



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

Recebido em: 30 dez. 2019


Aprovado em: 19 jun. 2020

Versão do autor aceita publicada online: 19 jun. 2020

Publicado online: 19 maio 2021

Como citar esse artigo - American Psychological Association (APA):

Mattos, M., Kleina, M., Marques, M. A. M., & Silva, W. de A. (2021, jul./set.). Aplicação de algoritmos evolucionários na otimização de um recorte de uma cadeia de suprimentos de papel. *Exacta*, 19(3), 706-728. <https://doi.org/10.5585/exactaep.2021.16318>.

Submeta seu artigo para este periódico 



Dados Crossmark



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 Mattos¹
 Mariana Kleina²
 Marcos Augusto Mendes Marques³
 William de Assis Silva⁴

Resumo: Em um cenário global cada vez mais competitivo para as empresas, é crescente a preocupação com redução de custos operacionais. Assim, a adoção de ferramentas de otimização por empresas é constante, buscando-se melhorias nos processos atuais mediante modelos matemáticos. Este artigo busca avaliar o desempenho de dois algoritmos evolucionários na otimização dos custos de uma cadeia de suprimentos, focando nos custos de aquisição de material, armazenagem e venda perdida. Para o estudo, foi analisado um recorte da cadeia de suprimentos de uma papelaria, considerando seu produto de maior receita, seus fornecedores de primeira camada e seus clientes de primeira camada. Um dos algoritmos mostrou-se eficaz comparado à política atual de compras da empresa, apresentando uma economia de 3,9%, porém, o outro apresentou um resultado ruim, elevando os custos da companhia em 74,4%. Já a solução ótima 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. Therefore, 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 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, considering its product with the biggest income, its first layer suppliers and its first layer clients. One of the algorithms was effective compared to the company's current purchasing policy, bringing a 3,9%, on the other hand, the other one presented a less favorable result to the company, raising its costs in 74,4%. The optimal solution resulted in a saving of 7,2% compared to what the company practiced.

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

¹ Graduação em Engenharia de Produção
Universidade Federal do Paraná – UFPR.
Curitiba, Paraná – Brasil.
mtts.mauricio@gmail.com

² Doutorado em Métodos Numéricos em Engenharia
Universidade Federal do Paraná – UFPR.
Curitiba, Paraná – Brasil.
marianakleina11@gmail.com

³ Doutorado em Métodos Numéricos em Engenharia
Universidade Federal do Paraná – UFPR.
Curitiba, Paraná – Brasil.
marquesamarcos@gmail.com

⁴ Mestrado em Engenharia de Produção
Universidade Federal do Paraná – UFPR.
Curitiba, Paraná – Brasil.
wiliamdeassis@gmail.com

Recebido em: 30 dez. 2019
Aprovado em: 19 jun. 2020

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. Araújo, Librantz e Alves (2009) estimam os parâmetros ponto de reposição e tamanho de lote em um modelo de gestão de estoques por meio de algoritmos genéticos. Boctor e Bolduc (2018) utilizam o chamado algoritmo evolucionário de duas populações para resolver um problema de reposição de estoque, modelado como um problema bi-objetivo: minimização da soma dos custos perdidos e de manutenção de estoque, e minimização do espaço de armazenamento necessário. Lu, Wu, Tan, Peng e Chen (2018) utilizam algoritmo genético para resolver problemas de sequenciamento *job shop* distribuídos e flexíveis, mudando dimensões de espaços de cromossomos de 1D para 3D. Yavari e Isvandi (2018) apresentam uma heurística baseada em algoritmo genético para solucionar um problema de agendamento de montagem em duas etapas na cadeia de suprimentos de três níveis. Wu, Huo, Zhang e Zhang (2018) utilizam otimização por enxame de partículas quânticas para minimizar simultaneamente custos logísticos e ambientais em uma cadeia de suprimentos. Afify *et al.* (2019) aplicam algoritmos de aprendizagem evolucionária para resolver problemas de localização de instalações em cadeias de suprimentos, visando a minimização dos custos de instalação e transporte das instalações para atender as demandas dos clientes.

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. Para muitas empresas de vários setores, o gerenciamento da cadeia de suprimentos é uma das tarefas mais importantes em suas operações diárias e planejamento a longo prazo (Xu *et al.*, 2019). 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. Fahimnia, Tang, Davarzani e Sarkis (2015) mostram que análises quantitativas do risco na cadeia de suprimentos se expandiu



rapidamente, revelando o interesse das empresas em aumentar sua vantagem competitiva em relação aos seus concorrentes.

