

UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENERGIA E AMBIENTE

JONAS FONTES DE CARVALHO

**OTIMIZAÇÃO POR ALGORITMO GENÉTICO DA PRODUTIVIDADE EM UMA
OFICINA DE MANUTENÇÃO DE VAGÕES APLICADA EM CASO REAL**

São Luís - MA

2019

JONAS FONTES DE CARVALHO

**OTIMIZAÇÃO POR ALGORITMO GENÉTICO DA PRODUTIVIDADE EM UMA
OFICINA DE MANUTENÇÃO DE VAGÕES APLICADA EM CASO REAL**

Dissertação apresentada como requisito para
obtenção do título de mestre em Energia e
Ambiente emitido pela UFMA.

Orientador: Prof. Dr. Clóvis Bôsko M. Oliveira

São Luís - MA

2019

JONAS FONTES DE CARVALHO

**OTIMIZAÇÃO POR ALGORITMO GENÉTICO DA PRODUTIVIDADE EM UMA
OFICINA DE MANUTENÇÃO DE VAGÕES APLICADA EM CASO REAL**

Dissertação apresentada como requisito para
obtenção do título de mestre em Energia e
Ambiente emitido pela UFMA.

Aprovado em ____ / ____ / ____

Professor Dr. Clóvis Bôsko Mendonça Oliveira
Orientador

Professor Dr. Paulo Henrique da Silva Leite Coelho
Examinador

Professora Dra. Eveline de Jesus Viana Sá
Examinadora

São Luís – MA

2019

Dedico este trabalho a meus pais, que sempre foram grandes incentivadores do meu desenvolvimento, a minha esposa Cecília, que foi fundamental nesta jornada e que sem ela seria impossível concluir este trabalho e ao meu filho João Vítor por me dar a alegria e motivação para a cada dia me tornar um ser humano melhor em todos os sentidos.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelo discernimento me dado para desenvolver este trabalho e força para persistir nos momentos difíceis ao longo dessa jornada.

Aos meus pais por terem me colocado no caminho certo, por todo sacrifício que sempre fizeram em prol da minha criação e educação e por terem me suportado e incentivado a fazer sempre meu melhor.

A minha esposa Cecília, minha grande motivadora e grande entusiasta deste passo importante na minha vida, por ter cedido em vários momentos em prol de minha carreira e por ser sempre meu porto seguro e ter me dado apoio incondicional para concluir este mestrado.

Ao meu filho João Vítor, que apesar de sua pouca idade e inocência, sempre manteve um sorriso no rosto mesmo nos momentos que precisei estar ausente em prol deste trabalho.

Aos professores do programa de pós-graduação do mestrado em energia e ambiente da UFMA, em especial ao meu orientador Professor Clóvis Bôsko por ter acreditado no projeto, ter me desafiado e ter me conduzido na elaboração desta dissertação.

Aos meus colegas discentes deste mestrado, pelas noites agradáveis de aula e pelas parcerias em tantos trabalhos e artigos que desenvolvemos juntos ao longo desta jornada.

Por fim, agradeço muito a minha equipe de trabalho, em especial aos inspetores Adriano, Cleoberto, Romário e Márcio, que acreditaram na proposta de trabalho e não mediram esforços em testar na prática a otimização proposta.

*“A distância entre o sonho e a realidade
chama-se disciplina.”*

Bernardino

RESUMO

Na indústria atual a busca pela otimização de processos tem sido cada vez mais constante, porém muitas vezes tal prática mostra-se bastante complexa dada a quantidade de variáveis envolvidas, um exemplo disso é o caso em que a partir de um grupo heterogêneo de trabalhadores deseja-se definir o melhor conjunto de duplas de trabalho de forma que a produtividade coletiva seja a maior possível. Em situações como esta, o uso da metaheurística algoritmo genético torna-se bastante atrativa, uma vez que na literatura há muitos exemplos de seu uso na otimização de problemas não lineares, com características contínuas e discretas das variáveis de controle e com aumento exponencial no número possível de soluções, além da flexibilidade de incorporar à solução as restrições reais do problema. Neste contexto, este estudo codificou um problema de definição de equipes de trabalho em uma oficina de manutenção de vagões de carga de uma mineradora. Na etapa de simulação teórica, utilizando dados históricos de desempenho das equipes, o algoritmo genético indicou uma solução 22% melhor quando comparada com a escolha aleatória de equipes de trabalho. Por fim a solução sugerida pelo algoritmo genético foi implementada em campo, resultando em um aumento de performance de 7,9% quando comparando os trimestres antes e depois da otimização.

Palavras-chave: manutenção de vagões; otimização; metaheurística; sistemas evolutivos; algoritmos genéticos.

ABSTRACT

In today's industry, the search for process optimization has become increasingly common, but often this practice is quite complex given the number of variables involved, as in the case of defining the most productive work teams from a heterogeneous group of workers. In situations like this, the use of the metaheuristic genetic algorithm becomes attractive, since in the literature it presents many successful experiences with nonlinear problem optimization, with continuous and discrete control variables and with an exponential increase in the possible number of solutions, besides the flexibility to incorporate constraints of the problem into the solution. In this context, this work modeled a problem of work teams definition in a cargo wagon maintenance workshop of a mining company. In the simulation phase, using historical performance data of the teams, the genetic algorithm indicated an optimized solution 22% better than the random work team selection. Finally, the solution indicated by the genetic algorithm optimization was implemented in practice and comparing the results from the trimesters before and after the field tests, the optimization done improved in 7,9% the team performance.

Keywords: wagon maintenance; optimization; metaheuristic; evolutionary systems; genetic algorithms.

LISTA DE FIGURAS

Figura 1 - Vagão tipo gôndola.....	18
Figura 2 - Estrutura típica de um vagão ferroviário	19
Figura 3 - Truque de um vagão	20
Figura 4 - Vista explodida de um truque de vagão.....	20
Figura 5 - Rodeiro ferroviário	21
Figura 6 – Sequência de etapas na troca de rodeiros.....	22
Figura 7 - Componentes de um cromossomo	25
Figura 8 – Fluxo de implementação de um algoritmo genético típico.....	26
Figura 9 – Exemplo de cromossomo com codificação binária.....	27
Figura 10 - <i>Crossover</i> de um ponto.....	29
Figura 11 - <i>Crossover</i> de dois pontos.....	29
Figura 12 – Mutação em um ponto	30
Figura 13 – Fluxo seguido para coleta e tratamento da base de dados.....	34
Figura 14 – Fluxo seguido para simulações e testes de campo	36
Figura 15 – Exemplo de sorteio pelo método da roleta.....	43
Figura 16 – Mutação em cromossomo para otimização baseada em ordem	45
Figura 17 – Quadro de gestão da oficina com divulgação das duplas otimizadas	54

LISTA DE GRÁFICOS

Gráfico 1 - Evolução do AG em 100 gerações (População = 20 e Taxa de mutação = 1%)... 47	47
Gráfico 2 - Distribuição de 50 tempos médios de troca de rodeiros obtidos via AG versus escolha aleatória..... 48	48
Gráfico 3 - Comparativo de desempenho entre otimização aleatória e otimização via AG (P = população e M = taxa de mutação) 49	49
Gráfico 4 - Comparativo do AG para diferentes parâmetros de população (P) e taxa de mutação (M) 50	50
Gráfico 5 – Histórico do tempo médio de troca de rodeiros do grupo de controle (min) 55	55
Gráfico 6 – Tempo médio de troca de rodeiros agrupado por trimestre (min)..... 56	56
Gráfico 7 – Histórico do tempo médio de troca de rodeiro expurgando o impacto de indisponibilidade de rodeiros novos (min) 58	58

LISTA DE TABELAS

Tabela 1 - Dados reais de tempos médios de troca de rodeiros para 16 mecânicos (min)	38
Tabela 2 - Dados reais e estimados de tempos médios de troca de rodeiros para 16 mecânicos (min)	40
Tabela 3 - Exemplo de um cromossomo viável para o problema.....	41
Tabela 4 - Exemplo de avaliação da <i>fitness</i> de cromossomos de uma população hipotética ..	42
Tabela 5 – Sequência do <i>Crossover OX</i>	44
Tabela 6 – Matriz de tempos médios de troca de rodeiros para inspetoria de 10 mecânicos (min)	52
Tabela 7 – Escalas de trabalho praticas na oficina (T = dia de trabalho, F = dia de folga).....	53
Tabela 8 – Histórico de impactos no tempo de troca de rodeiro por falta de rodeiro disponível	57
Tabela 9 – Histórico da taxa de trocas de rodeiros feitas por duplas otimizadas	58
Tabela 10 – Histórico dos tempos médios de troca de rodeiros feitas por duplas otimizadas e não otimizadas	59

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Motivação	14
1.2	Objetivo geral	15
1.3	Objetivos específicos	16
1.4	Metodologia	16
1.5	Organização da dissertação	17
2	MANUTENÇÃO DE VAGÕES	18
2.1	Estrutura básica de um vagão	18
2.2	Aspectos da manutenção de rodeiros	20
2.3	O processo de troca de rodeiros	21
3	ALGORITMOS GENÉTICOS	24
3.1	Conceitos fundamentais	24
3.1.1	Codificação.....	26
3.1.2	Geração da população inicial	27
3.1.3	Função de aptidão.....	27
3.1.4	Operadores genéticos	28
3.1.4.1	Seleção.....	28
3.1.4.2	Crossover.....	29
3.1.4.3	Mutação	30
3.1.5	Parâmetros do AG	30
3.2	Aplicações de algoritmos genéticos	31
4	CODIFICAÇÃO DO PROBLEMA DE ALOCAÇÃO ÓTIMA DE PESSOAL NA MANUTENÇÃO DE VAGÕES	33
4.1	Preparação da base de dados	33
4.2	Sequência de trabalho adotada para otimização em campo	35
4.3	Aspectos da complexidade do problema	36
4.4	Levantamento dos dados de tempo médio de troca de rodeiro por dupla	38
4.5	Modelagem do algoritmo genético	40
5	DESCRIÇÃO E ANÁLISE DE RESULTADOS	47
5.1	Comparação da otimização via AG versus escolha aleatória	48
5.2	Comparação da otimização via AG versus otimização aleatória	48
5.3	Análise de sensibilidade dos parâmetros do AG	50
5.4	Verificação em campo	51
6	CONCLUSÃO	61
	REFERÊNCIAS	63
	APÊNDICES	66

1 INTRODUÇÃO

A necessidade constante de aumento de competitividade faz com que as empresas busquem cada vez mais otimizar seus processos e recursos, dentre estes, pode-se destacar o uso racional da mão de obra, ou seja, distribuir adequadamente as pessoas disponíveis para realização de tarefas em frentes de serviço, de forma que a produtividade global do processo seja maximizada.

Segundo Cardozo e Silva (2014) o ser humano por natureza é um ser social que por critérios de afinidade tende a formar grupos, desta forma o relacionamento interpessoal no ambiente de trabalho é bastante complexo, envolve muitas variáveis e dentre outros pode afetar o indicador de produtividade de uma organização.

Isto posto, torna-se um desafio atual das organizações definir a alocação ótima de pessoal e garantir as condições ideais de trabalho, de forma que seja obtido a maior rentabilidade possível (BRITTO, *et al.*, 2015).

Entretanto, devido ao elevado número de variáveis envolvidas na otimização da alocação de mão de obra, o uso de técnicas metaheurísticas de otimização representam uma alternativa bastante atrativa devido a sua robustez aliada a resultados muito próximos do ótimo global a um custo computacional baixo.

Um dos métodos metaheurísticos de maior representatividade são os algoritmos genéticos (AG), uma vez que são baseados na teoria da evolução natural e na genética, têm aplicação prática nas mais diferentes áreas e destacam-se por sua robustez e eficiência (RODRIGUES, *et al.*, 2004).

1.1 Motivação

Em um cenário de busca contínua por otimização de processos e redução de desperdícios nas indústrias, é de extrema relevância, sobretudo, alocar da maneira mais adequada a mão de obra que se dispõe para execução das tarefas.

Antes de tudo, vale ressaltar que na rotina de uma área de manutenção ferroviária, a tomada de decisões é uma constante, algumas delas, pela agilidade exigida somada ao grande número de variáveis envolvidas, nem sempre são tomadas da melhor maneira, o que pode gerar custos e ineficiências no processo produtivo.

Em qualquer ferrovia de carga um dos ativos que mais merecem atenção pelo time de manutenção são seus vagões, estes apresentam desgaste principalmente em suas rodas devido

ao contato roda-trilho. Como resultado disso, além das rodas, os vagões também apresentam grande demanda de manutenção em seus rolamentos, estes encontram-se posicionados nas extremidades dos eixos onde as rodas estão fixadas e servem de ponto de apoio para a caixa do vagão onde a carga é acondicionada para transporte.

Ao conjunto formado por um eixo, duas rodas e dois rolamentos dá-se o nome de rodeiro, sendo que cada vagão possui quatro destes em sua estrutura. A oficina onde este trabalho foi aplicado é responsável pela manutenção dos rodeiros dos vagões de minério de ferro de uma mineradora global, cuja frota alocada na ferrovia em questão se aproxima de 20 mil vagões, totalizando assim 80 mil rodeiros.

Com efeito, na ferrovia a que este trabalho se refere, por questões operacionais, quando um vagão é identificado com necessidade de trocar um ou mais rodeiros, o mesmo não é manobrado sozinho para o galpão de manutenção, mas, dentro de um lote fixo de 110 vagões chamado de lote homogêneo.

Desta forma, caso deseje-se realizar uma substituição de um único rodeiro de um vagão e considerando que esta atividade leve 12 minutos, de fato não será apenas um vagão que ficará parado em manutenção por este tempo, mas, 110 vagões ficarão parados por 12 minutos, aguardando um único ativo ser mantido, ou seja, em vez de 12 minutos de perda, serão 1.320 minutos de redução de tempo de vagão disponível.

No estudo de caso abordado mensalmente tem-se como meta realizar a substituição de 4.500 rodeiros defeituosos, sabendo que cada uma destas demandará parar um lote completo de 110 vagões, portanto, qualquer redução do tempo de troca de rodeiro tem um ganho potencializado pela elevada quantidade de vagões impactados, a saber, para esta meta mensal de trocas de rodeiros, uma redução de 1 minuto no tempo unitário desta atividade implicaria em um ganho de 495.000 minutos de tempo de vagão disponível.

Neste contexto, o presente trabalho tem como motivação prover através do uso da metaheurística algoritmo genético uma solução otimizada para a definição de duplas de trabalho em uma oficina de manutenção de vagões, mais especificamente manutenção de rodeiros, problema este que pelas muitas variáveis envolvidas acaba tornando-se inviável de ser otimizado através da simples análise humana.

1.2 Objetivo geral

Este trabalho tem como objetivo geral através da aplicação da metaheurística algoritmo genético otimizar a distribuição de duplas de trabalho em uma oficina de manutenção de vagões,

de modo que o desempenho médio do grupo de trabalho seja o melhor possível, utilizando para isto dados históricos de desempenho dos membros da equipe.

1.3 Objetivos específicos

Este trabalho tem como objetivos específicos:

- Levantar e contribuir para o estado da arte referente ao tema;
- Implementar um algoritmo genético para otimizar a alocação de mão de obra em uma oficina de manutenção de vagões;
- Melhorar o método de definição de equipes de trabalho em uma oficina de manutenção de vagões.

1.4 Metodologia

O desenvolvimento deste trabalho iniciou-se com uma pesquisa bibliográfica que serviu de fundamentação conceitual para a etapa do estudo de caso da otimização da produtividade de uma oficina de manutenção de vagões.

A primeira etapa foi o embasamento teórico e conhecimento de trabalhos de otimização semelhantes ao abordado, após isto passou-se para a modelagem do problema com vistas à metaheurística do algoritmo genético.

Nesta etapa inicial foi necessária uma intensa fase de levantamento e processamento de dados reais de campo, para isto utilizou-se o banco de dados de manutenção da oficina e um tratamento de dados através de Excel.

De posse da modelagem do problema e dos dados de campo pré-processados, passou-se para codificação em si do algoritmo de otimização em linguagem VBA, após isso foi possível fazer simulações computacionais a fim de evidenciar o ganho potencial no tempo médio de troca de rodízios da oficina em questão.

Após a etapa de simulações computacionais passou-se para a implementação em campo, cujo foco era testar na prática a eficácia do código de otimização implementado, para isto definiu-se um grupo de controle onde a otimização foi aplicada e seus resultados monitorados por um trimestre a fim de comparar na prática a performance antes e depois da melhoria.

1.5 Organização da dissertação

Esta dissertação encontra-se dividida em 6 capítulos conforme descrição a seguir:

Capítulo 1 – Introdução

Este capítulo, visa contextualizar o problema abordado assim como a motivação em desenvolver o trabalho e os objetivos da pesquisa.

Capítulo 2 – Manutenção de vagões

Neste capítulo, são contextualizados aspectos da manutenção de vagões pertinentes ao problema abordado, de forma a possibilitar um melhor entendimento desta dissertação.

Capítulo 3 – Algoritmo genético

Neste capítulo, são referenciados os fundamentos da metaheurística de algoritmos genéticos, descrevendo os principais aspectos teóricos utilizados ao longo do estudo.

Capítulo 4 – Codificação do problema de alocação ótima de pessoal na manutenção de vagões

Neste capítulo, descreve-se a abordagem adotada perante as características do problema estudado de forma a viabilizar a codificação e otimização do mesmo através de um algoritmo genético.

Capítulo 5 – Descrição e análise de resultados

Neste capítulo, são descritos os resultados das simulações computacionais feitas e os resultados dos testes práticos de campo, com destaque para os ganhos reais alcançados.

Capítulo 6 – Conclusões

Neste capítulo, são resumidas as principais conclusões do trabalho após a implementação das simulações computacionais e testes de campo.

2 MANUTENÇÃO DE VAGÕES

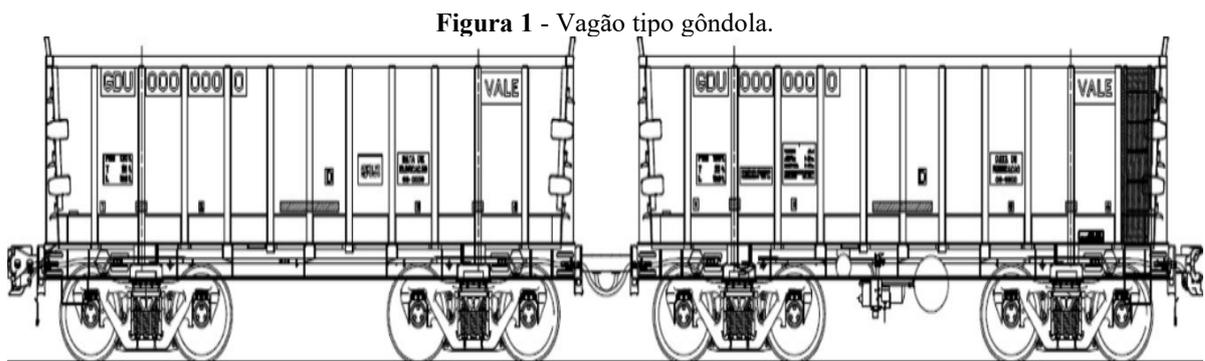
O escopo de manutenção de vagões ferroviários é bastante amplo, em virtude da gama variada de componentes que demandam manutenção, tais como rodas, rolamentos, sistema de freio, engates e até mesmo a própria superestrutura do vagão.

Entretanto, negligenciar um ou mais aspectos citados acima põe em risco a segurança operacional da ferrovia, o que pode acarretar em acidentes de grandes proporções com efeitos nos ativos da empresa, no meio ambiente e até mesmo em pessoas.

2.1 Estrutura básica de um vagão

Dentre os diversos componentes de uma operação ferroviária, destacam-se os materiais rodantes, que podem ser divididos no grupo daqueles que são tracionados e naqueles que são rebocados. No entanto, dentre os tracionados vale ressaltar principalmente as locomotivas, responsáveis por tracionar toda a composição pela via férrea, enquanto que no grupo dos rebocados merecem destaque os vagões, que permitem o acondicionamento e transporte adequado das mais variadas cargas pelo modal ferroviário (COSTA, 2018).

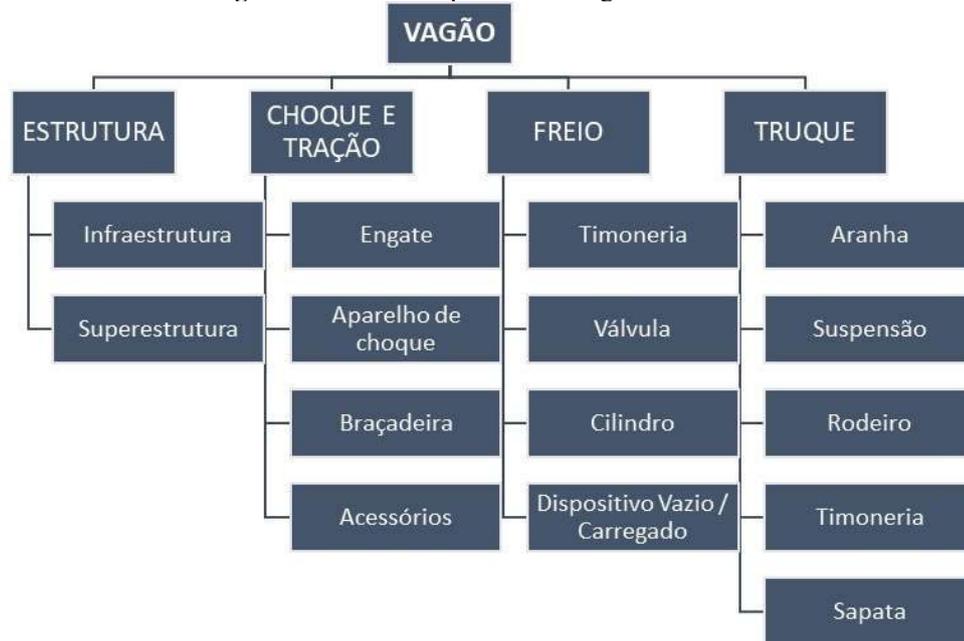
Na Figura 1 é ilustrado um vagão tipo gôndola, que é o tipo mais comum utilizado para transporte de minério de ferro dentre outros minerais.



