEI, H.Y., MEZMAZ, M., JALWAN, J., 2013. “Simulation-based genetic algorithm towards an energy-efficient railway traffic control”. *Mathematical Problems in Engineering*, Article ID 805410, 1–12.
- VIANA, L.C.S, NABUCO, L.F., MACHADO, C.J.S, 2007, “Ontologias e tecnologia da informação e comunicação: sistemas especialistas, web semântica e gestão integrada de compras governamentais eletrônicas”. In *RECIIS – Electronic Journal of Communication Information & Innovation Health*. Rio de Janeiro, v.1, n.1, p. 141-152.
- VIEIRA V., L. R. CALDAS, AND A. C. SALGADO, 2011, “Towards an Ubiquitous and Context Sensitive Public Transportation System,” in *Fourth International Conference on Ubi-Media Computing*, pp. 174-179

- YANG, X., LI, X., GAO, Z., WANG, H., TANG, T., 2013. "A cooperative scheduling model for timetable optimization in subway systems". *IEEE Transactions on Intelligent Transportation Systems* 14 (1), 438–447.
- YANG, X., CHEN, A., LI, X., NING, B., TANG, T. An energy-efficient scheduling approach to improve the utilization of regenerative energy for metro systems. *Transportation Research Part C: Emerging Technologies*, v. 57, p. 13-29, Agosto, 2015.
- XU, X., LI, K., LI, X. A multi-objective subway timetable optimization approach with minimum passenger time and energy consumption. *Journal of Advanced Transportation* v. 50, no. 1 (2016): p. 69-95. Janeiro, 2016

## APÊNDICE I

### MAPEAMENTO SISTEMÁTICO

Um mapeamento sistemático é uma forma de identificar, avaliar e interpretar todas as pesquisas disponíveis relevantes para uma questão de pesquisa particular. Uma das razões para a realização de revisões sistemáticas é que esta resume as evidências existentes em relação a um tratamento ou tecnologia (KITCHENHAM, 2004). Assim, no tema deste trabalho, foi relevante levantar vários estudos sobre a temática em questão, obtendo uma visão da evolução da área nos últimos anos.

Kitchenham (2007) aponta que este método de pesquisa baseado em evidência necessita da definição de um protocolo para assegurar sua imparcialidade e para que seja passível de auditoria. As etapas desse protocolo são: Planejamento, Condução e Reporte do Mapeamento. No Planejamento, destaca-se a especificação das questões de pesquisa e o desenvolvimento do protocolo da mesma. Na Condução, há a seleção dos estudos primários e posterior avaliação da qualidade do material, além da extração e síntese dos dados. Na etapa de Reporte, serão apresentados os resultados a partir das respostas das questões de pesquisa definidas.

#### 1.1 PLANEJAMENTO

As questões de pesquisa norteiam a metodologia do Mapeamento Sistemático, sendo a definição das mesmas considerada a atividade mais importante por Kitchenham (2007). Pelo fato de somente os dados que têm relações com elas serem avaliados, as questões também atuam como fatores de inclusão e exclusão de trabalhos na etapa de Condução, além dos resultados em si serem fruto de suas respostas. Neste trabalho, dois conjuntos de questões foram elaborados, os quais se referem às duas fases da Condução. A

primeira fase tem como finalidade decidir a inclusão ou exclusão dos trabalhos, bem como a identificação dos estudos primários relacionados ao tema. A segunda fase aborda questões mais detalhadas sobre os conceitos observados no material obtido na pesquisa, que servirão de fato como resultados do Mapeamento Sistemático. As referidas questões estão incluídas no Apêndice II deste trabalho.

Em seguida, foi realizado um levantamento sobre a disponibilidade de trabalhos relacionados ao tema nos engines de busca, e os seguintes foram escolhidos: ACM, Arxiv, EBSCOhost, IEEE, Science Direct (Elsevier), Scopus, Springer e Wiley Online Library.

Uma vez que a fonte de pesquisa foi estabelecida, foi necessário definir a String de Busca que represente o escopo do levantamento, refletindo o conteúdo abordado nas questões de pesquisa. A seguinte String de Busca foi concebida: ("Genetic Algorithm") AND ("Energy Efficiency") AND ("Subway" OR "Train") AND ("Speed Profile"). Houve a necessidade de adaptá-la ao formato de entrada que alguns engines de busca exigiam.

Crerios de inclusão e exclusão foram incluídos para auxiliar na seleção de estudos relevantes ao mapeamento, feita na primeira fase da Condução. Os seguintes tipos de estudos foram incluídos nesta avaliação sistemática:

Estudos completos publicados em revistas ou conferências sobre a Eficiência Energética em malhas metroferroviárias que respondam pelo menos uma das três (3) questões principais da pesquisa Speed Profile, Reuso de Energia ou Timetable;

Estudos teóricos ou experimentais com o objetivo de apresentar conceitos para o entendimento da área;

- O artigo precisa ter sido publicado a partir de 2011;
- Acessível eletronicamente.

Os seguintes estudos serão excluídos:

- Estudos que não estejam claramente relacionados à área de Eficiência Energética em malhas metroferroviárias;
- Estudos que não respondem a nenhuma das três (3) questões de pesquisa;
- Artigos duplicados, ou seja, aqueles encontrados em mais de um engine de busca;
- Artigos convidados, tutoriais, relatórios técnicos que não passam pelo critério de avaliação por pares das conferências ou revistas;

- Estudos não disponíveis eletronicamente.

Posteriormente, a etapa de condução é iniciada com o propósito de filtrar os trabalhos aos quais se teve acesso e analisar os pormenores dos que foram incluídos.

## 1.2 CONDUÇÃO

A condução do mapeamento sistemático é a etapa mais substancial do processo e, por isso, também a mais longa. Como mencionado anteriormente, levantou-se vários engenhos de busca para iniciar esta fase, de modo que 8 foram escolhidos: **ACM, Arxiv, EBSCOhost, IEEE, Science Direct (Elsevier), Scopus, Springer e Wiley Online Library**. Foi necessária a adaptação da String de busca para o formato particular de cada um deles, com o objetivo de abranger o maior número de citações que envolviam Algoritmos Genéticos aplicados ao problema de eficiência energética em trens urbanos no período de 2011 a 2016.

### 1.2.1 Primeira Fase - Inclusão/Exclusão dos trabalhos

A fase inicial de condução do mapeamento tem como objetivo filtrar os artigos obtidos e identificar, em linhas gerais, quais estratégias de eficiência energética eram utilizadas, bem como as questões abordadas sobre Algoritmos Genéticos. Para tal, foram utilizados os critérios de inclusão e exclusão definidos na seção referente ao planejamento, com a finalidade de manter apenas aqueles trabalhos que se alinhavam com a proposta da pesquisa. Desses critérios, as questões particulares que envolvem conceitos de Algoritmos Genéticos foram levantadas para identificar a frequência com que os autores as abordavam e as primeiras tendências sobre essas definições.

Por conta do número de artigos selecionados e a necessidade de oferecer uma confiabilidade maior a este processo, na tentativa de eliminar a subjetividade, foi decidido que cada trabalho seria analisado por dois pesquisadores de forma independente.

Em virtude do volume de leituras e da disponibilidade de pesquisadores, a equipe desta fase foi composta por 12 pessoas, na qual cada membro se responsabilizou por uma parcela das obras. Trabalhos cujos títulos ou resumos remetiam diretamente a estudos sobre outras áreas eram antecipadamente descartados. Aqueles que continuaram se

submetiam ao processo na etapa executada com o emprego de leituras objetivas em cima dos aspectos a serem examinados. Uma questão relevante seria verificar a ocorrência das estratégias de eficiência energética juntamente com o emprego de cada uma delas em conjunto.

Como o número de leituras para cada artigo foi par, houve opiniões divergentes quanto à inclusão de obras para a próxima fase. Para solucionar esse impasse, uma terceira leitura dos trabalhos em questão foi realizada por um outro membro da equipe com o propósito de desempatar e decidir a inclusão ou não.

Embora o foco do mapeamento seja atentar para a utilização dos AGs na eficiência energética, foi constatado o uso de diversas outras formas de otimização para solucionar esse problema. Esse fato foi responsável por reduzir a maior parte do número de artigos aprovados. Dentre as técnicas identificadas, se destacaram: Fuzzy Logic, (CARVAJAL-CARREÑO et al., 2016), Simulated Annealing (XIE et al., 2012), Ant Colony Optimization, (LU et al., 2013) e Linear Programming (GUPTA et al., 2016).

Do total de 115 artigos que entraram nesta fase, 18 deles atenderam aos critérios, bem como responderam às questões de pesquisa, portanto foram incluídos para a próxima fase do mapeamento, conforme ilustra a Figura abaixo. Os artigos excluídos nesta etapa não foram aceitos não apenas por limitações impostas pelos critérios, mas também porque foram identificados relevantes *surveys* sobre o campo de pesquisa. Esse material, não incluído no Mapeamento, foi reservado para ser utilizado em comparações com o material aqui produzido, segundo Kitchenham e Dyba (2004) indicam este procedimento.

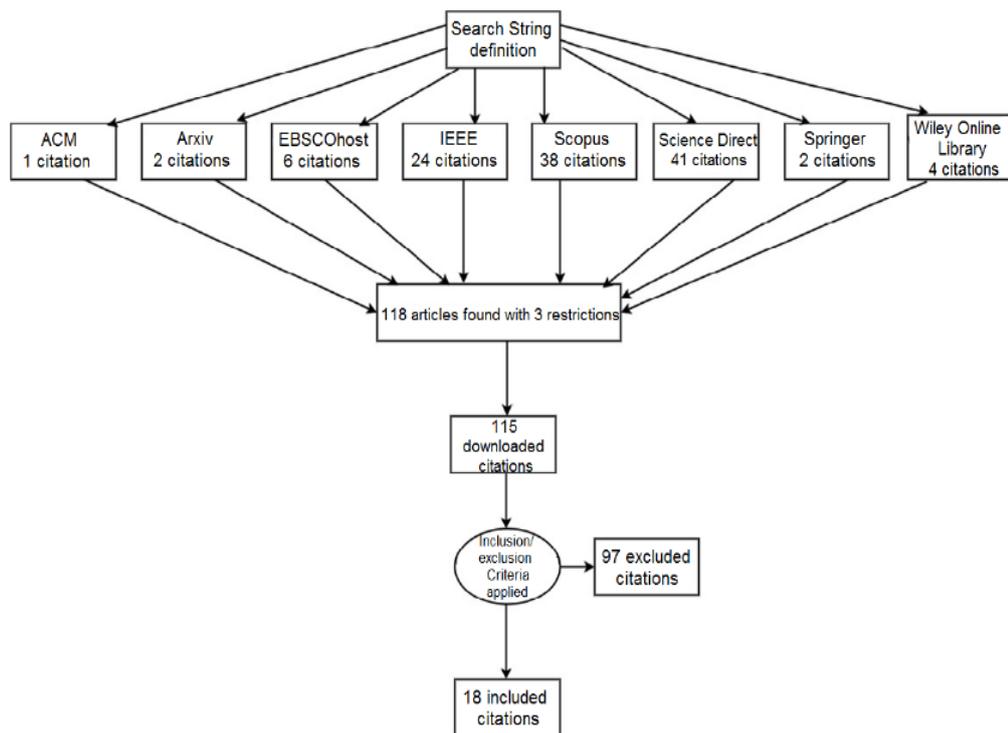


Figura 1: Desenvolvimento – Mapeamento Sistemático

Em resumo, no diagrama da Figura acima, a segunda linha refere-se aos engenheiros de busca e a quantidade de citações que foram baixadas dos mesmos. Na terceira linha, são expostas a quantidade de citações encontradas, que foram 118 e 3 restrições, nas quais 3 referem-se àquelas que não se foi possível ter livre acesso. A quarta linha diz respeito aos 115 artigos que foram baixados. Neste momento, foram aplicados questionários sobre os critérios de inclusão e exclusão da primeira etapa do mapeamento. Desses, 97 artigos foram excluídos e os 18 restantes passaram para a etapa subsequente. A quinta linha trata dos 18 artigos que foram incluídos na primeira etapa do mapeamento para serem examinados em seguida.

### 1.2.2 Segunda Fase - Análise detalhada e preparação para resposta das questões de pesquisa

Antes de iniciar de fato a segunda fase do mapeamento, decidiu-se realizar uma etapa prévia para o consenso sobre os conceitos abordados pelas questões de pesquisa. Como a referida fase envolve questões de pesquisa mais elaboradas, abordando definições a respeito dos AGs, foi necessário formalizar o entendimento global sobre as ideias

envolvidas, além de como proceder em certos cenários. Desta maneira, o viés de pesquisa individual é reduzido, de forma a incrementar a impessoalidade do procedimento.

Por exemplo, na questão que aborda o relato dos elementos de um Algoritmo Genético (QP2) foi decidido que apenas a menção deles já seria suficiente para contabilizar na resposta, pois questões posteriores já entrariam em detalhes sobre tais componentes. Na questão referente às estratégias de eficiência energética (QP1), os conceitos são correlatos, portanto pode se tornar difícil abordá-los separadamente. O direcionamento que a equipe tomou foi discriminar as principais estratégias adotadas pelos autores, desconsiderando as auxiliares.

Após a inclusão e exclusão dos artigos na fase de filtragem, os remanescentes foram redistribuídos pela equipe com o intuito de analisá-los de maneira mais profunda para responder às questões de pesquisa, de modo que se tenha uma representação significativa e documentada do estado da arte. A equipe desta etapa foi reduzida e contou com 7 colaboradores, em virtude de suas disponibilidades. Embora o número de trabalhos a serem examinados fosse inferior, o detalhamento exigido na leitura era substancialmente maior, para melhor compreensão dos conteúdos levantados nas questões. Além disso, foi estabelecido o número de três leituras individuais por texto para dissolver a fase de desempate no próprio processo.

Algumas vezes, aspectos específicos sobre os Algoritmos Genéticos eram relevados de modo que o foco era direcionado à modelagem do problema e análise dos resultados dos métodos propostos. Nesse ponto, ressalta-se a importância do mapeamento sistemático para extrair informações inerentes à associação do AG como método computacional ao problema de eficiência energética em si.

### 1.3 REPORTE

Esta etapa de Reporte dedica-se a discutir os resultados do Mapeamento Sistemático, bem como analisar as respostas das principais questões de pesquisa relevantes a este trabalho.

Dentre os trabalhos obtidos, publicados entre 2011 e 2016, nota-se grande parcela de Universidades e Institutos europeus e chineses. Certamente, isso ocorre devido ao grande impacto que os transportes metroferroviários provocam na sociedade desses territórios. Há uma dominância de pesquisadores chineses, provavelmente por terem acesso

facilitado às linhas urbanas, destacando-se o State Key Laboratory of Rail Traffic Control and Safety da Beijing Jiaotong University.

### QP2.1 - Qual a estratégia de eficiência energética utilizada?

Segundo os artigos relevantes da pesquisa, 67% dos estudos utilizavam a estratégia de eficiência energética pela otimização do Speed Profile. Observou-se também o uso integrado desses métodos, com 16% atribuídos ao emprego conjunto de Speed Profile e Timetable, e 17% na qual essa integração enfatiza a intenção do reuso de energia. A Figura abaixo apresenta a distribuição do uso das referidas estratégias.