O presente artigo visa utilizar dois algoritmos evolucionários em uma cadeia de suprimentos real, cujo objetivo é definir a quantidade ideal de itens que devem ser comprados, e conseqüentemente calculam-se as vendas (efetivas ou perdidas) e níveis de estoque a fim de minimizar os custos envolvidos. 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

2.1 Cadeia de Suprimentos

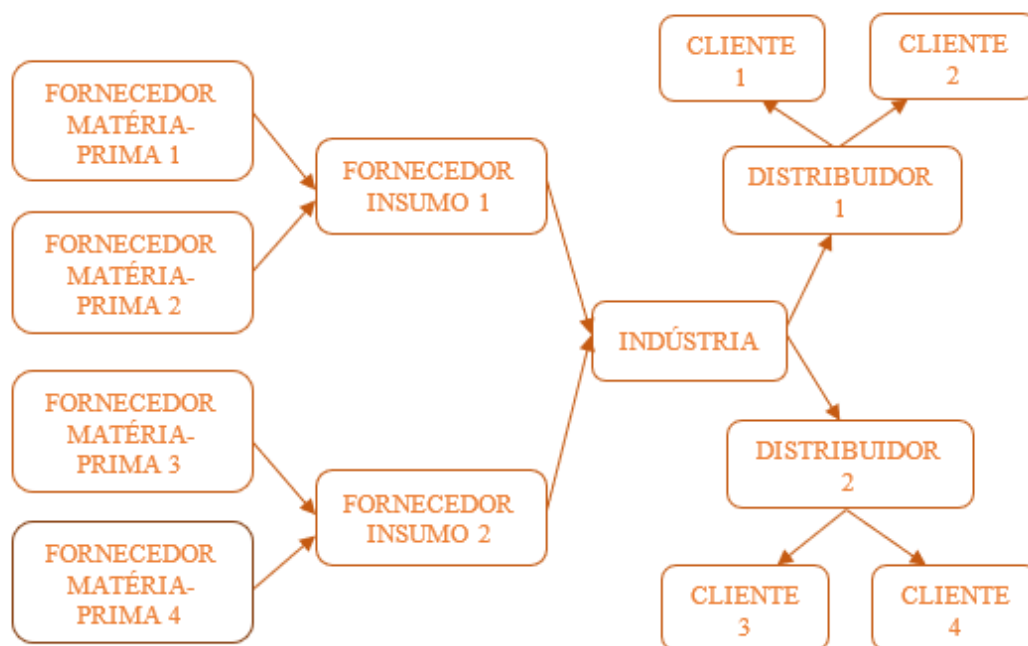
Cadeia de suprimentos pode ser definida como sendo todas as etapas que devem ser realizadas para que o pedido de um cliente seja atendido, composta não somente por fornecedores e fabricantes, mas também envolvendo pontos de venda, transportadoras, armazéns e até mesmo clientes finais (Chopra & Meindl, 2010; Ramish & Aslam, 2016; Lei, DeCandia, Oppenheim, & Zhao, 2017; Xu *et al.*, 2019). 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 (Chopra & Meindl, 2012). Segundo Munir, Jajja, Chatha e Farooq (2020), muitas empresas se esforçam para gerenciar riscos, lidar com interrupções inesperadas e melhorar o desempenho em ambientes de negócios incertos em constante mudança. Entretanto, Faustino, Amorim, Oliveira e Gohr (2018) notam que falta uma análise da colaboração dos clientes na cadeia, e muitas vezes, o único elo considerado é a partir da ótica da empresa focal.

Pires (2009) exemplifica uma cadeia de suprimentos a partir de uma montadora de veículos, 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.

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 ao fazer com que o produto seja entregue com qualidade, no tempo certo e no lugar certo, por meio de transporte, fluxo de informação e estoques eficazes (Ballou, 2006; Mital, Del Giudice & Papa, 2017). 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. Segundo Braz, De Mello, Gomes e Nascimento (2018), o efeito chicote consiste no acréscimo da demanda ao longo de uma cadeia, relacionada a distorções de informações ao longo do tempo. De acordo com os autores, as principais causas do efeito chicote são: distorções na demanda, tais como erros de previsão; pedidos em lotes, feitos com menos frequência do que pedidos individuais; flutuações de preços que podem afetar as decisões de compras dos clientes; e exagero em um pedido por parte do cliente, sabendo antecipadamente que o fornecedor disponibilizará menos quantidade do que o solicitado. Pires (2009) cita que uma consequência imediata do efeito chicote é o aumento dos níveis de estoques nas empresas, consequentemente aumentando seus custos.

