

Modelagem do problema de roteamento de veículos usando algoritmos genéticos: o caso da coleta de leite

Rafael Henrique Palma Lima (UTFPR-LD) rafaelhlma@utfpr.edu.br
Anna Flávia Vieira e Almeida (UFTM) annaflavia_almeida@hotmail.com

Resumo:

A coleta de leite é feita em propriedades rurais geograficamente dispersas, o que é geralmente feito por transportadoras terceirizadas. O problema de coleta de leite pode ser visto como uma especialização do Problema de Roteamento de Veículos. Na literatura, diversas abordagens meta-heurísticas são propostas para obter soluções quase ótimas para esta classe de problema. Por isso, este trabalho faz a modelagem do problema de roteamento de uma transportadora de leite utilizando algoritmos genéticos. O algoritmo foi testado em instâncias de tamanhos variando entre 20 e 400 pontos de coleta, sob diversas condições de parâmetros, tais como a quantidade de gerações, tamanho da população e probabilidade de aplicação de operadores genéticos. Ao final do trabalho, foi obtido um algoritmo capaz de apresentar soluções factíveis para o problema, assim como a configuração ideal de seus parâmetros.

Palavras chave: Problema de roteamento de veículos, Algoritmos genéticos, Coleta de leite.

Modeling the vehicle routing problem with genetic algorithms: the case of dairy milk pick-up

Abstract

Milk is usually produced in geographically dispersed rural properties and is collected by third-party carriers. The dairy milk pick-up problem can be viewed as an instance of the general Capacitated Vehicle Routing Problem. The specialized literature discusses several metaheuristic approaches to find near-optimal solutions for this class of problems. Hence, the purpose of this paper is to propose a model for the routing problem of a milk carrier using genetic algorithms. The algorithm was tested in randomly generated instances of size ranging from 20 to 400 points, under a variety of parameters, such as the number of generations, population size and probabilities of genetic operators. As a result, the algorithm was shown to find feasible solutions for the problem. An ideal set of parameters was also determined.

Key-words: Vehicle routing problems, Genetic algorithms, Milk pick-up.

1. Introdução

A produção leiteira no Brasil é caracterizada por pequenos produtores rurais, que criam seu rebanho sem confinamento. As propriedades, portanto, são dispersas e o leite precisa ser coletado a partir de diversos pontos de origem para abastecer a indústria de laticínio. Essa coleta é feita, muitas vezes, por empresas terceirizadas que atuam como transportadoras de leite a granel (NOGUEIRA; LOPES; SOUZA, 2010). Segundo Ribeiro et al. (2003), a granelização consiste no resfriamento do leite imediatamente após sua ordenha. O produto é acondicionado em

tanques de expansão e posteriormente transferido para caminhões isotérmicos, por meio de mangotes flexíveis, com auxílio de uma bomba autoaspirante. Yamaguchi (2002) destaca que sistema de coleta a granel proporcionou redução nos custos de transporte e melhoria da qualidade da matéria-prima, com implicações logísticas importantes. Porém, apesar da busca constante por redução de custos, o sistema convive com problemas de más condições das vias de acesso ao produtor; a não utilização da carga consolidada; bem como o cruzamento de linhas, em que empresas concorrentes, realizam a passagem de dois veículos em um mesmo percurso e ambos com carga incompleta.

Ainda segundo Yamaguchi (2002), as transportadoras enfrentam dificuldades na implementação de procedimentos de otimização de suas linhas de coleta. Uma das razões apontadas pelo autor é a baixa oferta de ferramentas que considerem as restrições comumente encontradas na produção nacional de leite.

O problema de coleta de leite pode ser visto como um Problema de Roteamento de Veículos. Segundo Yeun et al. (2008) tais problemas podem ser definidos como um processo de busca por rotas ótimas de entrega ou coleta partindo de um ou vários depósitos para um conjunto de cidades ou clientes, satisfazendo um conjunto de restrições. Essas restrições podem ser em relação à capacidade limitada dos veículos, tamanho da frota, demanda de clientes, tempo de entrega, entre outras. Entre os métodos meta-heurísticos para resolução de problemas de roteamento, destacam-se os algoritmos genéticos, que utilizam conceitos de evolução biológica para tratar problemas de otimização por meio de algoritmos computacionais (OLIVEIRA et al., 2006).