Fonte: GREENBRIER MAXION, 2019.

Em linhas gerais um vagão pode ser dividido em quatro elementos principais, cada um deles apresenta uma função definida para o ativo e pode ser subdividido em subcomponentes, conforme apresentado na Figura 2.

Figura 2 - Estrutura típica de um vagão ferroviário.



Fonte: Adaptado pelo autor.

A estrutura em si do vagão divide-se em superestrutura e infraestrutura, visto que a primeira correspondente à caixa ou plataforma do vagão, responsável pelo acondicionamento e segurança da carga a ser transportada, enquanto a infraestrutura é a base de sustentação da superestrutura (COSTA, 2018).

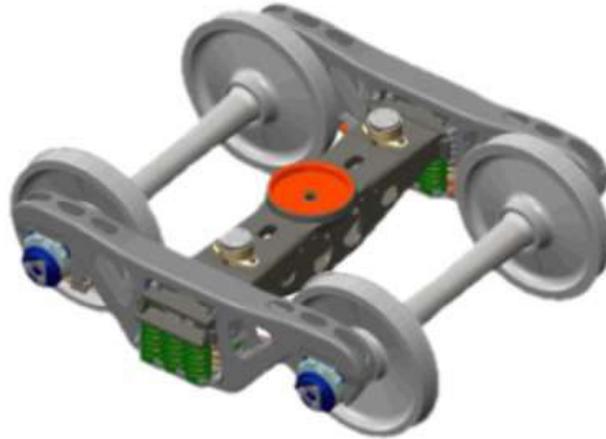
O conjunto choque e tração é responsável por garantir a conexão entre os vagões, sendo que cada um destes possui um engate na sua traseira e outro na dianteira de forma a possibilitar a ligação em série de vários vagões. Este conjunto desempenha também a importante função de absorver os impactos de tração e compressão entre veículos oriundos da dinâmica de aceleração e frenagem de um trem (NETO, 2012).

Já o sistema de freio desempenha a relevante função de controlar a velocidade do trem, isto é feito através de um sistema pneumático que uma vez combinado com a timoneria de freio e um conjunto de sapatas, permite a aplicação de freio nas rodas dos veículos ferroviários (SIEMENTKOWSKI, 2016).

Por fim, o truque é responsável por distribuir o peso da estrutura do vagão e da carga para os trilhos através das rodas, além de inscrever o vagão nas curvas e amortecer os impactos provenientes da via e do contato roda trilho (SIEMENTKOWSKI, 2016).

Cada vagão possui dois truques em sua montagem, estes podem apresentar diferentes configurações quanto a alguns elementos de sua constituição, porém o princípio de funcionamento é essencialmente o mesmo. Na Figura 3 é mostrado um truque bastante comum utilizado em vagões ferroviários.

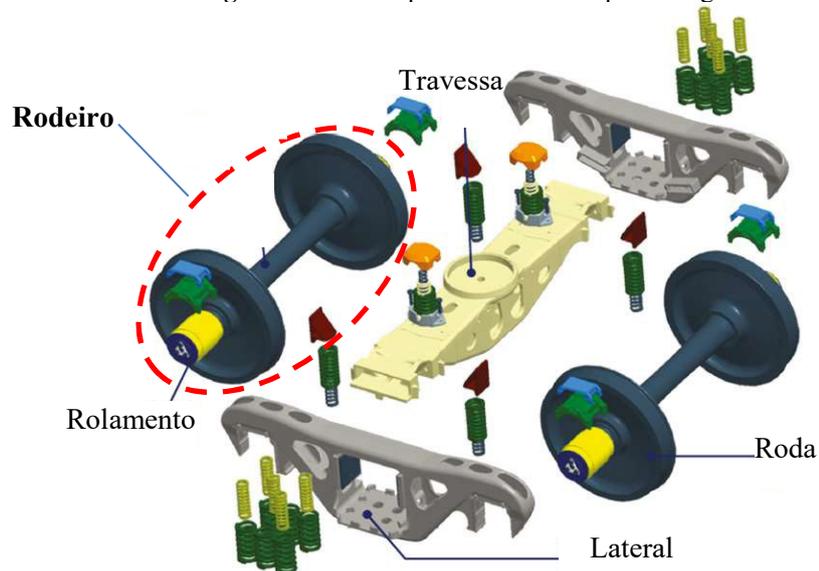
Figura 3 - Truque de um vagão.



Fonte: GREENBRIER MAXION, 2019.

Conforme mostrado na Figura 4, é no truque que se encontram as rodas do vagão, cada par destas encontra-se conectado por um eixo com dois rolamentos em suas extremidades, sobre os quais ficam apoiadas as laterais direita e esquerda do truque. A este conjunto formado por um eixo, duas rodas e dois rolamentos dá-se o nome de rodeiro.

Figura 4 - Vista explodida de um truque de vagão.



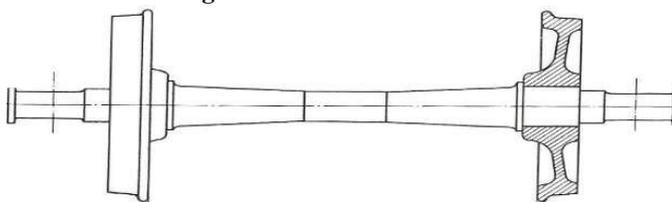
Fonte: GREENBRIER MAXION, 2019.

2.2 Aspectos da manutenção de rodeiros

Dentre os diferentes componentes a manter em um vagão, um dos mais importantes são seus rodeiros, cada um destes, como dito anteriormente é formado pelo conjunto de duas

rodas ligadas por um eixo com um rolamento em cada extremidade. Desse modo, são quatro rodeiros por vagão, responsáveis por sustentar a carga total do veículo ferroviário além de mantê-lo sobre os trilhos.

Figura 5 - Rodeiro ferroviário.



Fonte: NETO, 2012.

À medida que o vagão se desloca pela ferrovia cada rodeiro deste sofre desgaste, tanto na roda, devido ao contato roda-trilho, quanto nos rolamentos, devido ao atrito que ocorre em suas partes internas, sendo em qualquer ferrovia fundamental a gestão da manutenção de sua frota de rodeiros.

Neste contexto de deterioração contínua dos rodeiros, à medida que os vagões se deslocam pela ferrovia, a quantidade de rodeiros a manter se altera constantemente, desta forma, diariamente novos rodeiros são incluídos na lista daqueles com necessidade de manutenção, além de serem substituídos rodeiros defeituosos por outros bons no galpão de manutenção.

Uma vez retirado o rodeiro a manter o mesmo não é descartado, mas recuperado, para isso é necessário usinar as rodas de forma que as mesmas voltem a adquirir o perfil adequado e tenham quaisquer defeitos de sua superfície de rolamento removido, e para os casos de defeitos de rolamento, faz-se necessário retirar os rolamentos antigos e colocar rolamentos novos ou mantidos.

A oficina onde este trabalho foi desenvolvido está localizada em São Luís no Maranhão e é responsável por fazer a substituição de rodeiros defeituosos por outros em bom estado.

Quanto à estrutura, a oficina em questão possui 5 linhas ferroviárias para trocas simultâneas de rodeiros, funcionando 24h por dia, todos os dias do ano, o que tem proporcionado cerca de 4,5 mil rodeiros trocados por mês.

2.3 O processo de troca de rodeiros

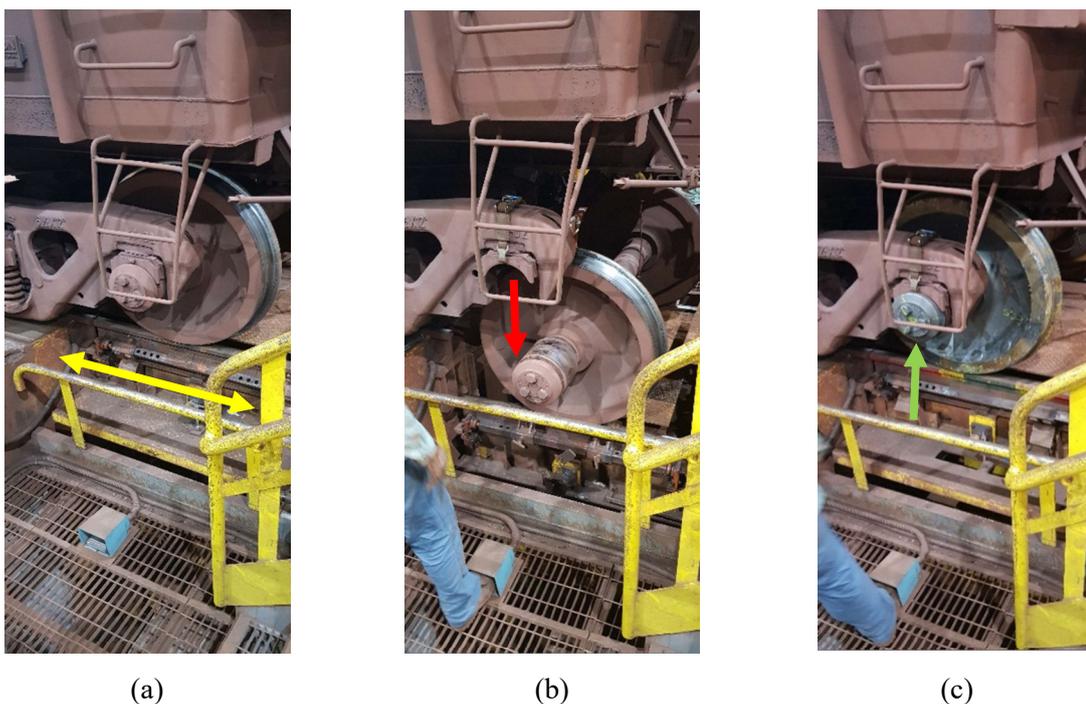
Para fazer a substituição de um rodeiro na oficina onde este trabalho foi desenvolvido é utilizado um equipamento chamado de mesa falsa, para isto o vagão onde se encontra o rodeiro

a ser substituído é posicionado sobre esta mesa, mais especificamente o rodeiro em questão deve ficar alinhado com o centro da base da mesa, então uma vez atingida esta posição, dois mecânicos fazem uma primeira intervenção de forma a liberar o rodeiro que descerá junto com a base da mesa falsa em direção a uma galeria subterrânea.

Após a descida do rodeiro a ser mantido o novo rodeiro faz exatamente o caminho oposto do rodeiro retirado, ou seja, o rodeiro novo é elevado através da mesa falsa desde a galeria subterrânea até o truque do vagão, depois disso os dois mecânicos novamente intervêm no vagão e concluem a substituição do rodeiro.

A sequência das etapas de substituição de um rodeiro é ilustrada na Figura 6 onde são mostradas as etapas de posicionamento do vagão, retirada do rodeiro a manter e instalação do rodeiro novo.

Figura 6 – Sequência de etapas na troca de rodeiros: posicionamento do rodeiro do vagão sobre a mesa (a), retirada do rodeiro defeituoso (b) e instalação do rodeiro novo (c).



Fonte: Acervo do autor.

Cada troca de rodeiro é feita simultaneamente por dois mecânicos, um atuando do lado direito e outro do lado esquerdo do vagão, sendo cada um deles responsável por um conjunto de tarefas até que o novo rodeiro esteja colocado no vagão em manutenção.

O tempo estimado para uma dupla de mecânicos fazer uma troca de rodeiro é de 12 minutos, tempo este orçado com base na capacidade de realização da tarefa associado à necessidade operacional para se cumprir o orçamento de transporte de minério.

Cada vez que uma troca desta é feita um dos mecânicos da dupla registra em um sistema informatizado os dados da manutenção que acabou de fazer, utilizando para isto um *tablet* onde se destacam as seguintes informações:

- Código do vagão mantenido;
- Motivo da troca do rodeiro;
- Horário de início da troca do rodeiro;
- Horário de término da troca do rodeiro;
- Mecânicos que fizeram a troca do rodeiro;
- Justificativa para execução da manutenção acima do tempo previsto (caso ultrapasse 12 minutos).

3 ALGORITMOS GENÉTICOS

O conceito de otimização pode ser entendido como um processo de tornar algo melhor, na prática comumente consiste em ajustar os valores de entrada de um processo ou os próprios parâmetros de processo de forma que a saída do mesmo seja máxima ou mínima, conforme o desejado, sendo isto possível de ser feito computacionalmente, desde que seja viável algoritmizar o problema a ser otimizado (HAUPT & HAUPT, 2004).

Uma expressão conhecida no âmbito dos problemas de otimização é a denominação NP-Complexo, onde NP é uma abreviatura para Não-Polinomial e faz referência àqueles problemas cujo tempo execução do código de otimização apresenta características não polinomiais, mais comumente do tipo exponencial ou fatorial, como exemplo 2^n e $n!$ (LINDEN, 2018).

Algoritmos de otimização exatos indicam com precisão absoluta a melhor solução de um problema, ainda que isso possa demandar grande tempo de execução computacional, porém, uma alternativa interessante para estas situações são os chamados algoritmos evolucionários. Estes são baseados na heurística em que não há garantia de que a solução encontrada seja a melhor de todas, mas usualmente indicam uma solução muito próxima da ótima, com o diferencial de fazerem isso em um tempo computacional aceitável (SAMPAIO, 2012).

Preferencialmente, deve-se usar algoritmos exatos para solução dos problemas, porém, nos casos de problemas do tipo NP-Complexos, devido ao elevado tempo para obter uma otimização exata, deve-se dar preferência aos métodos heurísticos, dentre os quais se destaca o algoritmo genético (AG), que consiste em um tipo específico de algoritmo evolucionário cujo processo de otimização é baseado no regime biológico da seleção natural (LINDEN, 2018).

Algoritmos genéticos apresentam uma série de vantagens quando comparados com algoritmos exatos de otimização, tais como sua capacidade de lidar simultaneamente com muitas variáveis, menor tempo de otimização e menor risco de ficar preso em soluções locais ao invés de globais (HAUPT & HAUPT, 2004).

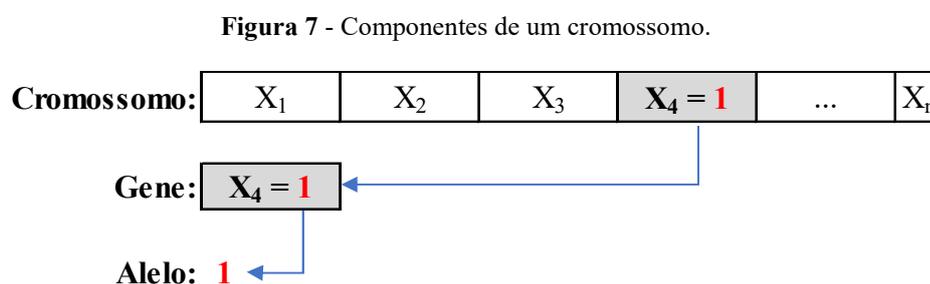
3.1 Conceitos fundamentais

Uma vez que os AGs são baseados no processo da seleção natural, há alguns termos da natureza que neste contexto assumem um sentido computacional, o primeiro deles é o cromossomo ou indivíduo, que é a representação codificada do problema a ser otimizado, sendo cada cromossomo uma possível solução do problema, logo ao final da otimização faz-se necessário decodificar o cromossomo sugerido pelo AG para tornar viável a aplicação prática

da otimização (LINDEN, 2018).

O cromossomo por sua vez é formado por genes, cada um destes corresponde a uma determinada característica do indivíduo e por sua vez o valor contido dentro do gene é chamado de alelo. Neste contexto, um algoritmo genético permite através de uma sequência de iterações lógicas evoluir uma população inicial de indivíduos de forma que com o passar das iterações, aqui chamadas de gerações, obtenha-se um cromossomo ideal que representará a solução proposta pelo AG para o problema em questão (COLHERINHAS, 2016)

Na Figura 7 é ilustrado como os elementos cromossomo, gene e alelo estão relacionados.



Fonte: Próprio autor

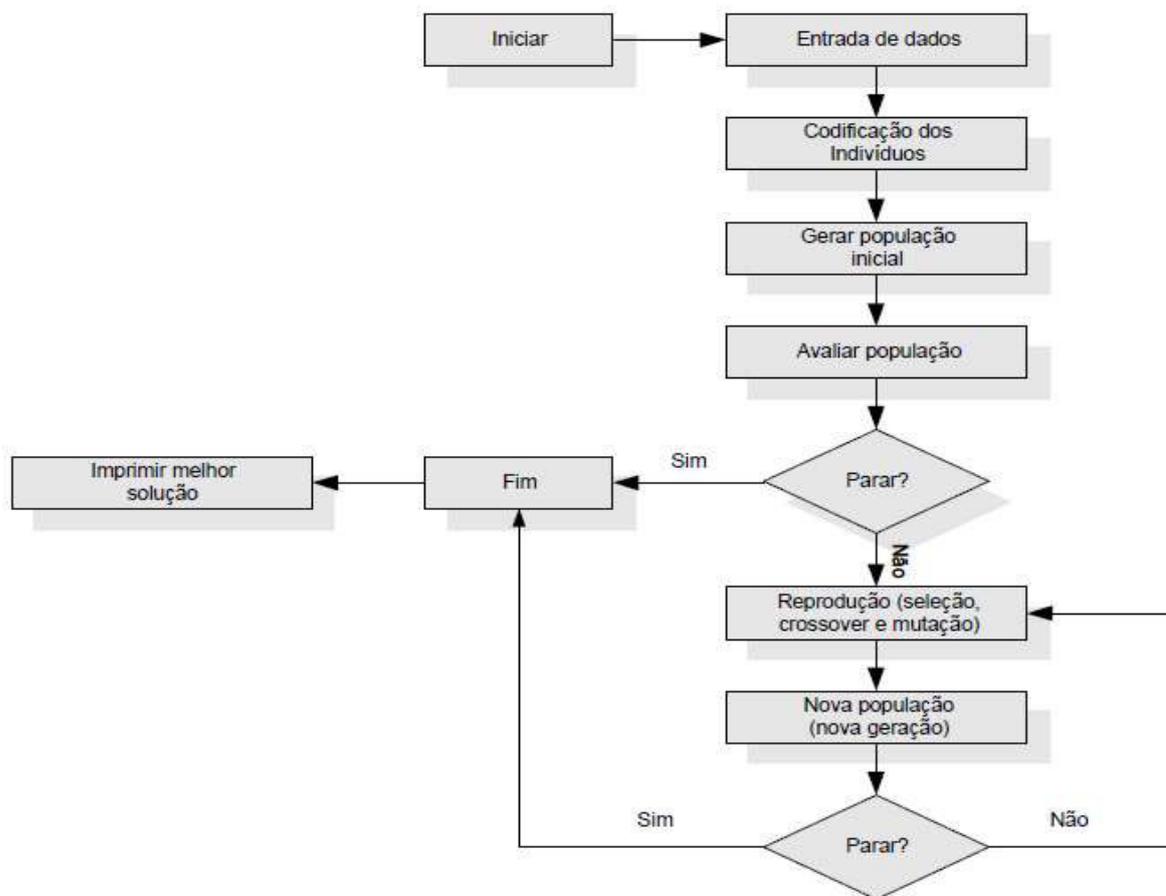
Dentro da temática de AG existem também os termos genótipo e fenótipo, que apesar de semelhantes distinguem-se, pois enquanto o primeiro corresponde ao vetor característico de vários alelos que formam o cromossomo, o segundo trata-se do valor real da variável do problema obtido após decodificar o genótipo de um cromossomo (NASCIMENTO, 2015).

Os algoritmos genéticos são processos estocásticos, sendo assim quase sempre serão obtidos resultados diferentes em caso de se repetir um mesmo experimento, desta forma a avaliação do desempenho do AG deve ser feita através da análise dos resultados obtidos a partir de vários experimentos de otimização (COSTA, 2017).

A implementação de um AG começa com a população inicial, nesta etapa é criada uma população de cromossomos, onde cada um deste deve obedecer às restrições do problema em questão. Após isso, o próximo passo é avaliar a qualidade de cada indivíduo da população, utilizando para isto uma função objetivo, através da qual cada cromossomo recebe uma nota que influenciará diretamente na próxima etapa que é a seleção. Para seleção os cromossomos de maior nota terão uma maior chance de serem escolhidos para se reproduzirem e terem seu material genético propagado para seus filhos na geração seguinte (COLHERINHAS, 2016).

A partir da Figura 8 vê-se um fluxograma onde é mostrado a lógica de implementação de um algoritmo genético, podendo este fluxo ser implementado em diferentes linguagens de programação e ser adotado para as mais diversas aplicações (RODRIGUES, *et al.*, 2004).

Figura 8 – Fluxo de implementação de um algoritmo genético típico



Fonte: RODRIGUES, *et al.*, 2004.

Segundo Velez (2015), existem cinco aspectos essenciais que são necessários para uma otimização através de algoritmo genético, são eles:

- Codificação genética de soluções para o problema;
- Procedimento de criação da população inicial;
- Função de avaliação que proporcionará a aptidão de cada indivíduo;
- Operadores genéticos que manipularão a codificação dos indivíduos pais durante o processo de reprodução, permitindo assim a formação de novos indivíduos;
- Parâmetros a serem utilizados no AG durante o processo de cruzamento e mutação.

3.1.1 Codificação

De acordo com a característica do espaço de possíveis soluções de um determinado problema pode-se representar os cromossomos de diferentes maneiras, dentre elas destaca-se a representação binária, a representação real e a representação através de permutação de

símbolos. A codificação binária é a mais simples de todas, nela cada cromossomo é formado por uma sequência de bits 0 e 1, ou seja, cada gene do cromossomo será preenchido com um alelo 0 ou 1, conforme ilustrado na Figura 9 (MOTTA, 2013).

