

APLICAÇÃO DE ALGORITMOS EVOLUCIONÁRIOS NA OTIMIZAÇÃO DE UM RECORTE DE UMA CADEIA DE SUPRIMENTOS DE PAPEL

EVOLUTIONARY ALGORITHMS APPLICATION IN THE OPTIMIZATION OF A CUT OF A PAPER SUPPLY CHAIN

Mauricio Mattos* mttts.mauricio@gmail.com
Mariana Kleina* marianakleina11@gmail.com
*Universidade Federal do Paraná, Curitiba, Paraná

Resumo: Em um cenário global cada vez mais competitivo para as empresas, é crescente a preocupação com redução de custos operacionais, de forma a melhorar o resultado da companhia e direcionar os gastos para áreas mais estratégicas do negócio que possam alavancar o resultado da empresa como um todo. Com isso, a adoção de ferramentas de otimização por empresas é constante, uma vez em que se busca, em modelos matemáticos, oportunidades de melhorias nos processos atuais. O presente artigo busca avaliar o desempenho de dois algoritmos evolucionários (Otimização por Enxame de Partículas e Algoritmo Genético) na otimização dos custos de uma cadeia de suprimentos, com foco nos custos de aquisição de material, custo de armazenagem e custo de venda perdida. Para o estudo, foi analisado um recorte da cadeia de suprimentos de papel. Os dados utilizados foram provenientes de uma papelaria, levando em conta seu produto de maior receita, seus fornecedores de primeira camada e seus clientes de primeira camada. O desempenho dos dois algoritmos selecionados foi comparado entre si, com a solução ótima e com os resultados da atual política de compras da empresa. A Otimização por Enxame de Partículas se mostrou eficaz comparada à política atual de compras da empresa, apresentando uma economia de 3,9%. Porém, o Algoritmo Genético apresentou um resultado menos vantajoso para a companhia, elevando seus custos em 74,4%. Ambos os algoritmos tiveram desempenho inferior à solução ótima, que apresentou uma economia de 7,2% em relação ao que foi praticado pela empresa.

Palavras-chave: Algoritmos evolucionários. Otimização por enxame de partículas. Algoritmo genético. Cadeia de suprimentos.

Abstract: In a global scenario getting more and more competitive for companies, the concern about the reduction of operational costs is growing, because it can improve the company's results and focus the spending in more strategic departments of the business. Thereby, the adoption of optimization tools by companies is constant, since they search, in mathematical methods, opportunities to improve current processes. This article aims to evaluate the performance of two evolutionary algorithms (Particle Swarm Optimization and Genetic Algorithm) in the costs optimization of a supply chain, focusing on materials acquisition costs, storing costs and missed sales costs. For this study, it was analyzed a part of a paper supply chain. The data was collected from a stationery store, considering its product with the biggest income, its first layer suppliers and its first layer clients. The performance of the two algorithms was compared with each other, with the optimal solution and with the company's current purchasing policy. The Particle Swarm Optimization was effective compared to the company's current purchasing policy, bringing a 3,9% saving. On the other hand, the Genetic Algorithm presented a less favorable result to

the company, raising its costs in 74,4%. Both algorithms had a worse result than the optimal solution, that resulted in a saving of 7,2% compared to what the company practiced.

Keywords: Evolutionary algorithms. Particle swarm optimization. Genetic algorithm. Supply chain.

1 INTRODUÇÃO

A computação evolucionária consiste em métodos computacionais que são baseados em teorias biológicas para a solução de problemas, conforme Barreto (2001). Segundo o autor, o baseamento na biologia surge a partir da suposição de que a natureza resolve constantemente problemas de otimização, ao estimular alterações nos seres vivos para que eles se tornem mais adaptados ao ambiente.

Nas últimas décadas, a quantidade de trabalhos publicados sobre computação evolucionária vem crescendo. O que se destaca é a versatilidade de aplicação desses algoritmos, que podem ser utilizados para otimizar resultados nas mais diversas áreas. Exemplos são os trabalhos de Argoud, Gonçalves Filho e Tiberti (2008), que utilizaram algoritmo genético para otimização do arranjo físico de uma fábrica, reduzindo a distância percorrida pelos materiais, de Goldberg, Goldberg e Medeiros Neto (2005), que utilizam diferentes algoritmos evolucionários para reduzir os custos em um sistema de cogeração de energia, e o trabalho de Tavares Neto e Godinho Filho (2013), que utilizam a otimização por colônia de formigas para sugerir um novo sequenciamento de tarefas em uma máquina de forma que os custos de produção sejam reduzidos. Nos três casos citados, os algoritmos evolucionários apresentaram resultados eficazes e melhores do que os resultados anteriores à implementação dos algoritmos.

Ao olhar a realidade das empresas no século XXI, percebe-se que há uma necessidade de que elas se tornem mais competitivas perante o mercado. Para isso, um dos movimentos mais realizados pelas empresas é a busca por maneiras de reduzir os seus custos, aumentando assim o retorno financeiro com a venda dos seus produtos e serviços. Quando se desenha a cadeia de suprimentos de uma companhia, percebe-se a incidência de custos em diversas partes, desde o valor do custo das matérias primas, de transporte, armazenagem, transformação, custos de venda, entre

outros. Devido a essa alta concentração de gastos, percebe-se que a cadeia de suprimentos possui muitas oportunidades para redução de custos, impactando diretamente no resultado da companhia.

O presente artigo visa utilizar dois algoritmos evolucionários para otimizar os custos de uma cadeia de suprimentos real. Primeiramente, realiza-se uma revisão dos principais conceitos de cadeia de suprimentos e dos dois algoritmos selecionados: otimização por enxame de partículas e algoritmo genético. Posteriormente, descreve-se a metodologia utilizada para aplicação dos algoritmos, incluindo a modelagem matemática e o detalhamento do *software* e pacotes utilizados. Por fim, o resultado da aplicação é apresentado e analisado, comparando o desempenho dos algoritmos evolucionários com a solução exata do problema proposto.