Nesse contexto, o objetivo do presente trabalho é desenvolver um algoritmo genético que encontre soluções factíveis para o problema de roteamento de veículos de uma transportadora de leite a granel. Para isso, foram utilizados dados e conhecimento obtidos em uma transportadora de leite que atua na região do Triângulo Mineiro. Também é objetivo deste trabalho testar diversas configurações de parâmetros do algoritmo proposto, de forma a melhorar as soluções encontradas.

2. Referencial teórico

2.1 Problemas de roteamento de veículos

O transporte é responsável por uma parcela considerável dos custos incorridos nos processos produtivos de uma empresa, sendo assim, qualquer sucesso da cadeia de suprimentos está intimamente ligado ao uso apropriado de tal atividade (CHOPRA; MEINDL, 2011). A necessidade empresarial de minimizar os custos de transporte despertou o interesse de diversos pesquisadores em busca de soluções para os Problemas de Roteamento de Veículos (VRP, do inglês *Vehicle Routing Problems*) (PIMENTA, 2001). Pacotes de otimização baseados em técnicas de Pesquisa Operacional e Programação Matemática têm sido amplamente utilizados nos últimos anos a fim de obter um gerenciamento e planejamento efetivo nos sistemas de distribuição de bens e serviços. Com a ampla gama de aplicações de tais procedimentos computadorizados, pode-se observar uma economia significativa nos custos globais de transporte, em geral de 5% à 20%. Considerando que o processo de transporte envolve todos os estágios de produção e distribuição de bens, a redução nos custos finais dos bens é relevante, geralmente de 10% à 20% (TOTH; VIGO, 2002).

Os VRPs são problemas de otimização combinatória classificados como *NP-hard*. Nessa classe de problemas, apenas instâncias com tamanho muito pequeno podem ser solucionadas em

tempo computacional viável. Na medida em que o tamanho dos problemas cresce, o conjunto de soluções possíveis aumenta exponencialmente, o que requer um esforço computacional inviável. Apesar disso, devido à relevância estratégica desse problema, diversas ferramentas têm sido estudadas e implementadas a fim de encontrar soluções satisfatórias para os mesmos (HEINEN; OSÓRIO, 2006).

O termo “Problema de Roteamento de Veículos” é um nome genérico que se refere à uma classe de problemas com características e objetivos semelhantes. Em geral, deve-se estabelecer e organizar rotas eficientes para um veículo, ou uma frota de veículos, de capacidades iguais ou distintas, atendendo a uma demanda específica de um conjunto de clientes (LIMA, 2009). Tais problemas dizem respeito ao transporte entre um ou vários depósitos e os clientes finais, objetivando a minimização dos custos incorridos. Porém estes não se restringem a aplicações de coleta e entrega, podendo incluir a busca por soluções de atividades rotineiras, como por exemplo, rotas de ônibus escolares, coleta de resíduos sólidos, limpeza de ruas, transporte de pessoas portadoras de necessidades especiais, entre outras (TOTH; VIGO, 2002).

Neste contexto, os VRP’s levam em consideração restrições operacionais de acordo com a aplicação que se deseja dar ao problema, as quais podem ser relacionadas a frotas heterogêneas, distâncias máximas percorridas, janelas de tempo, coleta e entrega, entre outras.

Segundo Pimenta (2001), na literatura existem diversas pesquisas abordando o tema. As modelagens variam desde as mais simples, com frota homogênea, único produto, e sem janelas de tempo, a modelos mais complexos, com frota heterogênea, diferentes produtos, com janelas de tempo para entrega, roteamento dinâmico, entre outros.

Os primeiros pesquisadores desta área foram Dantzing e Ramser (1959), que demonstraram a complexidade e relevância de tais problemas ao estudarem a distribuição de gasolina para postos de venda de combustíveis. Mais tarde, Clarke e Wright (1964) propuseram um método heurístico, conhecido como Heurística das Economias, efetuando melhorias do modelo proposto por Dantzing e Ramser. Baker (1982) utilizou a estratégia *branch-and-bound* para um problema de roteirização com um único veículo, considerando restrições de capacidade e de janelas de tempo (*time windows*).