Figura 9 – Exemplo de cromossomo com codificação binária

C₁:

1	0	0	1	1	1	0
---	---	---	---	---	---	---

Fonte: Próprio autor

Uma vez a otimização via algoritmo genético concluída, o cromossomo encontrado deve ser decodificado para que seja conhecida a solução real do problema e de forma a permitir a aplicação prática da mesma, sendo que no caso da codificação binária a representação final da solução consiste na conversão do número binário em número real (MOTTA, 2013).

3.1.2 Geração da população inicial

Antes de iniciar de fato o processo de otimização, o algoritmo genético precisa ter inicializada sua primeira geração, isto significa definir quais serão os cromossomos a partir dos quais ocorrerão os cruzamentos e que gerarão novos indivíduos para a próxima geração, podendo esta população inicial ser definida aleatoriamente (CAMPOS, 2017).

É preciso também fixar o tamanho da população que se deseja, tal definição depende da complexidade do problema, a lógica é que quanto mais complexo o problema maior deve ser a população, isto visa evitar que o problema apresente uma convergência prematura para um ponto de ótimo local e não global (VÉLEZ, 2015).

3.1.3 Função de aptidão

Uma parte de extrema importância dentro do AG é sua função objetivo, também chamada de função aptidão ou *fitness*, através dela é atribuída uma nota para cada indivíduo da população, sendo que esta depende do quão ótimo é o indivíduo do ponto de vista da função que se deseja otimizar (NASCIMENTO, 2015).

A função de avaliação pode ser entendida como o meio pelo qual o problema real se liga ao algoritmo genético, para isso ela sempre representa de forma numérica os objetivos do problema, assignando para cada cromossomo um número que indicará quão boa é a solução representada por ele (CAMPOS, 2017).

3.1.4 Operadores genéticos

Os operadores genéticos são utilizados após a seleção dos cromossomos de melhores aptidões dentro da população atual, dentre estes o principal é a recombinação ou *crossover* que permite formar novos indivíduos cada vez melhores ao longo das gerações, seguindo assim os princípios Darwinianos (SILVA, 2001).

Todas as operações genéticas entre indivíduos envolvem técnicas probabilísticas e não determinísticas, isto posto, rodando um mesmo algoritmo genético com os mesmos parâmetros, a partir da mesma população inicial, não há garantia que serão encontradas as mesmas soluções (SAMPAIO, 2012).

Segundo Velez (2015) a função básica dos operadores genéticos é melhorar a população ao longo de sucessivas gerações, semelhante ao que ocorre na natureza, para isto pode-se dividir o ciclo reprodutivo dos cromossomos de uma população em três etapas:

- Seleção dos pais;
- Cruzamento (*crossover*) dos pais para gerar novos indivíduos (filhos);
- Mutação, que gera diversidade na nova população alterando genes dos filhos.

3.1.4.1 Seleção

Há diferentes maneiras de se fazer esta escolha dos cromossomos mais adaptáveis que serão considerados para o *crossover*, dentre as quais destaca-se a escolha proporcional (ou da roleta), por torneio e por normalização linear (NASCIMENTO, 2015).

O método de seleção da roleta é muito comum, nele para cada indivíduo da população é atribuída uma fatia de uma roleta circular, proporcional à aptidão de cada um, ou seja, aqueles que tiverem as maiores aptidões terão as maiores fatias da roleta. Após esta etapa, simula-se um giro da roleta e a fatia sorteada terá seu cromossomo correspondente escolhido para participar das estratégias evolutivas através do *crossover* e mutação para a próxima geração (ATALA, 2014).

Outro método de seleção é o por torneio, nele pelo menos dois indivíduos são escolhidos aleatoriamente e dentro deste conjunto aquele que apresentar a maior aptidão é o campeão do torneio e será considerado nos processos de *crossover* e mutação a fim de gerar filhos para a geração seguinte (VÉLEZ, 2015).

Além disso, existe o método de seleção por normalização linear, que consiste em ordenar os indivíduos da população de acordo com suas respectivas aptidões, a partir do exposto

atribui-se um valor máximo ao melhor indivíduo e um mínimo ao pior, enquanto que para os demais indivíduos atribui-se valores proporcionais àqueles atribuídos ao melhor e pior cromossomo. A partir deste ponto a seleção decorre igual ao método da roleta, com a única diferença que o critério de atribuição do tamanho da fatia na roleta não depende da aptidão em si de cada indivíduo, mas sim de sua posição relativa dentro da população após esta ser ordenada pelo critério de aptidão. (MOTTA, 2013).

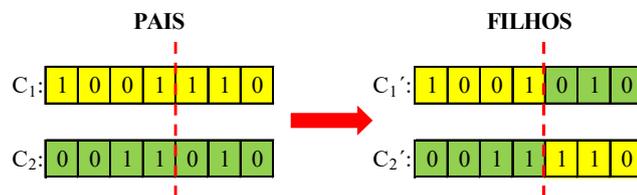
Percebe-se que por serem métodos probabilísticos e não determinísticos, há risco de que após aplicação dos operadores genéticos perca-se o melhor indivíduo da geração atual. Para evitar isso, existe o elitismo, através do qual opta-se por manter de uma geração para outra uma pequena parcela dos melhores indivíduos da geração atual, devendo esta parcela ser muito pequena de forma a permitir a diversidade genética ao longo das gerações (COSTA, 2017).

3.1.4.2 Crossover

O *crossover* tem a função de combinar dois indivíduos a fim de gerar filhos para a próxima geração, sendo que tais filhos manterão características do material genético de seus pais e a partir desta mistura busca-se encontrar indivíduos cada vez mais aptos (REIS, 2018).

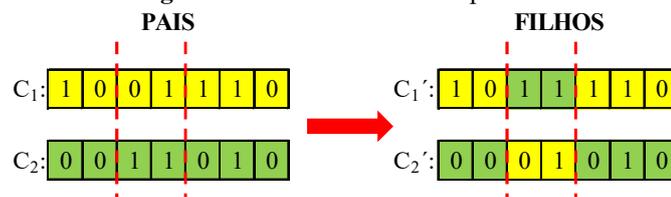
Segundo Campos (2017), existem várias maneiras de fazer o cruzamento entre dois indivíduos, o mais simples consiste em escolher aleatoriamente um ou mais pontos dentro dos cromossomos dos pais e utilizar estas posições como referências para permuta de genes entre os mesmos, gerando assim filhos com material genético dos dois pais, conforme ilustrado na Figura 10 e Figura 11.

Figura 10 - *Crossover* de um ponto.



Fonte: Próprio autor.

Figura 11 - *Crossover* de dois pontos



Fonte: Próprio autor

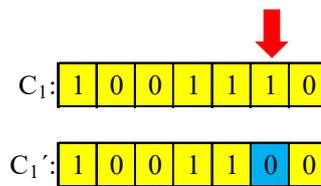
3.1.4.3 Mutaç o

Ainda que na l gica do AG haja uma tend ncia de indiv duos mais aptos se perpetuarem, existe o conceito de muta o que cria diversidade atrav s da mudan a aleat ria de um ou mais genes de um indiv duo, processo este muito importante para evitar estagnar a otimiza o em m ximos ou m nimos locais (REIS, 2018).

A muta o   o operador gen tico mais simples, em codifica es bin rias por exemplo, basta escolher aleatoriamente um ou mais genes de um cromossomo e inverter o valor do alelo contido nestas posi es (COLHERINHAS, 2016).

Na Figura 12   mostrado um caso de muta o de apenas um ponto em um cromossomo utilizando codifica o bin ria.

Figura 12 – Muta o em um ponto



Fonte: Pr prio autor

3.1.5 Par metros do AG

A evolu o do processo de otimiza o via algoritmo gen tico   diretamente influenciada pelos par metros de tamanho da popula o, taxa de *crossover*, taxa muta o, n mero de gera es a ser calculadas e crit rio de parada do AG (MOTTA, 2013).

A taxa de muta o representa a probabilidade de um determinado indiv duo sofrer altera o em um ou mais genes, isto tem como fun o principal recuperar a diversidade gen tica da popula o e reduzir a chance do AG ficar estagnado em m ximos ou m nimos locais por falta de diversidade (V LEZ, 2015).

Ao mesmo tempo que   necess ria, a taxa de muta o n o pode ser muito alta, pois caso isso ocorra o algoritmo pode apresentar caracter sticas de busca aleat ria, uma vez que h  a possibilidade da muta o gerar um indiv duo pior que o original, sendo comumente adotado para este par metro valores inferiores a 10% (LYRA, 2014).

Analogamente ao conceito de taxa de muta o, a taxa de *crossover* representa a probabilidade de cruzamento entre dois indiv duos, por m ao contr rio da muta o, a taxa de

crossover deve ser próxima a 100% de forma a permitir a geração de diversidade genética ao longo das gerações (COSTA, 2017).

Segundo Oliveira (2019) o critério de parada também é um importante parâmetro do AG, este é responsável por indicar quando o algoritmo deverá parar o processo de otimização e indicar a melhor solução encontrada. Dentre os critérios de parada mais comuns pode-se citar:

- Atingimento de um número máximo de gerações;
- Atingimento de um tempo máximo de processamento;
- Obtenção de um indivíduo com uma aptidão considerada aceitável;
- Estagnação da *fitness* ao longo das gerações.

3.2 Aplicações de algoritmos genéticos

O uso de algoritmos genéticos na otimização de processos é bastante comum e diversificado, é possível por exemplo utilizar a técnica na otimização da estratégia de manutenção de equipamentos industriais, obtendo a periodicidade ótima para realização de planos de manutenção de forma que a confiabilidade dos equipamentos seja o maior possível com o custo mínimo (ABREU, et al., 2015).

O trabalho de Gross *et al.* (2016) também apresenta um exemplo industrial onde foi adotado o uso de algoritmo genético, neste caso específico um AG foi implementado com o objetivo de criar uma composição de cimento com um custo mais otimizado e dentro dos parâmetros aceitáveis de qualidade.

Outra aplicação bastante comum da otimização através de algoritmos genéticos é na definição de escalas de trabalho, que pode ser aplicada nos mais diversos segmentos, a exemplo dos trabalhos de Lopes (2018) e Martins e Silva (2017), onde foram utilizadas esta técnica para otimizar as escalas de trabalho de enfermeiros em um hospital e de tripulações em um sistema público de transporte, respectivamente.

Além da utilização de algoritmos genéticos para definição de escalas de trabalho de equipes, é possível encontrar aplicações de AG para formação de grupos, como cita o trabalho de Baliero *et al.* (2017) onde foi utilizado um AG para a partir de um grupo heterogêneo de alunos, sugerir uma combinação de grupos de estudo para uma plataforma de ensino à distância, considerando para isto que os alunos alocados em cada grupo apresentassem a menor diversidade possível em termos de idade, disciplina, tempo de estudo diário e horário de estudo.

Dentro do escopo de operações logísticas foi encontrado no trabalho de Carraro *et al.* (2013) o uso de algoritmo genético para criar uma abordagem que permitisse otimizar os planos de cargas

de navios-contêineres em um terminal portuário, tal abordagem visava reduzir o número de movimentações de containers durante o processo de carregamento de um navio, reduzindo desta forma os custos operacionais.

Também é possível ver aplicações de algoritmos genéticos focados em maximizar ganhos financeiros, como foi apresentado no trabalho de Rodrigues *et al.* (2004) em que foi implementado um AG em que a partir da manipulação de mais de uma centena de variáveis de entrada de um problema de planejamento florestal foi possível encontrar uma configuração que permitisse o maior valor presente líquido de um investimento.

Apesar de ser possível encontrar na literatura várias aplicações de algoritmos genéticos bem sucedidas, há situações específicas em que seu uso não é recomendado, como por exemplo quando o objetivo for encontrar com exatidão a solução ótima de um problema, pois geralmente o AG entregará soluções muito boas, próximas da solução ótima, mas não exatamente igual à melhor solução possível (COLHERINHAS, 2016).

4 CODIFICAÇÃO DO PROBLEMA DE ALOCAÇÃO ÓTIMA DE PESSOAL NA MANUTENÇÃO DE VAGÕES

Uma vez que este trabalho utilizou dados reais de campo, inicialmente foi necessária uma extensa fase de coleta e processamento de dados de campo de forma a prover as informações de entrada necessárias para o AG.

Considerando a complexidade da base de dados, na etapa inicial deste trabalho foram assumidas algumas premissas e restrições ao problema, tais considerações serão abordadas na primeira parte deste capítulo e na sequência serão detalhados os aspectos da codificação e otimização do problema.

4.1 Preparação da base de dados

Dado que cada troca de rodeiro é registrada em um sistema de manutenção, foi possível através de dados históricos avaliar a performance de cada mecânico fazendo dupla com diferentes colegas de trabalho, isto posto, supondo uma equipe de N mecânicos, cada um destes podendo formar $N-1$ duplas e cada uma destas com seu próprio tempo médio de troca de rodeiro.

Relativo aos dados de trocas de rodeiros utilizados neste estudo foram consideradas aquelas que atendessem as seguintes especificações:

- Feitas entre 1 de janeiro de 2018 e 31 de janeiro de 2019.
- Feitas no turno das 7h às 16h.
- Feitas por exatamente dois mecânicos.
- Feitas por mecânicos que após janeiro de 2019 ainda continuavam no turno das 7h às 16h.

A preferência pelo turno das 7h às 16h deu-se por uma questão de maior autonomia uma vez que era o turno onde o autor do trabalho atuava como supervisor.

Considerando estes critérios, fizeram parte do estudo 3.126 amostras de trocas de rodeiros, feitas por um total de 16 mecânicos.

Para o espaço amostral de 16 mecânicos, cada possível solução do problema será formada por um agrupamento de 8 duplas, havendo ao todo 120 possibilidades de duplas diferentes (combinação de 16 elementos tomados dois a dois).

A partir dos dados históricos das 3.126 trocas de rodeiros consideradas, das 120 possibilidades de duplas de trabalho foi possível obter 96 tempos médios de troca, ou seja, até o momento tinha-se 24 duplas cujos mecânicos não tinham trabalhado juntos antes para ter seu

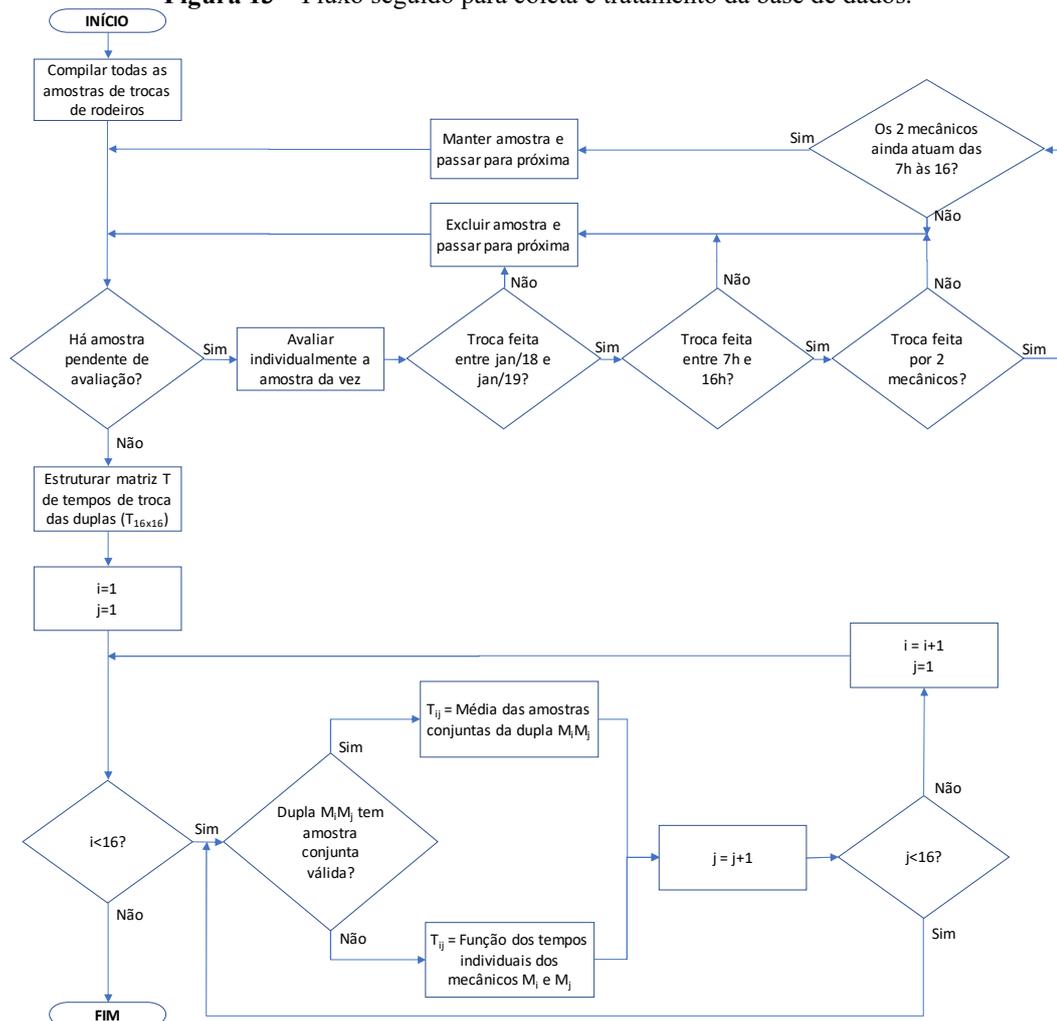
tempo amostrado. Para este grupo de duplas sem amostra prévia, o tempo conjunto da dupla foi obtido a partir de uma aproximação com base nos tempos individuais de cada membro da dupla.

Supondo A e B dois mecânicos que nunca trabalharam juntos e que estão no grupo das 24 duplas sem amostragem de tempo, foi considerado como estimativa do tempo médio de troca de rodeiro da dupla AB uma média ponderada entre o tempo médio de troca de rodeiro de A com outros mecânicos (excluindo B), e do tempo médio de troca de rodeiro de B com outros mecânicos (excluindo A), somando-se a esta média ponderada uma constante de ajuste.

Os coeficientes de ponderação foram obtidos a partir dos dados das 96 duplas que tiveram seus tempos já amostrados, estes foram interpolados através da ferramenta SOLVER no Excel de forma a obter uma equação que permitisse calcular o tempo de uma dupla a partir dos tempos individuais de dois mecânicos, buscando para isso apresentar um erro mínimo.

A seguir é apresentado na Figura 13 um resumo dos passos descritos nesta sessão que foram seguidos para coleta e preparação da base de dados.

Figura 13 – Fluxo seguido para coleta e tratamento da base de dados.



Fonte: Próprio autor.

Uma vez obtidos todos os tempos médios de troca de rodeiros para as 120 duplas de trabalho possíveis, o problema foi modelado para que o algoritmo genético propusesse uma combinação otimizada de 8 duplas mecânicos, de forma que o tempo médio de troca de rodeiros deste conjunto fosse minimizado.

4.2 Sequência de trabalho adotada para otimização em campo

Durante a implementação do AG foram fixados a taxa de *crossover* e o critério de parada, porém foram considerados diferentes parâmetros de população e de taxa de mutação de forma a avaliar a performance do AG perante distintas configurações.

Cada configuração do AG foi simulada por 50 vezes e seus resultados foram comparados entre si e também com relação a escolha e otimização aleatórias, sendo aquela configuração que apresentou melhor performance considerada para ser levada adiante para a fase de testes práticos de campo.

Depois de validados o AG e seus respectivos parâmetros, passou-se para fase de testes de campo, para isto considerou-se um escopo menor de mecânicos, uma vez que os 16 inicialmente avaliados trabalhavam em duas inspetorias distintas o que implicaria em uma maior dificuldade em realizar o estudo simultaneamente em dois grupos. Assim, optou-se pela inspetoria que dispunha de mais mecânicos e que apresentava mais dados amostrados de trocas de rodeiros, o que garantiria uma maior consistência da base de dados a ser considerada.