1.1 Objetivo Geral

Comparar o desempenho de dois algoritmos evolucionários na otimização de custos em uma cadeia de suprimentos.

1.2 Objetivos Específicos

- Revisar os principais conceitos de cadeia de suprimentos;
- Selecionar dois algoritmos evolucionários e compreender seus princípios, aplicações e funcionamento;
- Aplicar os dois algoritmos selecionados em um recorte da etapa final de uma cadeia de suprimentos de papel real para otimização de custos;
- Analisar e comparar os resultados dos algoritmos entre si e com um modelo de solução exata para o problema.

2 REVISÃO DA LITERATURA

Revista Produção Online. Florianópolis, SC, v.??, n.??, p. ??-??, ??/??., 201?

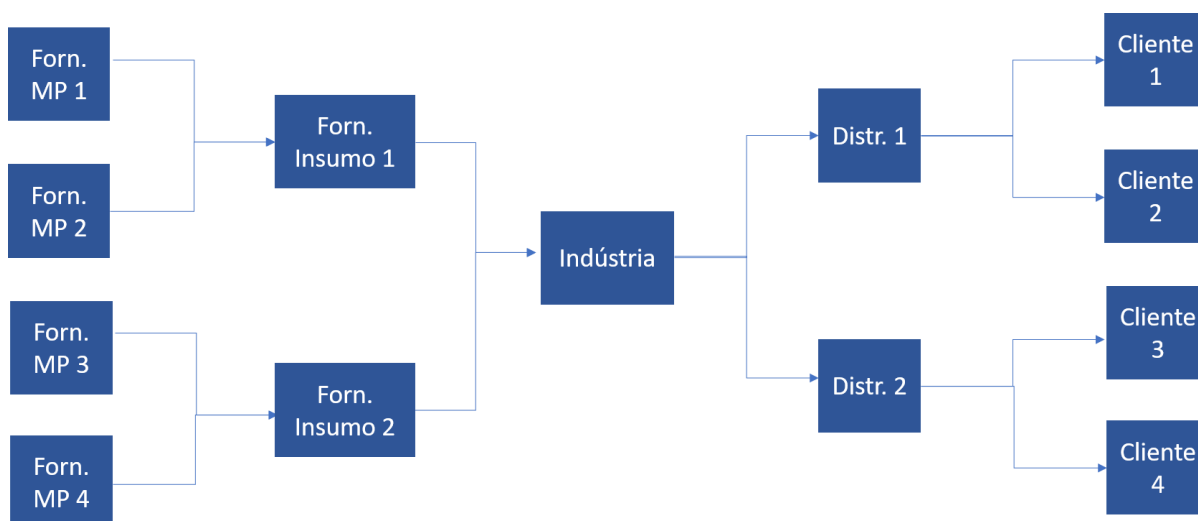
2.1 Cadeia de Suprimentos

Chopra e Meindl (2010) definem cadeia de suprimentos como sendo todas as etapas que devem ser realizadas para que o pedido de um cliente seja atendido. Os autores ressaltam, ainda, que uma cadeia de suprimentos não é composta somente por fornecedores e fabricantes, mas envolve também os pontos de venda, as transportadoras, os armazéns e até mesmo os clientes finais. Chopra e Meindl (2010) afirmam que, ao olhar para a cadeia de suprimentos no interior de uma única empresa, observa-se que ela é composta pelas mais diversas áreas, como pesquisa e desenvolvimento, *marketing*, operações e financeiro, uma vez que todas essas áreas atuam no atendimento do pedido de um cliente.

Para Ballou (2006), uma cadeia de suprimentos consiste em uma sequência de atividades que acontecem a todo o momento no processo de transformação de matérias primas em produto acabado. O autor também alega que uma cadeia de suprimentos consiste nas interações logísticas de diferentes áreas dentro de uma empresa, além da interação entre diferentes empresas que pertençam a um mesmo fluxo de produto.

Pires (2009) apresenta uma definição de cadeia de suprimentos semelhante aos autores já citados, afirmando que uma cadeia de suprimentos é uma rede de empresas que se encarregam da obtenção, produção e liberação de um produto ou serviço ao consumidor final. O autor exemplifica uma cadeia de suprimentos a partir de uma montadora de veículos. A cadeia de suprimentos exemplificada é composta pelo fornecedor direto da montadora (denominado fornecedor de primeira camada), o fornecedor desse fornecedor (fornecedor de segunda camada), o distribuidor (cliente de primeira camada), o varejista (cliente de segunda camada) e por fim o consumidor final. O autor distribui esta rede de empresas em linha, conforme o fluxo do produto. A Figura 1 exemplifica uma cadeia de suprimentos com duas camadas de fornecedores e duas camadas de clientes.

Figura 1: Exemplo de uma cadeia de suprimentos



Fonte: elaborada pelos autores (2018)

Com base nesse modelo, Pires (2009) apresenta a decomposição que Lambert, Cooper e Pagh (1998) fazem da cadeia de suprimentos em três estruturas: a estrutura horizontal (corresponde ao nível de camadas de uma cadeia de suprimentos, ou seja, a quantidade de fornecedores e clientes em torno da empresa foco), a estrutura vertical (quantidade de empresas em cada camada) e posição da empresa foco (qual ponto da cadeia a empresa foco está localizada).

Pires (2009) também traz uma divisão da cadeia de suprimentos sugerida por Slack (1993), que consiste na análise da cadeia em três níveis. O primeiro nível é denominado cadeia interna, que consiste somente nos fluxos de materiais e informações desempenhados dentro do âmbito de uma empresa. O segundo nível é a cadeia imediata, que engloba uma empresa, seus fornecedores diretos e seus clientes diretos. Por fim, o último nível é chamado de cadeia total, que envolve todas as camadas de fornecedores e clientes de uma cadeia.