Taillard (1993) classificou os VRP’s como problemas NP-difíceis (*NP-hard*) e sugeriu o uso de técnicas de otimização combinatória e métodos heurísticos para as suas resoluções. Por isso, as diversas contribuições científicas sobre o tema se dividem em abordagens de resolução exatas, como foi apresentado por Laporte e Norbert (1983), ou em métodos heurísticos como Toth e Vigo (2002) e Christofides, Mingozzi e Toth (1981).

2.2 Algoritmos genéticos

Os Algoritmos Genéticos são métodos de busca aleatória baseados na Teoria da Evolução Natural das Espécies. Em contraste com Estratégias de Evolução e Programação Evolutiva, o objetivo original de Holland (1975), criador dos Algoritmos Genéticos, era estudar formalmente o fenômeno de adaptação e desenvolver maneiras em que tais mecanismos possam ser importados para sistemas de computadores. Segundo Mitchell (1999), o GA (do inglês, *Genetic Algorithm*) é um método de se mover de uma população para uma nova população, usando uma espécie de “seleção natural” em conjunto com os operadores de seleção, cruzamento e mutação. Cada população é constituída por vários indivíduos, conhecidos como “cromossomos”. Por sua vez, cada cromossomo representa uma solução candidata ao problema, que é representada por uma cadeia de bits, números ou mesmo caracteres. Esses são constituídos por “genes”, por

exemplo, um bit, possuindo uma localização particular no mesmo. Cada um dos genes é uma manifestação de um “alelo” especial, por exemplo, 0 ou 1.

Sendo os GAs baseados no princípio da seleção natural, a população inicial está também sujeita aos processos de seleção, cruzamento e mutação. O primeiro operador utilizado é conhecido como seleção. Como seu homólogo da seleção natural, a operação de seleção seleciona pares de organismos altamente aptos para o cruzamento. Assim, o foco dos Algoritmos Genéticos se dá na direção de indivíduos aptos, ou seja, portadores de melhores resultados para a função aptidão. Por sua vez, a analogia ao acasalamento é permitida pelo operador conhecido como cruzamento. Tal operador proporciona uma mistura de genes pais, e a combinação do material genético da população em uma visão global. Esse processo é responsável por fornecer robustez aos GAs. Desta maneira, dois indivíduos selecionados são combinados para formar um novo indivíduo com semelhanças com ambos os pais.

Enquanto a seleção e o cruzamento são os principais operadores usados em tais algoritmos, existem diversos outros operadores menores, a fim de fortalecer os GAs em determinadas circunstâncias. Em algumas situações, esses operadores podem fornecer maior eficiência ou impedir a conversão para um ótimo local, ao invés de um ótimo global. É possível que a solução convirja prematuramente devido a uma passagem única, misturando o material genético que está presente na população inicial, não introduzindo um novo material.

Na natureza os novos genes são introduzidos através da mutação. De maneira também análoga, os GAs permitem a modificação de um cromossomo para adicionar novos genes, por meio do operador mutação. Normalmente, um indivíduo que possui um alto valor de aptidão será selecionado para o cruzamento. Porém, por acaso, tal indivíduo pode não ser selecionado, ocasionando o atraso na resolução dos problemas. Para superar essa situação, utiliza-se uma estratégia elitista, permitindo que alguns dos indivíduos mais aptos sejam colocados de maneira inalterada na próxima geração (MESSA; LAYBANON, 1992).

Com essas operações, os cromossomos evoluem até que se encontre uma solução que melhor atenda a um critério específico de evolução. Para que se satisfaça tal objetivo, a cada geração as populações de soluções são avaliadas segundo uma função *fitness*, que mede seu grau de aptidão. Os cromossomos que possuem melhores *fitness* são selecionados para dar origem à próxima geração. A tendência é, portanto, que a cada geração, o conjunto de soluções vá sendo melhorado até um limite desejado (GOLDBERG, 1989).