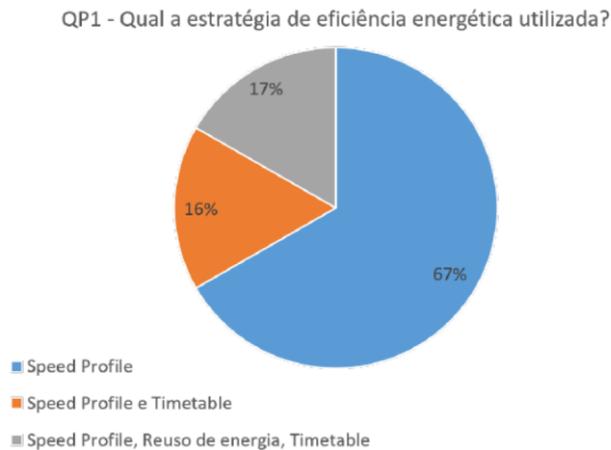


Figura 2: Estratégia de eficiência energética utilizada

### QP2.2 - Quais questões ou operadores da abordagem evolucionária são relatados no artigo?

Aqui, a menção de questões sobre operadores evolucionários era considerada para posterior verificação se os estudos também aprofundavam esse assunto. Por volta de 83% dos artigos mencionam os seguintes itens: criação/geração da população, seleção, crossover e mutação. O módulo da população, que trata de casos como o elitismo nas populações, foi citado em 61% das vezes.

### QP2.3 - Qual a abordagem de validação da proposta é utilizada no trabalho?

Em todos os trabalhos, foi registrado o uso de simulações para validar a técnica proposta, nos quais 83% utilizavam dados reais obtidos em linhas em que podiam direcionar a pesquisa. A metade dos estudos fazia algum tipo de comparação de seus

resultados com outras propostas ou com o estado de operação que as linhas se encontravam. 11% confirmaram seus resultados a partir de modelos teóricos nos quais se baseavam e que anteriormente já indicavam as conclusões tiradas.

#### **QP2.4 - Qual o tipo de representação cromossômica utilizada na modelagem do problema com algoritmo genético?**

O seguinte cenário foi observado nesta questão: 72% dos trabalhos representavam seus cromossomos com número reais, 5% com representação binária e 11% sequer mencionaram esse aspecto. Ainda, 11% especificava que utilizavam lista como estrutura de dados e 27% adotaram outra estrutura. Por exemplo, Li e Lo (2014) e Fernández-Rodríguez et al. (2015) utilizavam um vetor de duas dimensões (matriz). Esta expressiva utilização da representação real era prevista, pois o problema trata da otimização de variáveis numéricas contínuas, com certas restrições desses valores segundo o modelo matemático. Além disso, outra vantagem de se usar esse tipo de representação está na flexibilidade que os operadores reais possuem, pois normalmente realizam algum tipo de operação aritmética nos cromossomos para oferecer maior capacidade de exploração do espaço de busca.

#### **QP2.5 - O trabalho especifica a modelagem matemática que norteia a função de avaliação?**

Todos os estudos possuíam um rigoroso modelo matemático, muitas vezes bem descrito. Embora tivessem o mesmo objetivo e alguns usavam estratégias iguais, como otimizar Timetable, por exemplo, foi observado que a ideia de como criar a modelagem e os aspectos a serem otimizados variavam. Yang et al. (2015) procuram aumentar o uso de energia regenerativa ajustando o Timetable com base no tempo de permanência dos trens nas estações. Xu et al. (2016) formulam um modelo multiobjetivo com o intuito de equilibrar o tempo consumido pelos passageiros e a duração do percurso, também otimizando o Timetable.

#### **QP2.6 - O trabalho possui interface gráfica para a modelagem do domínio?**

Nenhum dos trabalhos analisados apresentou uma proposta de ferramenta dotada de interface gráfica. Não foi exposto se os sistemas que eles utilizavam para fazer simulações

dos resultados tinha alguma forma diferenciada de interação com o usuário. Tampouco exibiram plataformas concebidas para uso geral nesta área de estudo.

### QP2.7 - Qual o método de seleção utilizado?

A técnica de seleção mais utilizada foi a Roleta, relatada em 22% dos estudos. É o tipo de seleção mais popular e possui fácil compreensão e implementação. Em seguida, a seleção por Torneio se destacou com 17% dos casos e os autores certamente consideraram a capacidade do Torneio de aliviar a Pressão Seletiva do Algoritmo Genético, assim, diminuindo a probabilidade dos indivíduos mais bem avaliados dominarem a população. Outros operadores de seleção também foram verificados, por exemplo, Fernández-Rodríguez (2015) utiliza uma variação do NSGA-II (Non-dominated Sorting Genetic Algorithm II) para melhorar a resposta em ambientes dinâmicos. É importante ressaltar que 33% dos artigos não especificam nem entram em detalhes sobre este operador, de certa forma negligenciando este aspecto. A Figura abaixo ilustra os métodos de seleção encontrados.



Figura 3: Método de seleção utilizado

### QP2.8 - Quais os tipos de crossover utilizados?

Nesta questão, há uma maior variação no uso dos operadores. Em 28% dos estudos é empregado o crossover de um ponto. Este tipo de cruzamento, advindo da representação binária, apenas intercala nos filhos trechos dos cromossomos dos pais, sem gerar variações numéricas nos genes. É identificado o crossover uniforme em 11% das vezes e o SBX em 6%. Outros tipos de cruzamento também são identificados, como o Laplace Crossover

utilizado por Gong et al. (2014). Novamente, 33% dos autores negligenciaram a parte referente ao detalhe dos operadores. A Figura abaixo apresenta a distribuição dos operadores de crossover na pesquisa.

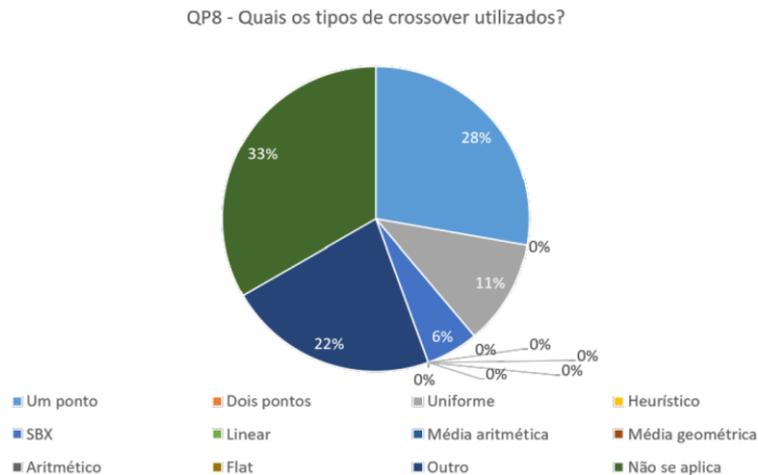


Figura 4: Tipos de crossover utilizados

#### QP2.9 - Quais os algoritmos de mutação utilizados?

A mutação uniforme foi utilizada em 22% dos casos, sendo conhecida como a modalidade de mutação mais elementar. Ela se dá pela simples substituição de um gene por um número aleatório pertencente a um intervalo permitido para aquele parâmetro. A mutação não uniforme, presente em 5% dos trabalhos, difere da modalidade anterior, pois se baseia em uma distribuição não uniforme. Outros algoritmos de mutação foram constatados, como a polynomial mutation em Chevrier et al. (2013), e a power mutation em Gong et al. (2014).

Assim, o levantamento destas informações através deste mapeamento sistemático foi muito importante para nortear a pesquisa desenvolvida. Foi fundamental conhecer como os Algoritmos Genéticos foram construídos dentro do contexto e quais os resultados obtidos nos trabalhos relatados.

## APÊNDICE II

### Questões de Pesquisa - 1ª Fase

QP1.1 - Qual a estratégia de eficiência energética utilizada?

- Speed Profile
- Reúso de Energia
- Timetable

QP1.2 - Quais questões ou operadores da abordagem evolucionária são relatados no artigo?

- Criação da população
- Geração da população
- Seleção
- Crossover
- Mutação
- Módulo da população
- Não se aplica
- Outro

QP1.3 - O artigo deve ser:

- Incluído no Mapeamento Sistemático
- Excluído no Mapeamento Sistemático

### Questões de Pesquisa - 2ª Fase

#### I. Gerais

QP2.1 - Qual a estratégia de eficiência energética utilizada?

- Speed Profile
- Reúso de Energia
- Timetable

QP2.2 - Quais questões ou operadores da abordagem evolucionária são relatados no artigo?

- Criação da população
- Geração da população
- Seleção
- Crossover
- Mutação
- Módulo da população

- Não se aplica
- Outro

QP2.3 - Qual a abordagem de validação da proposta é utilizada no trabalho?

- Dados reais
- Comparações de resultados
- Confirmação com modelo teórico
- Simulação
- Não se aplica

## II. Sobre a Modelagem

QP2.4 - Qual o tipo de representação cromossômica utilizada na modelagem do problema com algoritmo genético?

- Binária
- Real
- Árvore
- Lista
- Grafo
- Outra estrutura de dados
- Não se aplica

QP2.5 - O trabalho especifica a modelagem matemática que norteia a função de avaliação?

- Sim
- Não

QP2.6 - O trabalho possui interface gráfica para a modelagem do domínio?

- Sim
- Não

## III. Sobre Detalhamento Operadores

QP2.7 - Qual o método de seleção utilizado?

- Roleta
- Torneio
- Classificação
- Ranking
- Outro
- Não se aplica

QP2.8 - Quais os tipos de crossover utilizados?

- Um ponto
- Dois Pontos
- Uniforme

- Heurístico
- SBX
- Linear
- Média aritmética
- Média geométrica
- Aritmético
- Flat
- Outro
- Não se aplica

QP2.9 - Quais os algoritmos de mutação utilizados?

- Mutação Uniforme
- Mutação não Uniforme
- Mutação Limite
- Mutação Gaussiana
- Outro
- Não se aplica

Lista de artigos selecionados:

ID	Código	Nome
1	304	A Multi-Objective Subway Timetable Optimization Approach with Minimum Passenger Time and Energy Consumption
2	417	Energy efficiency in high speed railway traffic operation: a real-time ecodriving algorithm
3	424	Investigation into Train Positioning Systems for Saving Energy with Optimised Train Trajectories
4	513	A Two-level Optimization Model and Algorithm for Energy-Efficient Urban Train Operation
5	525	An energy-efficient scheduling and speed control approach for metro rail operations
6	529	Energy saving in railway timetabling: A bi-objective evolutionary approach for computing alternative running times
7	601	Fuzzy optimal schedule of high speed train operation to minimize energy consumption with uncertain delays and drivers behavioral response
8	602	Real time regulation of efficient driving of high speed trains based on a genetic algorithm and a fuzzy model of manual driving
9	604	Optimal design of energy-efficient ATO CBTC driving for metro lines based on NSGA-II with fuzzy parameters
10	612	Efficient driving algorithms for non-disturbed and disturbed trains with the CBTC signalling system
11	614	Impacts of energy saving strategies (ESSs) on rail services and related effects on travel demand
12	621	Optimization of Train Operation in Multiple Interstations with Multi-Population Genetic Algorithm
13	624	An energy-efficient scheduling approach to improve the utilization of regenerative energy for metro systems
14	626	Application of Genetic Algorithms for Driverless Subway Train Energy Optimization
15	627	An Integrated Energy-Efficient Operation Methodology for Metro Systems Based on a Real Case of Shanghai Metro Line One
16	628	A Hybrid Optimization Algorithm for Energy Efficient Train Operation
17	634	Single-Train Trajectory Optimization
18	801	Modeling and Optimizing Energy-Efficient Manual Driving on High-Speed Lines

## APÊNDICE III

Artigo aceito no Andescon 2016

# GeneticBee: A Theoretic and Evolutionary Formulation for the Energy Efficiency Problem of Urban Trains

Marcelle Batista Martins  
Universidade Federal da Paraíba  
Centro de Tecnologia  
João Pessoa – PB, Brasil  
marcellebm@gmail.com

Natasha Correia Queiroz Lino  
Universidade Federal da Paraíba  
Centro de Informática  
João Pessoa – PB, Brasil  
natasha@ci.ufpb.br

Abel Cavalcante Lima Filho  
Universidade Federal da Paraíba  
Centro de Tecnologia  
João Pessoa – PB, Brasil  
abelima@gmail.com

**Abstract** — The electric motors of the trains in a railway system are powered by electricity, and the energy demand is high. In addition, rail-based transport systems continue to grow, and therefore, solutions are currently sought to optimise energy consumption. This article presents an analysis of electric multiple units (EMUs) of the Companhia Brasileira de Trens Urbanos – Brazilian Urban Train Company (CBTU) – Recife, Brazil and the use of electric power provided by the engines during acceleration and braking. To this end, a general model is proposed that encompasses an analysis of the speed and driving profiles, herein termed speed profile optimisation. This model is validated by empirical simulations with the aid of MATLAB software and the implementation of a genetic algorithm of artificial intelligence using the Java programming language. We intend to demonstrate that by controlling the train speed profiles and considering some limits, restrictions and parameters, a decrease in energy consumption in the analysed stations will follow, which will promote more sustainable transport and cost savings.

**Keywords** — *Subway-Railway System, Energy Efficiency, Mathematical Modelling, Computational Modelling, Genetic Algorithms.*

### I. Introduction

The flow of vehicles has considerably increased over the years, causing traffic congestion on roadways and urban areas, constituting one of the most important problems in transport systems. Moreover, in large world metropolises, the subway-railroad system is a highly used public transport service. Therefore, to meet this demand, this subway-railroad system must have a considerable power supply, often based on electricity. In large systems, some details may result in lower efficiency and higher costs [1]. Thus, some methods for energy recycling and energy efficiency optimisation in subway-railway systems have been developed in the literature. The main objective of this work is to develop an energy efficiency model in subway-railway systems in the context of the RailBee Project, to be applied in EMUs of the CBTU stations in Recife. We call the system *GeneticBee* because it involves *Genetic Algorithms* and the *ZigBee* sensors technology.

## II. Energy Efficiency in Railways

The efficient use of energy in trains is a very complicated and difficult optimisation problem because schedule/timetable optimisation issues must be well defined to synchronise the acceleration and braking actions of the trains in the same substation; additionally, the speed profile should also be controlled to reduce traction energy consumption under speed, travel time and distance criteria [8]. Therefore, in the literature, the emerging research on energy efficiency in trains is divided between problem resolution for schedule/timetable optimisation, that is, improvements in train scheduling and synchronisation, and optimisation problems of the speed profiles. Following are some relevant studies in the field.

### A. Schedule / Timetable

**Ramos et al. (2007)** [5] proposed a schedule optimisation model to maximise the time between the acceleration and braking actions in trains of the same substation; **Nasri et al. (2010)** [6] studied the influence of advances in the use of regenerative energy. They found that the use of regenerative energy is efficient if the minimum acceptable power generated and consumed is used at the time of synchronisation of braking and accelerating in trains. **Pena-Alcaraz et al. (2012)** [7] developed a mathematical optimisation model to synchronise trains at the time of braking and acceleration with other trains and thus improve the use of regenerative energy; **David et al. (2012)** [8] formulated an optimisation model to maximise the use of regenerative energy, slightly modifying the permanence time of cars at the stations. A hybrid genetic and linear programming algorithm was implemented for validation. **Yang et al. (2013)** [9] proposed a cooperative scheduling rule to synchronise the acceleration and braking of successive train operations. Then, they formulated a cooperative scheduling model to maximise the junction time between trains, designed through a genetic algorithm to find the optimal schedule programming. **Li & Yang (2013)** [10] proposed a statistical analysis for a stochastic cooperative scheduling model that focused on the randomness of the departure delay in trains at stations, which was shown to save approximately 8% energy compared with a cooperative scheduling approach.