A cadeia de suprimentos agrega valor para o cliente, segundo Ballou (2006), ao fazer com que o produto seja entregue ao cliente no tempo certo e no lugar certo, por meio de transporte, fluxo de informação e estoques eficazes. Caso esses critérios não sejam atendidos, um produto ou serviço perde valor aos olhos do cliente.

Ballou (2006) aponta a existência de três principais objetivos de uma cadeia de suprimentos, sendo a primeira a redução de custos, por meio da escolha adequada

de locais de armazenagem ou modais de transporte, por exemplo. Outro objetivo, segundo o autor, é a redução de capital, que pode ocorrer por meio da redução de investimentos e aumento do retorno sobre os ativos existentes. Exemplos de atividades que convergem para isso são o transporte direto da produção ao cliente, evitando armazenamento ou ainda optar por armazenamento em locais públicos ao invés de instalações particulares. Por fim, o último objetivo é a melhoria de serviços, que é dada pelo desempenho de serviços que agreguem valor ao cliente. Ballou (2006) ressalta que, apesar dos custos para implantação de melhorias de serviços serem altos, o retorno sobre este investimento é significativo.

Para Chopra e Meindl (2010), o principal objetivo de uma cadeia de suprimentos é maximizar o valor global gerado, sendo este valor a diferença entre o valor do produto final e o custo total no decorrer da cadeia de suprimentos. Os autores afirmam que este valor deve ser medido para a cadeia como um todo, e não isoladamente para cada etapa da cadeia.

Pires (2009) relata que um dos maiores desafios das empresas, no que se remete à cadeia de suprimentos, é o efeito chicote. O autor explica que o efeito chicote consiste na amplificação da variação da demanda ao longo de uma cadeia. Essa ampliação tende a ser menos no varejo, segundo o autor, uma vez que o varejista possui contato direto com o consumidor final e é o primeiro a identificar a variação da demanda. Quando a informação sobre o aumento da demanda chega à parte inicial da cadeia, ela já foi amplificada, fazendo com que as companhias ao longo da cadeia produzam uma quantidade maior do que a demandada. Pires (2009) ainda cita que uma consequência imediata do efeito chicote é o aumento dos níveis de estoques nas empresas, consequentemente aumentando seus custos.

Atualmente, é possível encontrar na literatura trabalhos relacionados à minimização de custos em uma cadeia de suprimentos e técnicas de suavização do efeito chicote. Dentre as pesquisas publicadas, ressalta-se o trabalho de Silva (2008), que utiliza a técnica de otimização por enxame de partículas para otimizar uma cadeia de suprimentos (integrando estoque, produção e distribuição), visando minimizar os custos de armazenagem, fabricação, transporte e falta de produto. O autor conclui que esse algoritmo obteve bom desempenho na solução do problema proposto. Falcone

(2004) realizou um trabalho similar, ao propor a otimização dos mesmos quatro custos estudados por Silva (2008) por meio de algoritmos genéticos e evolução diferencial. Os custos de armazenagem e falta de produto estão diretamente ligados ao efeito chicote, uma vez que elevação dos custos de armazenagem quando a informação sobre a demanda é maior do que a realidade, e elevação dos custos de falta de produto quando a informação sobre a demanda é menor do que a realidade.

2.2 Otimização por enxame de partículas


Kennedy e Eberhart (2001) afirmam que o comportamento coletivo dos animais (seja uma revoada de pássaros, um cardume de peixes ou uma manada de elefantes), quando em busca de alimento, pode ser traduzido em um algoritmo de otimização. Os autores ressaltam que, nestas situações, os animais utilizam de duas memórias: a cognitiva (de acordo com as experiências individuais de cada elemento do grupo, onde ele sabe, dentre os locais que ele já passou, qual é o mais provável de encontrar alimento) e social (os membros de um coletivo se comunicam entre si, informando aos demais seus resultados).

A partir dessa teoria, Kennedy e Eberhart (2001) escreveram o algoritmo denominado *Particle Swarm Optimization* (PSO), que pode ser traduzido como Otimização por Enxame de Partículas. A ideia do algoritmo, segundo os autores, é espalhar uma série de partículas no espaço de busca de solução do problema que está sendo otimizado (este espaço contém todos os conjuntos soluções possíveis para o problema e possui j dimensões). As partículas percorrem o espaço de busca (com uma determinada velocidade), avaliando o resultado de cada ponto (sendo esse resultado chamado de valor *fitness*). Cada partícula, por meio da sua memória cognitiva, armazena os resultados dos pontos por onde ela passou, sendo que o melhor resultado é denominado *pbest* (*particle best*). Por meio da memória social, as partículas sabem qual foi o melhor valor *fitness* encontrado pelo grupo, sendo este valor chamado *gbest* (*global best*). A cada iteração, as partículas avaliam seus *pbest* e *gbest* e se movimentam na direção deles, na busca de melhores resultados. Após

Revista Produção Online. Florianópolis, SC, v.??, n.??, p. ??-??, ??/??., 201?

uma série de iterações, as partículas se acumulam em um ponto, que será escolhido como a melhor solução para o problema. A Figura 2 exemplifica o estado das partículas no início e no final das iterações.