3. Pesquisa de campo

3.1 Descrição da empresa

Uma transportadora de leite que atua na região do Triângulo Mineiro foi o objeto de estudo nesta pesquisa. Essa transportadora atua mediante um contrato de exclusividade com um grande laticínio da região. A transportadora deve atender a diversas legislações do setor lácteo em geral, além de restrições específicas da contratante.

Uma das restrições específicas do laticínio é o limite máximo de carga, que deve ser inferior à capacidade total do veículo. Tal exigência tem a finalidade de evitar que ocorra desperdício durante a atividade de homogeneização do leite. Anteriormente ao descarregamento na unidade de beneficiamento é preciso que o veículo seja pesado em outra unidade da contratante, e também higienizado exteriormente em um posto conveniado. A atividade de coleta,

identificação e acondicionamento de amostras de leite referentes a cada propriedade visitada também é um requisito específico da contratante.

A empresa também apresenta restrições operacionais, como por exemplo a existência de três compartimentos em cada veículo. Considera-se a inexistência de limites para o número de fornecedores distintos que terão seus produtos acondicionados em um mesmo compartimento do veículo. A sazonalidade e elasticidade da oferta do produto a ser transportado prejudica o planejamento efetivo da coleta do leite. De maneira geral, as variações estão entre 20% e 30%, com exceção do período de seca. Durante esse período, a diminuição da coleta global chega a 60.000 litros diários, que correspondem a 30% da média em dias normais.

Devido à característica perecível do leite, o intervalo de coleta em cada propriedade deve ser de dois dias. Para casos extremos em que a quantidade de leite coletada é pequena, o tanque de armazenamento do produtor é relativamente grande e existem dificuldades de se locomover até o mesmo, há a possibilidade de exceder o período regular de coleta. Tal período pode ser estendido para até quatro dias, mediante uma ocorrência realizada pela transportadora.

Uma forte restrição prática da empresa é relacionada à má qualidade da malha rodoviária rural da região. Tal restrição trata da impossibilidade de alguns veículos transitarem em determinados locais. Mediante este fato, os caminhões de três eixos são destacados por possuírem limitações de movimentação em locais de difícil acesso. O mesmo não acontece com os demais veículos.

Além das restrições formalizadas, a transportadora convive com situações que dificultam o planejamento de suas atividades, gerando muitas vezes, a diminuição da sua lucratividade. A qualidade inadequada da malha rodoviária rural dificulta a agilidade e acesso aos fornecedores, além da consideração de que existe o prejuízo nas condições das estradas durante o período de chuvas e a maior frequência de necessidade de manutenção dos veículos.

Devido à falta de um planejamento efetivo, que considere todas, ou a maioria, das restrições descritas, a empresa convive com atrasos frequentes, aumento dos custos e utilização sub-ótima de sua capacidade, visto que em períodos de baixa na oferta, a mesma frota de caminhões continua em circulação, ou seja, a receita é menor e os custos são praticamente os mesmos, prejudicando a lucratividade da transportadora.

3.2 Algoritmo proposto

Dentre os principais aspectos a serem modelados, destacam-se: dados de entrada, codificação dos indivíduos, população inicial, função *fitness*, operador seleção, operador cruzamento, operador mutação e operador substituição.

- **Dados de entrada:** Consistem basicamente em matrizes de distâncias entre os pontos de coleta. Devido à restrição de impossibilidade de alguns veículos em transitar em determinados trajetos, existem dois tipos de matrizes, as com restrição e as sem restrição. A tabela com restrição apresenta uma representação infinita nos trajetos que os veículos não conseguem transitar.
- **Codificação dos indivíduos:** Os cromossomos são codificados como mostra a Figura 1. A medida que as capacidades dos veículos vão sendo completadas os respectivos pontos de coleta são atribuídos ao próximo veículo.
- **População inicial:** A população inicial utilizada é aleatória. Também foi testado o método do vizinho mais próximo.