### B. Speed Profile

In the 1960s, Ishikawa (1968) proposed the first optimal control model that determined the most appropriate speed profile. Recently, some studies have favoured the optimisation of the speed profile relative to the minimum net energy consumption. For example, **Bocharnikov et al. (11)** [18] presented a speed profile optimisation model of a single train, considering the traction energy relative to the consumption and use of regenerative energy. In

addition, the authors subsequently conducted a multi-train simulation to estimate the benefits and effects of the ideal speed profile on the minimisation of the net energy consumption. **Dominguez et al. (2012)** [12] took into account the regenerative energy storage in stations and designed a genetic algorithm to solve the optimal speed profile for the minimum net energy consumption. Based on the assumption that all trains should follow a predetermined schedule, **Tuytens et al. (2013)** [13] designed a genetic algorithm to determine the speed profiles for all cars circulating within a specific period for the purpose of proposing a real-time traffic monitoring strategy in which empirical driving models are used to solve the optimal speed profile.

The use of mathematics is one of the most efficient optimisation methods to seek the strategy with the best energy performance and has been widely studied and well applied in subway-railway systems. Thus, associated with mathematical studies, this work proposes an analysis of speed profiles through empirical simulations and applying the genetic algorithm in the context of the trains (EMUs) of the CBTU stations of Recife.

## III. Problem Conceptualisation

The overall objective is to present an energy efficiency model for subway-railway grid systems that addresses speed profile optimisation, which means better control of the train speed profiles to reduce traction energy consumption, considering the allowed speed and voltage limits, travel time and distance.

For the optimisation, strategies for improving energy efficiency in subway-railway grids are analysed, in which the acceleration and deceleration (braking) of the train and its behaviour will be assessed with respect to the limits set by the speed signs along the way. Positive results on the analysis of speed profiles can be found in the studies presented in the previous section.

The study is relevant, as there are currently many government incentives for energy rationing, as a result of growing environmental concerns and high prices of consumed energy.

Therefore, the final goal is for the operational control centre (OCC), equipped with the system and intelligent technology (GeneticBee) generated through this work, to calculate the speed profile that consumes the minimum possible energy per trip. That is, the variables that impact the electricity are supervised and controlled by GeneticBee in this traffic manager centre. The intention is to increasingly automate this process in the future.

### A. RailBee

The RailBee project plans to develop a wireless sensor network (WSN), using the ZigBee protocol, for the monitoring and control of urban trains. The system aims to allow real-time monitoring of a large

set of vehicles that circulate in permanent railways, enabling increased efficiency and traffic safety and decreasing operation costs. The proposed system, called RailBee, consists of a WSN composed of remote modules installed in the vehicles, fixed routers arranged on the railways and base modules for the data reception from the routers. The remote modules will measure several parameters in the trains and send the values through routers to a base module. The data received in the base modules are then available through the intranet in order to be analysed in monitoring stations. The goal is to deploy the RailBee system on a large scale, encompassing a large number of trains. Some studies on the RailBee Project have been performed and validated in the Brazilian Urban Train Company – Recife Subway (CBTU/MetroRec). The main studies conducted are Santos (2010) [14] and (Araújo 2009) [15].

For the continuation of this work, new experimental and theoretical studies will be carried out for system implementation and performance evaluation, and new technologies and protocols will be proposed to meet the performance and cost requirements of the project.

### B. Energy Efficiency Models for Electric Trains

The objective is to implement a module for the design of energy-efficient driving strategies, in terms of speed profiles, which will require different simulation models. Thus, possible speed profiles are defined, according to strategies for energy consumption savings, considering acceleration, speed limits, deceleration and driver behaviour. The model is “calibrated” with data to be collected from sensors in trains of the CBTU/Recife stations. The goal is to demonstrate that the consumption varies considerably depending on the speed profile and driver behaviour. The model should be able to reproduce the average consumption for each driving strategy as well as suggest the best driving strategies for each section of a specific subway-railway substation.

As shown in Figure 1, all the necessary parameters and variables are initially collected, in this case, at the CBTU/Recife stations, and the data are stored in a database.

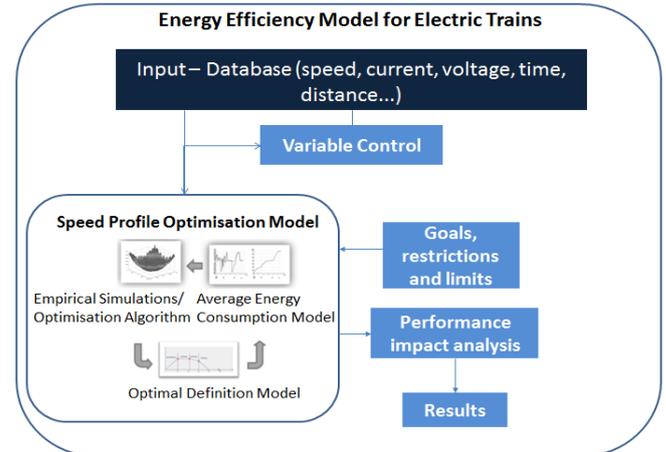


Figure 1- Energy Efficiency Theoretical Model

The model proposed for the speed profile optimisation works as follows: based on the collected data, an average energy consumption model related to the train travelling on a given section of a station is initially built, and then, through empirical simulations and the optimisation algorithms, the best solutions for the optimisation of speed profiles are generated.

Thus, based on the results an optimal definition model is built, where its impacts and performances are evaluated. The proposed energy efficiency theoretical model is specified in a looped speed profile optimisation model, until the best solution for a specific situation or section of the subway-railway grid is found.

### C. Mathematic Formulation

The energy consumption model is simulated taking into account the calculation of electric energy consumed by the trains in a predetermined section. Based on the work of Lima (2012) [16], we adopted the following mathematical calculation to obtain the average energy consumption (AEC) per segment:

The AEC per train is:

$$\text{AEC} = l * \text{sec} * w \quad \text{where}$$

$l$  = round trip line distance [km]

$\text{sec}$  = specific energy consumption of the train in [Wh/t km]

$w$  = full train weight in [t/train]

obs.: specific energy consumption (sec) = power x time

obs2.: power = current x voltage

The AEC can also be calculated using the integral calculation below. Note that for the mathematical modelling, a section in the MetroRec South Line is chosen so that the energy consumption by some trains in a fixed time interval can be evaluated.

$\text{AEC} = \int p \, (dt)$  (average energy consumption is equal to the integral of power over time).

Thus, with the AEC calculation per section and input data (speed, current, voltage and acceleration), several empirical simulations are carried out, and analytical charts describing the behaviour of each variable along the railway are developed. The objective is also to find the train acceleration and braking values during the time determined for its operation and thus critically examine what may be affecting the energy consumed by the trains. The figure below shows the entire data capture process up to its simulation with the aid of MATLAB software, which returns the graphs composed by the speed, power and acceleration curves that were operated by the three drivers, to assess which one had the more favourable energy efficiency curve.

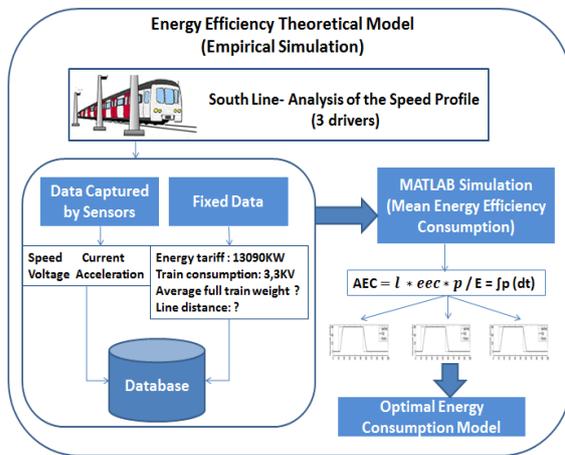


Figure 2 - Empirical Simulation

D. Genetic Bee (Evolutionary Formulation)

An overview of the proposed genetic algorithm is presented in the figure below, which contains the stages, step by step, to determine the best driving profile to be followed by the drivers to obtain an energy efficiency optimisation. The purpose of this genetic algorithm is to generate energy-efficient traffic control strategies.

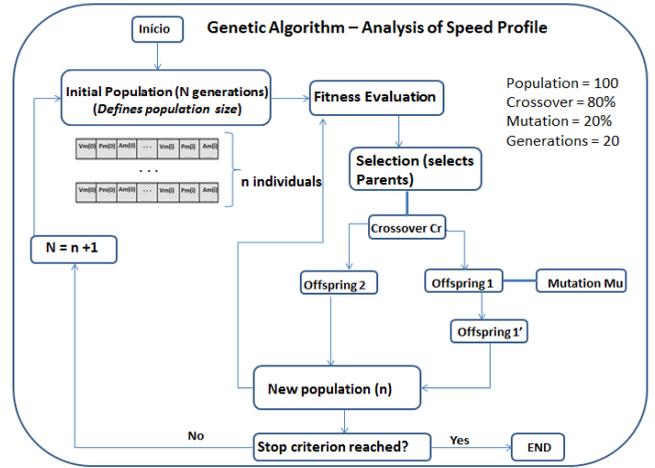


Figure 3 – Genetic Algorithm – Analysis of Speed Profile

For the representation of the problem, binary values are usually used, but for the context of this study, which involves many variables and parameters, the real representation is adopted, where the individual (chromosome) represents a set of subsections from one station to another, belonging to the MetroRec South Line. Then, data is captured (for instance, speed, power and acceleration), using ZigBee sensors in each subsection, that can be considered a gene on chromosome representation (since these values may differ from one section to another). Thus, the variables of interest to our problem are the following parameters: mean speed, mean power and mean acceleration. The real representation of our chromosome is as follows:

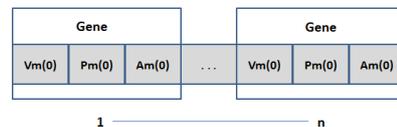


Figure 4 - Codification of Chromosome

In our initial tests, a random population is defined with 100 individuals and 20 generations. Some mathematical evaluation functions, shown in section “III.C” of this article, were defined for our problem to assign each chromosome or individual a

value to classify it to fit within the current generation. The total energy consumption of a specific traffic control is obtained by the sum of the energy consumed by all sub-sections included in the trip, as follows:

$$EEc = \sum_{i=1}^{20} F(x)(V, P, A)$$

Thus, with these values, we conduct the selection test, initially using the roulette method, where the parents are selected. Through the crossover technique, where the parents undergo crossover in 80% of the cases, the offspring are generated, which may or may not be mutated because the rate for this occurrence was initially defined as 20%. This selection process occurs until all parents are replaced by their offspring, creating a new population with 100 individuals. This cycle of new population generations is repeated up to 20 generations or until a good solution quality is found for our problem (i.e., until the solution quality corresponds to a good proposal for energy-efficient train driving).

#### IV. Conclusion

The main contribution of this paper is the formulation of the mathematical and evolutionary model to the problem, to propose an optimisation approach to improve operation and energy efficiency management in subway-railway systems. A theoretical model was abstractly demonstrated to formulate strategies to control speed profiles that can significantly contribute to the decrease of electric energy consumption. With the advances in studies in this field, future implementation in the power supply control of EMUs is made possible, thus contributing to energy saving.

The empirical study has been initiated with the survey of real data collected by sensors between the Recife and Joana Bezerra stations, in the Metrorec south line. The next step is to evaluate the results obtained in these experiments and then input the obtained values into our genetic algorithm. The work will be validated by comparing the experimental study and the results obtained from the genetic algorithm.

#### Acknowledgment

This work was supported by the National Institute of Science and Technology for Software Engineering (INES—[www.ines.org.br](http://www.ines.org.br)), funded by CNPq, grant 573964/2008-4. The authors thank CAPES (Coordenação de perfeiçãoamento de Pessoal de Nível Superior) e METROREC for incentive and opportunity to conduct this research.

#### References

- [1] Porto, C. C.; Matos, C. A. S.; Oliveira, F. S. ESTUDO DE POTENCIAIS TECNOLOGIAS DE REGENERAÇÃO E OTIMIZAÇÃO DE ENERGIA PARA OS TRENS DA CPTM - Unicamp, 2013
- [2] Feltes L. H. and J. L. V. Barbosa, "A Model for Ubiquitous Transport Systems Support", IEEE LATIN AMERICA TRANSACTIONS, VOL. 12, NO. 6, SEPTEMBER 2014
- [3] Brézillon P., Naveiro, M. Cavalcanti, J.-Ch. Pomerol; SART: AN INTELLIGENT ASSISTANT SYSTEM FOR SUBWAY CONTROL - Rio de Janeiro, 2000
- [4] Tuytens, D., Fei, H.Y., Mezmaz, M., Jalwan, J., 2013. Simulation-based genetic algorithm towards an energy-efficient railway traffic control. *Mathematical Problems in Engineering*, Article ID 805410, 1–12.
- [5] Ramos, A., Pena, M., Fernandez-Cardador, A., Cucala, A.P., 2007. Mathematical programming approach to underground timetabling problem for maximizing time synchronization. In: *Proceedings of the International Conference on Industrial Engineering and Industrial Management*, IEEE Publisher, Madrid, Spain, pp. 88–95.
- [6] Nasri, A., Fekri Moghadam, M., Mokhtari, H., 2010. Timetable optimization for maximum usage of regenerative energy of braking in electrical railway systems. In: *Proceedings of the International Symposium on Power Electronics, Electrical Drives, Automation and Motion*, IEEE Publisher, Pisa, Italy, pp. 1218–1221.
- [7] Pena-Alcaraz, M., Fernandez, A., Cucala, A., Ramos, A., Pecharroman, R., 2012. Optimal underground timetable design based on power flow for maximizing the use of regenerative-braking energy. *Journal of Rail and Rapid Transit* 226 (4), 397–408.
- [8] David, F., Denis, M., Francois, F., 2012. Energy optimization of metro timetables: a hybrid approach. In: *Proceedings of the 18th International Conference on Principles and Practice of Constraint Programming*, Lecture Notes in Computer Science, vol. 7514, Springer Publisher, Québec City, Canada, pp. 7–12.
- [9] Yang, X., Li, X., Gao, Z., Wang, H., Tang, T., 2013. A cooperative scheduling model for timetable optimization in subway systems. *IEEE Transactions on Intelligent Transportation Systems* 14 (1), 438–447.
- [10] Li, X., Yang, X., 2013. A stochastic timetable optimization model in subway systems. *International Journal of Uncertainty, Fuzziness & Knowledge-Based Systems* 21 (Supp. 1), 1–15.