Figura 2: Exemplo do estado inicial e final do algoritmo



Fonte: PAGMO (2018)

Eberhart e Shi (2001) separam o processo de implementação do PSO em seis principais passos:

- 1) Inicializar o grupo de partículas, atribuindo velocidades e posições aleatórias a cada uma delas;
- 2) Avaliar o valor *fitness* de cada partícula em seus respectivos pontos;
- 3) Comparar o valor *fitness* de cada partícula em sua posição atual com o seu *pbest*. Se o valor *fitness* atual for melhor do que o *pbest*, o valor *fitness* atual se torna o novo *pbest* e sua posição se torna a posição do *pbest*, caso contrário, o *pbest* permanece o mesmo;
- 4) Comparar o valor *fitness* de cada partícula em sua posição atual com o *gbest* do grupo. Se o valor *fitness* atual for melhor do que o *gbest*, o valor *fitness* atual se torna o novo *gbest* e sua posição se torna a posição do *gbest*, caso contrário, o *gbest* permanece o mesmo;
- 5) Calcular a nova velocidade (v) e a nova posição (x) de cada partícula a partir das Equações 1 e 2:

(1)

$$\begin{aligned}
 v_{k,j}(t+1) &= w \cdot v_{k,j}(t) + c_1 \cdot r_1 \cdot (pbest_{k,j} - x_{k,j}(t)) + c_2 \cdot r_2 \cdot (gbest_j - x_{k,j}(t)) \\
 x_{k,j}(t+1) &= x_{k,j}(t) + v_{k,j}(t)
 \end{aligned}
 \tag{2}$$

Sendo:

$v_{k,j}$: velocidade da partícula k na dimensão j ;

$x_{k,j}$: posição da partícula k na dimensão j ;

t : número da iteração;

w : fator de inércia;

c_1 : parâmetro de confiança na memória cognitiva;

c_2 : parâmetro de confiança na memória social;

r_1 : parâmetro aleatório da memória cognitiva;

r_2 : parâmetro aleatório da memória social;

$pbest_{k,j}$: $pbest$ da partícula k na dimensão j ;

$gbest_j$: $gbest$ na dimensão j .

- 6) Retornar ao passo 2 e executar novamente, até que um critério de parada seja atendido.

Eberhart e Shi (2001) ressaltam que a velocidade irá reduzir conforme as partículas se aproximam do valor ótimo, e que é importante atribuir um valor máximo para a velocidade, uma vez que se a velocidade for muito grande, a partícula pode passar direto pelo valor ótimo. Porém, se a velocidade for muito baixa, as partículas podem demorar muito para convergir ao valor ótimo. Para isso, os autores sugeriram a inserção do fator de inércia w , de forma a controlar a velocidade e evitar que ela atinja valores muito altos. Os autores sugerem um valor de w entre 0,4 e 0,9.

Eberhart e Shi (2001) ainda afirmam que c_1 e c_2 atribuem pesos distintos às memórias sociais e cognitivas. Valores muito baixos fazem com que as partículas percorram lugares muito distantes do espaço antes de encontrar o valor ótimo, já valores muito altos resultam em uma convergência muito brusca, podendo passar direto pelo valor ótimo. Os autores afirmam que, baseado em experiências passadas de tentativa e erro, o valor mais indicado para se atribuir a ambas as variáveis é 2,0.


2.3 Algoritmo genético

Sakawa (2001) apresenta o algoritmo genético como criação de John Holland, na década de 70, quando o pesquisador utilizou conceitos de seleção natural e genética como técnica de busca. Michalewicz (1996) explica que não somente o conceito da genética foi aproveitado nos algoritmos genéticos, mas também algumas nomenclaturas. No algoritmo, geram-se populações de indivíduos, que podem ser chamados também de cromossomos, e cada cromossomo apresenta uma solução potencial para o problema que se deseja resolver. Michalewicz (1996) diz que cromossomos são compostos de partes menores, chamadas genes, onde cada gene é uma variável do problema. O autor ainda acrescenta a definição de *locus*, que é a posição que um gene ocupa dentro do cromossomo.

Sakawa (2001) indica que um algoritmo genético inicia-se com uma população de indivíduos gerada aleatoriamente, sendo que cada indivíduo representa uma solução para o problema em questão. A cada iteração, uma nova geração de indivíduos é gerada por meio de operações genéticas, e estes novos indivíduos são avaliados por meio de um valor *fitness*, e a partir deles novas gerações são criadas, até que um critério de parada seja atendido.

Três tipos de operações genéticas são citadas por Sakawa (2001): seleção, *crossover* e mutação. A seleção consiste em selecionar os indivíduos que serão utilizados na criação dos indivíduos da próxima geração. Segundo o autor, o método mais utilizado para a seleção de indivíduos é o método da roleta, que se resume a um sorteio dentre os elementos da população, sendo que aqueles indivíduos com maior valor *fitness* possuem maior chance de serem selecionados. A Figura 3 exemplifica o funcionamento do método da roleta.

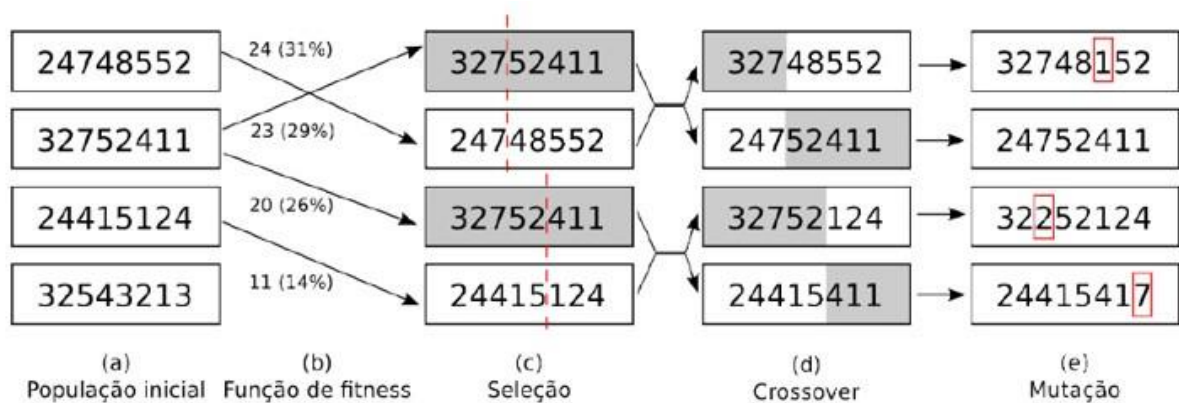
Figura 3: Exemplo do funcionamento do método da roleta