É possível encontrar na literatura trabalhos relacionados à minimização de custos em uma cadeia de suprimentos e técnicas de suavização do efeito chicote (Yavari & Isvandi, 2018; Bushuev, 2018; Wu *et al.*, 2018). 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

O comportamento comunitário de animais (tais como insetos, rebanhos, pássaros e peixes) constituem uma maneira cooperativa de encontrar comida e cada membro do enxame muda seu padrão de busca de acordo com seu aprendizado e de outros membros (Wang, Tan & Liu, 2018). Kennedy e Eberhart (2001) 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 uma série de iterações, as partículas se acumulam em um ponto, que será escolhido como a melhor solução para o problema.

Wang *et al.* (2018) explicam cinco princípios básicos para a construção de um sistema de enxame com comportamento cooperativo por computador: proximidade (cálculos simples de espaço e



tempo), qualidade (resposta a mudança de qualidade no ambiente), respostas diversas (não limitar o caminho para obter os recursos em um escopo restrito), estabilidade (não trocar seu comportamento a cada mudança ambiental) e adaptabilidade (mudar seu comportamento quando essa mudança é essencial).

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

- a) Inicializar o grupo de partículas, atribuindo velocidades e posições aleatórias a cada uma delas;
- b) Avaliar o valor *fitness* de cada partícula em seus respectivos pontos;
- c) 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 de torna a posição do *pbest*, caso contrário, o *pbest* permanece o mesmo;
- d) 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 de torna a posição do *gbest*, caso contrário, o *gbest* permanece o mesmo;
- e) Calcular a nova velocidade (*v*) e a nova posição (*x*) de cada partícula a partir das Equações 1 e 2:


$$v_{k,j}(t + 1) = w \cdot v_{k,j}(t) + c_1 \cdot r_1 \cdot (pbest_{k,j} - x_{k,j}(t)) + c_2 \cdot r_2 \cdot (gbest_j - x_{k,j}(t)) \quad (1)$$

$$x_{k,j}(t + 1) = x_{k,j}(t) + v_{k,j}(t) \quad (2)$$

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*.

- f) Retornar ao passo *b* 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. 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.

Araújo *et al.* (2009) e Zhang *et al.* (2019) explicam que um algoritmo genético começa com uma população de indivíduos inicializada aleatoriamente, e que cada indivíduo representa uma solução para o problema em questão. A cada iteração, operações genéticas são aplicadas para formar uma nova geração de indivíduos, e estes 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 citados por Sakawa (2001) e Zhang *et al.* (2019): 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.

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.

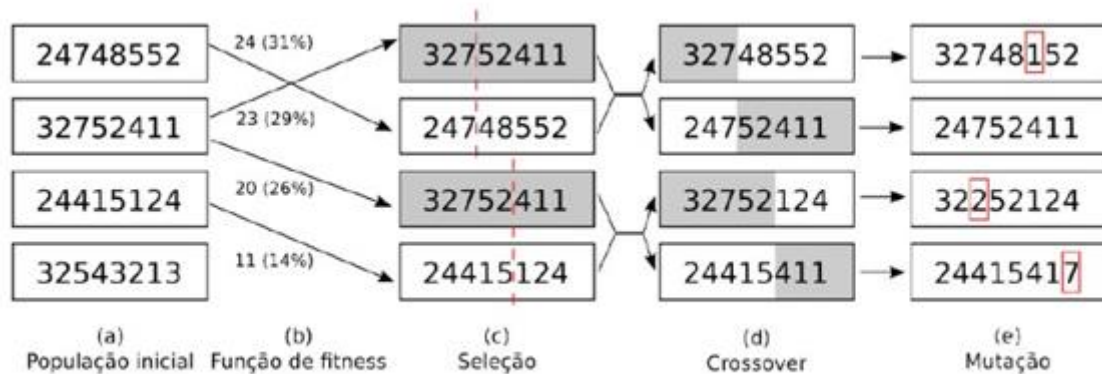
Banzhaf, Nordin, Keller e Francone (1998) descrevem as etapas de desenvolvimento de um algoritmo genético de forma análoga à forma descrita por Sakawa (2001), Araújo *et al.* (2009) e Teles (2011). Segundo os autores, pode-se separar as etapas em:

- a) 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;
- b) Calcular o valor *fitness* de cada indivíduo. Os autores ressaltam que populações iniciais, por serem aleatórias, geralmente possuem um valor *fitness* baixo;
- c) Selecionar os indivíduos que sofrerão operações genéticas por meio de algum algoritmo de seleção;
- d) Realizar o *crossover* entre indivíduos. Para isso, indivíduos aos pares são escolhidos, então se seleciona uma sequência de genes de cada indivíduo e permutam-se as seleções, trocando os genes de um indivíduo selecionado pelos genes do outro;
- e) 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;
- f) Realiza-se a reprodução. Essa etapa consiste em inserir a cópia de um indivíduo na população. Assim, passa a haver duas versões do mesmo indivíduo;
- g) 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 *b*.

A Figura 2 exemplifica as etapas descritas anteriormente que podem ocorrer no Algoritmo Genético.

Figura 2

Exemplo das Etapas do Algoritmo Genético



Fonte: Teles (2011).

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. A partir da escolha da empresa, selecionou-se um de seus materiais 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 mensal contendo as quantidades de entrada, saída, níveis de estoque, preços de compra e preços de venda do material em um período específico.

O problema proposto consiste em minimizar os custos da cadeia de suprimentos selecionada, por meio da definição da quantidade de itens do produto a ser adquirida a cada período (mês), 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.

A demanda é um dado de entrada para o modelo, e caso essa informação não seja conhecida, pode-se aplicar um método de previsão de demanda para estimá-la. 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 apresenta a função objetivo a ser minimizada, que leva em consideração um único produto. 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 a Equação 10 exige que a quantidade em cada período deve ser maior ou igual a zero.

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

tal que

$$C_{arm} = \sum_{t=1}^T K_t C_a \tag{4}$$

$$C_{aquis} = \sum_{t=1}^T I_t C_c \tag{5}$$

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

sujeito a

$$K_t + I_t - K_{t+1} \geq 0 \tag{7}$$

$$K_t + I_t - K_{t+1} \leq D_t \tag{8}$$

$$K_t \leq P \tag{9}$$

$$I_t \geq 0 \tag{10}$$

sendo que

- C_{arm} : custo total de armazenagem;
- C_{aquis} : custo total de aquisição de itens do produto;
- C_{falta} : custo total gerado pela falta de itens do produto;

- K_t : quantidade do produto em estoque no período t ;
- I_t (variável de decisão): quantidade de itens comprados do produto 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 do 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.

Portanto, o objetivo da modelagem matemática proposta é definir a quantidade de itens adquiridos do produto tal que o custo da cadeia seja o menor possível, dados o estoque no início do horizonte de planejamento e a demanda no mesmo período. Em um mês, com as informações de estoque inicial, demanda e quantidade comprada, calcula-se a quantidade vendida (que idealmente deve ser igual a demanda, para que não haja vendas perdidas) e o estoque final para aquele mês (estoque inicial mais as compras menos as vendas) que também será o estoque inicial no mês seguinte.

Para solucionar o problema apresentado, foram utilizados a Otimização por Enxame de Partículas e o Algoritmo Genético. Para avaliar a qualidade das soluções obtidas pelos algoritmos evolucionários, também são apresentadas a solução adotada pela empresa e a solução ótima. A solução exata é calculada por meio da ferramenta *Solver* do *Microsoft Office Excel 2010*, enquanto as soluções da Otimização por Enxame de Partículas e do Algoritmo Genético são geradas a partir de códigos elaborados pelos autores do trabalho na linguagem *Visual Basic for Applications (VBA)* também do *Microsoft Office Excel 2010*.

Para a Otimização por Enxame de Partículas, utilizou-se empiricamente uma população de dez partículas. Cada partícula foi representada no código VBA por um vetor de T posições, referentes aos T meses de análise. Inicialmente, um número aleatório entre 0 e 1000 foi atribuído a cada uma das T 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 (cada partícula indica uma possível solução 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 e a melhor solução (menor valor da função objetivo) apresentada.

Para a solução por meio do Algoritmo Genético foram utilizados dez cromossomos (número também escolhido empiricamente), cada um com T 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 e o melhor resultado é apresentado.

Populações maiores do que 10 indivíduos em ambos os algoritmos foram testadas, fornecendo resultados muito próximos ou até inferiores aos resultados quando usados 10 indivíduos, porém com tempo computacional maior.