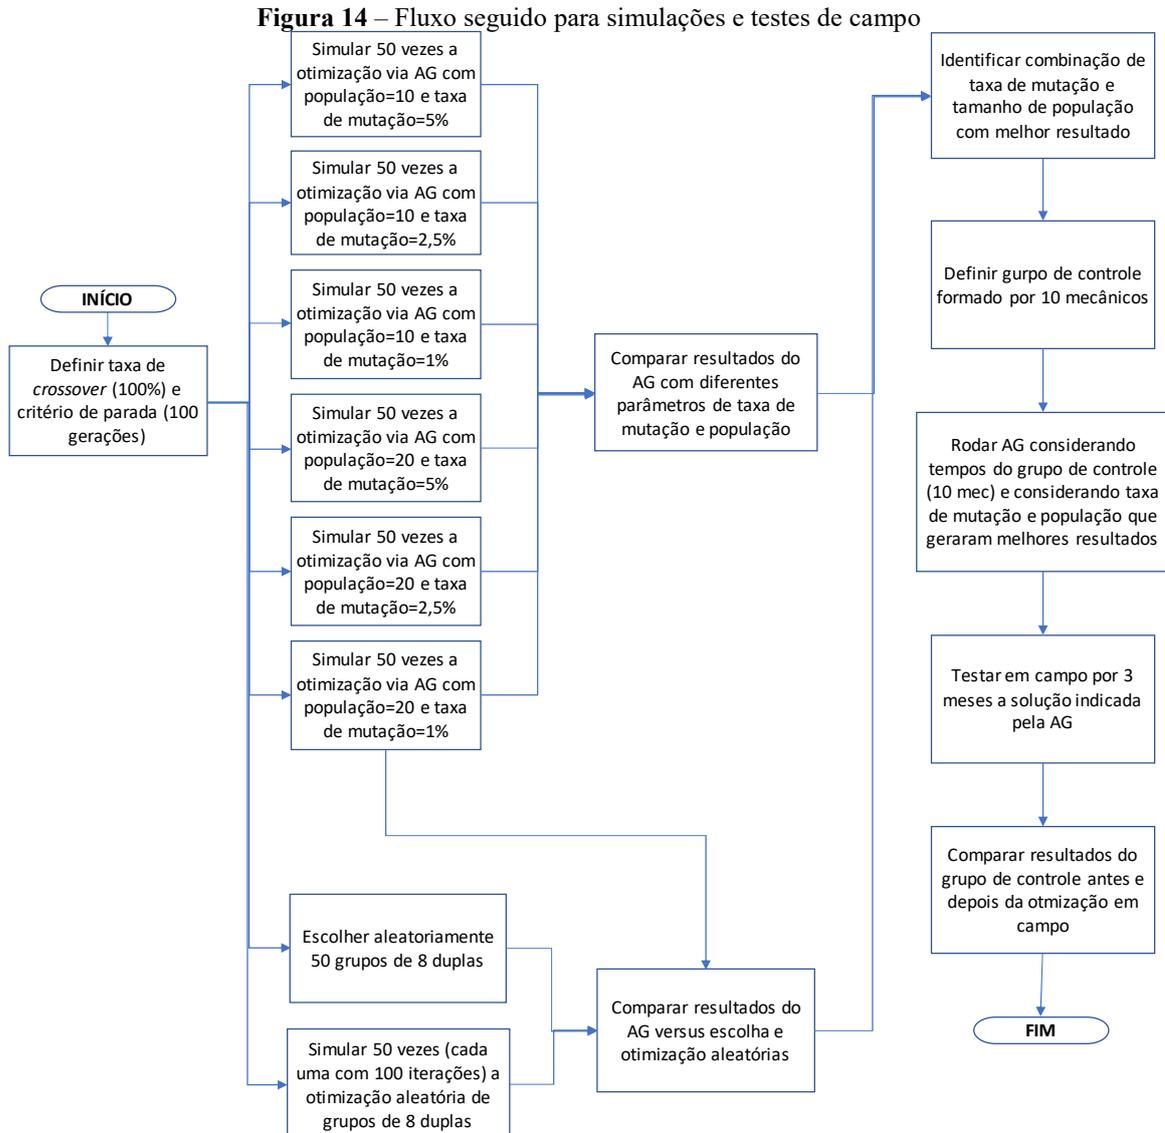
Desta forma, para a fase de testes em campo o AG foi rodado novamente considerando agora apenas a combinação de taxa de mutação e tamanho da população que apresentou melhor desempenho dentre as simulações feitas para o grupo de 16 mecânicos. Nesse sentido, considerando a partir de agora apenas os mecânicos da inspetoria priorizada, foram avaliados 10 mecânicos que ao final da otimização foram agrupados em 5 duplas de trabalho.

Estas 5 duplas de trabalho propostas pelo AG foram implementadas na prática, o que causou mudança de escala de alguns empregados e alteração de duplas de trabalho até então praticadas, sendo esta nova configuração praticada por três meses, entre abril e junho de 2019.

Após o término dos três meses de testes foi então avaliado se houve uma redução no tempo médio de troca de rodeiros deste grupo de 10 mecânicos, além de também comparar o tempo médio das trocas feitas pelas duplas ditas otimizadas com aquelas trocas feitas por duplas formadas aleatoriamente.

Na Figura 14 é apresentado o fluxo das simulações e testes de campo, nela percebe-se que o AG foi testado com 6 combinações distintas de taxa de mutação e tamanho de população,

sendo aquela com melhor resultado testada em campo dentro de um grupo de controle.



Fonte: Próprio autor

Para processar o AG foi utilizado um computador com processador AMD de 2,10 GHz, com memória RAM de 8 GB e sistema operacional Windows 10 de 64 bits, sendo utilizado na sua implementação a linguagem de programação Visual Basic dentro do ambiente Excel.

4.3 Aspectos da complexidade do problema

Dentre o total de 120 possibilidades de duplas, destaca-se que na formação do conjunto de 8 duplas um mesmo mecânico só pode estar presente em uma única dupla, desta forma, o total de cenários possíveis de agrupamentos de 8 duplas formadas a partir de 16 mecânicos pode

ser calculada pela sequência abaixo de produtos de combinações tomadas dois a dois:

$$\text{Número de soluções possíveis} = C_2^{16} \cdot C_2^{14} \cdot C_2^{12} \cdot C_2^{10} \cdot C_2^8 \cdot C_2^6 \cdot C_2^4 \cdot C_2^2 \quad \text{Equação 1}$$

Observando a Equação 1 percebe-se uma sequência de produtos de combinações tomadas dois a dois, o que permite chegar à Equação 2 que generaliza o cálculo do número total de possibilidades de soluções para um problema deste tipo para um número par qualquer M de mecânicos.

$$\text{Número de soluções possíveis} = \prod_{i=0}^{i=(M-2)/2} C_2^{M-2i} \quad \text{Equação 2}$$

Uma vez desdobrada a expressão da combinação contida na Equação 2, obtém-se a Equação 3, em que devido ao número de soluções possíveis para o problema variar com o fatorial do número de mecânicos M , conclui-se que o problema abordado é do tipo NP-Complexo, o que reforça a aplicabilidade de técnicas heurísticas de otimização ao invés do uso da otimização exata.

$$\text{Número de soluções possíveis} = \prod_{i=0}^{i=(M-2)/2} \frac{(M-2i)!}{2 \cdot (M-2i-2)!} \quad \text{Equação 3}$$

Sabendo que a oficina onde este trabalho foi desenvolvido possui 16 mecânicos no turno da manhã, o número de opções de agrupamentos de 8 duplas possíveis de serem formadas com esta equipe pode ser calculada através da Equação 3, conforme abaixo:

$$\text{Num Opções} = \prod_{i=0}^{i=\frac{M-2}{2}} \frac{(M-2i)!}{2 \cdot (M-2i-2)!} = \prod_{i=0}^{i=\frac{16-2}{2}} \frac{(16-2i)!}{2 \cdot (16-2i-2)!} = \prod_{i=0}^{i=7} \frac{(16-2i)!}{2 \cdot (14-2i)!}$$

$$\begin{aligned} \text{Num Opções} &= \frac{(16-2 \cdot 0)!}{2 \cdot (14-2 \cdot 0)!} \cdot \frac{(16-2 \cdot 1)!}{2 \cdot (14-2 \cdot 1)!} \cdot \frac{(16-2 \cdot 2)!}{2 \cdot (14-2 \cdot 2)!} \cdot \frac{(16-2 \cdot 3)!}{2 \cdot (14-2 \cdot 3)!} \cdots \\ &\cdots \frac{(16-2 \cdot 4)!}{2 \cdot (14-2 \cdot 4)!} \cdot \frac{(16-2 \cdot 5)!}{2 \cdot (14-2 \cdot 5)!} \cdot \frac{(16-2 \cdot 6)!}{2 \cdot (14-2 \cdot 6)!} \cdot \frac{(16-2 \cdot 7)!}{2 \cdot (14-2 \cdot 7)!} \end{aligned}$$

$$\text{Num Opções} = \frac{(16)!}{2 \cdot (14)!} \cdot \frac{(14)!}{2 \cdot (12)!} \cdot \frac{(12)!}{2 \cdot (10)!} \cdot \frac{(10)!}{2 \cdot (8)!} \cdot \frac{(8)!}{2 \cdot (6)!} \cdot \frac{(6)!}{2 \cdot (4)!} \cdot \frac{(4)!}{2 \cdot (2)!} \cdot \frac{(2)!}{2 \cdot (0)!}$$

$$\text{Num Opções} = 120 \cdot 91 \cdot 66 \cdot 45 \cdot 28 \cdot 15 \cdot 6 \cdot 1 = 81.729.648.000$$

A partir do resultado anterior vê-se que o problema em questão tem 81.729.648.000 cenários de solução, ou seja, dado um grupo de 16 mecânicos, tem-se mais de 80 bilhões de possibilidades de formar agrupamentos de 8 duplas com os mesmos.

4.4 Levantamento dos dados de tempo médio de troca de rodeiro por dupla

Os dados de tempo médio de troca de rodeiro por dupla de trabalho foram estruturados em forma de matriz, onde o elemento T_{ij} representa o tempo médio de troca de rodeiro da dupla formada pelo mecânico i com o mecânico j .

Neste sentido, convém destacar que nessa matriz de tempos a diagonal principal da mesma não deve ser considerada válida, uma vez que um mecânico não pode fazer dupla com ele mesmo, ou seja, o elemento T_{ii} não deve ser considerado em momento algum da análise ficando este inválido na matriz.

Outra característica da matriz de tempos é que a mesma é simétrica, isto deve-se ao fato do tempo médio de troca de rodeiros da dupla de mecânicos AB ser exatamente igual ao tempo da dupla BA, ou seja, o elemento T_{ij} da matriz é exatamente igual ao elemento T_{ji} , para todo e qualquer i e j menor ou igual ao número total de mecânicos.

No caso do problema em questão, uma vez que há 16 mecânicos, a tabela de tempos de troca de rodeiros consiste em uma matriz 16 x 16, onde cada elemento da mesma corresponde à média histórica de troca de rodeiros feita por dois mecânicos. Para cada um dos 16 mecânicos foi atribuída uma letra representativa, desta forma a matriz de tempos ficou com o aspecto mostrado na Tabela 1.

Tabela 1 - Dados reais de tempos médios de troca de rodeiros para 16 mecânicos (min)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	-	23,4	19,0	10,6	11,9	13,5	12,6	18,0	14,5	11,4	14,3	12,7	11,9	13,0	16,1	12,6
B	23,4	-				11,7	21,7		20,6	15,0		15,0		19,5	17,2	12,6
C	19,0		-		14,9	14,8	18,0	11,7	17,3			10,4	12,8		13,2	11,0
D	10,6			-	12,0		11,5	12,4	11,2	13,0	23,5	10,8	12,8	11,8	17,2	12,3
E	11,9		14,9	12,0	-	12,5		16,3	15,9	21,7	21,5	15,5	15,8	11,8	14,3	12,3
F	13,5	11,7	14,8		12,5	-		33,0	13,6	11,3	15,3		13,0	10,4	12,4	10,8
G	12,6	21,7	18,0	11,5			-		12,0	10,7	16,3	11,3	12,9	10,9	25,6	12,9
H	18,0		11,7	12,4	16,3	33,0		-					12,3	11,4		14,7
I	14,5	20,6	17,3	11,2	15,9	13,6	12,0		-		17,3	13,6		23,5		
J	11,4	15,0		13,0	21,7	11,3	10,7			-	12,9	12,1	11,5	14,0	26,0	14,0

Continua

Tabela 1 - Dados reais de tempos médios de troca de rodeiros para 16 mecânicos (min) - Continuação

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
K	14,3			23,5	21,5	15,3	16,3		17,3	12,9	-	13,0	12,2	14,0	14,8	12,8
L	12,7	15,0	10,4	10,8	15,5		11,3		13,6	12,1	13,0	-	14,0	13,6	15,3	12,7
M	11,9		12,8	12,8	15,8	13,0	12,9	12,3		11,5	12,2	14,0	-	13,1	13,6	12,8
N	13,0	19,5		11,8	11,8	10,4	10,9	11,4	23,5	14,0	14,0	13,6	13,1	-	10,3	8,2
O	16,1	17,2	13,2	17,2	14,3	12,4	25,6			26,0	14,8	15,3	13,6	10,3	-	8,2
P	12,6	12,6	11,0	12,3	12,3	10,8	12,9	14,7		14,0	12,8	12,7	12,8	8,2	8,2	-

Para o preenchimento completo da Tabela 1 eram necessários 240 dados de tempos médios de trocas de rodeiros, que podem ser reduzidos pela metade dada a simetria da tabela, porém como visto anteriormente, dos 120 tempos necessários 24 nunca tinham sido amostrados, ou seja, os mecânicos das duplas associadas às células marcadas em cinza na Tabela 1 até o momento da coleta de dados nunca tinham trabalhado juntos antes e por isso não foi possível obter seu tempo.

Apesar dos 24 tempos faltantes, outros 96 foram conseguidos com êxito a partir dos dados históricos, assim 80% dos dados necessários para usar como entrada para o AG estavam disponíveis, sendo então estes utilizados para estimar os 20% que não tinham amostras prévias.

Entre as 96 duplas com tempos já amostrados no histórico avaliado, 42 destas tiveram pelo menos 25 amostras consideradas na determinação de seu tempo médio de troca de rodeiro, então dado a sua maior representatividade de dados foram consideradas estas 42 duplas para interpolar uma equação que permitisse estimar o tempo médio de troca de rodeiro de uma dupla que nunca tivesse atuado em conjunto antes, usando para isso os tempos individuais de cada mecânico quando atuaram com outros parceiros.

A partir dos 42 tempos das duplas cujos valores foram obtidos a partir de mais de 25 amostras reais cada, simulou-se uma equação que considerasse o tempo da dupla como sendo uma média ponderada entre o tempo do mecânico mais rápido da dupla e o mais lento, ajustado por uma constante de correção, conforme apresentado na Equação 4.

$$\text{Tempo de troca} = A.\text{Tempo Mec Lento} + B.\text{Tempo Mec Rápido} + C \quad \text{Equação 4}$$

Para determinação dos parâmetros A , B e C da Equação 4 foi utilizado a ferramenta SOLVER de forma que a mesma indicasse uma combinação destes parâmetros que permitisse um erro mínimo entre os valores reais medidos e os valores calculados a partir da equação estimada.

Após o processamento do SOLVER, chegou-se a Equação 5, que quando utilizada a

título de comparação com os resultados reais medidos dos tempos de troca das 42 duplas com mais de 25 amostras cada, apresentou um erro médio de 7,8%. Deste modo as 24 duplas que não dispunham de amostras prévias tiveram seus tempos médio de troca de rodeiros estimados a partir da Equação 5.

Tempo de troca =

$$-0,69.Tempo Mec Lento + 1,64.Tempo Mec Rápido - 0,07$$

Equação 5

De posse da Equação 5 foi possível completar os tempos que faltavam na matriz de tempos médios de troca de rodeiros, sendo então a Tabela 2 utilizada como base de entrada para o algoritmo genético a ser implementado.

Tabela 2 - Dados reais e estimados de tempos médios de troca de rodeiros para 16 mecânicos (min)

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	-	23,4	19,0	10,6	11,9	13,5	12,6	18,0	14,5	11,4	14,3	12,7	11,9	13,0	16,1	12,6
B	23,4	-	12,5	10,6	12,0	11,7	21,7	15,1	20,6	15,0	14,0	15,0	13,0	19,5	17,2	12,6
C	19,0	12,5	-	11,8	14,9	14,8	18,0	11,7	17,3	13,5	13,1	10,4	12,8	13,6	13,2	11,0
D	10,6	10,6	11,8	-	12,0	12,1	11,5	12,4	11,2	13,0	23,5	10,8	12,8	11,8	17,2	12,3
E	11,9	12,0	14,9	12,0	-	12,5	13,3	16,3	15,9	21,7	21,5	15,5	15,8	11,8	14,3	12,3
F	13,5	11,7	14,8	12,1	12,5	-	12,9	33,0	13,6	11,3	15,3	12,7	13,0	10,4	12,4	10,8
G	12,6	21,7	18,0	11,5	13,3	12,9	-	12,1	12,0	10,7	16,3	11,3	12,9	10,9	25,6	12,9
H	18,0	15,1	11,7	12,4	16,3	33,0	12,1	-	15,8	12,0	13,7	12,5	12,3	11,4	13,4	14,7
I	14,5	20,6	17,3	11,2	15,9	13,6	12,0	15,8	-	12,0	17,3	13,6	12,7	23,5	13,4	11,5
J	11,4	15,0	13,5	13,0	21,7	11,3	10,7	12,0	12,0	-	12,9	12,1	11,5	14,0	26,0	14,0
K	14,3	14,0	13,1	23,5	21,5	15,3	16,3	13,7	17,3	12,9	-	13,0	12,2	14,0	14,8	12,8
L	12,7	15,0	10,4	10,8	15,5	12,7	11,3	12,5	13,6	12,1	13,0	-	14,0	13,6	15,3	12,7
M	11,9	13,0	12,8	12,8	15,8	13,0	12,9	12,3	12,7	11,5	12,2	14,0	-	13,1	13,6	12,8
N	13,0	19,5	13,6	11,8	11,8	10,4	10,9	11,4	23,5	14,0	14,0	13,6	13,1	-	10,3	8,2
O	16,1	17,2	13,2	17,2	14,3	12,4	25,6	13,4	13,4	26,0	14,8	15,3	13,6	10,3	-	8,2
P	12,6	12,6	11,0	12,3	12,3	10,8	12,9	14,7	11,5	14,0	12,8	12,7	12,8	8,2	8,2	-

4.5 Modelagem do algoritmo genético

A modelagem do AG foi concebida através de representação baseada em ordem, desta forma cada cromossomo foi composto por uma sequência de 16 letras, de forma que cada letra representava um mecânico diferente, sendo que cada duas letras sequenciais representava uma dupla de trabalho.

Em síntese, um cromossomo do problema em questão corresponde a um agrupamento de 8 duplas e sua função objetivo é o resultado da média dos tempos de troca de rodeiros destas

8 duplas, cujos tempos estão presentes na Tabela 2.

Na Tabela 3 é dado um exemplo de um cromossomo viável para o problema em questão.

Tabela 3 - Exemplo de um cromossomo viável para o problema

	Par 1	Par 2	Par 3	Par 4	Par 5	Par 6	Par 7	Par 8	Tempo Médio Cromossomo (min)
Tempo Dupla (min)	C K 13,1	G L 11,3	F D 12,1	J B 15,0	H O 13,4	E M 15,8	I N 23,5	A P 12,6	14,6

Para testar a performance do AG perante diferentes parâmetros de entrada, o mesmo foi avaliado variando-se o tamanho da população (10 e 20 indivíduos) e a taxa de mutação (1%, 2,5% e 5%), totalizando assim 6 combinações diferentes, definindo-se para todos o mesmo critério de parada que foi a limitação em 100 gerações.

A taxa de *crossover* foi de 100% e o método de escolha dos indivíduos para cruzamento foi o da normalização linear, método muito similar a roda da roleta, com a única diferença que as probabilidades de sorteio de cada cromossomo dependem não apenas da aptidão original dos indivíduos, mas sim da posição relativa de cada um destes perante a lista de todos os cromossomos da população quando ordenados decrescentemente por critério de aptidão.

Deste modo, a avaliação da aptidão de cada indivíduo deu-se através da função *fitness* mostrada na Equação 6, onde N é o número de indivíduos na população, e i é o índice do cromossomo na população em ordem decrescente da função objetivo. Comumente usa-se $1 \leq Max \leq 2$ e $Max + Min = 2$, sendo que neste trabalho foi adotado $Min = 0,5$ e $Max = 1,5$.

$$Fitness = Min + (Max - Min) \cdot \frac{N - i}{N - 1} \quad \text{Equação 6}$$

A partir da *fitness* apresentada na Equação 6 foi possível potencializar as diferenças de desempenho entre cromossomos, uma vez que caso os mesmos fossem avaliados diretamente pela função objetivo original, que é a média dos tempos de troca de rodeiro das 8 duplas do cromossomo, ter-se-ia um maior risco de indivíduos de bom e mau desempenhos apresentarem chances muito próximas de serem sorteados para *crossover*.

Com esta alteração na *fitness* obteve-se um critério mais efetivo na priorização dos melhores cromossomos, o que reduziu a chance do AG perder eficiência devido a sorteios pouco efetivos. Na Tabela 4 é mostrado um exemplo deste fato para uma população hipotética.

Tabela 4 - Exemplo de avaliação da *fitness* de cromossomos de uma população hipotética

										Função Objetivo	% de sorteio	i	<i>Fitness</i>	% de sorteio						
K	H	N	C	E	F	B	I	A	O	L	G	P	D	J	M	13,94	9,9%	7	0,8	8,3%
E	B	L	O	H	C	A	K	M	D	I	G	P	N	F	J	12,20	11,3%	1	1,5	15,0%
K	J	D	P	N	B	C	I	G	L	M	A	E	F	H	O	13,87	10,0%	5	1,1	10,6%
H	N	E	I	B	M	L	O	A	P	D	C	F	J	G	K	13,45	10,3%	4	1,2	11,7%
O	L	J	H	M	K	C	I	P	A	N	E	G	D	B	F	13,05	10,6%	3	1,3	12,8%
F	O	J	I	C	G	D	M	H	N	A	B	L	P	K	E	15,53	8,9%	9	0,6	6,1%
C	N	B	L	H	A	D	G	P	M	F	I	O	J	E	K	16,51	8,4%	10	0,5	5,0%
H	C	M	P	E	I	B	J	G	L	O	D	N	K	F	A	13,92	9,9%	6	0,9	9,4%
L	M	H	J	D	O	A	E	N	K	B	G	P	C	I	F	14,42	9,6%	8	0,7	7,2%
N	A	C	D	H	L	M	F	G	E	J	I	K	B	P	O	12,22	11,1%	2	1,4	13,9%

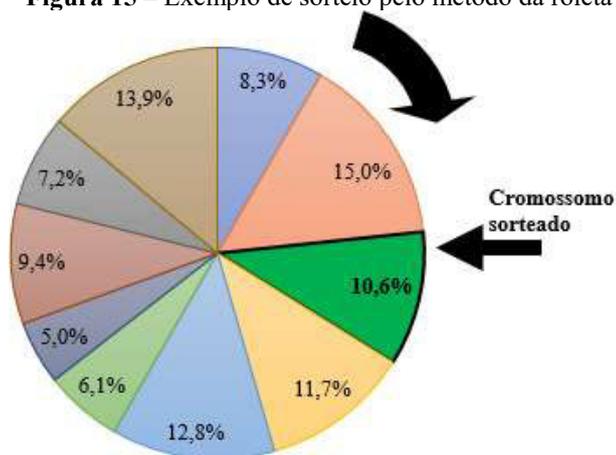
Observa-se na Tabela 4 o ganho de precisão que é possível ter com o ajuste de *fitness*, tal constatação fica clara a partir da comparação entre o pior e o melhor indivíduo da população, com tempos médios de troca de rodeiros de 16,51 e 12,20 minutos respectivamente. Caso fossem considerados seus valores de função objetivo para seleção para *crossover*, o pior indivíduo teria 8,4% de chance de ser sorteado e o melhor teria 11,3%, enquanto que considerando o uso da *fitness* estes percentuais se alteram para 5,0% e 15,0%.