Fonte: Linden (2006)

Sakawa (2001) apresenta o *crossover* como uma das operações utilizadas para a criação de novos indivíduos a partir da população atual. Este processo se dá pela combinação de partes de diferentes cromossomos. Dois indivíduos (denominados pais) são selecionados, e posteriormente ocorre a troca de um ou mais genes entre eles. Após a troca, dois novos elementos (chamados filhos) são obtidos, sendo que cada cromossomo possui uma parte de cada pai. O autor aponta que a probabilidade de ocorrência de *crossover* geralmente utilizada varia entre 0,6 e 0,9. Sakawa (2001) ainda apresenta a mutação, processo em que um gene aleatório dentro de um indivíduo é modificado. Esta operação, segundo o autor, ocorre em menor frequência, com probabilidade entre 0,001 e 0,01. A Figura 4 exemplifica as operações genéticas que podem ocorrer no Algoritmo Genético

Figura 4: Exemplo de operações genéticas do algoritmo genético



Fonte: Teles (2011)

Banzhaf *et al.* (1998) descrevem as etapas de desenvolvimento de um algoritmo genético de forma análoga à forma descrita por Sakawa (2001). Segundo os autores, pode-se separar as etapas em:

- 1) Inicialização da população. Para isso, define-se o tamanho da população de forma aleatória (respeitando um valor máximo pré-estabelecido) e o tamanho de cada indivíduo (quantidade de genes), definindo aleatoriamente o valor de cada gene;
- 2) Calcular o valor *fitness* de cada indivíduo. Os autores ressaltam que populações iniciais, por serem aleatórias, geralmente possuem um valor *fitness* baixo;
- 3) Selecionar os indivíduos que sofrerão operações genéticas por meio de algum algoritmo de seleção;
- 4) Realizar o *crossover* entre indivíduos. Para isso, indivíduos aos pares são escolhidos, então se seleciona um ou uma sequência de genes de cada indivíduo e permutam-se as seleções, trocando os genes de um indivíduo selecionado pelos genes do outro;
- 5) Realiza-se a mutação nos indivíduos. Nessa operação, escolhem-se os indivíduos que sofrerão mutação, seleciona-se o gene que receberá a mutação e seu novo valor é gerado. A geração desse novo valor pode ser aleatória ou respeitar alguma regra pré-estabelecida;
- 6) Realiza-se a reprodução. Essa etapa consiste em inserir a cópia de um indivíduo na população. Assim, passam a haver duas versões do mesmo indivíduo;
- 7) Se o critério de parada for atingido, elege-se o indivíduo com maior valor *fitness* como solução do problema. Caso contrário, retorna-se à etapa 2.

3 METODOLOGIA

Para comparar o desempenho dos dois algoritmos evolucionários selecionados, optou-se por aplicá-los na otimização dos custos de uma cadeia de

suprimentos real. Como objeto principal de estudo, um varejista do segmento de materiais escolares e de escritório foi selecionado. A partir da escolha da empresa, selecionou-se um dos materiais de maior expressão para a companhia (possui alto volume de vendas e alto retorno financeiro), que são as resmas de papel sulfite branco tamanho A4, e desenhou-se sua cadeia imediata, elencando os fornecedores de primeira camada e os clientes de primeira camada.

A empresa selecionada possui somente um fornecedor ativo para o material em questão, e revende diretamente para os consumidores finais da cadeia. Para o presente estudo, utilizou-se uma base histórica contendo as quantidades de entrada, saída, níveis de estoque, preços de compra e preços de venda do material em um período 24 meses.

O problema proposto consiste em minimizar os custos da cadeia de suprimentos selecionada, por meio da definição da quantidade ideal de compra para cada período, de forma que os custos de armazenagem (ocasionado por estoque acima da demanda) e de venda perdida (ocasionado por estoque abaixo da demanda) se equilibrem.

A função objetivo e as restrições apresentadas a seguir resumem matematicamente o problema. O modelo matemático foi construído com base nos trabalhos de Silva (2008) e Falcone (2004), porém resultou em um modelo simplificado, devido à menor complexidade da cadeia de suprimentos aqui estudada. Ao invés do custo de fabricação, utilizou-se o custo de aquisição do material, uma vez que se trata de um varejista e não de um produtor. O custo de transporte foi desconsiderado, uma vez que o transporte do fornecedor ao varejista é pago pelo fornecedor e não há custo de transporte entre o varejista e o cliente, já que para adquirir o produto, o cliente deve se locomover até o ponto de venda. O custo de armazenagem foi simplificado, tendo em vista que não há distinção entre estoque de entrada ou de saída, como nos trabalhos de Silva (2008) e Falcone (2004), e também não há informações sobre o nível de estoque do distribuidor. O custo de falta de produto é calculado levando em conta quantas vendas foram perdidas no mês (equivale ao quanto à demanda do mês foi superior ao nível estocado). A Equação 3

Revista Produção Online. Florianópolis, SC, v.???, n.???, p. ??-??, ??/??., 201?

apresenta a função objetivo a ser solucionada, enquanto as Equações 4, 5 e 6 apresentam o cálculo dos custos de armazenagem, aquisição e venda perdida, respectivamente. A Equação 7 indica que a quantidade vendida deve ser um número maior ou igual a zero, enquanto a Equação 8 indica que a quantidade máxima vendida será a quantidade demandada no período. A Equação 9 restringe a quantidade estocada ao número máximo de itens permitidos no estoque, enquanto as Equações 10, 11 e 12 ditam que a quantidade estocada, a quantidade comprada e a quantidade demandada em cada período devem ser, respectivamente, maior ou igual a zero.