- [11] Bocharnikov, Y.V., Tobias, A.M., Robe, C., 2010. Reduction of train and net energy consumption using genetic algorithms for trajectory optimisation. In: Proceedings of IET Conference on Railway Traction Systems, IEEE Publisher, Birmingham, UK, pp. 32–36.
- [12] Dominguez, M., Fernandez-Cardador, A., Cucala, A.P., Pecharroman, R.R., 2012. Energy savings in metropolitan railway substations through regenerative energy recovery and optimal design of ATO speed profiles. IEEE Transactions on Automation Science and Engineering.
- [13] Tuytens, D., Fei, H.Y., Mezmaz, M., Jalwan, J., 2013. Simulation-based genetic algorithm towards an energy-efficient railway traffic control. Mathematical Problems in Engineering, Article ID 805410, 1–12.
- [14] Santos, J. L. A., 2010, "Sistema Telemétrico para Monitoramento de Trens através de Rdes de Sensores sem Fio e Processamento em Sistema Embarcado". Dissertação de Mestrado, UFPB.
- [15] Araújo, R. C., Santos J. L. A., Anjos, E. G., Lima Filho, A. C., Belo, F. A., Lima, J. A. G; "RailBee", Sistema de instrumentação virtual de veículos em malhas metroferroviárias, Seminário Negócios nos Trilhos. Prêmio Alston de Tecnologia, Revista Ferroviária, 2009.
- [16] Lima, C. R., 2012. Estudo do Aproveitamento de Energia em Veículos Elétricos Utilizados no Sistema Metroferroviário de São Paulo. ISBN 978-85-62326-96-7.

## APÊNDICE IV

**Artigo aceito no ENUCOMP 2016**

### **Um estudo exploratório sobre o uso de algoritmos genéticos para o problema de eficiência energética em trens urbanos**

Mayrton Dias de Queiroz <sup>1</sup>  
Marcelle Batista Martins <sup>1</sup>  
Rodrigo Gonçalves Daniel <sup>1</sup>  
Natasha Correia Queiroz Lino <sup>1</sup>

**Resumo:** *Devido ao aumento populacional, podem-se observar alguns problemas da atualidade, tais como, o desperdício de recursos naturais, congestionamentos, poluição sonora e do ar, dentre outras questões, de forma que se faz necessário a adoção de medidas para minimizar tais problemas. Dentro desse cenário, podem-se destacar as Cidades Inteligentes, que tem como objetivo unir as cidades com as tecnologias de informação retornando assim uma solução inteligente para a sociedade. A Mobilidade Urbana é um dos eixos mais importantes inseridos nas Cidades Inteligentes, qual recebem atenção de vários pesquisadores, onde existe uma preocupação sobre como diminuir a quantidade de veículos nas ruas, reduzir o consumo de combustíveis fósseis, entre outros. Uma alternativa que ajuda a minimizar um dos problemas relatados é a utilização dos transportes urbanos como, por exemplo, os trens elétricos, contudo, surge um problema com relação ao consumo elevado da energia elétrica. Sabendo dessa problemática alguns autores aderem como solução para o problema do consumo energético, a utilização dos Algoritmos Genéticos a fim de encontrar os melhores perfis de condução e velocidade. Assim, este trabalho tem como objetivo fazer uma comparação sobre os possíveis tipos de implementação aplicando os operadores de Crossover encontrados na literatura para que sejam aprimorados possíveis algoritmos evolucionários, de forma a propor novas soluções para reduzir o consumo energético nos trens elétricos.*

**Palavras-chave:** Cidades Inteligentes. Eficiência Energética. Algoritmos Genético.

**Abstract:** *Due to population growth, it may be observed some present-day problems such as the waste of natural resources, traffic congestion, noise and air pollution, among other issues, so it is necessary to adopt measures to minimize such problems. In this scenario, one can highlight the Smart Cities, which aims to unite the cities with the information technology thus returning an intelligent solution to society. The Urban Mobility is one of the most important axes entered in Smart Cities, which receive*

*attention of many researchers, where there is a concern about how to reduce the number of vehicles on the streets, reduce the consumption of fossil fuels, among others. An alternative which helps minimize one of the problems reported is the use of urban transport, for example, electric trains, however, a problem arises with respect to the high consumption of electrical energy. Knowing of this problem some authors adhere as a solution to the problem of energy consumption, the use of genetic algorithms in order to find the best driving and speed profiles. This work aims to make a comparison on the possible types of implementation by applying the Crossover operators found in the literature to possibly improve evolutionary algorithms, in order to propose new solutions to reduce energy consumption in electric trains.*

**Keywords:** Energy Efficiency. Smart Cities. Genetic Algorithms.

## 1 Introdução

Ao observar o desenvolvimento populacional durante os últimos anos, um dos números que vem chamando a atenção de pesquisadores é com relação ao valor do crescimento populacional. Segundo a Organização das Nações Unidas [1], atualmente a população mundial é composta por 7,3 bilhões de pessoas. No entanto, as previsões presentes no relatório "Perspectivas da População Mundial: A Revisão de 2015", estima-se que a população atingirá a marca de 8,5 bilhões até 2030, e de 9,7 bilhões até 2050. Seguindo esse ritmo em 2100 chegará a 11,2, ou seja, um crescimento de 53% comparado com os dados do ano de 2015.

Com o aumento populacional atual, surgem diversas preocupações como destacado por [2]. Ele defende que um planeta onde a população cada vez mais torna-se urbana, dando origem as megacidades, ou seja, cidades com populações acima de 10 milhões de habitantes, é preciso desenvolver modelos de sustentabilidade urbana capazes de alinhar o desenvolvimento desses espaços com o respeito aos princípios da sustentabilidade.

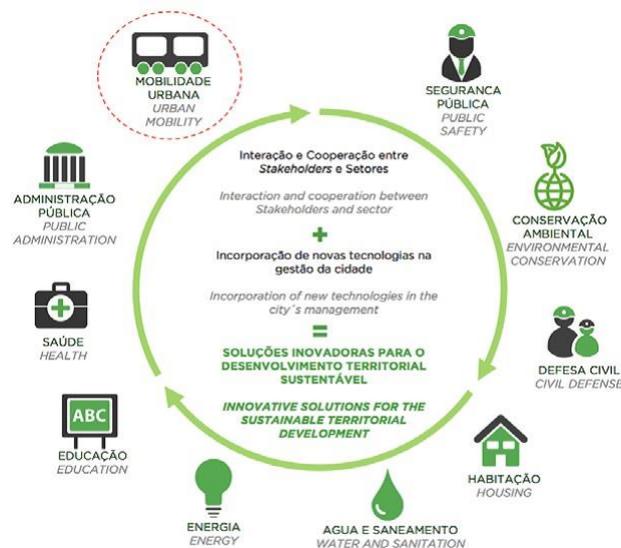
As cidades sustentáveis devem se basear em um modelo no qual consiga equilibrar, de forma eficiente, os recursos necessários para o seu funcionamento, como terra urbana e recursos naturais, água, energia, alimento, entre outros. Encontrar um modelo de funcionamento, gestão e crescimento distintos dos modelos anteriores que se baseava em simplesmente em "expansão com esgotamento" é um dever da cidade sustentável.

Como mostrado em [3], no contexto em que a população mundial se depara com o desafio de alcançar padrões sustentáveis de desenvolvimento já existem várias pesquisas com o intuito de buscar novas soluções para as cidades, visto que, o mundo pede cidades humanas, sustentáveis e inteligentes.

Diante dessas circunstâncias, em [4] é destacado o conceito de Cidade Inteligente (do inglês *Smart City*) que parte da perspectiva na qual a tecnologia é fator indispensável para que as cidades possam se modernizar e oferecer melhor infraestrutura à população. Além disso, esse conceito tem se mostrado fundamental no processo de tornar os centros urbanos mais eficientes e de oferecer boa qualidade de vida e gestão dos recursos naturais por meio de um processo participativo.

Conforme exposto por [4], o autor faz uma divisão dos pontos principais como as atividades de segurança pública, gestão de resíduos e da água, administração pública, saúde, educação, segurança, mobilidade, energia e habitação, entre outros. Onde as cidades devem direcionar-se pelos eixos (mostrado na Figura 1), visto que os mesmos direcionaram as cidades para um melhor desenvolvimento. Esse trabalho tem foco na Mobilidade Urbana, pois como afirma [5] a cidade deve ter um inteligente sistema logístico e de transporte de pessoas, ter meios eficientes de acessibilidade local e internacional, ter um sistema de transporte sustentável - não agressivo ao meio ambiente - e ter amplo acesso à internet.

**Figura 1: Mecanismo das cidades inteligentes Fonte: [4]**



Em relação aos tipos de transportes urbanos, pode-se destacar os Trens Unidade Elétrica (TUE), como uma forma de minimizar os efeitos da emissão de gases poluentes, diminuição de veículos individuais, bem como também a redução do consumo dos combustíveis fósseis. No entanto, surge um problema com relação ao gasto de energia, fazendo-se necessária a adoção de medidas que visam a eficiência energética.

No trabalho [6] é proposto o uso de Algoritmo Genético (em inglês, Genetic Algorithm GA) para determinar o melhor perfil de condução a ser seguido pelos maquinistas, a fim de encontrar a eficiência energética. A autora sugere um GA que tem objetivo de gerar estratégias de controle de tráfego energeticamente eficientes.

De maneira geral, esse trabalho consiste em fazer um comparativo entre os tipos de operadores genéticos de *crossover* existentes na literatura e que atendam as necessidades para solucionar o problema de eficiência energética em trens urbanos. Para facilitar a visualização do comportamento de cada operador de *crossover* foi desenvolvido um *software* com uma GUI (*Graphic User Interface*).

O restante deste trabalho está estruturado da seguinte forma: Na Seção 2 é apresentado detalhes sobre os trens Urbanos de Recife. Na Seção 3 são descritos os pontos relevantes dos GA, bem como também os operadores encontrados na literatura. Na Seção 4, metodologia realizada no

trabalho, Na Seção 5 , os dos resultados gerados do software desenvolvido e na Seção 6 as conclusões e trabalhos futuros.

## 2 Trens Urbanos

Conforme citado anteriormente, um dos eixos das Cidades Inteligentes é o da Mobilidade Urbana. Sendo assim, pode-se notar que na cidade de Recife existe uma alternativa para atender os requisitos da Mobilidade Urbana, que são os trens elétricos. O METROREC é uma empresa operadora de transporte urbano sobre trilhos inserida no Sistema de Transportes Públicos de Passageiros, da Região Metropolitana do Recife [7].

Um dos pontos relevantes do METROREC é com relação as pesquisas desenvolvidas, por exemplo, o sistema Railbee. Segundo [8] Railbee é um sistema de telemetria de sinais de trens desenvolvido e implementado nos TUE da Companhia de Transporte Metroferroviário que é composto por três subsistemas (Figura 2), sendo o primeiro deles um subsistema telemétrico para captação de sinais na via de tráfego, o segundo como um subsistema de recebimento, decodificação e envio dos dados recebidos pelo sistema de captação para o sistema de supervisão e por fim um subsistema de supervisão para armazenamento e visualização dos dados processados pelo sistema.

**Figura 2: Visão geral do sistema RailBee Fonte: [8]**



Esse sistema, denominado Sistema Telemétrico Dinâmico RailBee, é capaz de obter dados de sensores remotos dentro da cabine do TUE, processá-los e enviá-los às centrais de controle e monitoramento. Ele utiliza redes de sensores sem fio, com tecnologia ZigBee para processamento e distribuição dos dados coletados, possibilitando o monitoramento e a distribuição de informações sobre o desempenho dos trens na via de tráfego [8].

Cada TUE é composto por 4 carros, sendo 2 carros-motor e 2 carros-reboque. Os carros-motor são localizados nas extremidades do TUE, onde estão instalados a cabine de comando e os motores de tração, e sua capacidade de lotação é de 268 passageiros, sendo 61 sentados e 207 em pé. Os carros-reboque são os carros centrais, que possuem uma capacidade de lotação de 289 passageiros, sendo: 72 sentados e 217 em pé.

## 3 Algoritmos Genéticos

No ano de 1975, Holland publicou o livro "*Adaptation in Natural and Artificial Systems*". Em seu trabalho, Holland apresenta os GA como uma metáfora para os processos evolutivos, de forma

que ele pudesse estudar a adaptação e a evolução no mundo real, simulando dentro de computadores [9]. GA é um ramo dos algoritmos evolucionários, e como tal, podem ser definidos como uma técnica de busca baseada numa metáfora do processo biológico de evolução natural [9]. Os GA são técnicas de heurísticas de otimização global.

### **3.1 Um algoritmo básico**

Para solucionar um problema com GA tem-se a necessidade de analisar os passos básicos do algoritmo, a fim de identificar quais as adaptações necessárias para que o mesmo atenda de maneira efetiva ao problema. Dessa forma, pode-se notar o algoritmo básico proposto por [9] segue os seguintes passos:

1. Inicialização da população
2. Avaliação individual de cada cromossomo da população gerada
3. Seleção dos pais da população na geração atual
4. Aplicação dos operadores de crossover e de mutação no pais selecionados anteriormente para geração de novos cromossomos da próxima geração
5. Exclusão dos pais da população atual
6. Avaliação dos filhos e inserção na nova população
7. Verificação se já atende ao número de gerações, ou o melhor indivíduo já satisfaz os requerimentos e desempenho, dessa forma ele será retornado, caso contrário ira voltar ao passo 3.

### **3.2 Representação cromossomial**

A representação cromossomial é fundamental para o algoritmo genético, sendo a maneira básica de traduzir a informação do nosso problema em uma maneira viável de tratamento pelo computador [9]. Em outras palavras, a representação cromossomial é a forma de conectar as propriedades relevantes do mundo real ao algoritmo genético, com a finalidade de se obter o melhor resultado possível.

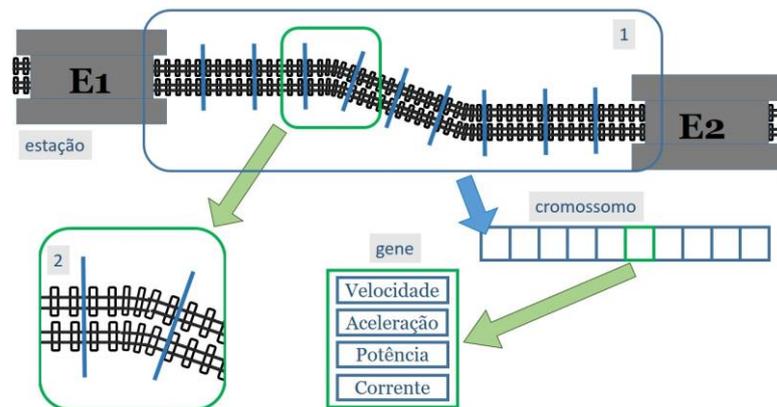
Existem vários tipos de representação cromossomial, como a binária, a de números reais, permutação de elementos para GA baseado em ordem, lista de regras, ou qualquer estrutura de dados necessária. Neste trabalho, foi acolhida a representação de números reais, visto que, a precisão é um fator importante para o problema. No caso da representação binária, existe o problema da necessidade de muito bits para ter uma maior precisão, bem como também um maior gasto de tempo na conversão de real para binário e de binário para real novamente.

Na Figura 3 observa-se a representação adotada neste trabalho, onde E1 e E2 são as estações de embarque e desembarque dos trens. No ponto 1, está a representação do trilho que possui 10 divisões, com base nas divisões existentes entre duas estações no METROREC. Essas divisões servem para que cada seção não passe corrente para a outra, pois cada valor da corrente

representa um valor para a velocidade, a qual auxilia o maquinista no controle da velocidade máxima de cada seção.