4 Estudo de caso

Para a aplicação da metodologia proposta, um varejista do segmento de materiais escolares e de escritório da cidade de Curitiba-PR foi selecionado, com fornecedor na mesma cidade. A partir da escolha da empresa, selecionou-se um dos materiais de maior expressão para a companhia (alto volume de vendas e alto retorno financeiro), que são as resmas de papel sulfite branco tamanho A4. O período de aplicação da metodologia é de 24 meses (de janeiro de 2016 a dezembro de 2017), ou seja $T = 24$. O estoque inicial no primeiro mês é de 63 unidades do produto e capacidade máxima do estoque é $P = 1240$. O custo para armazenar um item é R\$0,50 e o custo de venda perdida por item é o próprio preço de venda do item (se o preço de venda do item é R\$20 e o varejista perdeu uma venda, ele deixou de ganhar R\$20, que entra para o custo dele). As demais informações para o estudo de caso são fornecidas na Tabela 1.

Tabela 1

Informações do Estudo de Caso

Mês	Demanda	Preço de compra por unidade (R\$)	Preço de venda por unidade (R\$)
1	66	15,30	18,50
2	105	15,30	18,50
3	79	15,30	18,50
4	63	15,30	18,50
5	54	15,70	18,50
6	71	15,70	19,50
7	79	15,70	19,50
8	72	15,70	19,50
9	64	16,00	19,50
10	57	16,00	19,50
11	68	16,00	19,50
12	51	16,00	19,50
13	73	16,00	22,90
14	116	17,50	22,90
15	86	17,50	22,90
16	85	17,50	22,90
17	77	17,50	22,90
18	96	17,50	22,90
19	105	17,50	25,00
20	98	21,50	25,00
21	82	21,50	25,00
22	86	21,50	25,00
23	80	21,50	25,00
24	66	21,50	25,00

Fonte: Elaborada pelos autores.

5 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. Todos os resultados são apresentados em forma de tabelas que contém: na coluna “Mês” o número do mês correspondente (1 a 24), na coluna “Estoque Inicial” a quantidade de itens disponíveis em estoque no início de cada mês, na coluna “Compras” a quantidade de itens comprados no mês, na coluna “Demanda” a demanda de itens do mês, na coluna



“Vendas” a quantidade de itens vendidos em cada mês, na coluna “Vendas Perdidas” a quantidade de itens que não foram entregues em cada mês e finalmente na coluna “Estoque Final” o estoque ao final de cada mês.

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 sem vendas perdidas. A Tabela 2 apresenta os controles de estoques considerando a política de compras atual da empresa para os 24 meses analisados. A política atual de compras da empresa foi sempre manter itens em estoque (em média 43 itens por mês), para suprir eventuais oscilações de demanda e para evitar vendas perdidas, devido ao seu alto custo e risco de perda de fidelização do cliente. O volume de vendas é sempre igual a demanda, visto que os níveis de estoque são sempre suficientes para atender a demanda, o que resultou em não ocorrer vendas perdidas em nenhum mês do período de análise.

Tabela 2

Controle de Estoque: Política de Compras Atual

Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
1	63	50	66	66	0	47
2	47	100	105	105	0	42
3	42	80	79	79	0	43
4	43	60	63	63	0	40
5	40	60	54	54	0	46
6	46	60	71	71	0	35
7	35	90	79	79	0	46
8	46	70	72	72	0	44
9	44	60	64	64	0	40
10	40	60	57	57	0	43
11	43	60	68	68	0	35
12	32	70	51	51	0	54
13	54	80	73	73	0	61
14	61	100	116	116	0	45
15	54	80	86	86	0	39
16	39	80	85	85	0	34
17	34	80	77	77	0	37
18	37	120	96	96	0	61
19	61	90	105	105	0	46
20	46	80	98	98	0	28
21	28	90	82	82	0	36

Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
22	36	90	86	86	0	40
23	40	80	80	80	0	40
24	40	70	66	66	0	44

Fonte: Elaborada pelos autores.

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 e sem vendas perdidas), o que resulta em uma economia de 7,2% do valor gasto em comparação com a política adotada pela empresa. 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. Para mitigar o impacto dos reajustes de preço, a solução proposta concentra compras nos meses anteriores aos reajustes, e nesses casos, o custo de armazenagem compensa o custo de aquisição de um insumo mais caro. Em ambos os anos analisados, com ou sem estoque, não houve venda perdida, significando que a quantidade de itens vendidos foi igual a demanda. A Tabela 3 apresenta os controles de estoque apontados como solução ótima para os 24 meses analisados.