A partir da constatação acima percebe-se que o uso da Equação 6 como *fitness* permite evidenciar melhor os extremos entre os melhores e piores cromossomos, o que para o algoritmo genético é de grande valia uma vez que a tendência dos melhores indivíduos serem sorteados será maior, logo haverá maior chance do melhores genes se perpetuarem ao longo das gerações.

Após a etapa da normalização linear o sorteio em si dos indivíduos ocorreu pelo método da roleta, onde cada cromossomo da população era representado por uma fatia de uma roleta imaginária, sendo o tamanho desta fatia proporcional à *fitness* de cada cromossomo. Depois de todas as fatias da roleta serem delimitadas, era gerado um número aleatório simulando um giro da roleta, que por sua vez apresentava um ponteiro fixo indicando a fatia sorteada, desta forma quanto maior a *fitness*, maior a fatia deste cromossomo e maior sua chance de ser sorteado.

Na Figura 15 encontra-se um exemplo referente a um sorteio feito a partir da população mostrada na Tabela 4, para este caso tem-se 10 indivíduos representados na roleta, sendo que o sorteado foi aquele que tinha 10,6% de chance, cuja *fitness* era 1,1 e cujo o tempo médio de troca de rodeiro do conjunto de 8 duplas que o cromossomo representa valia 13,87 minutos.

Figura 15 – Exemplo de sorteio pelo método da roleta



Fonte: Próprio autor

Por se tratar de um problema de otimização combinatorial e não numérica, o operador de *crossover* a ser escolhido para este AG não pode apenas copiar parte do material genético de dois pais e juntar em um filho, dado que assim há risco de repetição de alguns genes.

Para casos como este o operador de *crossover* deve levar em conta a posição relativa de cada gene dentro do cromossomo e não apenas a posição absoluta, ou seja, dizer apenas que um determinado gene está localizado na posição 4 do cromossomo não teria muito sentido, esta informação só teria valor vindo juntamente com a especificação dos genes presentes nas posições adjacentes 3 e 5.

Sendo assim, uma vez sorteados dois cromossomos da população, o operador de cruzamento utilizado foi o *crossover OX* (*order crossover*), seu funcionamento básico pode ser resumido na sequência de passos abaixo:

- Passo 1: Sorteie aleatoriamente dois pontos de corte no cromossomo.
- Passo 2: De posse de dois cromossomos (C_1 e C_2) copie para o cromossomo filho (C_3) os genes de C_1 que se encontram entre os dois pontos de corte previamente sorteados.
- Passo 3: A partir da posição posterior ao segundo ponto de corte, copie para C_3 os genes de C_2 que ainda não estejam presentes entre os dois pontos de corte do cromossomo filho.
- Passo 4: Caso chegue ao final do cromossomo filho sem ter todas as posições preenchidas, continue o preenchimento a partir do início do mesmo seguindo a mesma lógica do passo anterior.

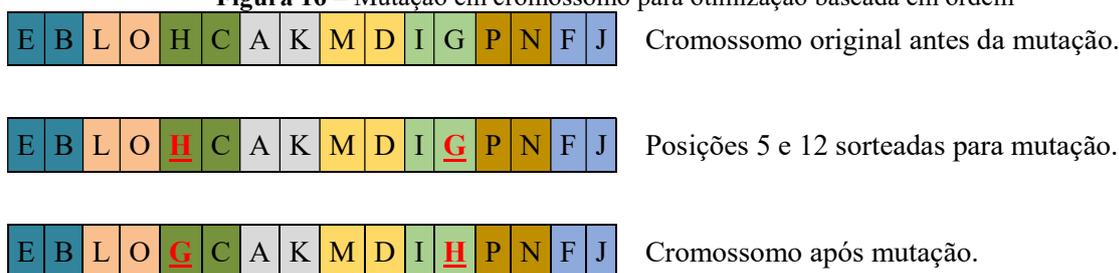
Na Tabela 5 ilustra-se os passos descritos acima, através dela é possível perceber que o *crossover OX* é muito adequado para este tipo de problema, uma vez que não permite que se tenham dois genes iguais dentro do mesmo cromossomo após o cruzamento.

Tabela 5 – Sequência do *Crossover OX*

PASSO	CROMOSSOMO	OBSERVAÇÃO
-	C ₁ K H N C E F B I A O L G P D J M	Cromossomo pai C ₁ : sorteados os pontos de corte entre os genes 2 e 3 e 13 e 14.
-	C ₂ E B L O H C A K M D I G P N F J	Cromossomo pai C ₂ : os genes marcados em vermelho já estão contidos entre os pontos de corte de C ₁ .
1	C ₃	Cromossomo filho C ₃ ainda vazio.
2	C ₃ N C E F B I A O L G P	Os genes entre as posições 3 e 13 de C ₁ são copiados para as mesmas posições em C ₃ .
3	C ₃ N C E F B I A O L G P J	Como N e F de C ₂ já constam em C ₃ entre os pontos de corte, pega-se o gene J de C ₂ e copia para posição posterior ao segundo ponto de corte em C ₃ .
4	C ₃ N C E F B I A O L G P J H	Como J é o último gene em C ₂ , deve-se buscar a partir do início de C ₂ qual gene dele ainda não consta em C ₃ , no caso é o gene H, que deve então ser copiado para próxima posição vazia de C ₃ .
5	C ₃ N C E F B I A O L G P J H K	Após o H em C ₂ o próximo gene que ainda não aparece em C ₃ é o K, logo este deve ser colocado na posição após o H em C ₃ .
6	C ₃ M N C E F B I A O L G P J H K	Como chegou-se ao final de C ₃ mas ainda há posições vazias no início do cromossomo, deve-se seguir a lógica de copiar os genes de C ₂ que ainda não apareceram em C ₃ só que considerando a partir da primeira posição de C ₃ .
7	C ₃ M D N C E F B I A O L G P J H K	Por fim conclui-se o <i>crossover</i> copiando o D de C ₂ para a última posição de C ₃ que se encontrava vazia.

Quanto à mutação, esta deu-se de forma que não gerasse indivíduos inconsistentes, como por exemplo quando há em um mesmo cromossomo duas letras iguais, o que significaria que um mesmo mecânico estaria alocado em duas duplas de trabalho ao mesmo tempo. Desse modo, a mutação foi baseada em um sorteio aleatório de duas posições do cromossomo, após isto os genes destas posições invertiam de lugar e davam assim origem a um novo cromossomo, conforme ilustrado na Figura 16.

Figura 16 – Mutação em cromossomo para otimização baseada em ordem



Fonte: Próprio autor

Além disso, de forma a não perder o melhor indivíduo de cada geração, foi adotado o elitismo, desta forma o algoritmo foi projetado para sempre levar para a próxima geração o melhor indivíduo da geração atual.

Com todas essas premissas descritas, o algoritmo básico do AG implementado pode ser resumido da seguinte maneira:

INÍCIO

```

Definir tamanho da população (População = 10 e 20).
Definir taxa de crossover (Taxa de Crossover = 100%).
Definir taxa de mutação (Taxa de Mutação = 1%, 2,5% e 5%).
Definir número de gerações como critério de parada (Critério de parada = 100° geração).
Sortear aleatoriamente a população inicial.
Enquanto critério de parada não é atingido
{
  Calcular fitness dos indivíduos da geração atual.
  Copiar melhor cromossomo da geração atual para próxima geração.
  Enquanto número de indivíduos da próxima geração não está completo
  {
    Sortear pelo método da roleta dois cromossomos a partir da geração atual.
    Fazer cruzamento entre os dois cromossomos sorteados.
    Sortear aleatoriamente a variável de mutação.
    Se sorteio da variável de mutação = positivo:
      Aplicar mutação ao cromossomo gerado.
    Copiar cromossomo gerado para a geração seguinte.
  }
  Incrementar geração.
}
Solução otimizada = cromossomo com melhor fitness da última geração criada.

```

FIM

Para fins de validação do algoritmo, cada uma das 6 combinações de tamanho de população (10 e 20 indivíduos) e taxa de mutação (1%, 2,5% e 5%) foi simulada por 50 vezes e a distribuição destes 50 tempos médios de troca de rodeiros obtidos após otimização via AG foi comparada com 50 tempos médios gerados a partir de escolha aleatória de um agrupamento de 8 duplas de mecânicos.

Também foi comparado o desempenho do algoritmo genético proposto com uma otimização aleatória, tendo sido verificado geração a geração a evolução da otimização para os dois métodos.

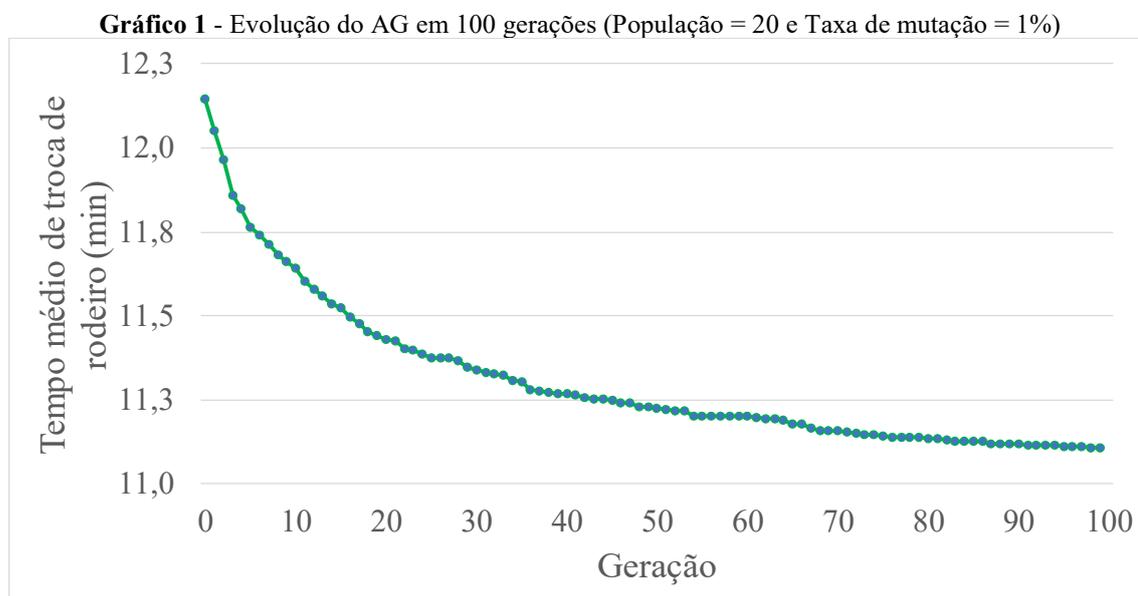
Após as simulações fez-se uma análise comparativa de performance entre cada uma das 6 combinações de cenários de tamanho de população e taxa de mutação, sendo aquela de melhor desempenho adotada para os testes de campo.

5 DESCRIÇÃO E ANÁLISE DE RESULTADOS

Após compilar as 3.126 amostras reais de trocas de rodeiros feitas em campo, foi possível elaborar a matriz de tempos médios de troca de rodeiros para as 120 duplas possíveis de serem formadas com uma equipe de 16 mecânicos, conforme foi apresentado anteriormente na Tabela 2, sendo esta a referência utilizada como base para avaliação das aptidões dos cromossomos.

Utilizando a modelagem proposta, onde cada cromossomo era formado por uma sequência de 16 letras em que cada uma destas representava um mecânico, foi escrito o código de otimização através de um algoritmo genético que adotou inicialmente uma taxa de *crossover* de 100%, taxa de mutação de 1%, população de 20 cromossomos e critério de parada o atingimento da centésima geração.

O código de otimização foi simulado 50 vezes sendo o tempo médio de processamento computacional de cada simulação de 12 minutos e 58 segundos. Em cada uma das 50 simulações foi calculada a média da solução otimizada pelo algoritmo genético a cada geração, resultando então no Gráfico 1.

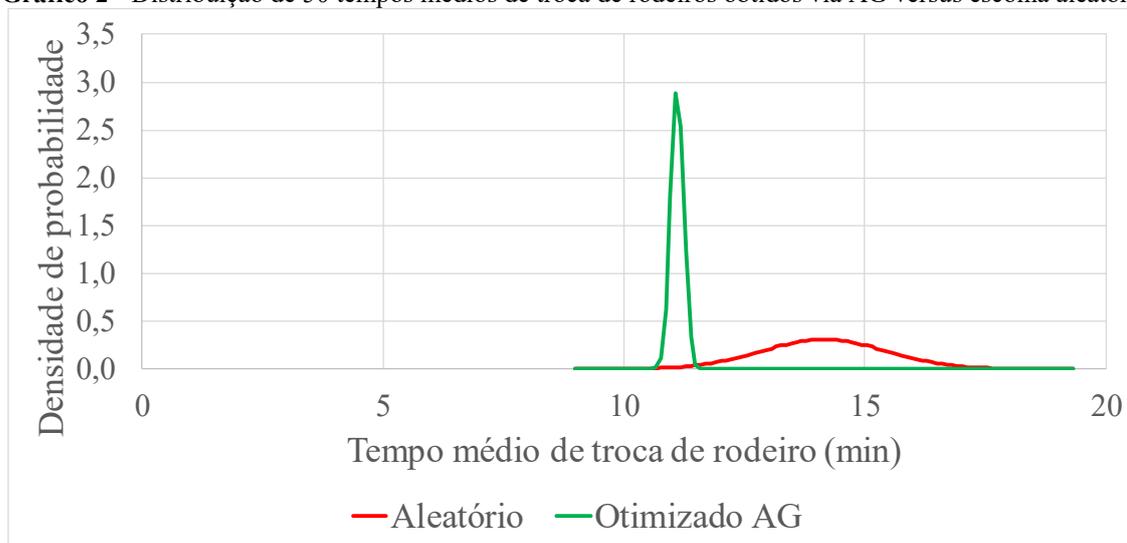


Calculando a média do valor otimizado ao chegar na centésima geração de cada uma das 50 simulações, foi obtido um tempo médio otimizado para o conjunto de 8 duplas de 11,1 minutos, sendo que o menor valor que foi encontrado nas simulações foi de 11 minutos, o que ilustra a efetividade da convergência do AG implementado.

5.1 Comparação da otimização via AG versus escolha aleatória

De forma a comparar a qualidade da escolha das duplas de trabalho através da otimização via algoritmo genético versus a escolha das duplas de maneira aleatória, os resultados obtidos pelas 50 simulações do AG foram comparados com 50 escolhas aleatórias de agrupamentos de 8 duplas de trabalho, resultando nas distribuições de dados presentes no Gráfico 2.

Gráfico 2 - Distribuição de 50 tempos médios de troca de rodeiros obtidos via AG versus escolha aleatória



Para os 50 resultados obtidos através do algoritmo genético foi constatado um tempo médio de 11,1 minutos com desvio-padrão de 0,14 minutos, enquanto que para os 50 resultados obtidos pela escolha aleatória a média foi de 14,2 minutos e o desvio-padrão 1,29 minutos, ambos com características de distribuição normal de dados.

Através desta simulação percebe-se que a otimização via algoritmo genético é capaz de potencializar o rendimento da equipe de trabalho, uma vez que comparado com a escolha aleatória das duplas de trabalho, que é o método comumente adotado na prática, o AG apresentou uma redução de 22% do tempo médio de troca de rodeiro e uma redução de 89% do desvio-padrão.

5.2 Comparação da otimização via AG versus otimização aleatória

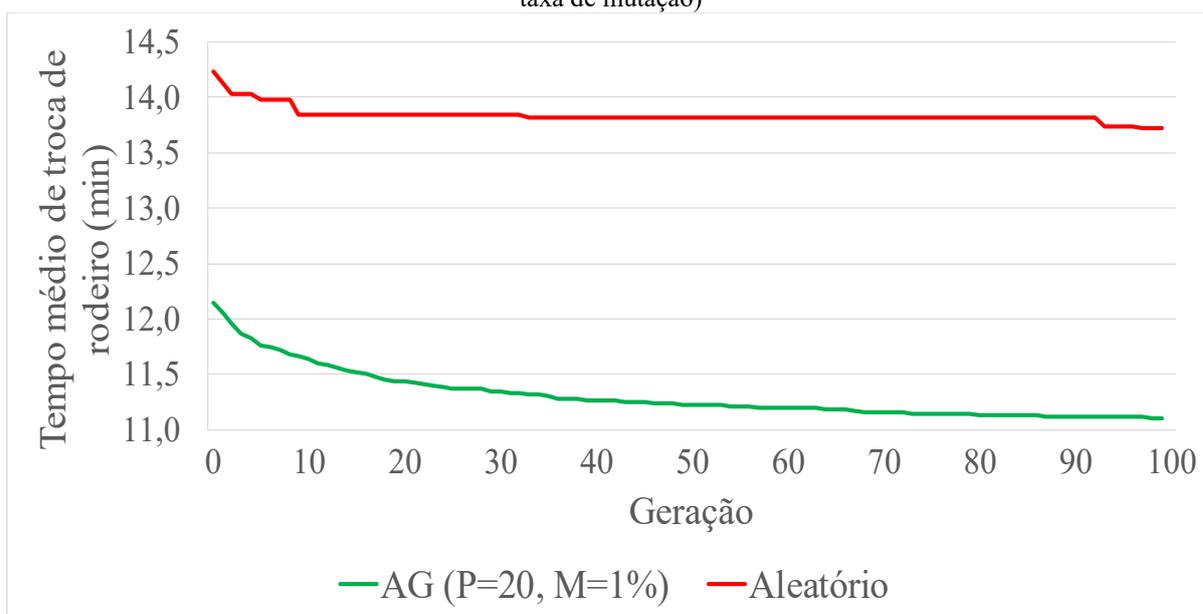
Além de comparar o conjunto de 50 amostras de tempos médios de troca obtidos através do algoritmo genético com outras 50 amostras obtidos a partir da escolha aleatória de duplas de

trabalho, também foi considerado simular 50 ciclos otimizações aleatórias para comparar com o desempenho do AG ao longo das gerações.

A otimização aleatória consistiu em escolher aleatória e sequencialmente 100 amostras de grupos de 8 duplas, sendo então calculado para cada conjunto deste de 8 duplas o tempo médio de troca de rodeiro associado. O tempo médio otimizado a cada iteração é dado pelo menor tempo médio encontrado até o momento, desta forma, na centésima iteração o tempo otimizado será o menor tempo médio encontrado ao longo das 100 amostras geradas de forma aleatória.

Foram rodadas 50 simulações aleatórias e a média do tempo otimizado a cada iteração foi comparada com as 50 simulações do algoritmo genético, estando o resultado da comparação apresentada no Gráfico 3.

Gráfico 3 - Comparativo de desempenho entre otimização aleatória e otimização via AG (P = população e M = taxa de mutação)



A média das 50 simulações de otimização aleatória ficou em 13,7 minutos, enquanto que através do AG foi obtido uma média de 11,1 minutos, ou seja, a otimização via AG se mostrou 19% mais eficiente que a otimização aleatória.

Além da superioridade no valor final que a otimização encontrou, vê-se claramente no Gráfico 3 o quanto o algoritmo genético demonstrou ser mais rápido do que a otimização aleatória, esta apresentou estagnação em boa parte ao longo das 100 iterações, dado que entre as gerações 10 e 90 praticamente o tempo médio otimizado aleatoriamente não variou, enquanto o valor do AG seguiu consistentemente sendo reduzido.

5.3 Análise de sensibilidade dos parâmetros do AG

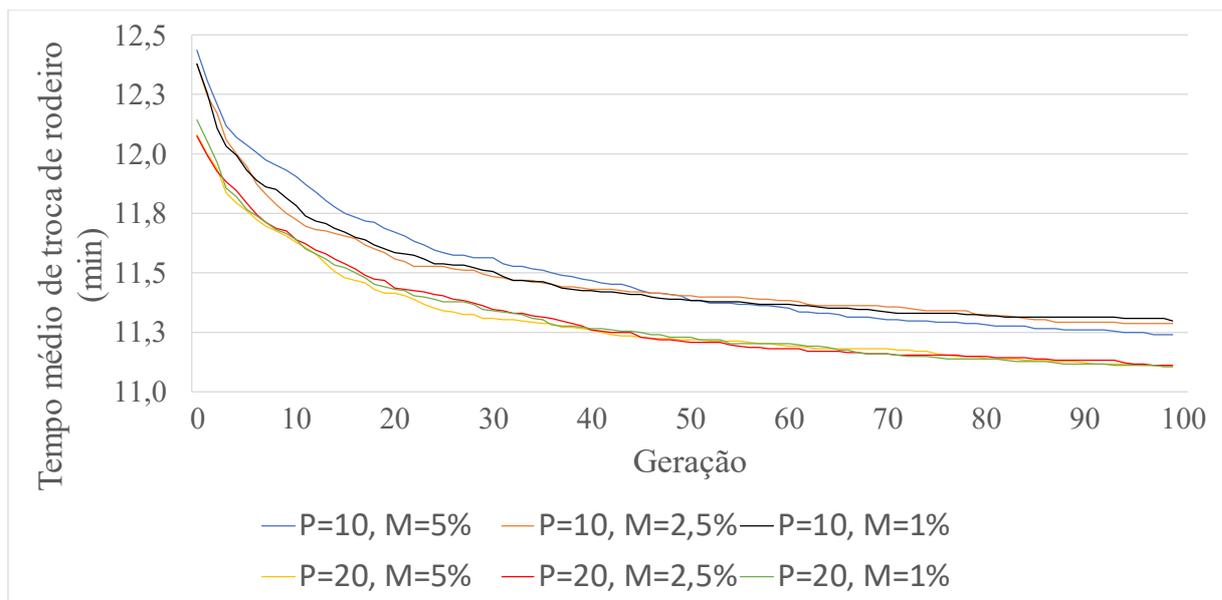
Para testar a sensibilidade dos parâmetros adotados no algoritmo genético e também para confirmar que os parâmetros utilizados até então de taxa de mutação de 1% e população de 20 indivíduos foram de fato escolhas assertivas, foram executadas simulações de otimização através do mesmo AG alterando apenas estes parâmetros de forma a permitir comparar seus desempenhos.