- **Função fitness:** A função fitness objetiva enfatizar indivíduos com menores distâncias totais. Para pontos em que o trajeto é impossível o fitness é penalizado com uma taxa de penalização passada como parâmetro.
- **Operador seleção:** O método utilizado é o da roleta. Uma abordagem elitista também foi testada.
- **Operador cruzamento:** Utilizou-se o método de cruzamento de 1 ponto, considerando a restrição de que cada ponto de coleta deve ser visitado somente uma vez. Sendo assim, após o cruzamento pontos que aparecem mais de uma vez são substituídos aleatoriamente por pontos ainda não contidos no mesmo.
- **Operador mutação:** O processo de mutação utilizado é o da troca. Duas posições são selecionadas aleatoriamente e seus valores são trocados.
- **Operador substituição:** O operador substituição por pai fraco é utilizado. Neste são avaliados os quatro indivíduos após o cruzamento, pais e filhos, os dois indivíduos que possuem melhores fitness prosseguem para a próxima geração.

A Figura 1 apresenta um exemplo de como as soluções são codificadas no algoritmo proposto. Já a Figura 2 sintetiza o algoritmo genético usando pseudocódigo.

Ordem dos Veículos		Ordem de Visita dos Pontos de Oferta					
1	2	3	4	1	5	6	2

Figura 1 – Exemplo de representação de soluções no cromossomo

```

Ler arquivos de entrada e parâmetros do algoritmo;
Populacao_atual = Cria_populacao_aleatoria();
Para i = 0 até num_geracoes Faça
    Calcular_fitness (Populacao_atual);
    Copiar_melhor_individuo (Populacao_atual, Populacao_nova);
    Para j = 0 até tamanho_populacao Faça
        Seleciona_individuos (Populacao_atual, ind1, ind2);
        pCross = num_aleatorio();
        pMut1 = num_aleatorio();
        pMut2 = num_aleatorio();
        pPaiFraco = num_aleatorio();
        Se pCross < prob_crossover Faça
            Populacao_nova = crossover (ind1, ind2);
        Se pMut1 < prob_mutacao Faça
            Populacao_nova = mutacao(ind1);
        Se pMut2 < prob_mutacao Faça
            Populacao_nova = mutacao(ind2);
        Se pPaiFraco < prob_pai_fraco Faça
            Populacao_nova = pai_fraco(ind1, ind2);
    Fim
    Populacao_atual = Populacao_nova;
    Atualiza_melhor_solucao_global();
Fim
Otimiza_2_opt (melhor_global);

```

Figura 2 – Síntese do algoritmo proposto usando pseudocódigo

4. Resultados computacionais

Como descrito na Seção 3, o algoritmo proposto possui alguns parâmetros que podem ser ajustados em busca de resultados para o problema. Estes parâmetros são (i) o tamanho da população, (ii) o conjunto de operadores genéticos, (iii) a probabilidade de cruzamento, (iv) a probabilidade de mutação, (v) a probabilidade de substituição por pai fraco e (vi) a quantidade de gerações.

A efetividade do algoritmo foi testada em problemas de diferentes tamanhos, ou seja, com diferentes quantidades de pontos de coleta de leite (ofertas). Desta maneira seis testes foram formulados para avaliar diferentes configurações de parâmetros. Os questionamentos e seus resultados são descritos nas subseções a seguir.

4.1 Conjunto de operadores genéticos

Foram testadas 4 configurações para o algoritmo. Uma versão básica, apenas com operadores de seleção, cruzamento e mutação (Cenário 1), uma versão que contém o operador substituição por pai fraco (Cenário 2), outra versão que contém o operador elitismo (Cenário 3) e por fim a última versão contém os dois operadores especiais (Cenário 4). Foram realizados 10 testes referentes a cada cenário em uma instância teste com 50 pontos de coleta, sendo medidas as distâncias totais das soluções encontradas. A versão que contém ambos os operadores especiais (substituição por pai fraco e elitismo) apresentou melhores resultados como mostra as medições do Questionamento 1 da Tabela 1. A diferença entre os resultados obtidos foi comprovada por meio de Análise de Variância de um fator. A Figura 3 apresenta a melhor solução encontrada para o Questionamento 1.