Então, com base nessa configuração própria do problema, pode-se tirar proveito dessa situação associando ao algoritmo genético, uma vez que cada seção possui um valor de corrente elétrica específica, podendo ser considerado um gene na representação cromossômica, como mostrado pela seta azul na Figura 3. Outro ponto importante é observar que com a ajuda do zigbee são capturados dados como velocidade, aceleração e corrente que podem ser considerados um gene, um vez que esses valores podem ser distintos de uma seção para outra.

**Figura 4: Representação cromossomial adotada nesse trabalho. Fonte: Autor**



### 3.3 Escolha da população inicial

Ao analisar as formas de criação da população inicial, pode-se citar como exemplo o método de criação aleatória, o da divisão do espaço de busca em  $k$  espaços iguais e selecionando  $n/k$  indivíduos de cada espaço e o método da criação a partir de uma população conhecida. A técnica comumente usada é da criação aleatória, por ser mais simples e em linhas gerais, ela gera uma boa distribuição e juntamente com os operadores de mutação, devolvem uma boa exploração do espaço de busca. Diante dos métodos citados, nesse trabalho utilizou-se da criação aleatória para obter resultados iniciais com a aplicação de crossover distintos.

### 3.4 Função de avaliação

Conforme afirma [9], a função de avaliação é a maneira utilizada pelos GAs para determinar a qualidade de um indivíduo como solução do problema em questão. Pode-se entendê-la mais facilmente tratando a função de avaliação como uma nota dada ao indivíduo na resolução do problema. Essa nota será usada para a escolha dos indivíduos pelo módulo de seleção de pais.

O foco deste trabalho é em relação à busca da eficiência energética, no entanto, é válido destacar, que para os algoritmos genéticos os melhores indivíduos são os que tem maior probabilidade de sobreviver e transmitir suas características para as próximas gerações, ou seja, os máximos da função. Como o problema em questão é para encontrar as configurações que gaste o mínimo possível de energia atendendo as necessidades dos trens, logo pode-se usar a equação descrita em 2 para encontrar o valor da energia, no entanto para a função será adotada a função 1 que é justamente o inverso da função de energia, sendo assim o algoritmo avaliará os indivíduos de menor gasto de energia como bons indivíduos:

$$g(v) = \frac{1}{f(v)} \text{(1)}$$

$$f(v) = \frac{mv^2}{2} \text{(2)}$$

onde:

$g(v)$  é a função que o algoritmo irá maximizar

$f(v)$  é a função que mostra o valor da energia

gasta

$m$  é a massa do trem

$v$  é a velocidade do trem

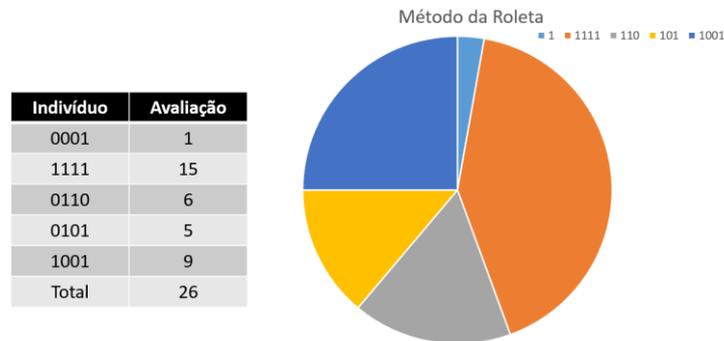
### 3.5 Seleção dos pais

A seleção dos pais deve simular o mecanismo de seleção natural, a qual atua sobre as espécies biológicas, em que os pais mais capazes geram mais filhos, ao mesmo tempo ela permite que os pais menos aptos também gerem descendentes [9]. Nesta etapa, os operadores de seleção devem priorizar os indivíduos que possuem as melhores avaliações, todavia, sem desprezar os indivíduos com baixa avaliação, desse modo, caso sejam selecionados só os melhores, nas próximas gerações, os indivíduos começarão a ficar muito semelhantes e faltará diversidade para que a população possa progredir de forma satisfatória, causando o efeito chamado de convergência genética.

#### 3.5.1 Método da roleta

Para melhor entendimento do método da roleta pode-se observar a Figura 4 que possui a tabela com cinco indivíduos e suas respectivas avaliações, no entanto, vale destacar que na prática dificilmente será criada uma população com cinco indivíduos, mas esse exemplo vale para fins didáticos. Então, como foi citado anteriormente, é preciso prover a chance para cada indivíduo. Como descreve [9], nesse método é criado uma roleta (virtual) na qual cada cromossomo recebe um pedaço proporcional à sua avaliação.

**Figura 5: Tabela com os indivíduos com suas avaliações e a roleta representando os indivíduos de forma proporcional. Fonte: Autor**



De posse do valor da soma total das avaliações dos indivíduos, pode-se verificar a proporção de cada indivíduo na roleta, como mostrado na Figura 4. No passo seguinte, é sorteado um valor aleatoriamente de 1 até o valor da soma total das avaliações, a fim de se verificar em qual pedaço da roleta ficou o número sorteado e assim descobrir qual o indivíduo que corresponde ao pedaço da roleta.

### 3.5.1 Método do torneio

O método do torneio como relata [9], consiste em selecionar uma série de indivíduos da população e fazer com que eles entrem em competição direta pelo direito de ser pai. Para selecionar o pai por esse método é necessário determinar o valor do atributo  $k$ , que define a quantidade de indivíduos a serem selecionados aleatoriamente dentro da população para competir.

**Figura 6: Método do torneio. Fonte: Autor**

#### Método do Torneio para $k = 3$

Indivíduo	Avaliação	1	2	3	
x1	1	x2	x1	x4	x2
x2	15	x4	x3	x1	x3
x3	6	x5	x3	x3	x5
x4	5	x1	x3	x4	x3
x5	9	x4	x4	x4	x4

A Figura 5 possui duas tabelas onde a primeira possui os indivíduos e suas respectivas avaliações, e a segunda tabela mostra quais os indivíduos  $k$  indivíduos escolhidos aleatoriamente. Nesse exemplo foram selecionado 3 indivíduos e entre eles será escolhido o de maior avaliação. Na segunda linha pode-se ver que os indivíduos escolhidos foram o X2, X1 e X4, logo o indivíduo selecionado será o indivíduo X2 por possuir a avaliação 15, superando a avaliação de X1 e X4.

### 3.6 Crossover

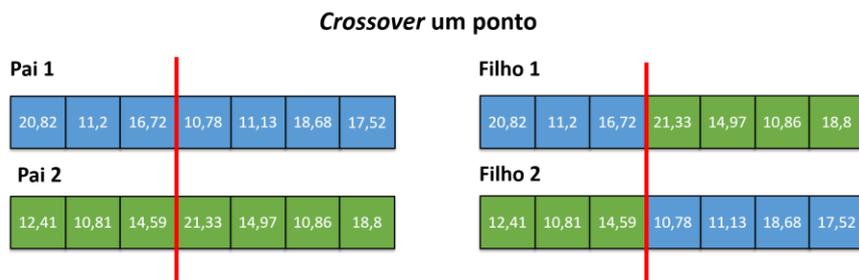
Esse método é baseado no modo como as cadeias de DNA recombina as umas com as outras na reprodução humana para combinar características de cada pai em um filho [10]. Já [11] complementa que nos algoritmos genéticos contínuos há vários modos diferentes de realizar o cruzamento. O cruzamento é dependente da forma como o cromossomo é representado.

#### 3.6.1 Crossover de um ponto

O operador de *Crossover* de um ponto como mostrado na Figura 6 é aplicado em dois cromossomos de mesmo comprimento, como a seguir:

- Selecionar um ponto aleatório para o cruzamento
- Separar cada cromossomo em duas partes, dividindo-o no ponto de cruzamento
- Recombinar os cromossomos separados, combinando a parte inicial de um com a parte final do outro e vice-versa, para produzir dois novos cromossomos [12].

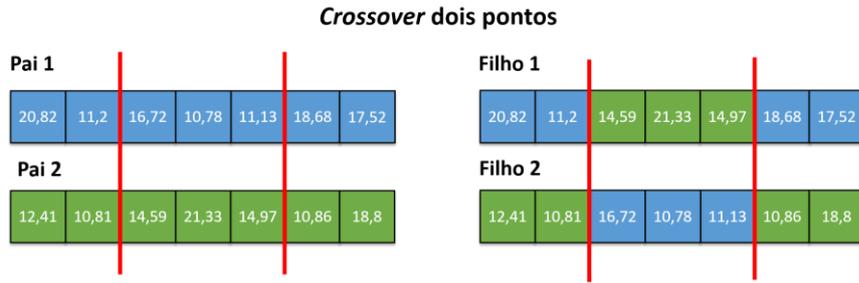
Figura 7: *Crossover* de um ponto. Fonte: Autor



#### 3.6.2 Crossover de dois pontos

Segundo [12] nesse *crossover*, dois pontos são escolhidos para dividir os cromossomos em duas seções, com as seções externas juntando-se para transformar o cromossomo em um anel. As duas seções são trocadas como mostrado na Figura 7.

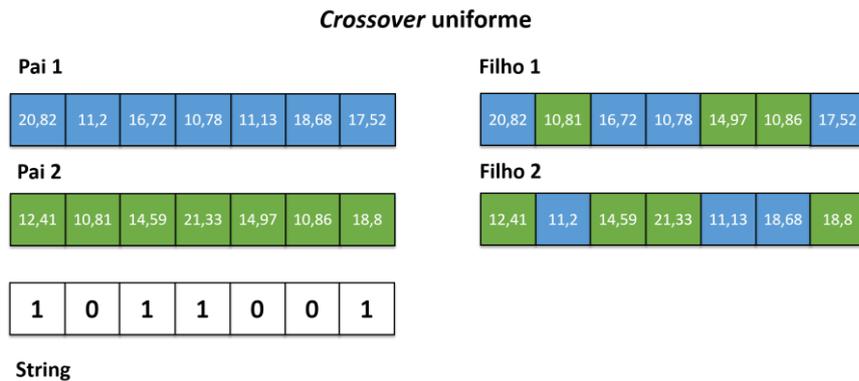
**Figura 8: Crossover de dois pontos . Fonte: Autor**



### 3.6.3 Crossover uniforme

Conforme mostrado em [9] o *crossover* uniforme, faz-se um sorteio para escolher em cada posição  $l$  um elemento pertencente ao conjunto dado por  $\{c_l^1, c_l^2\}$  e o segundo filho recebe o elemento não sorteado para o primeiro. Um exemplo do funcionamento deste operador pode ser visto na Figura 8. Este operador é mais eficiente quando a função de avaliação é linear, não havendo termos cruzados entre os valores armazenados.

**Figura 8: Crossover uniforme. Fonte: Autor**



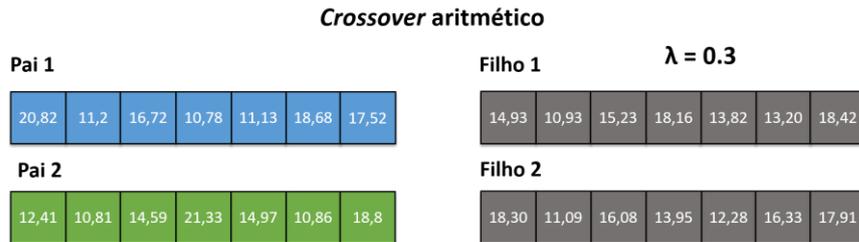
### 3.6.4 Crossover aritmético

Como relata [9] o *crossover* aritmético, define-se um parâmetro  $\lambda \in [0,1]$ , e calcula-se cada posição do primeiro filho através da fórmula 3, onde  $l$  é o índice da posição que varia de 1 a quantidade de genes dos pais. De maneira análoga, para gerar o segundo filho será usada a fórmula 4.

$$C_{filho1} = \lambda C_{l1} + (1 - \lambda) C_{l2} \quad (3)$$

$$C_{filho2} = \lambda C_{l2} + (1 - \lambda) C_{l1} \quad (4)$$

Figura 9: Crossover aritmético. Fonte: Autor



### 3.6.5 Crossover linear

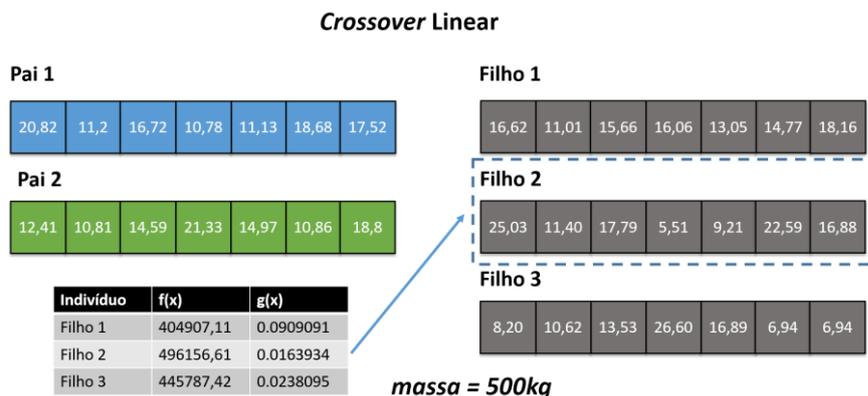
O operador de *crossover* linear conforme apresenta [9] evita a criação de filhos iguais em uma reprodução, de forma que ele gera três filhos com base nas fórmulas 5, 6 e 7. Para manter o tamanho da população é avaliada cada filho gerado e o filho de avaliação mais baixa é excluído. Como pode ser visto na Figura 10 a tabela que possui o valor da avaliação dos três filhos, sendo que o filho 2 obteve a menor avaliação como mostrado na coluna  $g(x)$ , logo esse filho será excluído, restando apenas dois filhos.

$$c_l^{filho1} = \frac{c_l^1}{2} + \frac{c_l^2}{2} \quad (5)$$

$$c_l^{filho2} = \frac{3 * c_l^1}{2} - \frac{c_l^2}{2} \quad (6)$$

$$c_l^{filho3} = \frac{-c_l^1}{2} + \frac{3 * c_l^2}{2} \quad (7)$$

Figura 10: Crossover linear. Fonte: Autor



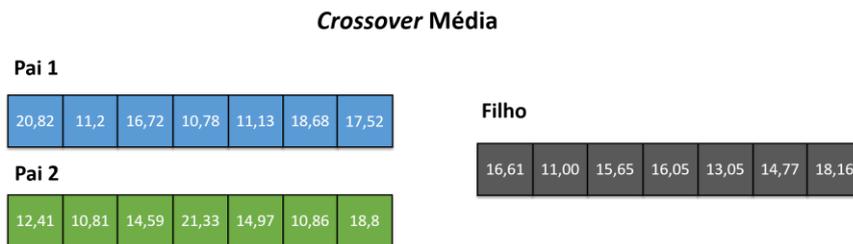
### 3.6.6 Crossover média

Nesse *crossover* é realizado a média entre os valores dos genes de cada pai, ou seja, será feita a média com o primeiro gene do primeiro pai e o primeiro gene do segundo pai, esse processo continua até que seja feita a média entre o último gene do primeiro pai com o último gene do segundo pai, gerando assim um novo valor (caso os genes não sejam os mesmos) para o filho como

mostrado na Figura 11. Assim sendo  $p_i^1$  e  $p_i^2$  são os cromossomos dos pais,  $c$  o cromossomo filho e  $i$  um gene do cromossomo. A média aritmética é expressa na equação 8 [11].