Foram consideradas 2 opções de tamanho de população (10 e 20 indivíduos) e 3 opções de taxa de mutação (1%, 2,5% e 5%), totalizando assim 6 combinações possíveis.

Para cada combinação de parâmetros foram executadas 50 simulações de otimização e em cada simulação foi utilizado o mesmo critério de parada, que foi o atingimento da centésima geração de indivíduos.

As médias dos valores otimizados a cada geração para cada uma das combinações de parâmetros possíveis são mostradas no Gráfico 4, a partir do qual observa-se que as 3 simulações que consideraram uma população de 10 indivíduos tiveram um desempenho pior do que as 3 simulações com população de 20 indivíduos, sendo a média das 3 primeiras 11,3 minutos e das 3 últimas 11,1 minutos.

Gráfico 4 - Comparativo do AG para diferentes parâmetros de população (P) e taxa de mutação (M)



Observando as simulações com tamanho de população igual a 20, viu-se que mesmo alterando a taxa de mutação entre 1%, 2,5% e 5% não houve diferença significativa entre elas ao longo das gerações, porém considerando as mesmas taxas de mutação para o caso da

população ser de 10 indivíduos, viu-se uma maior variação de desempenho do AG, principalmente nas 50 primeiras gerações.

Pelos resultados obtidos viu-se que a definição da taxa de mutação em 1% juntamente a uma população de 20 indivíduos, que foram os parâmetros utilizados até então, constituem uma configuração aceitável para rodar o algoritmo genético construído, sendo então estes os parâmetros a serem considerados para a implementação em campo.

5.4 Verificação em campo

Todo o processo de otimização foi baseado em dados reais de tempos de trocas de rodeiros, desde que atendessem alguns critérios conforme abordado anteriormente, desta forma ao término da otimização o algoritmo indicou uma combinação de duplas de trabalho que com base nos dados históricos, supostamente conseguiriam em conjunto apresentar um tempo médio de troca de rodeiros otimizado para a oficina em questão.

Neste ponto, de posse da indicação do grupo otimizado de duplas de trabalho, a estratégia para avaliar o ganho real advindo da otimização foi com base na indicação do algoritmo genético manter duplas fixas de trabalho, de forma a fazer o maior número de trocas de rodeiros utilizando as duplas indicadas pelo algoritmo. Após essa redefinição das duplas, o tempo médio de troca da oficina foi acompanhado por três meses sendo então comparados o tempo médio de troca de rodeiros antes e depois da implementação da otimização das duplas.

Dos 16 mecânicos considerados no problema, 10 deles pertenciam a uma mesma inspetoria e 6 pertenciam a outra, desta forma, na prática o algoritmo poderia indicar uma dupla formada por dois mecânicos de duas inspetorias distintas, o que se deseja evitar pois assim ter-se-ia dois inspetores para uma mesma dupla de trabalho.

A inspetoria com 6 pessoas além de fazer trocas de rodeiros também era responsável por outros serviços de manutenção, enquanto que a com 10 mecânicos era exclusivamente responsável por trocar rodeiros, por este motivo esta última equipe apresentava o maior percentual dos rodeiros trocados na oficina.

Conforme apresentado na Tabela 2, considerando 16 mecânicos tem-se 120 duplas possíveis de serem formadas, porém no problema em questão 24 destas duplas não tinham atuado junto nos últimos 13 meses para que pudessem ter seu tempo amostrado, sendo que nestes casos foi considerada a Equação 1 como forma de estimar o tempo da dupla e assim possibilitar os dados necessários para rodar o código de otimização.

Na prática cada inspetoria formava suas duplas de trabalho utilizando seus próprios

mecânicos, ou seja, embora não fosse proibido não era comum misturar os mecânicos de uma inspetoria com os da outra, exceto quando necessário devido a alguma questão operacional, como por exemplo a ausência de um mecânico, o que geralmente ocorre por motivos de férias, treinamento, doença, licenças legais, horário de almoço, etc.

Destaca-se que quanto mais duplas sem amostras reais do seu tempo de troca de rodeiro, mais vezes será preciso utilizar a Equação 1 para estimar este valor e maior a chance de erro nesta interpolação, conseqüentemente maior a chance de imprecisão no resultado do algoritmo de otimização.

Considerando apenas a inspetoria formada por 10 mecânicos, tem-se a possibilidade de formar 45 duplas, sendo que para o problema em questão, apenas 3 destas duplas não tinham amostras passadas de troca de rodeiros e somente nestes casos seria então necessário utilizar a Equação 1, o que reduziria a exposição ao erro devido a esta aproximação.

Sabe-se que o algoritmo genético originalmente considerou 16 mecânicos, a partir destes dados fizeram-se diversas simulações que mostraram um ganho potencial no tempo médio de troca de rodeiros caso fosse adotada a combinação de duplas de trabalho apontada por ele, porém para comprovação prática viu-se que trabalhar simultaneamente com 16 mecânicos tornaria o teste de campo mais complexo pelas questões anteriormente expostas, por isto optou-se por fazer os testes em campo considerando como grupo de controle a inspetoria composta por 10 mecânicos.

Uma vez adotado apenas o grupo de 10 mecânicos, obteve-se a Tabela 6 de tempos a ser considerada pelo algoritmo genético como dados de entrada para avaliação da combinação otimizada de duplas de trabalho.

Tabela 6 – Matriz de tempos médios de troca de rodeiros para inspetoria de 10 mecânicos (min)

	A	B	D	G	J	K	L	M	N	O
A	-	23,4	10,6	12,6	11,4	14,3	12,7	11,9	13,0	16,1
B	23,4	-	10,6	21,7	15,0	14,0	15,0	13,0	19,5	17,2
D	10,6	10,6	-	11,5	13,0	23,5	10,8	12,8	11,8	17,2
G	12,6	21,7	11,5	-	10,7	16,3	11,3	12,9	10,9	25,6
J	11,4	15,0	13,0	10,7	-	12,9	12,1	11,5	14,0	26,0
K	14,3	14,0	23,5	16,3	12,9	-	13,0	12,2	14,0	14,8
L	12,7	15,0	10,8	11,3	12,1	13,0	-	14,0	13,6	15,3
M	11,9	13,0	12,8	12,9	11,5	12,2	14,0	-	13,1	13,6
N	13,0	19,5	11,8	10,9	14,0	14,0	13,6	13,1	-	10,3
O	16,1	17,2	17,2	25,6	26,0	14,8	15,3	13,6	10,3	-

A partir dos tempos indicados na Tabela 6 foi rodado novamente o algoritmo genético, sendo considerados os parâmetros de taxa de mutação de 1%, taxa de *crossover* de 100%, população de 20 indivíduos e critério de parada o atingimento de 100 gerações.

Após rodar a otimização via AG considerando os tempos da Tabela 6, obteve-se uma indicação de 5 duplas de trabalho que passou a ser a combinação desejada de equipe de trabalho, uma vez que fazendo as trocas de rodeiros através destas duplas espera-se ter um tempo médio de troca de rodeiro melhor do que considerando a formação aleatória das duplas.

Vale destacar que dentro do grupo de 10 mecânicos considerados para os testes de campo, existiam pessoas que trabalhavam em escalas distintas, sendo assim, mesmo todos eles trabalhando no turno da manhã, a cada dia parte das 10 pessoas encontrava-se de folga enquanto outras estavam trabalhando.

O fato da escala proporcionar que dois mecânicos trabalhando em escalas diferentes haja dias em que quando um estiver trabalhando o outro estará de folga, impacta diretamente nos testes de campo uma vez que dentre as 5 duplas sugeridas pelo AG havia pares que atualmente trabalhavam em escalas diferentes, logo haveria dias que seria impossível que eles atuassem juntos na oficina.

A escala de trabalho até então praticada na oficina era composta por um ciclo de quatro dias de trabalho seguidos de um dia de folga, seguidos de mais quatro dias de trabalho seguidos de dois dias de folga. Ao todo tinha-se seis escalas distintas, todas rodando nesta sequência, apenas se diferenciando pela defasagem entre elas, sendo assim todos os dias tinha-se uma ou duas escalas de folga, o que fazia com que em dias específicos alguns mecânicos não estivessem simultaneamente na oficina,

Na Tabela 7 estão as escalas da oficina, nela vê-se por exemplo que nos dias 5 e 6 um mecânico que trabalhe na escala 1 e outro na escala 2 não estarão juntos na oficina, pois o primeiro estará de folga no primeiro dia enquanto o segundo estará de folga no segundo dia.

Tabela 7 – Escalas de trabalho praticas na oficina (T = dia de trabalho, F = dia de folga)

Escala / Dia	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
Escala 1	T	T	T	T	F	T	T	T	T	F	F	T	T	T	T	F	T	T
Escala 2	F	T	T	T	T	F	T	T	T	T	F	F	T	T	T	T	F	T
Escala 3	F	F	T	T	T	T	F	T	T	T	T	F	F	T	T	T	T	F
Escala 4	T	F	F	T	T	T	T	F	T	T	T	T	F	F	T	T	T	T
Escala 5	T	T	F	F	T	T	T	T	F	T	T	T	T	F	F	T	T	T
Escala 6	T	T	T	F	F	T	T	T	T	F	T	T	T	T	F	F	T	T

Entretanto, após a indicação das duplas otimizadas, os dois mecânicos que compunham cada um dos cinco pares de trabalho indicados pelo algoritmo genético foram colocados na mesma escala de trabalho, de forma que se por exemplo na combinação das duplas o mecânico A fosse o par ideal do mecânico B, ambos trabalhassem na mesma escala, possibilitando assim que na maioria das vezes eles pudessem trocar rodeiros juntos.

Mesmo definido pares fixos de trabalho e ajustando as escalas para facilitar na prática a formação destes grupos de trabalho, não se pôde garantir que todas as trocas de rodeiro foram sempre realizadas pelas duplas otimizadas, uma vez que durante a jornada de trabalho há necessidade de fazer rodízio da equipe para o almoço além do absenteísmo médico, férias entre outras ausências de pessoal que podem ocorrer.

De posse das 5 duplas indicadas pelo AG como uma combinação otimizada de grupo de trabalho, foi divulgada para a equipe a adequação das duplas de trabalho e orientado o inspetor da área para que buscasse ao máximo manter esta combinação. Para lembrar as novas duplas de trabalho foi fixado no quadro de avisos da oficina quais as duplas dever-se-iam adotar a partir daquele momento, conforme pode ser visto na Figura 17.

Figura 17 – Quadro de gestão da oficina com divulgação das duplas otimizadas

DUPLAS OTIMIZADAS - TROCA DE RODEIROS T2			
Mecânico 1	Mecânico 2	Escala	Linha
Paulo José	Marcos Gouveia	A1	Cobertura
Claudenilton Silva	Cicero Sousa	A2	TR3
Rogério Diniz	Rouberth Lima	A3	TR4
Marcos Ciorli	Elias Gonçalves	A4	Cobertura
Jessé Ferreira	Bruno Castro	A5	TR2
Eldio Cruz	Osvaldo Júnior	A6	TR1



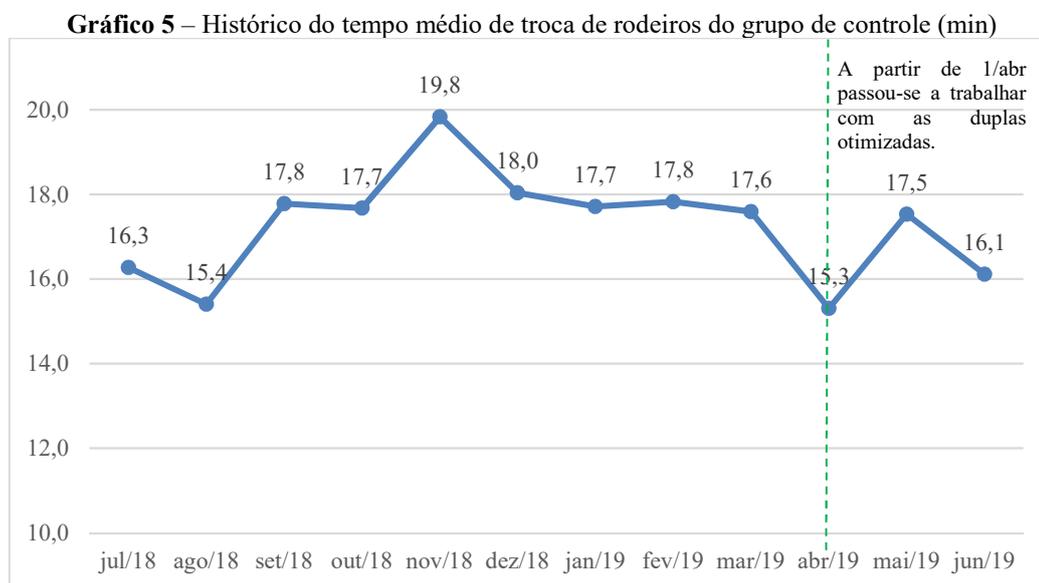
Fonte: Próprio autor.

Para fins de comparação antes e depois da implementação das duplas de trabalho otimizadas, observou-se o histórico dos últimos 9 meses antes da otimização e mais 3 meses após a mudança, totalizando assim uma análise de desempenho em uma janela de 1 ano.

Neste período de 12 meses foram contabilizadas 10.835 trocas de rodeiros, sendo que desta quantidade 7.228 trocas foram executadas pela inspetoria composta por 10 mecânicos que foram priorizados para os testes de campo, ou seja, aproximadamente 67% da produção da oficina no turno abordado foi cumprida justamente pelo grupo de controle escolhido.

A padronização das duplas de trabalho a partir da indicação feita pelo algoritmo genético passou a valer a partir do dia 1 de abril de 2019, e seguiu até 30 de junho do mesmo ano, neste período foi buscado ao máximo manter trabalhando juntos os mecânicos de cada uma das 5 duplas de trabalho apontadas pelo AG, pois caso as formações das duplas de troca de rodeiros continuassem essencialmente aleatórias, seria impossível associar qualquer ganho de produtividade à implantação das duplas sinalizadas pelo AG.

Considerando a inspetoria formada pelos 10 mecânicos, foram 7.228 trocas de rodeiros executadas entre 1 julho de 2018 e 30 de junho de 2019, com os tempos médios de troca de rodeiros mostrados no Gráfico 5.



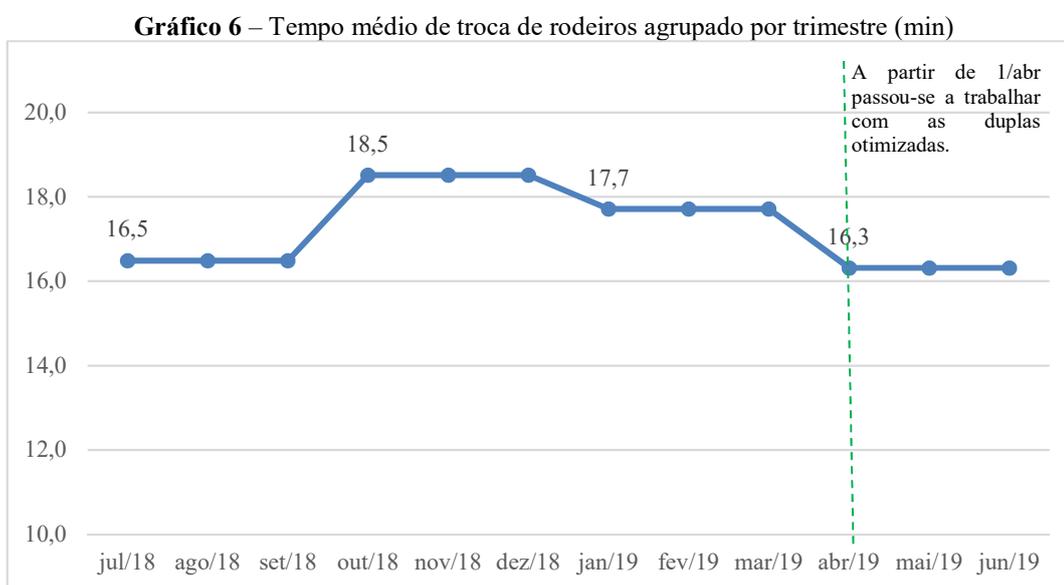
Observa-se que apesar dos meses de abril e junho de 2019 terem apresentado excelentes resultados, com tempos médios de troca de rodeiros de 15,3 e 16,1 minutos, respectivamente, o mês de maio ficou aquém das expectativas, apresentando 17,5 minutos, valor melhor, mas muito próximo que patamar que vinha ocorrendo antes da otimização.

O resultado destoante no mês de maio de 2019 pode ser entendido através de fatores

operacionais que podem ter comprometido a performance naquele mês específico, neste caso, houve impactos enormes devido à falta de rodeiros novos para serem instalados, uma vez que por várias vezes no mês de maio após o mecânico retirar um rodeiro ruim do vagão, em vez dele já contar prontamente com o rodeiro novo para ser instalado no lugar do que acabara de ser removido, dada a falta de rodeiros novos, o mesmo rodeiro retirado era enviado para o processo de recuperação e após todo o ciclo de manutenção do rodeiro este mesmo voltava para o vagão, o que afetou consideravelmente o tempo médio de troca de rodeiros.

Além de eventuais impactos operacionais não associados diretamente à performance das duplas de trabalho, tal como ocorreu em maio de 2019 com o impacto devido à falta de rodeiros, há outras variáveis que também podem afetar o tempo médio de troca, tais como falha de equipamentos industriais e falta de mão de obra, porém, historicamente o problema de falta de rodeiro tem sido o mais representativo de todos.

De forma a reduzir a sazonalidade de eventuais problemas operacionais que possam comprometer o tempo médio de troca de rodeiros, foi analisado o mesmo período de 12 meses, porém em janelas trimestrais, podendo o resultado ser observado no Gráfico 6.



No trimestre entre abril e junho de 2019, período em que a otimização foi testada na prática, obteve-se o melhor tempo médio de troca de rodeiros dos últimos 4 trimestres, e comparando-se com o trimestre entre janeiro e março de 2019, viu-se uma redução de 17,7 para uma média de 16,3 minutos, o que representa uma melhoria de 7,9% entre o primeiro e segundo trimestre de 2019.

Uma vez que há um entendimento prático de que o impacto por falta de rodeiro tem sido

o maior problema na oficina e que este afeta diretamente o tempo médio de troca de rodeiro, ainda que não tenha relação direta com o desempenho da dupla de trabalho, decidiu-se então levantar o impacto mês a mês dessa falta de rodeiro e expurgar este efeito dos tempos médios de troca, para que assim fosse possível ter um resultado mais ajustado e mais coerente com os aspectos de performance das equipes de trabalho.

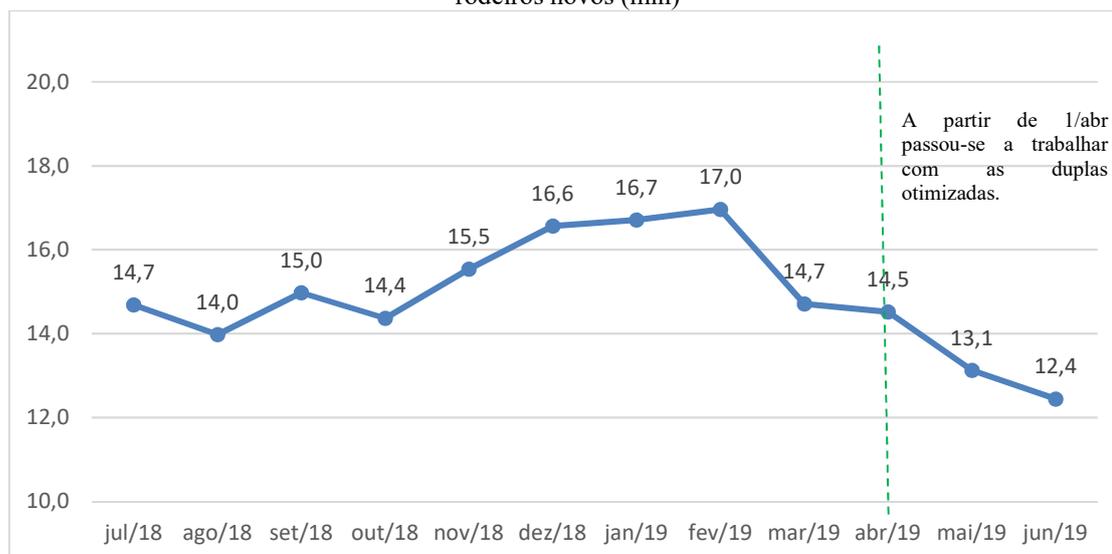
Levantando o impacto devido à falta de rodeiros chegou-se à Tabela 8 através da qual é possível ver que de fato em maio de 2019 houve o maior impacto no tempo de troca por motivo de falta de rodeiro novo para substituir aquele retirado do vagão, sendo que neste mês o tempo médio do grupo de controle foi de 17,5 minutos, dos quais 4,4 minutos foram de impacto devido a dupla ter que esperar a chegada do rodeiro novo, desta forma, expurgando este efeito, o tempo médio de troca de rodeiro ajustado do mês de maio de 2019 seria de 13,1 minutos.