Medições	Questionamento 1				Questionamento 2		
	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 1	Cenário 2	Cenário 3
1	13294	12233	12624	11869	25157	25734	27621
2	12181	12609	13238	11336	23945	25897	27195
3	12478	11958	12802	11509	24668	25321	26853
4	13046	12176	12994	12510	25011	26064	26509
5	12995	11601	12430	12116	24702	26521	26092
6	12811	11634	13284	12861	24970	25863	28407
7	13434	12147	13578	11590	23663	27035	26373
8	13594	12682	13148	11623	24044	26418	27130
9	13406	12045	12163	11219	24801	27250	28159
10	12888	11877	12788	12583	24324	24612	27076
Média	13012,7	12096,2	12904,9	11921,6	24528,5	26071,5	27141,5
Desvio P.	445,28	359,38	428,68	568,88	506,92	783,20	749,02

Tabela 1 – Resultados dos Questionamentos 1 e 2

Na Figura 3 é possível visualizar graficamente as rotas obtidas na melhor solução do Questionamento 1.




Figura 3 – Melhor solução encontrada para o Questionamento 1

4.2 Tamanho da População

Foram testados três cenários em uma instância teste com 90 pontos de oferta a fim de avaliar qual o tamanho da população traz melhores resultados. Os cenários apresentavam os valores de 50, 100 e 200 indivíduos por população. Os resultados sintetizados no Questionamento 2 da Tabela 1, demonstram que populações menores trazem resultados mais satisfatórios. Tal hipótese foi confirmada por um teste de análise de variância de um fator.

4.3 Probabilidade de cruzamento

A probabilidade de realização de cruzamento também foi avaliada para 3 cenários com valores de 0.6, 0.8 e 0.9 respectivamente em uma instância teste de tamanho 20. Os resultados do Questionamento 3 da Tabela 2 demonstram a obtenção de melhores resultados para a probabilidade com valor 0.9 devido sua menor variabilidade e bom valor médio. Esta hipótese foi confirmada por meio do teste ANOVA de um fator.

Medições	Questionamento 3			Questionamento 4		
	Cenário 1	Cenário 2	Cenário 3	Cenário 1	Cenário 2	Cenário 3
1	5830	4883	4631	45228	57438	68667
2	4892	4584	5010	49030	59367	68292
3	4464	5318	4398	51635	57061	67925
4	4567	4464	4490	51149	59533	68415
5	4464	4423	4973	51547	57409	64706
6	6164	4398	4696	49429	57035	64827
7	4567	4423	4452	52267	59419	69582

8	4948	4398	4398	51343	57328	66833
9	4977	4579	4515	53676	59334	66975
10	5517	4926	5138	57617	59774	69247
Média	5039	4639,6	4670,1	51292,1	58369,8	67546,9
Desvio P.	601,88	307,26	274,98	3200,78	1188,89	1701,10

Tabela 2 – Resultados dos Questionamentos 3 e 4

4.4. Probabilidade de Mutação

A probabilidade de ocorrência de mutação foi avaliada para cenários com valores de 0.1, 0.2 e 0.3 respectivamente em uma instância teste de tamanho 200. Sendo assim, os resultados sintetizados no Questionamento 4 da Tabela 2, demonstram a efetividade do Cenário 1. A hipótese de que menores valores de mutação ocasionam melhores resultados foi confirmada por meio de Análise de Variância.

4.5 Substituição por pai fraco

Avaliando três cenários com probabilidades de substituição por pai fraco com valores de 0.2, 0.5 e 0.8 respectivamente em uma instância teste de tamanho 400. Obteve-se os resultados demonstrados no Questionamento 5 da Tabela 3. Sendo assim, observa-se que valores maiores para este parâmetro apresentam melhores resultados.

4.6 Otimização local

Após a verificação de que é possível obter-se melhorias locais nos resultados obtidos, foi testada uma nova configuração do algoritmo que gera a população inicial com base no vizinho mais próximo, e ao final realiza uma melhoria 2-opt na melhor solução encontrada. Essa configuração foi testada em uma instância teste de tamanho 90. Os resultados são sintetizados no Questionamento 6 da Tabela 3. Observa-se que a melhoria foi considerável, o que também foi comprovado pelo teste ANOVA.