$$c_i = \frac{(p_i^1 + p_i^2)}{2} \quad (8)$$

**Figura 11: Crossover média. Fonte: Autor**

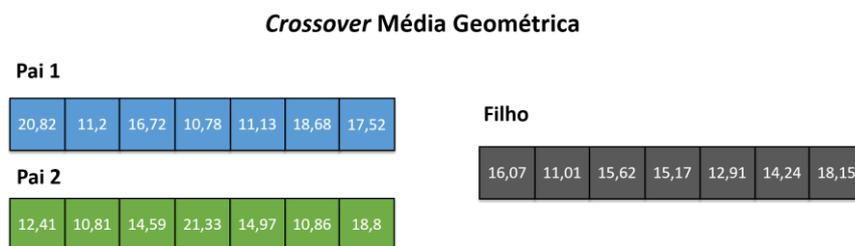


### 3.6.7 Crossover média geométrica

O *crossover* média geométrica, consiste em criar um filho  $c$  aplicando a equação descrita em 9, onde  $p_i^1$  é a informação do gene  $i$  do pai  $n$ , sendo  $i$  a quantidade de genes do cromossomo, e  $n$  representa o valor do pai, logo os valores podem ser 1 ou 2. O cromossomo média induz os genes para o meio do intervalo entre os genes, acarretando perda de diversidade [13].

$$c_i = p_2 (p_{i1} * p_{i2}) \quad (9)$$

**Figura 12: Crossover média geométrica. Fonte: Autor**

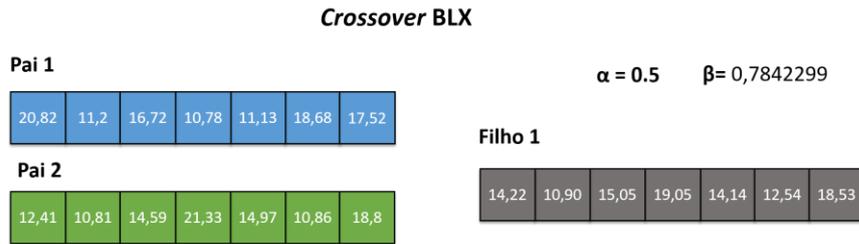


### 3.6.8 Simulated Binary Crossover

Segundo [11] no *Simulated Binary Crossover* (SBX -  $\alpha$ ) os filhos são criados a partir da fórmula descrita em (10), de forma que o  $\beta$  será um número entre  $(-\alpha, 1+\alpha)$ . Na Figura 13 é mostrado um exemplo, com  $\alpha = 0.5$  e  $\beta = 0.7842299$ .

$$c = p_1 + \beta(p_2 - p_1) \quad (10)$$

**Figura 13: Simulated Binary Crossover. Fonte: Autor**



### 3.6.9 Crossover flat

O *crossover flat* segundo [9] consiste em estabelecer um intervalo fechado para cada par de valores no cromossomo, do menor valor armazenado até o maior e escolher um valor aleatório pertencente a este intervalo. Pode-se observar o funcionamento desse na Figura 14.

**Figura 14: Crossover flat. Fonte: Autor**

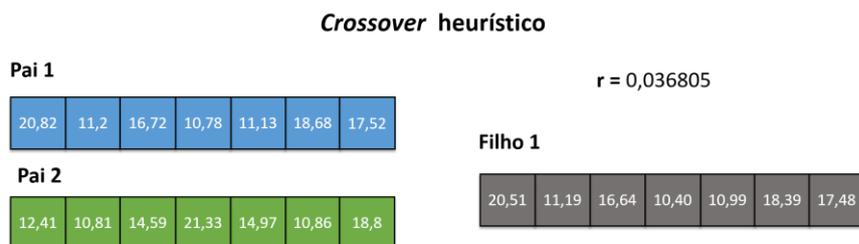


### 3.6.10 Crossover heurístico

O *crossover heurístico* (Figura 15), como descrito por [11] é um *crossover* baseado em direção, onde faz uso da informação da função de avaliação ou do gradiente para determinar a direção da busca. Por exemplo, se temos uma  $f(x)$  que é a função de avaliação que desejamos minimizar, o filho é gerado conforme a equação.

$$c = \begin{cases} p_1 + r(p_1 - p_2) & \text{se } f(p_1) < f(p_2) \\ p_1 + r(p_2 - p_1) & \text{se } f(p_1) \geq f(p_2) \end{cases}$$

**Figura 15: Crossover heurístico. Fonte: Autor**



### 3.7 Mutação

A etapa final do GA é chamado mutação. A mutação em biologia é relativamente rara, pelo menos na medida em que afeta sensivelmente a prole. Na maioria das implementações de GA a mutação também é rara ( na ordem de 2%). A melhor taxa de mutação depende do problema, do tamanho da população, codificação, e outros fatores. Independentemente da sua frequência, a mutação é importante porque permite que o processo evolutivo possa explorar novas soluções potenciais para o problema. Se alguma informação genética está em falta a partir da população, a mutação fornece a possibilidade de injetar essa informação para a população [10].

Logo, pode-se dizer que o operador de mutação é uma heurística exploratória, injetando novos cromossomos na população e permitindo que o GA busque soluções fora dos limites definidos pela população [14]. Um detalhe relevante é que com a representação numérica, não binária, a probabilidade da mutação, deve ser um pouco mais alta, devido ao efeito da ocorrência de duas ou mais mutações no mesmo cromossomo binário [15].

#### 3.7.1 Mutação uniforme

Conforme afirma [11] a mutação uniforme troca o valor de um gene por um número aleatório uniforme no intervalo  $[a_i, b_i]$  aceito pelo gene. Caso seja preciso fazer a mutação em um determinado  $k$ -ésimo gene  $p$  do cromossomo, então o filho  $c$  será calculado conforme a equação a seguir:

$$c_i = \begin{cases} U(a_i + b_i) & i = k \\ p_i & i \neq k \end{cases}$$

## 4 Metodologia

Ao fazer uma busca pelos operadores na literatura foi observado que alguns possuíam parâmetros a serem definidos, no entanto, no primeiro momento foram mantidos os valores já usados da fonte, dessa forma podemos citar os seguintes operadores com seus respectivos parâmetros.

- No operador de Seleção torneio, é preciso definir qual o valor de  $K$  que representa a quantidade de indivíduos que irá ser escolhido para competir, no nosso problema foi usado  $K = 3$ .
- No operador de *Crossover* aritmético, há a necessidade de definir o valor de  $\lambda$ , onde foi definido como  $\lambda = 0.3$ .
- O operador *Simulated Binary Crossover* possui o parâmetro  $\alpha$  que foi definido como sendo  $\alpha = 0.2$ .
- O operador *Crossover* heurístico o valor do parâmetro  $r$  é um valor aleatório dentro do intervalo  $(0, 1)$ , mas ele é definido no momento da reprodução.

Já os valores em relação a todos os experimentos foram:

- População: 100 indivíduos
- Geração: 50
- Mutação: 0.1

Após realizada a representação cromossômica e as implementações, o próximo passo foi analisar e organizar as implementações, mas de forma que os operadores não interferissem no resultado uns dos outros, visto que havia o interesse em fazer uma comparação, a fim de encontrar os operadores mais adequados para compor o algoritmo genético que busca resolver o problema da eficiência energética dos trens urbanos.

Na Figura 16 pode-se encontrar a tela inicial do software, onde é possível observar elementos gráficos, nos quais o usuário poderá fazer modificações quanto a execução de comparações. Dessa forma, foi criada uma classe Experimento que possui atributos como geração, seleção, *crossover* e mutação. Esses atributos auxiliam no momento de combinar os operadores desejados pelo usuário.

Figura 16: Tela inicial do software desenvolvido. Fonte: Elaborada pelo autor

The screenshot shows the 'GeneticBee' software interface with the following configuration options:

- Parâmetros do Experimento:**
  - População: 100
  - Geração: 50
  - Mutação: 0.1
- Parâmetros dos Operadores:**
  - Lambda: 0.3
  - K: 3
  - Alfa: 0.2
  - Trechos: 5
- Operadores:**
  - Geração:**
    - Aleatório
    - Dados
  - Seleção:**
    - Roleta
    - Torneio
  - Crossover:**
    - Um ponto
    - Dois pontos
    - Uniforme
    - Heurístico
    - Flat
    - Aritmético
    - Linear
    - Média Aritmética
    - Média Geométrica
    - SBX
  - Mutação:**
    - Uniforme

An 'Executar' button is located at the bottom right of the configuration area.

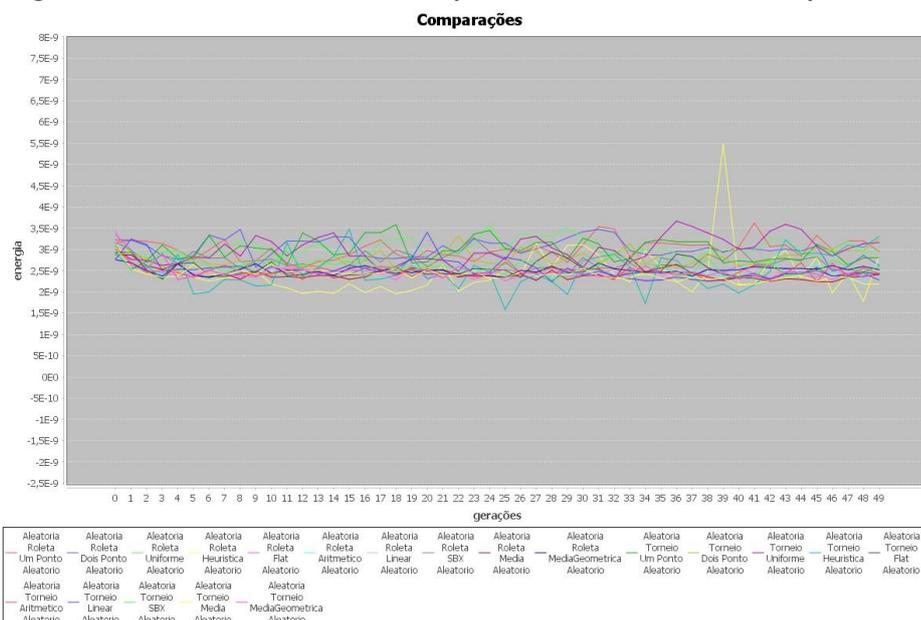
Já os outros atributos são definidos pelo usuário, como População, Geração e Mutação, que são comuns a todos os experimentos. A cada novo experimento será gerada uma nova população, de forma que cada um seja independente. Após a conclusão dos experimentos, foi gerado gráficos com o auxílio da biblioteca JFreeChart. Essa biblioteca manipula gráficos 2D e 3D e tem fácil integração com Java.



Nos três gráficos mostrado nas Figuras 17, 18 e 19, é possível observar a relação de numero de gerações pelo valor da energia gasta, ou seja, para cada geração é escolhido o indivíduo que possui o maior valor da avaliação, sendo então colocado no gráfico o valor da energia gasta.

No gráfico da Figura 17 é possível observar que o *crossover* heurístico teve bastante variação, já os *crossover* de média aritmética e média geométrica, se mantiveram mais constantes. No geral, é possível notar que os *crossover* de um ponto, dois pontos e uniforme se mostraram mais eficientes em relação aos outros *crossover*, pois se mantiveram na parte inferior do gráfico, ou seja, a região de menor gasto energético.

**Figura 19: Resultado com todos os operadores. Fonte: Elaborada pelo autor**



O gráfico da Figura 18, mostra os resultados usando o método do torneio. Em geral, os melhores *crossover* foram também os *crossover* de um ponto, dois pontos e uniforme. Apesar de ter sido superior aos demais o uniforme gastou um pouco mais de energia nessa execução. No entanto o *crossover* heurístico obteve o pior desempenho em relação à todos os outros operadores de *crossover*.

Por último, como mostrado na Figura 19, foi combinado todos os operadores, sendo que os dois que mais se destacaram foram os *crossover* de um ponto com o método da roleta e uniforme com o método do torneio, e mais uma vez o método heurístico obteve os piores resultados, pois o mesmo varia muito em relação aos demais.

## 5 Conclusão

Apesar desse trabalho ser uma parte de um problema maior, que é o da eficiência energética em trens urbanos, o *software* desenvolvido tenta facilitar o processo de aplicação do operador de *crossover*, visto que auxiliará na verificação do comportamento individual de cada *crossover* caso seja inserido uma nova variável, bem como também ajustes na função de avaliação.

Diante do que já foi desenvolvido, é possível destacar os operadores de *crossover* de um ponto e o *crossover* uniforme, como sendo melhores do que os outros operadores comparados nesse trabalho, no entanto conforme o aprimoramento o algoritmo genético atual, pode ser que outro tipo de *crossover* se destaque, visto que os operadores estão relacionados ao problema.

Para os trabalhos futuros pode-se apontar o seguinte melhoramentos:

- Fazer levantamento de trabalhos relacionados na área de análise dos operadores dos GAs.
- Acrescentar as variáveis aceleração e corrente.
- Validar a função de avaliação;
- Inserir dados reais;
- Comparar o resultado do algoritmo genético com os dados reais.

## Referências

- [1] ONU, disponível em [www.onu.org.br/](http://www.onu.org.br/), acessado em 03 de jun de 2016.
- [2] LEITE, C. Cidades inteligentes, Cidade Sustentáveis. Porto Alegre, Bookman, 2012.
- [3] COSTA, Carlos. CIDADES INTELIGENTES E BIG DATA. CADERNOS, FGV Projetos,10 , N° 24, 108-123, 2015.
- [4] AQUINO, Andre L.L.; RAMOS, Heitor S.; PEREIRA, Leonardo V.; FRERY, Alejandro C.; Cidades Inteligentes, um Novo Paradigma da Sociedade do Conhecimento, p. 165-178 . In: SP: Blucher, 2015.
- [5] SOARES, David. Cidades inteligentes: um novo arranjo para o desenvolvimento. II Encontro das faculdades de gestão e negócios, Uberlândia, MG, 2012. Disponível em:<[http://www.swge.inf.br/PDF/ENFAGEN2012-0100\\_4886.PDF](http://www.swge.inf.br/PDF/ENFAGEN2012-0100_4886.PDF)>. Acesso em: 19 jun. 2016
- [6] MARTINS, Marcelle (2015). Modelo teórico de eficiência energética para sistemas de malhas metroferroviárias. I Workshop do GPICEEMA. João Pessoa. ISBN: 978-85-237-1027-9, 2015
- [7] CBTU, disponível em [www.cbtu.gov.br/](http://www.cbtu.gov.br/), acessado em 03 de jun de 2016.
- [8] ARAUJO, R. C., Santos, J. L. A., Belo, F. A., Lima, J. A. G; Utilização do Sistema Telemétrico Dinâmico RailBee para estimativa em tempo real do número de passageiros e análise do desempenho do TUE. Prêmio Alston de Tecnologia. Revista Ferroviária 2010.
- [9] LINDEN , Ricardo. Algoritmos Genéticos. 3 edição. ed. [S.l.]: Editora Ciência Moderna, 2012.
- [10] SIMON, D. Evolutionary Optimization Algorithms, 1 edição, editora:Wiley, 2013.
- [11] SOUZA, Gustavo. Otimização de funções reais multidimensionais utilizando algoritmo genético contínuo, Departamento de Informática e Estatística, Universidade Federal de Santa Catarina, Florianópolis, 2014.
- [12] COPPIN, Ben. Inteligência Artificial. 1ª Edição. Rio de Janeiro: LTC, 2004.