$$\text{minimizar } \textit{aval}(x) = C_{arm} + C_{aquis} + C_{falta} \quad (3)$$

tal que

$$C_{arm} = \sum_{t=1}^T K_t C_a \quad (4)$$

$$C_{aquis} = \sum_{t=1}^T I_t C_c \quad (5)$$

$$C_{falta} = \sum_{t=1}^T [D_t - (K_t + I_t - K_{t+1})] C_v \quad (6)$$

sujeito a

$$K_t + I_t - K_{t+1} \geq 0 \quad (7)$$

$$K_t + I_t - K_{t+1} \leq D_t \quad (8)$$

$$K_t \leq P \quad (9)$$

$$K_t \geq 0 \quad (10)$$

$$I_t \geq 0 \quad (11)$$

$$D_t \geq 0 \quad (12)$$

sendo que

- C_{arm} : custo total de armazenagem;
- C_{aqis} : custo total de aquisição de produtos;
- C_{falta} : custo total gerado pela falta de produtos;
- K_t : quantidade do produto em estoque no período t ;
- I_t : quantidade de produtos comprados no período t ;
- C_a : custo de armazenagem de uma unidade do produto;
- C_c : valor de compra de uma unidade do produto;
- D_t : demanda pelo produto no período t ;
- C_v : custo gerado pela falta de uma unidade do produto;
- T : quantidade de períodos a serem analisados;
- P : quantidade máxima de itens que cabem no estoque.

Para solucionar o problema apresentado, foram utilizados a Otimização por Enxame de Partículas e o Algoritmo Genético. Além disso, buscou-se solucionar o problema de maneira exata, para avaliar se há benefícios na utilização dos algoritmos evolucionários. Todas as soluções serão geradas a partir do *Microsoft Office Excel 2010*. A solução exata será calculada por meio da ferramenta *Solver*, enquanto as soluções da Otimização por Enxame de Partículas e do Algoritmo Genético serão geradas a partir de códigos elaborados pelos autores do trabalho na linguagem *Visual Basic for Applications (VBA)*.

4 RESULTADOS

Primeiramente, optou-se por resolver o problema proposto de maneira exata, pois assim pode-se medir a qualidade dos resultados encontrados pelos algoritmos evolucionários e também avaliar a eficiência da política de compras atual da papelaria. A política atual, nos 24 meses de análise, resultou em um custo de R\$33.066,00, sendo R\$32.553,00 gastos com aquisição de material, R\$513,00 gastos com custo de armazenagem e não houve vendas perdidas. As Tabelas 1 e 2 apresentam os

controles de estoques considerando a política de compras atual da empresa para o primeiro e para o segundo ano analisado, respectivamente.

Tabela 1: Controle de Estoque – Política de Compras Atual (Ano 1)

Mês	1	2	3	4	5	6	7	8	9	10	11	12
Est. Inicial	63	47	42	43	40	46	35	46	44	40	43	32
Compras	50	100	80	60	60	60	90	70	60	60	60	70
Demanda	66	105	79	63	54	71	79	72	64	57	68	51
Venda	66	105	79	63	54	71	79	72	64	57	68	51
Est. Final	47	42	43	40	46	35	46	44	40	43	35	54

Fonte: elaborada pelos autores (2018)

Tabela 2: Controle de Estoque – Política de Compras Atual (Ano 2)

Mês	13	14	15	16	17	18	19	20	21	22	23	24
Est. Inicial	54	61	54	39	34	37	61	46	28	36	40	40
Compras	80	100	80	80	80	120	90	80	90	90	80	70
Demanda	73	116	86	85	77	96	105	98	82	86	80	66
Venda	73	116	86	85	77	96	105	98	82	86	80	66
Est. Final	61	45	39	34	37	61	46	28	36	40	40	44

Fonte: elaborada pelos autores (2018)

A resolução por meio da ferramenta *Solver* do *Microsoft Office Excel 2010* apresentou um custo ótimo de R\$30.689,70 (sendo R\$29.833,20 de custo de aquisição, R\$856,50 de custo de armazenagem de sem vendas perdidas), o que resulta em uma economia de 7,2% do valor gasto. Durante o primeiro ano, a solução ótima é manter estoques zerados e comprar uma quantidade alinhada à demanda. Já para o segundo ano, a sugestão é concentrar a compra em alguns meses, uma vez que há aumentos de preço repassado pelo fornecedor nos meses 14 e 20. Nesses casos, o custo de armazenagem compensa o custo de aquisição de um insumo mais caro. As Tabelas 3 e 4 apresentam os controles de estoque apontados como solução ótima para o primeiro e para o segundo ano, respectivamente.

Tabela 3: Controle de Estoque – Solução Ótima (Ano 1)

Mês	1	2	3	4	5	6	7	8	9	10	11	12
Est. Inicial	63	0	0	0	0	0	0	0	0	0	0	0
Compras	3	105	79	63	54	71	79	72	64	57	68	51
Demanda	66	105	79	63	54	71	79	72	64	57	68	51
Venda	66	105	79	63	54	71	79	72	64	57	68	51
Est. Final	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: elaborada pelos autores (2018)

Tabela 4: Controle de Estoque – Solução Ótima (Ano 2)

Mês	13	14	15	16	17	18	19	20	21	22	23	24
Est. Inicial	0	287	171	85	0	0	0	412	314	232	146	66
Compras	360	0	0	0	77	96	517	0	0	0	0	0

Demanda	73	116	86	85	77	96	105	98	82	86	80	66
Venda	73	116	86	85	77	96	105	98	82	86	80	66
Est. Final	287	171	85	0	0	0	412	314	232	146	66	0

Fonte: elaborada pelos autores (2018)