Medições	Questionamento 5			Questionamento 6	
	Cenário 1	Cenário 2	Cenário 3	Cenário 1	Cenário 2
1	95167	77254	75910	25157	15845
2	95737	74145	72577	23945	16062
3	92675	73084	70353	24668	15792
4	99067	78901	75111	25011	16216
5	93015	78257	70509	24702	15175
6	93321	77913	72415	24970	15718
7	95876	76068	69749	23663	15452
8	88427	78084	75301	24044	16425
9	88325	77884	77043	24801	15724
10	84601	76909	72651	24324	15302
Média	92621,1	76849,9	73161,9	24528,5	15771,1
Desvio P.	4337,84	1891,09	2554,44	506,92	394,17

Tabela 3 – Resultados dos Questionamentos 5 e 6

5. Considerações Finais

Neste trabalho foram estudados diversos aspectos relacionados ao problema de roteamento de uma transportadora de leite a granel. Para solucionar o problema de roteamento dessa empresa, foi proposto um algoritmo genético parametrizável, em que fatores como a probabilidade de ocorrência de operadores genéticos podem ser configuradas pelo usuário.

Para avaliar o algoritmo genético proposto, diversos questionamentos e cenários foram testados. O objetivo central foi conhecer o efeito dos parâmetros na resolução de diferentes problemas. Neste contexto, ao avaliar o tamanho da população, observa-se que populações menores, com 50 indivíduos, trazem resultados mais satisfatórios. Tal fato se deve à consideração de que grandes populações lidam com maior número de soluções ruins, diminuindo a chance de que as melhores soluções sejam escolhidas.

Quanto à probabilidade de crossover, os resultados demonstraram que altas probabilidades, como 90%, levam a bons resultados com maior confiabilidade. A probabilidade de mutação, por sua vez, demonstra que porcentagens menores, como 10%, apresentam melhores resultados. Com relação à probabilidade de substituição por pai fraco, quanto maior for o valor assumido, melhor é a tendência de resultados, sendo o uso de 80% considerado o mais adequado. O questionamento referente aos operadores genéticos demonstrou a efetividade do Elitismo e Substituição por Pai Fraco, resultando em soluções de menor custo. Após a verificação da necessidade de melhorias locais, foram acrescentados dois conceitos ao algoritmo: a geração da população inicial pelo algoritmo do vizinho mais próximo e a otimização 2-opt da melhor solução encontrada. A efetividade do algoritmo aumentou consideravelmente, por meio de grande redução nos custos das soluções.

Mediante tais resultados, a empresa terá uma ferramenta de otimização em mãos que permitirá atendimento de suas restrições práticas específicas. O algoritmo conseguiu reunir todos os aspectos relevantes para a organização, gerando resultados totalmente viáveis, diferentemente do método atual de roteamento. De maneira descritiva a empresa poderá reduzir seus tempos de movimentação, minimizar seus custos globais, aumentando consideravelmente sua eficiência e nível de serviço.

Como limitação deste trabalho, deve-se ressaltar a inexistência de dados necessários para o completo funcionamento do algoritmo. A empresa em questão possui apenas algumas imagens que demonstram as rotas atuais realizadas pela empresa. Contudo, não há dados no formato adequado para dar origem às matrizes de custo, que são uma das entradas do algoritmo. A fim de contornar tal limitação, foi feito um algoritmo que gera problemas aleatórios com dimensões próximas as da empresa, os quais foram usados nos testes.

Como sugestão para trabalhos futuros pode-se destacar a possibilidade de implementação de novos operadores genéticos, que podem contribuir para melhores soluções. Neste contexto, Baker e Ayechev (2003) e Bjarnadóttir (2004) sintetizam diversos operadores de cruzamento e mutação que podem ser testados em Problemas de Roteamento de Veículos. A heurística proposta pode conter novos testes referentes a Algoritmos de otimização local, que também podem fornecer melhores soluções. Por fim, o Algoritmo pode ser efetivamente implementado na empresa em questão e em outras organizações do mesmo ramo, trazendo implicações positivas para as mesmas.

Como conclusão final o objetivo central de estabelecer um modelo de utilização eficiente de frota, minimizando custos totais, e consequentemente aumentando a eficiência e o nível de serviço da empresa, foi atingido satisfatoriamente.