Tabela 8 – Histórico de impactos no tempo de troca de rodeiro por falta de rodeiro disponível

	jul/18	ago/18	set/18	out/18	nov/18	dez/18	jan/19	fev/19	mar/19	abr/19	mai/19	jun/19
Tempo médio de troca de rodeiro (min)	16,3	15,4	17,8	17,7	19,8	18,0	17,7	17,8	17,6	15,3	17,5	16,1
Rodeiros trocados	453	857	498	437	385	665	500	690	504	800	733	706
Tempo aguardando rodeiro (min)	719	1.222	1.397	1.444	1.651	983	503	599	1.453	628	3.228	2.589
Tempo aguardando rodeiro / Troca (min)	1,6	1,4	2,8	3,3	4,3	1,5	1,0	0,9	2,9	0,8	4,4	3,7
Tempo médio de troca expurgando impacto por falta de rodeiro (min)	14,7	14,0	15,0	14,4	15,5	16,6	16,7	17,0	14,7	14,5	13,1	12,4

No Gráfico 7 é mostrado o histórico do tempo médio de troca de rodeiro do grupo de controle expurgando os impactos por falta de rodeiro, nele percebe-se mais claramente o efeito da otimização nos meses de abril, maio e junho de 2019, onde vê-se a redução do tempo médio, sendo que no mês anterior à otimização praticava-se 14,7 minutos e ao final do terceiro mês rodando com as duplas fixas otimizadas chegou-se ao tempo de 12,4 minutos, o que representa uma redução de 2,3 minutos por troca de rodeiro ou 15,6%.

Gráfico 7 – Histórico do tempo médio de troca de rodeiro expurgando o impacto de indisponibilidade de rodeiros novos (min)



Sabe-se que a partir de abril de 2019 houve uma maior busca pela manutenção de duplas fixas de trabalho, sendo a definição destas duplas obtidas a partir da indicação do algoritmo genético, enquanto que antes deste mês a definição das duplas de trabalho era feita de maneira essencialmente aleatória.

Embora tenha havido uma maior repetição das duplas ditas otimizadas a partir de abril de 2019, vale esclarecer que não foi possível garantir que todas as trocas neste período fossem realizadas exclusivamente por estas duplas, porém quando comparado com o período antes de abril, o percentual de trocas feitas pelas duplas consideradas otimizadas foi bem maior, conforme pode ser visto na Tabela 9.

Tabela 9 – Histórico da taxa de trocas de rodeiros feitas por duplas otimizadas

	jul/18	ago/18	set/18	out/18	nov/18	dez/18	jan/19	fev/19	mar/19	abr/19	mai/19	jun/19
Rodeiros Trocados	453	857	498	437	385	665	500	690	504	800	733	706
Rodeiros trocados por duplas não otimizadas	431	817	493	429	371	633	462	676	465	224	187	268
Rodeiros trocados por duplas otimizadas	22	40	5	8	14	32	38	14	39	576	546	438
% de trocas feitas por duplas otimizadas	5%	5%	1%	2%	4%	5%	8%	2%	8%	72%	74%	62%

A partir da Tabela 9 vê-se que nos três meses antes dos testes de campo, em média

apenas 6% das trocas de rodeiros do mês eram feitas pelas duplas ditas otimizadas, enquanto que a partir de abril de 2019, após rodar o algoritmo de otimização, readequar as escalas de trabalho e divulgar para a equipe as duplas otimizadas que deveriam ser seguidas, atingiu-se no período de avaliação em campo uma média de 69% das trocas feitas pelo grupo de controle sendo executadas pelas duplas otimizadas.

Através desta avaliação, pode-se fazer a conexão entre o percentual de trocas feitas pelas duplas otimizadas e o tempo médio de troca de rodeiros do grupo de controle. Para o primeiro trimestre de 2019 tivemos 16,1 minutos como tempo médio de troca de rodeiros expurgando o efeito de falta de rodeiros, sendo que neste mesmo período apenas 6% das trocas amostradas pertenciam a duplas ditas otimizadas, enquanto que na fase de teste de campo, decorrida no segundo trimestre de 2019, obteve-se 13,3 minutos de tempo médio de troca expurgando impactos de falta de rodeiro e 69% das trocas feitas com duplas otimizadas neste mesmo período, ou seja, um aumento 63 pontos percentuais na taxa de trocas feitas por duplas otimizadas acarretou em uma redução de 17,4% no tempo médio de troca de rodeiro.

A fim de avaliar mês a mês os tempos médios de troca de rodeiros, analisando neste caso separadamente as trocas feitas pelas duplas apontadas pelo AG com aquelas ditas não otimizadas cuja formação deu-se de maneira aleatória, obteve-se os dados da Tabela 10.

Tabela 10 – Histórico dos tempos médios de troca de rodeiros feitas por duplas otimizadas e não otimizadas

	jul/18	ago/18	set/18	out/18	nov/18	dez/18	jan/19	fev/19	mar/19	abr/19	mai/19	jun/19
Total de trocas de rodeiros feitas pelo grupo de controle	453	857	498	437	385	665	500	690	504	800	733	706
Trocas feitas pelas duplas NÃO otimizadas do grupo de controle	431	817	493	429	371	633	462	676	465	224	187	268
Trocas feitas pelas duplas otimizadas do grupo de controle	22	40	5	8	14	32	38	14	39	576	546	438
Tempo médio das duplas NÃO otimizadas expurgando impacto por rodeiro (min)	14,9	14,1	15,0	14,4	15,4	16,8	17,0	16,9	14,8	14,8	13,1	12,7
Tempo médio das duplas otimizadas expurgando impacto por rodeiro (min)	10,7	11,6	11,6	12,5	19,3	12,2	13,7	17,9	14,2	14,4	13,1	12,3

Expurgando as perdas associadas à espera por rodeiro, observa-se na Tabela 10 que no período de 12 meses em questão em apenas 2 deles o tempo médio das duplas otimizadas foi pior que o tempo médio das duplas formadas aleatoriamente (tempos destacados em vermelho), o que representa uma taxa de assertividade com relação à maior eficiência das duplas propostas pelo AG de 83% dos meses nesta janela de observação.

De forma a dar mais representatividade à amostra, continuando ainda na Tabela 10, caso fosse considerado apenas os meses em que as duplas otimizadas fizeram pelo menos 20 trocas no mês, dos 12 meses sobrariam 8, nos quais em todos eles o tempo médio de troca de rodeiro das duplas otimizadas se mostraram melhores que quando comparado com o tempo médio das duplas não otimizadas, o que reforça a qualidade da indicação das cinco duplas apontadas pelo algoritmo genético.

Considerando o primeiro e segundo trimestre de 2019, houve uma redução de 17,7 para 16,3 minutos no tempo médio de troca de rodeiros, ou seja, a troca de rodeiro se mostrou 1,4 minutos mais rápida após a implantação da otimização, mesmo considerando os impactos por falta de rodeiro. Este valor apesar de aparentar ser pequeno, somando-se à grande quantidade de trocas de rodeiros feitas e o alto custo em deixar um vagão parado, estima-se um elevado potencial de ganho financeiro.

Na oficina em questão para trocar um rodeiro é necessário parar um lote completo de 110 vagões e não apenas o vagão com o rodeiro defeituoso a ser trocado, sendo assim, estimando-se que a cada 1 hora de um lote de 110 vagões parado a companhia deixa de ganhar aproximadamente R\$ 13.000,00 e sabendo-se que no segundo trimestre de 2019 foram 2.239 trocas de rodeiros feitas pelo grupo de controle, a um tempo médio 1,4 minuto inferior ao primeiro trimestre do mesmo ano, isto significa que houve uma redução de 52,2 h na indisponibilidade de lotes de 110 vagões, o que representou para a empresa deixar de perder R\$ 679.163,33 com vagões parados em manutenção entre abril e junho de 2019.

A partir de julho de 2019 não foi mais possível coletar novos dados de desempenho do grupo de controle uma vez que a partir desta data houve uma mudança de turno de trabalho por parte da empresa, o que causou uma total redistribuição das equipes de trabalho e perdeu-se as referências de duplas otimizadas, porém de acordo os 3 meses de testes práticos da otimização da distribuição das duplas de trabalho via algoritmo genético, foi perceptível a melhoria na performance média do grupo de controle.

6 CONCLUSÃO

Ao término do trabalho foi apresentada uma aplicação prática de otimização, onde a partir de dados históricos de desempenho de uma equipe de manutenção, aliado ao uso da metaheurística algoritmo genético, foi possível chegar a uma solução otimizada para distribuição de equipes de trabalho, de forma que o rendimento médio da equipe como um todo fosse maximizado.

Após 50 simulações do AG com 1% de taxa de mutação, população de 20 indivíduos e critério de parada de 100 gerações, foi obtido um tempo médio otimizado de 11,1 minutos, que se mostrou 19% melhor que quando comparado com o tempo médio a partir de 50 simulações de otimização aleatória.

Ao observar a consistência do AG, percebemos que após 50 simulações os tempos médios otimizados produzidos pelo AG apresentaram média de 11,1 minutos e desvio-padrão de 0,14 minuto, o que demonstra melhoria quando comparado com a média de 14,2 minutos e desvio-padrão de 1,29 minuto produzidos a partir da geração aleatória de 50 agrupamentos de 8 duplas de trabalho cada, desta forma o tempo médio de troca de rodeiros da solução proposta pelo AG se mostrou 22% melhor que quando comparado com a escolha aleatória das equipes.

Com efeito, verificou-se que a modelagem do problema, a codificação do AG e seus parâmetros de população, taxa de mutação e critério de parada se mostraram robustos o suficiente para entregar uma solução otimizada dentro de um tempo computacional aceitável para a complexidade do problema abordado, cujo número de possíveis soluções superava 81 bilhões de alternativas.

Na etapa de teste de campo, viu-se que comparando o tempo médio de troca de rodeiros no trimestre depois da implementação da otimização com o trimestre antes da fase de teste de campo, foi percebida uma redução de 7,9%, diminuindo este tempo de 17,7 para 16,3 minutos, o que representa um ganho financeiro estimado de R\$ 679.163,33.

Na avaliação individual mês a mês dentro do trimestre em que foi implantada a otimização, observou-se que no segundo mês (maio/19) ocorreu uma elevação acentuada no tempo médio de troca de rodeiros, sendo este pico explicado pelo impacto da falta de rodeiros novos no pátio de rodeiros.

A fim de comparar a performance coletiva da equipe antes e depois da otimização proposta, desconsiderando impactos causados por aspectos fora da alçada direta dos mecânicos, foram recalculados os tempos médios de troca de rodeiros expurgando os impactos de trocas que demoraram mais do que o previsto pela demora no aguardo do rodeiro novo para ser

instalado no vagão, neste caso, de maneira mais acentuada, foi observado ainda o ganho atingido com a otimização, sendo que após três meses trabalhando com as equipes de maneira otimizada chegou-se a um tempo médio de troca de rodeiro de 12,4 minutos, que representa 15,6% de redução com relação ao tempo de 14,7 minutos que se praticava no mês imediatamente anterior à implementação otimização.

A redução do tempo médio de troca de rodeiro no período entre abril e junho de 2019 pôde ser associada à implementação da melhoria proposta pelo algoritmo genético, uma vez que foi visto que no trimestre de avaliação da otimização, em média 69% das trocas foram realizadas pelas cinco duplas sugeridas pelo AG, índice este que no trimestre anterior à melhoria era de apenas 6%.

A partir da avaliação do tempo médio de troca de rodeiros expurgando eventuais impactos por falta de rodeiros novos, vendo um trimestre antes e um depois da implementação da otimização, constatou-se que um incremento de 63 pontos percentuais na proporção de trocas de rodeiros feitas pelas duplas otimizadas causou uma redução de 17,4% no tempo médio de troca de rodeiros no trimestre, sendo este reduzido de 16,1 para 13,3 minutos.

Avaliando também o tempo médio de troca de rodeiros expurgando-se o efeito de impactos por falta de rodeiros, observamos que em uma janela de 12 meses, em 10 deles o tempo médio das trocas feitas por duplas ditas otimizadas foi menor que o tempo médio das trocas feitas por duplas não otimizadas, o que representa uma taxa de assertividade de 83% para a indicação feita pelo algoritmo genético.

Como recomendação de novos trabalhos, sugere-se a implementação do algoritmo genético utilizado neste problema através de outras linguagens de programação mais robustas e com bibliotecas estruturadas para aplicação da metaheurística de algoritmo genético, a exemplo da linguagem Python e Java, sendo que com estas linguagens há uma expectativa de simplificar o código que foi escrito em VBA neste trabalho.

Apesar dos testes de campo terem sido feitos para uma inspeção de 10 pessoas em um único turno de funcionamento da oficina em questão, uma vez que os dados de manutenção são registrados em sistema informatizado por todas as equipes em todos os horários, vislumbra-se uma grande oportunidade de um futuro trabalho o desenvolvimento de um software capaz de interpretar os dados de campo a medida que eles são inseridos no sistema informatizado e a partir destas informações, utilizando a mesma lógica de programação desenvolvida neste trabalho, seja possível indicar uma combinação otimizada de equipes de trabalho para a condição atual da oficina, expandindo assim o ganho constatado neste experimento para todos os turnos e todos os processos da oficina onde este trabalho foi desenvolvido.

REFERÊNCIAS

- ABREU, A., CALADO, J. M. F. & Pêgo, E. **Preventive maintenance planning using genetic algorithms**. 2015.
- ATALA, A. V. **Programação de Horários Usando um Algoritmo Genético**. Ilha Solteira: UNESP, 2014.
- BALIEIRO, A. M. et al., **Uma Abordagem Baseada em Algoritmo Genético para Formação de Grupos de Estudos em Ambientes Virtuais de Aprendizagem**. 2017
- BRITTO, P. C.; LOPES, E. d. S.; DRINKO, C. H. F. & GONÇALVES, S. B. **Fatores Humanos e Condições de Trabalho em Atividades de Implantação e Manutenção Florestal**. Revista Floresta e Ambiente. 2015.
- CAMPOS, E. d. S. **Algoritmo Genético Aplicado ao Planejamento de Redes de Telecomunicações**. Goiânia: PUC-GO, 2017.
- CARDOZO, C. G. & SILVA, L. O. **A importância do relacionamento interpessoal no ambiente de trabalho**. Revista Interbio, 2014. 24-33 p.
- CARRARO, L. F.; CHIWIACOWSKY, L. D.; GÓMEZ, A. T. & OLIVEIRA, A. C. M. d. **Uma aplicação das metaheurísticas algoritmo genético e colônia artificial de abelhas através da codificação de regras para resolver o problema de carregamento de navios-contêineres**. Natal, 2013.
- CARVALHO, J. F. d.; MARTINS, É. P. T.; LAURENY, L. & PAPANDRÉA, P. J. **Qualidade de Vida no Trabalho e Fatores Motivacionais dos Colaboradores nas Organizações**. Revista Educação em Foco, 2013. 21-31 p.
- COLHERINHAS, G. B. **Ferramenta de Otimização Via Algoritmos Genético com Aplicações em Engenharia**. Brasília: Universidade de Brasília, 2016.
- COSTA, E. M. **Análise Estrutural de um Vagão Graneleiro em Compósitos**. Joinville, 2018.
- COSTA, R. R. L. **Algoritmo Genético Aplicado à Formulação de Ração para Frangos de Corte**. Pirassununga: USP, 2017.
- CRISTO, R. L. **Balanceamento de Linhas de Montagem com Uso de Algoritmo Genético para o Caso de Linhas Simples e Extensões**. UFSC, 2010.
- DOS SANTOS, F. G. **Estudo para Implantação de Eixos de Bitolas Variáveis no Material Rodante Ferroviário Brasileiro**. Brasília. 2011.
- G. M.; Greenbrier Maxion. **An Amsted Rail Global Partner**. Disponível em: www.gbmx.com.br/negocios/vagao-gondola-gdu/. Acesso em: 20 mai. 2019.
- GROSS, L.; PAULUS, G.; CHINCON, P. M. M. & ANTONIAZZI, R. L. **Algoritmo Genético Aplicado ao Sequenciamento de Produção**. Revista Interdisciplinar de Ensino,

Pesquisa e Extensão, Vol. 4, 2016.

HAUPT, R. L. & HAUPT, S. E. **Practical Genetic Algorithms**. 2ª ed. s.l.:Wiley Interscience, 2004.

LINDEN, R. **Algoritmos Genéticos**. Brasport, 2018.

LOPES, A. M. **Computação Evolucionária Aplicada ao Problema de Geração de Escala de Enfermeiros**. João Monlevade: UFOP, 2018.

LYRA, L. G. **Algoritmo Genético Aplicado ao Controle do Mosquito Transmissor da Dengue**. Botucatu: UNESP, 2014.

MARTINS, L. d. C. & SILVA, G. P. **Aplicação de um algoritmo genético ao problema de rodízio de tripulações do sistema de transporte público urbano**. 2017.

MOTTA, A. R. V. **Otimização de Rotas de Helicópteros Offshore Utilizando Algoritmo Genético**. Maceió: UFAL, 2013.

NASCIMENTO, T. P. D. **Um Serviço Baseado em Algoritmos Genéticos para Predição da Bolsa de Valores**. São Luís: UFMA, 2015.

NETO, C. B. **Manual Didático de Ferrovias**. 2012.

OLIVEIRA, J. C. **Obtenção do Modelo Matemático e Mapa de Calor do Consumo de Combustível de um Caminhão na Mineração a Céu Aberto Utilizando Algoritmo Genético e Regressão Linear Múltipla**. Uberlândia: Universidade Federal de Uberlândia, 2019.

REIS, L. R. D. **Determinação de Parâmetros de Módulos Fotovoltaicos Utilizando o Método de Newton Raphson e Algoritmos Genéticos**. Uberlândia: Universidade Federal de Uberlândia, 2018.

RODRIGUES, F. L. *et al.* **Metaheurística algoritmo genético para solução do problema de planejamento florestal com restrições de integridade**. Revista *Árvore*, 2004, 233-245 p.

SAMPAIO, G. S. **Otimização da exploração de centrais hídricas utilizando algoritmos genéticos, em ambiente de mercado**. Porto: Faculdade de Engenharia da Universidade do Porto, 2012.

SIEMENTKOWSKI, N. F. **Análise de Modos de Falha em Sistemas de Freio de Vagão de Carga com Aplicação de FMEA**. Joinville, 2016.

SILVA, E. E. **Otimização de Estruturas de Concreto Utilizando Algoritmos Genéticos**. São Paulo, 2001.

VÉLEZ, D. I. A. **Otimização de Estruturas Reticuladas Utilizando Algoritmos Genéticos**. Brasília: Universidade de Brasília, 2015

APÊNDICES

APÊNDICE A – RESULTADOS DAS SIMULAÇÕES

1º SIMULAÇÃO: GERAÇÕES = 100, TAXA DE MUTAÇÃO = 5%, POPULAÇÃO = 10

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
1	11,4	545	PO-FB-IG-AE-HN-CL-KM-DJ
2	11,5	552	BE-MH-DI-GJ-PF-AK-NO-LC
3	11,0	562	FN-OP-BD-CL-MK-AE-JH-GI
4	11,3	649	MA-LC-DB-NF-KH-OP-EG-IJ
5	11,3	751	DI-PO-CH-GN-KL-AM-JF-EB
6	11,2	751	BD-PO-EA-KJ-GH-NF-IM-CL
7	11,0	747	NF-IJ-EB-MK-HG-CL-OP-DA
8	11,4	750	DB-PI-KH-NO-CL-JG-EF-AM
9	11,0	751	AD-FJ-MK-NH-BE-GI-PO-LC
10	11,0	752	KM-GH-PO-AE-IJ-LC-BD-FN
11	11,0	749	HJ-IG-LC-KM-AE-FN-OP-DB
12	11,0	748	EB-ID-HG-NF-KM-LC-PO-JA
13	11,3	665	DA-LG-NH-PO-MK-BC-EF-IJ
14	11,2	614	FI-EB-LC-JG-NH-OP-KM-AD
15	11,2	750	EA-GJ-PN-ID-FB-CL-KM-HO
16	11,1	749	NF-HK-PO-ID-EB-GJ-LC-MA
17	11,2	751	DB-FN-MI-AE-JK-LC-GH-OP
18	11,1	751	BE-OP-LG-FN-CH-MK-ID-AJ
19	11,3	646	ON-JA-ID-FP-LC-MK-HG-BE
20	11,2	629	BF-AM-JG-NE-OP-KH-LC-DI
21	11,3	749	LD-CH-GJ-AE-FB-KM-OI-PN
22	11,1	671	NF-CL-EA-BD-GJ-HK-MI-PO
23	11,0	532	EA-MK-GJ-BF-OP-NH-CL-DI
24	11,2	611	HJ-PN-AE-FO-GI-MK-CL-BD
25	11,5	747	AE-GI-HK-MO-NP-DB-LC-JF
26	11,3	741	DB-CH-OF-EA-PN-GL-IJ-MK
27	11,5	746	GI-NP-OM-AD-LC-HK-BE-JF
28	11,2	745	GD-CL-NH-AE-BF-IJ-PO-MK
29	11,0	745	NF-IJ-MK-HG-OP-BD-CL-AE
30	11,5	746	AJ-NO-LC-EP-ID-HG-MK-BF
31	11,5	744	OF-JH-PN-MK-EA-GL-CB-ID
32	11,3	746	DL-IO-HC-NP-GJ-MK-AE-BF
33	11,2	745	MK-JH-DA-IG-FO-BE-NP-CL
34	11,0	744	CL-NF-OP-AE-KM-DB-JI-GH
35	11,2	745	EB-KA-JG-DI-PO-HM-LC-NF
36	11,3	745	KM-GH-NO-CL-EB-DI-FP-AJ
37	11,5	746	CL-FJ-BD-MA-PN-GI-EO-HK
38	11,0	743	CL-DI-JA-KM-GH-EB-FN-PO
39	11,0	745	DB-HG-AE-CL-IJ-OP-FN-MK

Continua

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
40	11,4	746	GL-NE-PO-KC-ID-JA-FB-MH
41	11,1	743	GJ-PO-EA-FN-BD-IM-CL-HK
42	11,3	750	NE-DA-PO-MH-IG-KJ-CL-BF
43	11,3	746	PN-MI-BD-AE-FO-GJ-KH-CL
44	11,6	746	EB-ON-KM-IP-JF-GA-LC-HD
45	11,5	745	HG-ID-KJ-NO-LC-AM-BE-PF
46	11,8	744	BD-NF-EA-MO-IJ-HK-LG-PC
47	11,2	747	AE-ID-BF-CH-OP-LJ-GN-KM
48	11,1	747	JG-LC-KH-OP-BD-AE-NF-MI
49	11,4	746	OP-EA-MK-CH-DN-GL-JI-FB
50	11,3	743	OP-NF-CK-IM-AE-GJ-LH-DB