- [13] CARVALHO, E. A. Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais. In: . Porto Alegre: Universidade/UFRGS : Associação Brasileira de Recursos Hídricos., 1999. cap. Capítulo 3: Introdução aos algoritmos genéticos., p. 99,150.
- [14] VOSE, M. The Simple Genetic Algorithm, Prentice-Hall of India, Nova Dheli, India. 2004
- [15] DEB, K. AGRAWAL, S. Understanding Interaction Among Genetic Algorithm Parameters, In Banzhaf, W.: Reeves, C> Foundations of Genetic Algorithms 5, pag 256-286, Morgan Kaufman Pub., São Francisco, EUA, 1998

## APÊNDICE V

### Artigo aceito no Expotec 2016

### Uma Metodologia para a Otimização da Energia Elétrica em Sistemas Metroferroviários

1Centro de Tecnologia – Universidade Federal da Paraíba (UFPB)  
Caixa Postal 15.064 – 91.501-970 – João Pessoa – PB – Brazil

2Centro de Informática – Universidade Federal da Paraíba (UFPB)

{marcellebm,mayrtondias,abelima}@gmail.com, natasha@ci.ufpb.br

*Resumo. O objetivo geral é apresentar um Modelo Teórico de Eficiência Energética para Sistemas de Malhas Metroferroviárias, abordando dois aspectos: a otimização de “Schedule” dos trens, ou seja, otimização na programação de horários dos trens e sincronização da aceleração e frenagem dos trens em uma mesma estação; a otimização de “Speed Profile”, que significa melhorar o controle dos perfis de velocidade dos trens a fim de reduzir o consumo de energia de tração, considerando os limites de velocidades permitidos, o tempo de viagem e a distância. A pesquisa é relevante, visto que atualmente existem muitos incentivos governamentais visando o racionamento do uso da energia. O resultado do estudo será aplicado nas estações do METROREC, em Recife.*

#### 1. INTRODUÇÃO

Devido às crescentes preocupações ambientais e elevados preços da energia consumida é avaliada formas de otimizar a eficiência energética em sistemas de malhas metroferroviárias. A questão emergente é de como a programação dos horários (Schedule) de sincronização de trens e o controle de velocidade (Speed profile) podem ser aperfeiçoadas. Assim, a utilização de tecnologias para melhorar a eficiência energética de trens, geralmente consiste em dois níveis, conforme expostos nos parágrafos seguintes.

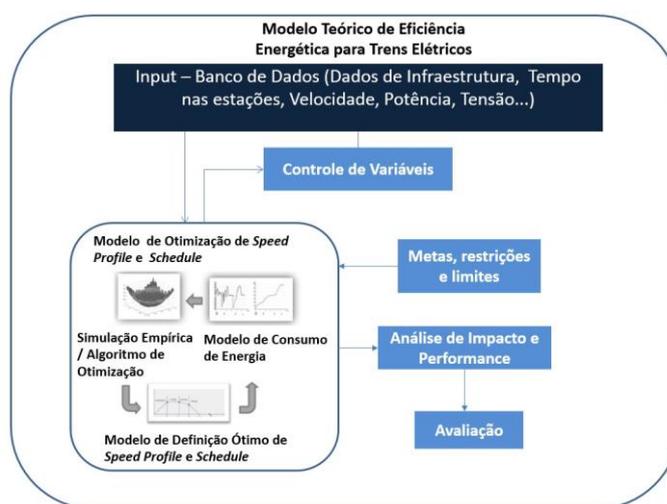
No primeiro nível, tem-se o desenvolvimento da programação de horários dos trens (Schedule), incluindo informações sobre o número de trens em serviços em uma estação, o tempo de viagem e o tempo de permanência nas estações, visando desta maneira melhorar a utilização da energia regenerativa, através da sincronização de operações sobre a aceleração e frenagem nos trens e seus vagões [Yang et al., 2013].

No segundo nível, o sistema de assistência ao condutor irá calcular o perfil de velocidade em relação ao consumo mínimo de energia de acordo com as limitações da carga horária entre as estações [Su et al., 2013], orientando os motoristas para controlar o perfil de velocidade sob a supervisão de um centro de gestão do tráfego.

A fim de alcançar um melhor desempenho na economia de energia, este trabalho propõe um estudo nos dois níveis propostos, com a finalidade de identificar a operação mais adequada para os trens elétricos de maneira a economizar o máximo de energia possível, dentro dos limites permitidos.

Pretende-se validar este trabalho, posteriormente, de forma empírica nos trens das estações do METROREC na cidade de Recife e também através de simulações utilizando Algoritmos de Otimização da Inteligência Artificial, como por exemplo os Algoritmos Genéticos.

## 2. METODOLOGIA



**Figura 1. Modelo Teórico de Eficiência Energética**

Conforme podemos ver na Figura 1, inicialmente, serão captados todos os parâmetros e variáveis necessários, neste caso, nas estações da CBTU/Recife e seus dados armazenados em um Banco de Dados.

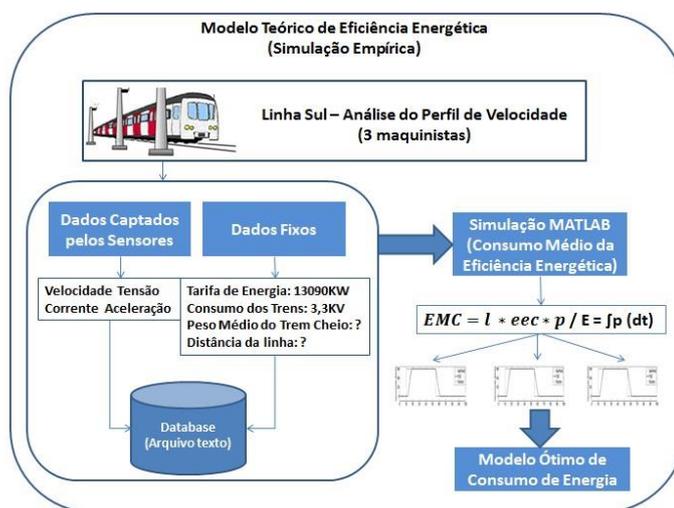
O modelo proposto para a otimização de Speed Profile e Schedule funciona da seguinte forma: a partir dos dados coletados será construído um Modelo do Consumo de Energia de um determinado trem ou estação, e então através das simulações empíricas e ou algoritmos de otimização, serão geradas as melhores soluções para a otimização dos perfis de velocidade e otimização da energia regenerativa (soluções de como a energia gerada na frenagem pode ser convertida em energia para a aceleração, seguindo um calendário de sincronização entre os trens).

Assim, com base nos resultados será construído um Modelo de Definição Ótimo, onde serão avaliados seus impactos e performances. O modelo teórico de eficiência energética proposto é especificado em um modelo de otimização de Speed Profile e Schedule em loop, até que se encontre

a melhor solução para uma situação ou trecho específico de uma determinada malha metroferroviária.

### 3. SIMULAÇÃO EMPÍRICAS

Assim, como podemos visualizar na Figura 2 abaixo, através do cálculo da Energia Média Consumida (EMC) por trecho e tendo os dados de entrada (velocidade, corrente, tensão e aceleração) serão realizadas várias simulações empíricas, onde serão levantados gráficos analíticos sobre o comportamento de cada variável ao longo da via. O objetivo também será encontrar os valores de aceleração e frenagem do trem durante o tempo determinado para sua operação e assim examinar criticamente o que pode estar impactando na energia consumida pelos trens. Pode-se observar todo o processo de captação dos dados até sua simulação com o auxílio da ferramenta MATLAB, onde serão calculados os valores de energia gasta, conforme fórmulas demonstradas e retornados gráficos compostos pelas curvas de velocidade, potência e aceleração que foram operados pelos três maquinistas, a fim de avaliar qual teve a melhor curva de eficiência energética.



**Figura 2. Modelo teórico**

### 4. CONCLUSÕES

O trabalho ainda está em fase intermediária de desenvolvimento, contudo sua principal contribuição é propor uma abordagem de otimização para melhorar a gestão de operação e de eficiência energética nos sistemas metroferroviários. Um modelo teórico foi demonstrado, a fim de formular estratégias no controle dos perfis de velocidade (Speed Profile), como também no sincronismo e programação de horários entre a frenagem e a aceleração de trens (Schedule) que podem contribuir de forma relevante na diminuição do consumo de energia elétrica. O avanço nos estudos desta área, torna-se possível a implementação futura no controle de sistemas de alimentação elétrica, tornando um sistema consumidor em sistema parcialmente autossustentável, contribuindo, assim, para a conservação de energia. O estudo empírico já está sendo iniciado com o levantamento dos dados reais captados pelos sensores entre as estações Recife e Joana Bezerra, na linha Sul do METROREC. A próxima etapa é avaliar os resultados obtidos nestes experimentos e em seguida inserir tais valores captados em nosso Algoritmo Genético, em construção. A validação do

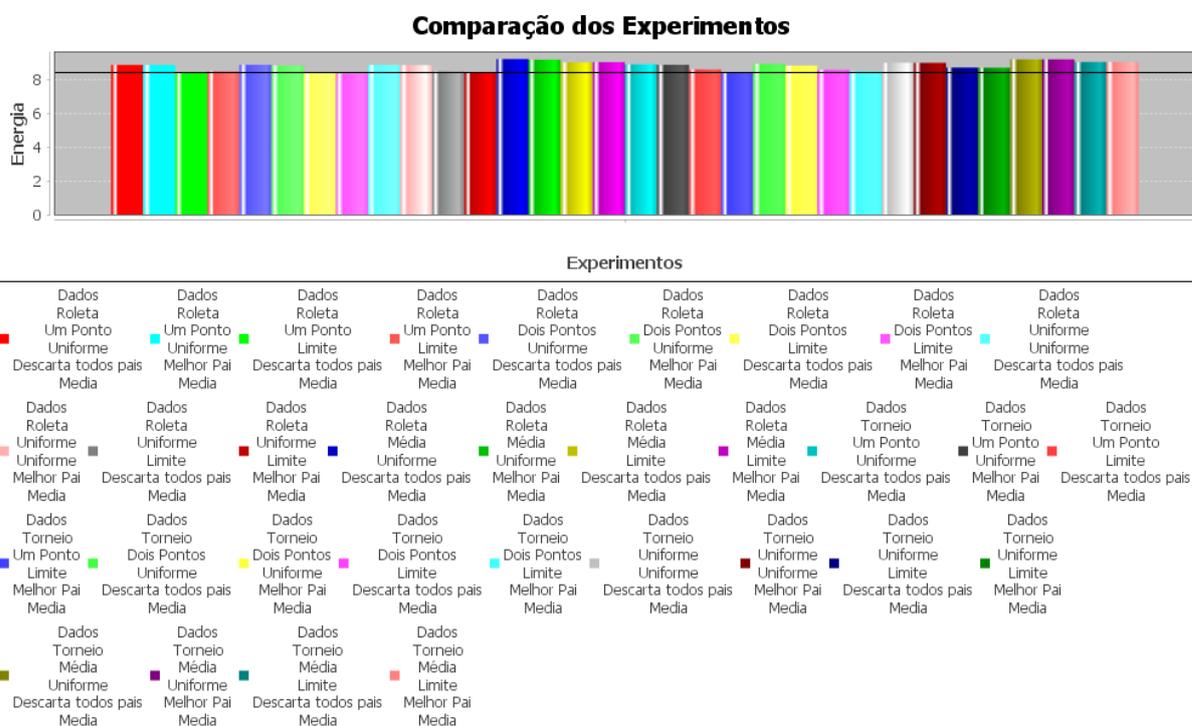
trabalho se dará com a comparação do estudo experimental e os resultados obtidos através do Algoritmo Genético.

## Referências

- Yang, X., Li, X., Gao, Z., Wang, H., Tang, T., 2013. A cooperative scheduling model for timetable optimization in subway systems. *IEEE Transactions on Intelligent Transportation Systems* 14 (1), 438–447.
- Su, S., Li, X., Tang, T., Gao, Z., 2013. A subway train timetable optimization approach based on energy-efficient operation strategy. *IEEE Transactions on Intelligent Transportation Systems* 14 (2), 883–893.

## APÊNDICE VI

### Análise Trecho I – Coqueiral a Alto do Céu



### Resultados:

Experimento: 1  
 Avaliação: 0.11316527506312464  
 Energia: 8.83663296397407  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Um Ponto  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 2

Avaliação: 0.11335056651046324  
 Energia: 8.822187932406067  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Um Ponto  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 3  
 Avaliação: 0.11290137815978409

Energia: 8.857287805510632  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Um Ponto  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 4**  
**Avaliação: 0.11848388599993502**  
**Energia: 8.43953010053522**  
**Geração: Dados**  
**Seleção: Roleta**  
**Crossover: Um Ponto**  
**Mutação: Limite**  
**Módulo: Melhor Pai**  
 Suavização: Media

Experimento: 5  
 Avaliação: 0.11315305339580722  
 Energia: 8.837587409170649  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Dois Pontos  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 6  
 Avaliação: 0.1133708692219036  
 Energia: 8.820608035055947  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Dois Pontos  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 7  
 Avaliação: 0.11287882837113149  
 Energia: 8.859057224727076  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Dois Pontos  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 8**  
**Avaliação: 0.11337317534452412**  
**Energia: 8.365028615156535**  
**Geração: Dados**  
**Seleção: Roleta**  
**Crossover: Dois Pontos**

Mutação: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 9  
 Avaliação: 0.11313524260572924  
 Energia: 8.838978703435064  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Uniforme  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 10  
 Avaliação: 0.11321489122032813  
 Energia: 8.83276033056371  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Uniforme  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 11  
 Avaliação: 0.11286825174804105  
 Energia: 8.859887386510849  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Uniforme  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 12**  
**Avaliação: 0.11817150104542826**  
**Energia: 8.485541221283856**  
**Geração: Dados**  
**Seleção: Roleta**  
**Crossover: Uniforme**  
**Mutação: Limite**  
**Módulo: Melhor Pai**  
**Suavização: Media**

Experimento: 13  
 Avaliação: 0.10902530582127397  
 Energia: 9.172182480637181  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Média  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 14  
 Avaliação: 0.10924367602882264  
 Energia: 9.153847951218356  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Média  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 15  
 Avaliação: 0.10891240830626114  
 Energia: 9.181690273416827  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Média  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 16  
 Avaliação: 0.10914059934477909  
 Energia: 9.162493206043004  
 Geração: Dados  
 Seleção: Roleta  
 Crossover: Média  
 Mutação: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 17  
 Avaliação: 0.11236982988528682  
 Energia: 8.899185849269807  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Um Ponto  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 18  
 Avaliação: 0.11281963286562656  
 Energia: 8.863705496994895  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Um Ponto  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 19  
 Avaliação: 0.11195018169049357  
 Energia: 8.93254468103214  
 Geração: Dados