Referências

- BAKER, B. M.; AYECHIEW, M. A.** *A genetic algorithm for the vehicle routing problem*. Computers & Operations Research, [S.l.], v. 30, pp. 787- 800, 2003.
- CHRISTOFIDES, N., MINGOZZI, A., TOTH, P.** *Exact Algorithms for the Vehicle Routing Problem, based on Spanning Tree and Shortest Path Relaxation*. Mathematical Programming, [S.l.], v. 20, pp 255- 282, 1981.
- CHOPRA, S., MEINDL, P.** *Gestão da Cadeia de Suprimentos: Estratégia, Planejamento e Operações*. 4 ed. São Paulo: Pearson Education do Brasil, 2011. 519 p.
- CLARKE, G., WRIGHT, J.W.**, *Scheduling of Vehicles From a Central Depot to a Number of Delivery Points*. Operations Research, [S.l.], v.12, pp 568 – 581, 1964.
- DANTZIG, G. B., RAMSER, J. H.** *The truck dispatching problem*. Management Science, Philadelphia, v. 6, pp 80-91, 1959.
- GOLDBERG, D. E.** *Genetic Algorithms in Search, Optimization and Machine Learning*, Nova Iorque, 1989.
- HEINEN, M. R., OSÓRIO, F.S.**, *Algoritmos Genéticos Aplicados ao Problema de Roteamento de Veículos*. Hífen, São Leopoldo, v. 30, pp 89-95, 2006.
- HOLLAND, J. H.** *Adaptation in Natural and Artificial Systems*. University Michigan Press, 1975.
- LAPORTE, G., NORBERT, Y.** *A Brach-and-Boud Algorithm for the Capacitated Vehicle Routing Problem*. Operations Research Spektrum, [S.l.], v. 5, pp 77-85, 1983.
- LIMA, I.X.A.** *Algoritmos para problemas de roteamento de veículos com entrega e coleta*. 2009. 59 f. Dissertação (Mestrado em Computação) – Universidade Federal Fluminense, Niterói, 2009.
- MESSA, K., LYBANON, M.** *Curve Fitting Using Genetic Algorithms*. Naval Oceanographic and Atmospheric Research Laboratory, [S.l.], pp. 1-23, 1992.
- MITCHELL, M.** *An Introduction to Genetic Algorithms*. 5 ed. Londres: Massachusetts Institute of Technology, 1999.
- NOGUEIRA, D. A.; LOPES, F. V.; SOUZA, M. M. O.**; *Alternativas de baixo custo para a produção de leite a pasto em assentamentos de reforma agrária na mesorregião do Triângulo Mineiro/ Alto Paranaíba*. Uberlândia, 2010.
- OLIVEIRA, H. C. B., SOUZA, M. M., ALVARENGA, G.B., SILVA, R.M.A.** *Adaptação do Algoritmo Genético no Tratamento do Problema de Roteamento de Veículos com Janela de Tempo* . Lavras, 2006.
- PIMENTA, D. J.** *Algoritmo de Otimização para o Problema de Roteamento de Veículos no Transporte Conjunto de Cargas e de Passageiros*. 2001. 65 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte, 2001.
- RIBEIRO, P. C. C. R., SILVA, G. P., SIMÕES, J. M. S. S., SILVA, V.** *Transporte na Indústria Brasileira de Laticínios: Um estudo de caso*. In: Encontro Nacional de Engenharia de Produção, XXII, 2003, Ouro Preto: 21/10 à 24/10, pp. 1-7.
- TAILLARD, E.**, *Parallel Iterative Search Methods for Vehicle Routing Problem*. Networks, Lausanne, v. 23, p 661-673, 1993.
- TOTH, P., VIGO, D.** *The Vehicle Routing Problem*. 1.ed. Philadelphia: SIAM, 2002. 363 p.
- YAMAGUCHI, L.T.C.** *Otimização da logística da captação de leite de uma cooperativa agropecuária*, Revista Brasileira de Agroinformática, [S.l.], v.4, pp. 90-103, 2002.
- YEUN, L. C., ISMAIL, W. R., OMAR, K., ZIROUR, M.** *Vehicle Routing Problem: Models and Solutions*, Journal of Quality Measurement and Analysis, [S.l.], v. 4, pp. 205-218., 2008.