Para a Otimização por Enxame de Partículas, utilizou-se uma população de dez partículas. Cada partícula foi representada no código VBA por um vetor de 24 posições, referentes aos 24 meses de análise. Inicialmente, um número aleatório entre 0 e 1000 foi atribuído a cada uma das 24 posições dos dez vetores, indicando a quantidade de compra. O número que ocupa a posição 1 representa a quantidade de compra no mês 1, o número da posição 2 indica a quantidade comprada no mês 2 e assim por diante. Assim, têm-se dez soluções diferentes para o problema. Para as variáveis específicas do algoritmo, seguiram-se as recomendações de Eberhart e Shi (2001). O fator de inércia w é um valor gerado aleatoriamente entre 0,4 e 0,9, os parâmetros de confiança nas memórias cognitiva e social c_1 e c_2 receberam o valor 2,0 e os parâmetros aleatórios das memórias cognitivas e social r_1 e r_2 receberam valores aleatórios entre 0 e 1. O critério de parada utilizado foi o número máximo de cinquenta iterações.

Buscando obter o melhor resultado do método estudado, o algoritmo foi programado para ser executado mil vezes seguidas, e seus resultados foram armazenados. A melhor solução apresentou um custo final de R\$31.787,08 (sendo R\$29.575,42 de custo de aquisição de material, R\$2.211,66 de custo de armazenagem e sem vendas perdidas), o que apresenta uma redução de custos para a empresa de 3,9%, porém a solução ótima apresentada pelo *Solver* ainda é mais eficiente. Nessa solução, o valor atribuído para r_1 foi 0,886582 e para r_2 foi 0,594320. As Tabelas 5 e 6 apresentam os controles de estoque apontados como solução por meio da Otimização por Enxame de Partículas para o primeiro e para o segundo ano, respectivamente.

Tabela 5: Controle de Estoque – Otimização por Enxame de Partículas (Ano 1)

Mês	1	2	3	4	5	6	7	8	9	10	11	12
Est. Inicial	63	368	263	184	121	273	202	123	51	177	120	52
Compras	371	0	0	0	206	0	0	0	190	0	0	0
Demanda	66	105	79	63	54	71	79	72	64	57	68	51
Venda	66	105	79	63	54	71	79	72	64	57	68	51
Est. Final	368	263	184	121	273	202	123	51	177	120	52	1

Fonte: elaborada pelos autores (2018)

Tabela 6: Controle de Estoque – Otimização por Enxame de Partículas (Ano 2)

Mês	13	14	15	16	17	18	19	20	21	22	23	24
Est. Inicial	1	417	301	215	130	176	80	412	314	232	146	66
Compras	489	0	0	0	123	0	437	0	0	0	0	0
Demanda	73	116	86	85	77	96	105	98	82	86	80	66
Venda	73	116	86	85	77	96	105	98	82	86	80	66
Est. Final	417	301	215	130	176	80	412	314	232	146	66	0

Fonte: elaborada pelos autores (2018)

Para a solução por meio do Algoritmo Genético foram utilizados dez cromossomos, cada um com 24 genes, de forma análoga à estrutura utilizada na Otimização por Enxame de Partículas. Para cada gene foi atribuído, inicialmente, um valor gerado aleatoriamente entre 0 e 1000. O valor do gene 1 indica a quantidade comprada no mês 1, o valor do gene 2 a quantidade de compra no mês 2 e assim por diante. O valor *fitness* dos 10 cromossomos foi avaliado a cada iteração e as

operações foram realizadas conforme as sugestões de Sakawa (2001), em que a probabilidade de ocorrência de *crossover* é de 0,6 e a probabilidade de ocorrer mutação é de 0,1. Para a seleção de cromossomos para as operações genéticas, utilizou-se o método da roleta. A seleção do ponto de corte e pontos de mutação dentro dos cromossomos selecionados foi feita aleatoriamente.

Seguindo o mesmo padrão executado na busca pela melhor solução da Otimização por Enxame de Partículas, o Algoritmo Genético foi programado para ser executado mil vezes seguidas, e seus resultados foram armazenados. O custo total da melhor solução foi R\$57.668,00 (sendo R\$50.496,50 de custo de aquisição, R\$7.171,50 de custo de armazenagem e sem vendas perdidas). Essa solução é menos vantajosa do que a política atual da empresa (apresentando um aumento de 74,4% nos custos), e por consequência menos vantajosa do que a solução ótima (87,9% mais onerosa) e do que a solução encontrada via Otimização por Enxame de Partículas (81,4% mais onerosa). As Tabelas 7 e 8 exibem os controles de estoque resultantes da solução por meio do Algoritmo Genético para o primeiro e para o segundo ano, respectivamente.

Tabela 7: Controle de Estoque – Algoritmo Genético (Ano 1)

Mês	1	2	3	4	5	6	7	8	9	10	11	12
Est. Inicial	63	270	273	284	331	348	486	515	504	610	643	579
Compras	273	108	90	110	71	209	108	58	173	90	4	5
Demanda	66	105	79	63	54	71	79	72	64	57	68	51
Venda	66	105	79	63	54	71	79	72	64	57	68	51
Est. Final	270	273	284	331	348	486	515	504	610	643	579	533

Fonte: elaborada pelos autores (2018)

Tabela 8: Controle de Estoque – Algoritmo Genético (Ano 2)

Mês	13	14	15	16	17	18	19	20	21	22	23	24
Est. Inicial	533	580	587	518	600	688	655	704	926	883	912	868
Compras	120	123	17	167	165	63	154	320	39	115	36	247
Demanda	73	116	86	85	77	96	105	98	82	86	80	66
Venda	73	116	86	85	77	96	105	98	82	86	80	66
Est. Final	580	587	518	600	688	655	704	926	883	912	868	1049

Fonte: elaborada pelos autores (2018)