Seleção: Torneio  
 Crossover: Um Ponto  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 20  
 Avaliação: 0.11322766740785004  
 Energia: 8.831763674844284  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Um Ponto  
 Mutação: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 21  
 Avaliação: 0.11172704511849427  
 Energia: 8.95038438490368  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Dois Pontos  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 22  
 Avaliação: 0.11289238081301055  
 Energia: 8.857993717541943  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Dois Pontos  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 23  
 Avaliação: 0.1118330735592765  
 Energia: 8.941898565185687  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Dois Pontos  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 24  
 Avaliação: 0.11224939263017611  
 Energia: 8.908734172795596  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Dois Pontos  
 Mutação: Limite  
 Módulo: Melhor Pai

Suavização: Media

Experimento: 25  
 Avaliação: 0.11138299020965076  
 Energia: 8.978031547884905  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Uniforme  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 26  
 Avaliação: 0.1112989152775116  
 Energia: 8.98481353126048  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Uniforme  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 27  
 Avaliação: 0.1109672908702112  
 Energia: 9.011664537882726  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Uniforme  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 28  
 Avaliação: 0.11123380984297401  
 Energia: 8.990072365692365  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Uniforme  
 Mutação: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 29  
 Avaliação: 0.10912413874617592  
 Energia: 9.163875302842134  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Média  
 Mutação: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

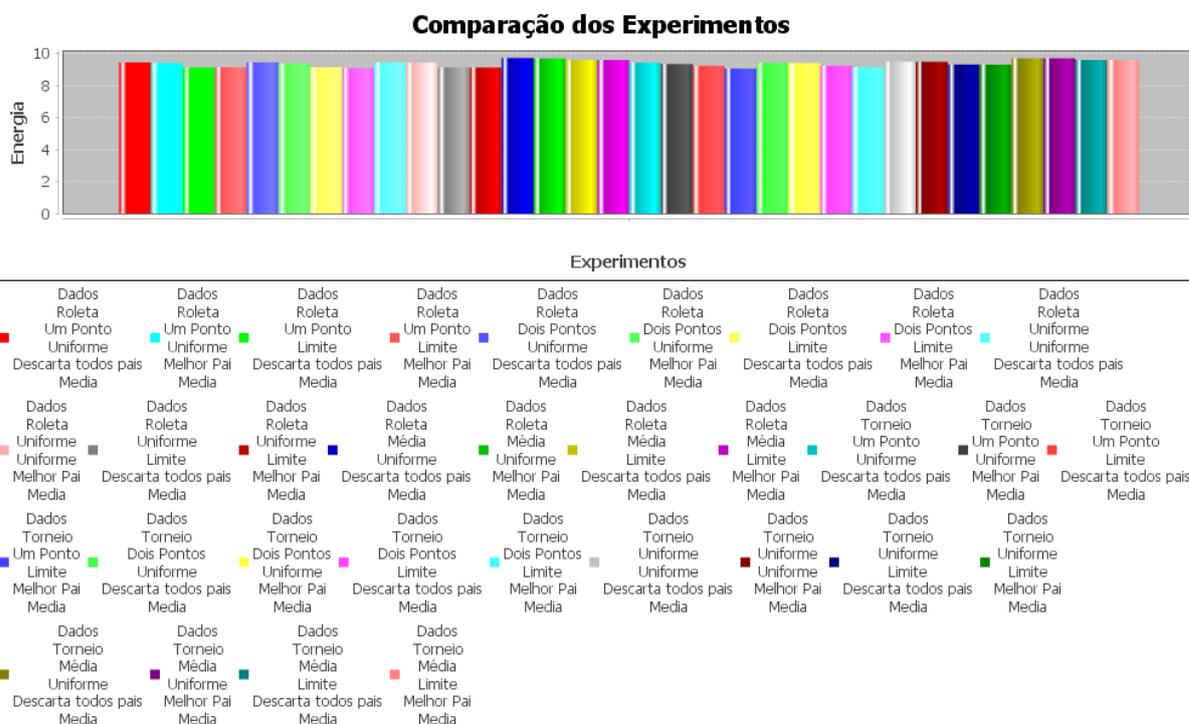
Experimento: 30  
 Avaliação: 0.10913982376356751  
 Energia: 9.162558317542517  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Média  
 Mutação: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 31  
 Avaliação: 0.10892453349761032  
 Energia: 9.180668191908657  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Média  
 Mutação: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 32  
 Avaliação: 0.10923585067663062  
 Energia: 9.154503707398097  
 Geração: Dados  
 Seleção: Torneio  
 Crossover: Média  
 Mutação: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

	Aval.	Energia	Seleção	Crossover	Mutação	População
Exp 4	0.11848	8.4395	Roleta	Um Ponto	Limite	Melhor Pai
<b>Exp 8</b>	<b>0.11954</b>	<b>8.3650</b>	<b>Roleta</b>	<b>Dois Pontos</b>	<b>Limite</b>	<b>Melhor Pai</b>
Exp 12	0.11817	8.4855	Roleta	Uniforme	Limite	Melhor Pai

## Análise Trecho II – Alto do Céu a Curado

**Resultados:**

Experimento: 1  
 Avaliação: 0.10605850218709892  
 Energia: 9.428758462342694  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 2  
 Avaliação: 0.10602379555823258  
 Energia: 9.431844943249173  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 3  
 Avaliação: 0.10965759805600045  
 Energia: 9.119295130733352

Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 4**  
**Avaliação: 0.10982145539125109**  
**Energia: 9.105688833182818**  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 5  
 Avaliação: 0.10604220194864397  
 Energia: 9.430207800516044  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Dois Pontos

Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 6  
 Avaliação: 0.10644540434544959  
 Energia: 9.394487306889062  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Dois Pontos  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 7  
 Avaliação: 0.10975798695282654  
 Energia: 9.110954270961576  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Dois Pontos  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 8**  
**Avaliação: 0.11003334220439107**  
**Energia: 9.088154371812704**  
**Geracao: Dados**  
**Selecao: Roleta**  
**Crossover: Dois Pontos**  
**Mutacao: Limite**  
**Módulo: Melhor Pai**  
**Suavização: Media**

Experimento: 9  
 Avaliação: 0.10602226778919922  
 Energia: 9.431980855081019  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 10  
 Avaliação: 0.10622015241832017  
 Energia: 9.414409386853096  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 11  
 Avaliação: 0.10952704540038088  
 Energia: 9.13016503224803  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 12  
 Avaliação: 0.10962570463518359  
 Energia: 9.121948208477532  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 13  
 Avaliação: 0.10314775885516952  
 Energia: 9.694830126208625  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 14  
 Avaliação: 0.10346419962535067  
 Energia: 9.665178908463535  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 15  
 Avaliação: 0.10429912910457309  
 Energia: 9.587807765847913  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 16  
 Avaliação: 0.10434089953024503  
 Energia: 9.583969512455013  
 Geracao: Dados

Selecao: Roleta  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 17  
 Avaliação: 0.10626941810194641  
 Energia: 9.410044939181653  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 18  
 Avaliação: 0.107702554829534  
 Energia: 9.284830815599017  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 19  
 Avaliação: 0.10817183011716253  
 Energia: 9.244550997398168  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Um Ponto  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 20**  
**Avaliação: 0.10985012553533625**  
**Energia: 9.103312309627931**  
**Geracao: Dados**  
**Selecao: Torneio**  
**Crossover: Um Ponto**  
**Mutacao: Limite**  
**Módulo: Melhor Pai**  
**Suavização: Media**

Experimento: 21  
 Avaliação: 0.10559250454300285  
 Energia: 9.470369173720536  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais

Suavização: Media

Experimento: 22  
 Avaliação: 0.10680625271416362  
 Energia: 9.36274772860175  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 23  
 Avaliação: 0.10934894221332668  
 Energia: 9.145035880174495  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 24  
 Avaliação: 0.10948571931539784  
 Energia: 9.133611271432384  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 25  
 Avaliação: 0.10535781641794721  
 Energia: 9.491464743660487  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 26  
 Avaliação: 0.10558224283791504  
 Energia: 9.47128961387147  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 27  
 Avaliação: 0.10748123714396386

Energia: 9.303949475949626  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 28  
 Avaliação: 0.10759655821400711  
 Energia: 9.293977582545184  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 29  
 Avaliação: 0.10319624485579389  
 Energia: 9.690275081204717  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 30  
 Avaliação: 0.1032179597567205  
 Energia: 9.688236449906094  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 31  
 Avaliação: 0.10432516076745196  
 Energia: 9.585415374811351  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 32  
 Avaliação: 0.10437184065381563  
 Energia: 9.581128336299413  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

	Aval.	Energia	Seleção	Crossover	Mutação	População
Exp 4	0.10982	9.1056	Roleta	Um Ponto	Limite	Melhor Pai
<b>Exp 8</b>	<b>0.1105</b>	<b>9.0465</b>	<b>Dados</b>	<b>Dois Pontos</b>	<b>Limite</b>	<b>Melhor Pai</b>
Exp 20	0.11035	9.0616	Torneio	Um Ponto	Limite	Melhor Pai

## Análise Trecho III – Curado a Rodoviária

### Comparação dos Experimentos



Experimentos																			
■	Dados Roleta Um Ponto Uniforme	■	Dados Roleta Um Ponto Uniforme	■	Dados Roleta Um Ponto Limite	■	Dados Roleta Um Ponto Limite	■	Dados Roleta Dois Pontos Uniforme	■	Dados Roleta Dois Pontos Uniforme	■	Dados Roleta Dois Pontos Limite	■	Dados Roleta Dois Pontos Limite	■	Dados Roleta Um Ponto Uniforme	■	Dados Roleta Um Ponto Uniforme
■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Descarta todos pais Media
■	Dados Roleta Uniforme	■	Dados Roleta Uniforme	■	Dados Roleta Uniforme	■	Dados Roleta Uniforme	■	Dados Roleta Linear Uniforme	■	Dados Roleta Linear Uniforme	■	Dados Roleta Linear Limite	■	Dados Roleta Linear Limite	■	Dados Torneio Um Ponto Uniforme	■	Dados Torneio Um Ponto Uniforme
■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Descarta todos pais Media	■	Descarta todos pais Media
■	Dados Torneio Um Ponto Limite	■	Dados Torneio Dois Pontos Uniforme	■	Dados Torneio Dois Pontos Uniforme	■	Dados Torneio Dois Pontos Limite	■	Dados Torneio Dois Pontos Limite	■	Dados Torneio Dois Pontos Limite	■	Dados Torneio Uniforme						
■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Descarta todos pais Media	■	Melhor Pai Media
■	Dados Torneio Linear Uniforme	■	Dados Torneio Linear Uniforme	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite	■	Dados Torneio Linear Limite
■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media	■	Descarta todos pais Media	■	Melhor Pai Media

### Resultados:

Experimento: 1  
 Avaliação: 0.09374441486608076  
 Energia: 10.66730216865247  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 2  
 Avaliação: 0.09467744412554155  
 Energia: 10.562177815805926  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 3  
 Avaliação: 0.09583820794360075

Energia: 10.43425186527365  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Um Ponto  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 4**  
**Avaliação: 0.09692748809134373**  
**Energia: 10.316990770023954**  
**Geracao: Dados**  
**Selecao: Roleta**  
**Crossover: Um Ponto**  
**Mutacao: Limite**  
**Módulo: Melhor Pai**  
**Suavização: Media**

Experimento: 5  
 Avaliação: 0.09381547581521814  
 Energia: 10.659222173211923  
 Geracao: Dados

Selecao: Roleta  
 Crossover: Dois Pontos  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 6  
 Avaliação: 0.09380105060167447  
 Energia: 10.660861403850296  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Dois Pontos  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 7  
 Avaliação: 0.09572873146125595  
 Energia: 10.446184596154682  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Dois Pontos  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 8**  
**Avaliação: 0.09607851259080394**  
**Energia: 10.408154466951167**  
**Geracao: Dados**  
**Selecao: Roleta**  
**Crossover: Dois Pontos**  
**Mutacao: Limite**  
**Módulo: Melhor Pai**  
**Suavização: Media**

Experimento: 9  
 Avaliação: 0.09383180462875775  
 Energia: 10.657367232320267  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 10  
 Avaliação: 0.09396678575530233  
 Energia: 10.64205816940559  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Melhor Pai

Suavização: Media

Experimento: 11  
 Avaliação: 0.09594923406234876  
 Energia: 10.422178037921492  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 12  
 Avaliação: 0.09581628577758282  
 Energia: 10.436639156743018  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 13  
 Avaliação: 0.09002800231856331  
 Energia: 11.107655110034639  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 14  
 Avaliação: 0.09039474516024547  
 Energia: 11.06258995727318  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 15  
 Avaliação: 0.09104285458584319  
 Energia: 10.983838375334686  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 16  
 Avaliação: 0.09106201668877678

Energia: 10.981527055541788  
 Geracao: Dados  
 Selecao: Roleta  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 17  
 Avaliação: 0.09354167432627976  
 Energia: 10.69042228720358  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 18  
 Avaliação: 0.09481371711048368  
 Energia: 10.546997106280823  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Um Ponto  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 19  
 Avaliação: 0.09483559127913084  
 Energia: 10.544564403639209  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Um Ponto  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

**Experimento: 20**  
**Avaliação: 0.09601038890529408**  
**Energia: 10.415539520274345**  
**Geracao: Dados**  
**Selecao: Torneio**  
**Crossover: Um Ponto**  
**Mutacao: Limite**  
**Módulo: Melhor Pai**  
**Suavização: Media**

Experimento: 21  
 Avaliação: 0.09333817758896135  
 Energia: 10.713729642373746  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos

Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 22  
 Avaliação: 0.09357448652972092  
 Energia: 10.686673655242364  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 23  
 Avaliação: 0.0950388675799984  
 Energia: 10.522010893682587  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 24  
 Avaliação: 0.09580720433579386  
 Energia: 10.437628432357847  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Dois Pontos  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 25  
 Avaliação: 0.09283223201478479  
 Energia: 10.772120612598613  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 26  
 Avaliação: 0.09295374249271102  
 Energia: 10.758039140580221  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 27  
 Avaliação: 0.09408143328666192  
 Energia: 10.629089768998785  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 28  
 Avaliação: 0.09430070328950228  
 Energia: 10.604374783187028  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Uniforme  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 29  
 Avaliação: 0.09015509267644359  
 Energia: 11.09199680586971  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 30  
 Avaliação: 0.09024917039205728  
 Energia: 11.080434265000278  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Uniforme  
 Módulo: Melhor Pai  
 Suavização: Media

Experimento: 31  
 Avaliação: 0.09100259277470593  
 Energia: 10.988697898703705  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Descarta todos pais  
 Suavização: Media

Experimento: 32  
 Avaliação: 0.09102042611549759  
 Energia: 10.986544918292083  
 Geracao: Dados  
 Selecao: Torneio  
 Crossover: Média  
 Mutacao: Limite  
 Módulo: Melhor Pai  
 Suavização: Media

	Aval.	Energia	Seleção	Crossover	Mutação	População
<b>Exp 4</b>	<b>0.0967</b>	<b>10.3340</b>	<b>Roleta</b>	<b>Um Ponto</b>	<b>Limite</b>	<b>Melhor Pai</b>
Exp 8	0.09607	10.4081	Roleta	Dois Pontos	Limite	Melhor Pai
Exp 20	0.09601	10.4155	Torneio	Um Ponto	Limite	Melhor Pai