	TEMPO DE TROCA (min)	TEMPO DE SIMULAÇÃO (s)
MÉDIA	11,2	716,0
DESVIO PADRÃO	0,19	62,90

2º SIMULAÇÃO: GERAÇÕES = 100, TAXA DE MUTAÇÃO = 2,5%, POPULAÇÃO = 10

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
1	11,7	778	NP-HJ-BK-CL-OI-GD-MA-EF
2	11,0	706	LG-MK-CH-JI-DB-NF-OP-EA
3	11,5	768	DA-EN-CL-HG-MJ-PO-FI-BK
4	11,3	618	FN-PO-IM-CK-BD-JG-LH-AE
5	11,4	720	CL-DE-MK-NP-IG-FB-OH-JA
6	11,1	783	MK-PO-NH-BD-AJ-LC-EF-GI
7	11,4	776	KM-CL-NP-HO-ED-JA-FB-IG
8	11,4	777	MG-BK-CL-AE-DI-OP-HJ-FN
9	11,0	782	JG-EA-KM-HN-OP-DI-LC-BF
10	11,3	779	NH-MA-DE-CL-GI-KJ-OP-BF
11	11,3	775	AE-MK-BF-NH-JI-OP-LG-DC
12	11,3	778	KC-MJ-LG-AE-OP-HN-BF-DI
13	11,4	783	FJ-MK-BH-LC-AE-NG-DI-PO
14	11,3	783	IO-EA-KM-HC-NP-FJ-LG-DB
15	11,7	780	JA-GI-KM-BP-DL-ON-HC-FE
16	11,4	775	KB-JF-GI-PO-DE-NH-LC-MA
17	11,3	782	BC-NH-GL-EA-PO-ID-FJ-KM
18	11,2	777	PO-CL-JH-IF-DB-EA-NG-MK
19	11,5	776	BF-AE-IO-PN-CK-JG-MH-DL

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
20	11,2	779	HC-BE-AD-NF-GJ-MI-KL-OP
21	11,4	781	HN-AM-BD-CK-FE-IJ-GL-OP
22	11,0	777	BD-PO-NF-KM-JH-LC-AE-IG
23	11,0	777	NH-LC-AE-KM-JF-IG-DB-PO
24	11,1	782	NE-JH-LC-OP-BF-DA-KM-IG
25	11,5	775	CP-AE-JF-BD-HL-MK-ON-IG
26	11,2	778	DA-OP-IJ-GF-CL-BE-HN-MK
27	11,2	775	MK-EA-ID-LC-JG-FB-NP-OH
28	11,0	780	MK-BE-CL-JA-HG-NF-OP-DI
29	11,1	774	FN-JK-IG-EA-BD-MH-CL-PO
30	11,2	776	KM-HD-EA-IJ-LC-BF-OP-GN
31	11,6	777	EA-FB-GI-CH-OK-JM-LD-PN
32	11,0	777	EA-NF-OP-LC-DB-GI-HJ-MK
33	11,1	775	EA-HK-OP-DB-CL-NF-IM-JG
34	11,4	776	DL-BE-GI-KM-JA-PF-ON-CH
35	11,1	777	EA-GJ-FN-PO-DB-CL-IM-HK
36	11,3	780	BD-FE-GI-PN-MK-HO-JA-CL
37	11,4	774	EF-OP-GI-JM-DB-AK-LC-HN
38	11,4	775	IJ-DB-EF-GH-CL-KM-OP-NA
39	11,4	774	OP-MK-DI-BC-FE-JG-NH-LA
40	11,0	780	HJ-LC-PO-DB-AE-MK-GI-NF
41	11,3	775	HL-DC-BE-JA-FN-PO-MK-GI
42	11,1	777	LC-BD-MI-FN-PO-EA-HK-JG
43	11,5	782	JL-HD-AE-GI-NF-PO-KM-BC
44	11,3	778	PO-GI-MH-DL-JA-EB-KC-FN
45	11,0	777	KM-HJ-GI-AE-LC-OP-DB-NF
46	11,3	694	BD-OP-AM-LK-EN-CH-JF-IG
47	11,5	602	NO-CL-GJ-EA-PI-KH-DB-FM
48	11,3	705	DB-MI-EA-JG-PO-HL-FN-CK
49	11,7	761	KA-PN-OI-BE-JF-MH-DG-CL
50	11,3	616	CB-EA-IG-JF-HN-MK-LD-OP

	TEMPO DE TROCA (min)	TEMPO DE SIMULAÇÃO (s)
MÉDIA	11,3	761,6
DESVIO PADRÃO	0,20	43,14

3º SIMULAÇÃO: GERAÇÕES = 100, TAXA DE MUTAÇÃO = 1%, POPULAÇÃO = 10

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
1	11,2	614	KM-JI-BD-NP-HG-CL-OF-EA
2	11,2	585	AM-JK-ID-HG-NF-BE-OP-CL
3	11,3	571	EA-JF-LG-IO-CH-KM-NP-BD
4	11,4	581	HG-IM-CL-BK-EN-PO-DA-JF
5	11,0	665	KM-GI-BD-HJ-OP-AE-CL-NF
6	11,5	618	CL-GF-PN-JA-EB-DI-HO-MK
7	11,4	532	KL-JI-DB-OP-HC-GE-NF-AM
8	11,1	482	JG-PO-KH-IM-NF-DB-AE-CL
9	11,0	500	FN-KM-PO-EB-AD-HJ-CL-GI
10	11,0	668	CL-NH-BD-AE-KM-PO-IG-JF
11	11,7	663	HG-FO-AL-BE-CD-PN-KM-JI
12	11,2	665	AE-BD-LC-FO-HJ-KM-IG-NP
13	11,0	662	MK-JI-FN-DB-CH-EA-PO-LG
14	11,8	669	KM-BF-AD-JH-IO-EN-CP-GL
15	11,1	663	NF-EB-GJ-ID-AM-CH-OP-KL
16	11,3	664	LC-IG-JA-HM-NF-KB-PO-DE
17	11,3	663	OP-NF-GJ-AE-CH-IM-DL-BK
18	11,4	659	GJ-CH-AE-OF-BD-MI-KL-PN
19	11,3	661	GI-FL-CH-JA-BD-OP-EN-MK
20	11,7	664	HL-NO-BC-IP-DG-KM-AE-JF
21	11,2	660	HC-MK-JA-LG-NE-DI-BF-PO
22	11,1	664	OP-JA-EB-GL-HC-ID-KM-FN
23	11,2	662	HK-BF-PO-IM-JG-EN-CL-DA
24	11,0	662	FN-JH-OP-MK-BE-CL-IG-DA
25	11,0	661	HJ-NF-EA-IG-DB-CL-PO-MK
26	11,0	661	KM-EA-PO-DB-LC-IG-JH-FN
27	11,8	662	FN-HM-KB-LC-EP-DA-GJ-IO
28	11,3	662	LG-HM-NF-EB-CK-OP-ID-AJ
29	11,3	661	LF-PO-EB-AJ-NG-ID-MK-CH
30	11,2	662	GI-DL-EB-PO-JK-HC-NF-MA
31	11,3	661	NP-IM-OF-KH-CL-BD-GJ-AE
32	11,1	662	FN-DI-EB-OP-LC-KH-JG-AM
33	11,3	661	HM-DA-CL-KB-JF-IG-NE-PO
34	11,5	665	EA-MK-FB-ON-DI-CP-HJ-GL
35	11,6	662	AE-CD-FB-KM-HJ-ON-GL-PI
36	11,7	601	MA-LJ-HO-FE-NP-KC-IG-DB
37	11,6	634	AE-PN-JK-HM-FB-OC-IG-DL
38	11,0	852	NF-GI-MK-LC-PO-HJ-DB-EA
39	11,4	772	FI-BD-AJ-CH-KM-OP-GL-NE
40	11,5	777	CL-PO-KF-DB-EA-JI-MH-NG
41	11,4	776	GI-CL-BF-PN-MK-ED-HO-AJ
42	11,3	798	JI-DB-HK-LC-PO-EF-MA-GN

Continua

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
43	11,0	787	MK-ID-NF-BE-OP-JA-GH-CL
44	11,9	779	LA-HJ-IM-NO-CK-DG-EB-FP
45	11,4	756	NF-OP-DG-BM-LC-EA-IJ-HK
46	11,5	753	JM-DC-IG-KH-PO-LA-NF-EB
47	11,4	753	OP-JI-AM-NG-DE-BF-LC-KH
48	11,3	759	MK-LC-JF-BD-NP-GH-EA-OI
49	11,1	755	KL-NF-PO-ID-BE-JG-HC-AM
50	11,0	752	HJ-OP-AE-MK-DB-IG-FN-LC

	TEMPO DE TROCA (min)	TEMPO DE SIMULAÇÃO (s)
MÉDIA	11,3	673,7
DESVIO PADRÃO	0,24	74,59

4° SIMULAÇÃO: GERAÇÕES = 100, TAXA DE MUTAÇÃO = 5%, POPULAÇÃO = 20

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
1	11,0	570	OP-MK-FJ-AE-LC-DB-NH-IG
2	11,1	660	HC-ID-FN-GL-AJ-EB-MK-PO
3	11,0	762	CL-EB-NF-OP-HG-JA-DI-MK
4	11,0	764	BD-KM-CH-LG-EA-IJ-FN-PO
5	11,2	758	MK-CL-NP-DI-AE-JG-BF-OH
6	11,1	759	LC-BE-AM-FN-GJ-DI-OP-KH
7	11,3	759	NP-LC-HG-MK-DB-OI-AE-JF
8	11,1	756	PO-FN-JG-MI-EB-LC-DA-KH
9	11,1	756	DB-EA-OP-NF-CL-GJ-IM-HK
10	11,0	754	NF-OP-MK-AE-DB-CL-GH-IJ
11	11,0	759	OP-DB-JF-NH-MK-CL-GI-AE
12	11,0	760	FN-MK-GH-CL-JA-BE-DI-PO
13	11,3	755	CH-AM-LK-PO-NE-FB-GJ-DI
14	11,1	755	AM-EB-DI-LC-KH-JG-NF-OP
15	11,0	756	GH-ID-CL-EB-OP-NF-AJ-KM
16	11,0	757	BE-KM-CL-JH-PO-AD-NF-GI
17	11,3	758	ID-AM-EB-FN-JG-HL-OP-CK
18	11,0	755	JA-BE-DI-CL-NF-HG-PO-KM
19	11,2	755	JG-OP-EB-DA-FI-NH-MK-LC
20	11,3	755	MK-HI-NF-PO-JG-LC-AE-DB
21	11,1	759	CL-GI-JK-BD-EA-MH-NF-PO
22	11,1	754	NF-GI-AJ-BE-OP-HC-DL-MK

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
23	11,2	756	EA-FN-DI-HK-MB-JG-LC-PO
24	11,0	755	FB-DI-AE-PO-HN-GJ-KM-CL
25	11,0	755	DA-MK-HJ-EB-OP-IG-NF-CL
26	11,2	758	LG-OP-BE-DI-KJ-FN-HC-AM
27	11,1	755	FN-MH-DB-EA-KJ-PO-CL-GI
28	11,2	756	CH-NF-JM-LK-EB-DA-IG-OP
29	11,3	755	GI-AJ-HM-EB-LD-PO-CK-NF
30	11,2	762	NF-CH-PO-GJ-IL-DB-AE-KM
31	11,1	753	FN-KL-DB-CH-PO-MI-AE-GJ
32	11,2	755	AG-JF-HN-BE-MK-LC-OP-DI
33	11,0	756	HJ-FN-OP-IG-CL-DB-EA-KM
34	11,1	758	KH-JG-PO-AM-FN-BE-LC-DI
35	11,1	756	JG-DB-HC-LK-OP-AE-NF-MI
36	11,0	755	CL-BD-JH-MK-EA-FN-OP-GI
37	11,1	758	ID-CL-HK-PO-JG-AM-BE-FN
38	11,0	755	EA-DB-PO-KM-LC-FN-JI-GH
39	11,2	759	KM-BF-DE-NH-LC-IG-AJ-PO
40	11,1	755	BE-LC-DI-HJ-PO-AG-MK-FN
41	11,1	768	DB-PO-IG-EA-NF-HC-JL-KM
42	11,1	758	DI-JA-HC-OP-BE-MK-LG-FN
43	11,2	759	NP-BD-KM-HO-IG-CL-FJ-AE
44	11,1	671	NF-OP-JG-BE-KH-CL-DI-MA
45	11,0	590	EA-MK-HN-PO-DB-CL-IG-FJ
46	11,4	701	BK-PO-EF-ID-NG-HM-AJ-CL
47	11,1	803	KM-DL-FN-HC-BE-OP-AJ-GI
48	11,3	798	FN-JI-KH-LC-OP-AM-DG-BE
49	11,2	794	JG-NF-PO-HC-IM-DA-BE-KL
50	11,0	792	IJ-PO-MK-BD-FN-LC-HG-EA

	TEMPO DE TROCA (min)	TEMPO DE SIMULAÇÃO (s)
MÉDIA	11,1	748,5
DESVIO PADRÃO	0,10	41,82

5° SIMULAÇÃO: GERAÇÕES = 100, TAXA DE MUTAÇÃO = 2,5%, POPULAÇÃO = 20

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
1	11,3	576	EA-IG-KB-OP-CH-JM-NF-DL
2	11,0	701	FN-MK-JH-DA-CL-PO-BE-IG
3	11,0	811	MK-GJ-CL-NH-EA-ID-PO-FB
4	11,1	806	JA-LG-CH-NF-PO-ID-EB-KM
5	11,2	811	DI-PO-JG-AM-LC-BF-HK-NE
6	11,0	801	IJ-LC-NF-PO-DB-GH-MK-EA
7	11,1	801	KM-HC-EB-DI-AJ-PO-LG-NF
8	11,1	803	JK-MH-CL-IG-FN-PO-EB-DA
9	11,0	805	BD-IG-KM-PO-FN-EA-HJ-CL
10	11,4	801	MI-LC-AE-GJ-BD-ON-KH-FP
11	11,0	801	MK-BE-PO-NF-ID-AJ-CL-GH
12	11,3	805	DI-MK-JA-OF-NP-HG-CL-EB
13	11,3	799	LC-EF-IM-NH-PO-AD-KB-JG
14	11,2	798	FI-KM-DA-EB-LC-GJ-HN-PO
15	11,3	893	NH-EF-OP-KB-DI-CL-AM-JG
16	11,0	698	IG-BE-FN-PO-KM-AD-CL-HJ
17	11,1	584	IJ-MK-GH-AD-NE-OP-FB-CL
18	11,2	682	LC-PO-KH-NE-DA-GJ-IM-BF
19	11,0	788	OP-FN-GH-MK-LC-BE-DI-JA
20	11,2	789	OP-AM-GI-LC-KH-NE-DB-FJ
21	11,0	786	FN-OP-IG-LC-DB-MK-JH-AE
22	11,1	783	EB-KL-JG-NF-PO-CH-MA-DI
23	11,0	781	EB-LC-FN-IG-HJ-DA-MK-OP
24	11,1	788	OP-FN-AG-JH-BE-DI-KM-LC
25	11,1	782	GL-NF-BE-OP-CH-KM-DI-AJ
26	11,0	811	PO-IJ-GL-MK-DB-FN-CH-EA
27	11,3	873	NP-BD-JF-IO-EA-KM-CL-GH
28	11,0	869	FN-OP-AE-KM-HJ-BD-LC-IG
29	11,0	877	MK-EA-JH-GI-FN-OP-DB-LC
30	11,0	872	EA-MK-DB-JH-LC-NF-PO-GI
31	11,1	875	PO-DI-MK-JH-BE-GA-NF-LC
32	11,3	879	HG-CL-BE-FJ-ON-AD-MK-PI
33	11,1	878	OP-CL-HK-GJ-NF-DI-EB-MA
34	11,1	881	EB-MI-CL-PO-GJ-FN-AD-KH
35	11,2	881	ID-HK-LC-BF-GJ-PO-NE-AM
36	11,3	786	EA-KM-BD-HC-JF-GL-PN-IO
37	11,1	1042	HM-AD-LC-KJ-EB-NF-IG-OP
38	11,0	1072	AE-NF-DB-LC-OP-IJ-MK-HG
39	11,2	1073	IM-CL-BD-NG-HK-PO-EA-FJ
40	11,1	1064	KB-NF-OP-AE-HM-ID-JG-CL
41	11,1	1048	HK-MA-OP-EB-FN-GJ-DI-LC
42	11,1	1056	EB-AM-GJ-LC-DI-NF-PO-KH

Continua

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
43	11,0	1056	DA-PO-NF-BE-GI-MK-CL-HJ
44	11,2	1043	MJ-FN-GH-EA-CL-ID-PO-BK
45	11,0	1053	AE-BD-PO-JI-FN-MK-LC-HG
46	11,2	1051	BE-ID-GH-LC-KJ-OP-NF-AM
47	11,0	1050	MK-NF-OP-HJ-BD-EA-LC-GI
48	11,0	1059	IJ-FN-DB-HC-KM-AE-GL-PO
49	11,2	1050	DA-OP-EB-MI-JG-FN-LK-CH
50	11,1	1052	IG-FN-HC-MK-LD-JA-OP-EB

	TEMPO DE TROCA (min)	TEMPO DE SIMULAÇÃO (s)
MÉDIA	11,1	870,5
DESVIO PADRÃO	0,12	132,28

6° SIMULAÇÃO: GERAÇÕES = 100, TAXA DE MUTAÇÃO = 1%, POPULAÇÃO = 20

SIMULAÇÃO	TEMPO MÉDIO (min)	TEMPO SIMULAÇÃO (s)	SOLUÇÃO PROPOSTA
1	11,0	706	NH-MK-AD-IG-LC-PO-JF-BE
2	11,0	886	GJ-AE-MK-BF-PO-HN-ID-LC
3	11,2	944	LG-BF-KM-CH-PO-DI-AJ-NE
4	11,4	941	EA-BD-OK-HM-GI-JF-CL-PN
5	11,2	932	NF-AE-MB-LC-PO-HK-JG-DI
6	11,0	934	KM-NF-OP-CL-JH-DA-IG-BE
7	11,0	929	DB-AE-FN-IG-PO-MK-JH-CL
8	11,0	833	JI-DB-MK-AE-NF-OP-CL-HG
9	11,4	581	DI-BE-OF-LK-JG-PN-HC-MA
10	11,0	679	KM-OP-GJ-FB-EA-HN-ID-CL
11	11,2	771	MK-DI-JF-LC-PO-NH-EB-GA
12	11,3	773	CL-NP-MI-OF-AE-BD-GJ-HK
13	11,0	770	MK-AE-OP-GI-JH-FN-DB-LC
14	11,1	763	EA-FN-DI-LC-HM-BK-PO-GJ
15	11,2	766	MK-IL-GJ-HC-AE-DB-OP-FN
16	11,0	771	CL-AD-GI-PO-HN-MK-BE-FJ
17	11,0	766	MK-HN-EA-JF-OP-GI-CL-DB
18	11,1	763	BE-JG-CH-OP-DI-FN-AM-LK
19	11,0	765	OP-JH-NF-MK-DB-CL-AE-IG
20	11,2	766	MK-BD-IJ-FO-NP-LC-HG-AE
21	11,0	765	PO-NF-GI-CL-MK-AD-EB-JH
22	11,0	765	BD-JI-HG-FN-MK-PO-AE-CL

23	11,0	765	MK-LC-NF-IJ-GH-BD-EA-PO
24	11,0	767	ID-GJ-BF-NH-LC-PO-EA-MK
25	11,1	764	HM-PO-DB-EA-NF-JK-GI-CL
26	11,0	766	KM-CL-BD-AE-IG-HJ-FN-PO
27	11,3	762	OP-HN-BF-IM-AE-GJ-LD-CK
28	11,0	767	ID-GH-OP-KM-JA-LC-FN-BE
29	11,0	764	NF-EA-KM-BD-IG-PO-HJ-LC
30	11,0	763	NF-EA-LC-JI-BD-PO-KM-HG
31	11,1	766	CL-NE-KM-BF-JH-OP-IG-DA
32	11,0	768	JG-ID-MK-BF-EA-HN-OP-CL
33	11,2	764	GI-PO-JA-KM-FB-NH-CL-ED
34	11,0	764	GI-DB-EA-NF-KM-HJ-PO-CL
35	11,0	763	EA-JI-PO-CL-NF-BD-MK-HG
36	11,3	768	NE-HM-ID-JG-CL-AK-FB-PO
37	11,2	763	GJ-BE-LK-CH-AD-IM-OP-NF
38	11,3	765	NF-EB-GJ-PO-KM-HI-LC-AD
39	11,2	762	BF-DI-MA-NE-CL-GJ-HK-OP
40	11,1	768	MH-NF-EA-JK-LC-OP-BD-IG
41	11,3	765	BF-CH-JG-KM-AE-PN-DL-IO
42	11,0	764	HG-LC-MK-BE-ID-OP-NF-AJ
43	11,0	764	LC-FN-GI-EB-DA-HJ-PO-MK
44	11,2	766	IG-CL-NP-AD-EB-JH-KM-FO
45	11,3	764	FO-EA-KM-HC-NP-JI-BD-GL
46	11,1	762	CL-PO-AM-BE-FN-KH-GJ-DI
47	11,0	761	HJ-EA-DB-OP-NF-MK-GI-LC
48	11,1	762	NF-MH-LC-BE-OP-JK-DA-GI
49	11,2	764	MK-HJ-OF-DB-CL-EA-IG-PN
50	11,2	676	BE-IF-CL-PO-AD-HN-GJ-KM

	TEMPO DE TROCA (min)	TEMPO DE SIMULAÇÃO (s)
MÉDIA	11,1	777,7
DESVIO PADRÃO	0,14	65,55