Como visto na solução ótima, o ideal é que ou a empresa compre exatamente o que for demandado ou que as compras não sejam realizadas todos os meses, uma vez que o custo de armazenagem é baixo e pode compensar o custo de aquisição. A Otimização por Enxame de Partículas se mostrou vantajosa porque, a cada iteração, a velocidade calculada conduz uma redução no valor de cada posição, trazendo o resultado geral mais próximo de zero na maioria dos meses. Como o custo de aquisição de uma unidade é bastante superior ao custo de armazenagem de uma unidade, isso se torna vantajoso. Já as atualizações a cada iteração do Algoritmo Genético são mais suaves, e possuem forte influência dos primeiros cromossomos gerados aleatoriamente. A única operação que poderia atuar no Algoritmo Genético para a redução da quantidade de compra é a mutação, porém ela ocorre em apenas 1% dos genes. Além disso, quando ela ocorre, ela substitui o valor antigo por outro aleatório, que pode ser ainda mais oneroso. A operação de *crossover* pode reduzir o custo global, mas ainda assim mantém valores de compras altos para a maioria dos meses, e usa como base os valores aleatórios da primeira iteração.

5 CONCLUSÃO

Ao comparar os resultados encontrados por meio dos algoritmos evolucionários com o modelo atual de compras praticado pela empresa estudada, pode-se ver que há vantagens na utilização da Otimização por Enxame de Partículas, uma vez que ela traria uma economia para a companhia no cenário estudado de 3,9%. Porém, o Algoritmo Genético não se mostrou vantajoso nesse cenário, já que elevaria os custos da companhia em 74,4%.

As operações de cálculo de nova velocidade da Otimização por Enxame de Partículas com base nos melhores resultados de cada indivíduo e do todo se mostrou eficaz, uma vez que seguiu uma tendência de concentração do volume de compra em alguns meses, zerando a compra em outros, assim como na solução ótima. O Algoritmo Genético apresentaria melhores resultados se as operações genéticas fossem mais bruscas, feitas com maior incidência e atribuíssem maior peso aos melhores *fitness* encontrados previamente.

Ambos os algoritmos não foram tão eficazes quando comparados à solução ótima, que apresentou um ganho de 7,2% para a empresa. Nesse cenário, a utilização da Otimização por Enxame de Partículas é recomendada na ausência de um modelo de solução ótima, enquanto a utilização do Algoritmo Genético não se mostrou adequada. Ambos os algoritmos foram testados com base em um histórico de compras e vendas realizado, não sendo feita nenhuma análise para projeção futura.

REFERÊNCIAS

ARGOUD, A. R. T. T.; GONÇALVES FILHO, E. V.; TIBERTI, A. J. **Algoritmo genético de agrupamento para formação de módulos de arranjo físico**. *Gestão & Produção*, v. 15, nº 2, p. 393-405, 2008.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. Porto Alegre: Bookman, 2006.

BANZHAF, W., NORDIN, P., KELLER, R. E., FRANCONI, F. D. **Genetic Programming - An introduction**. São Francisco: Morgan Kaufmann, 1998.

BARRETO, J. M. **Inteligência artificial no limiar do século XXI**. Florianópolis: Duplic, 2001.

CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos**. São Paulo: Pearson, 2010.

EBERHART, R. C.; SHI, Y. **Particle swarm optimization: developments, applications and resources**. Proceedings of the IEEE Congress on Evolutionary Computation, v. 1, p. 81-86, 2001.

FALCONE, M. A. **G. Estudo comparativo entre algoritmos genéticos e evolução diferencial para otimização de um modelo de cadeia de suprimento simplificada**. 96 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas) – Escola Politécnica, Pontifícia Universidade Católica do Paraná, Curitiba, 2004.

GOLDBARG, M. C.; GOLDBARG, E. F. G.; MEDEIROS NETO, F. D. **Algoritmos evolucionários na determinação da configuração de custo mínimo de sistemas de co-geração de energia com base no gás natural**. Revista Brasileira de Pesquisa Operacional, v. 25, nº 2, p. 231-259, 2005.

KENNEDY, J.; EBERHART, R. C. **Swarm intelligence**. São Francisco: Morgan Kaufmann, 2001.

LAMBERT, D. M.; COOPER, M. C.; PAGH, J. D. **Supply chain management: implementation issues and research opportunities**. The International Journal of Logistics Management, v. 9, nº 2, p. 1-19, 1998.

LINDEN, R. **Algoritmos genéticos: uma importante ferramenta da inteligência computacional**. Rio de Janeiro: Editora Brasport, 2006.

MICHALEWICZ, Z. **Genetic algorithms + data structures = evolution programs**. Nova Iorque: Springer-Verlag, 1996.

PAGMO. **Particle Swarm Optimization (PSO)**. Disponível em: <<https://esa.github.io/pagmo2/docs/cpp/algorithms/pso.html>>. Acesso em: 3 dez. 2018.

PIRES, S. R. I. **Gestão da cadeia de suprimentos**. São Paulo: Atlas, 2009.

SAKAWA, M. **Genetic algorithms and fuzzy multiobjective optimization**. Norwell: Kluwer Academic Publishers, 2001.

SILVA, L. A. W. **Otimização de uma cadeia de suprimentos usando a metaheurística enxame de partículas**. 86 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas) – Escola Politécnica, Pontifícia Universidade Católica do Paraná, Curitiba, 2008.

SLACK, N. **Vantagem competitiva em manufatura**. São Paulo: Atlas, 1993.

TAVARES NETO, R. F.; GODINHO FILHO, M. **Otimização por colônia de formigas para o problema de sequenciamento de tarefas em uma única máquina com terceirização permitida**. *Gestão & Produção*, v. 20, nº 1, p. 76-86, 2013.

TELES, R. M. **Um estudo de técnicas da inteligência artificial aplicadas na distribuição de recursos em áreas geográficas**. 138 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Goiás, Goiânia, 2011.