Tabela 3

Controle de Estoque: Solução Ótima

Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
1	63	3	66	66	0	0
2	0	105	105	105	0	0
3	0	79	79	79	0	0
4	0	63	63	63	0	0
5	0	54	54	54	0	0
6	0	71	71	71	0	0
7	0	79	79	79	0	0
8	0	72	72	72	0	0
9	0	64	64	64	0	0
10	0	57	57	57	0	0
11	0	68	68	68	0	0
12	0	51	51	51	0	0
13	0	360	73	73	0	287
14	287	0	116	116	0	171



Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
15	171	0	86	86	0	85
16	85	0	85	85	0	0
17	0	77	77	77	0	0
18	0	96	96	96	0	0
19	0	517	105	105	0	412
20	412	0	98	98	0	314
21	314	0	82	82	0	232
22	232	0	86	86	0	146
23	146	0	80	80	0	66
24	66	0	66	66	0	0


Fonte: Elaborada pelos autores.

A solução obtida pela Otimização por Enxame de Partículas 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 de 3,9% em relação a política praticada pela empresa. Nessa solução, o valor atribuído para r_1 foi 0,886582 e para r_2 foi 0,594320. A Tabela 4 apresenta os controles de estoque apontados como solução por meio da Otimização por Enxame de Partículas para os 24 meses analisados. Os estoques se mantiveram altos nessa solução na grande maioria dos meses, porém no último mês do primeiro ano, apenas uma unidade do item ficou em estoque. Em nenhum dos 24 meses houve venda perdida.

Tabela 4

Controle de Estoque: Otimização por Enxame de Partículas

Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
1	63	371	66	66	0	368
2	368	0	105	105	0	263
3	263	0	79	79	0	184
4	184	0	63	63	0	121
5	121	206	54	54	0	273
6	273	0	71	71	0	202
7	202	0	79	79	0	123
8	123	0	72	72	0	51
9	51	190	64	64	0	177



Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
10	177	0	57	57	0	120
11	120	0	68	68	0	52
12	52	0	51	51	0	1
13	1	489	73	73	0	417
14	417	0	116	116	0	301
15	301	0	86	86	0	215
16	215	0	85	85	0	130
17	130	123	77	77	0	176
18	176	0	96	96	0	80
19	80	437	105	105	0	412
20	412	0	98	98	0	314
21	314	0	82	82	0	232
22	232	0	86	86	0	146
23	146	0	80	80	0	66
24	66	0	66	66	0	0

Fonte: Elaborada pelos autores.

O custo total da solução obtida pelo Algoritmo Genético 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 do que a solução encontrada via Otimização por Enxame de Partículas (81,4% mais onerosa). A Tabela 5 exibe os controles de estoque resultantes da solução por meio do Algoritmo Genético para os 24 meses analisados. É possível observar os altos níveis de estoque em todos os meses (média de 600 itens em cada mês), também não havendo vendas perdidas nesta solução.



Tabela 5

Controle de Estoque: Algoritmo Genético

Mês	Estoque Inicial	Compras	Demanda	Vendas	Vendas Perdidas	Estoque Final
1	63	273	66	66	0	270
2	270	108	105	105	0	273
3	273	90	79	79	0	284
4	284	110	63	63	0	331
5	331	71	54	54	0	348
6	348	209	71	71	0	486
7	486	108	79	79	0	515
8	515	58	72	72	0	504
9	504	173	64	64	0	610
10	610	90	57	57	0	643
11	643	4	68	68	0	579
12	579	5	51	51	0	533
13	533	120	73	73	0	580
14	580	123	116	116	0	587
15	587	17	86	86	0	518
16	518	167	85	85	0	600
17	600	165	77	77	0	688
18	688	63	96	96	0	655
19	655	154	105	105	0	704
20	704	320	98	98	0	926
21	926	39	82	82	0	883
22	883	115	86	86	0	912
23	912	36	80	80	0	868
24	868	247	66	66	0	1049

Fonte: Elaborada pelos autores.

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. Uma das operações que poderia atuar no Algoritmo Genético para a redução da quantidade de compras 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.

6 Conclusões

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.

A solução ótima apresentou um ganho de 7,2% para a empresa, entretanto ela só foi possível de ser calculada porque o problema é pequeno. 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.


Entretanto, os dois algoritmos evolucionários selecionados usam diferentes parâmetros em suas abordagens, e apesar deste trabalho tentar padronizar os experimentos, não se pode afirmar que Otimização por Enxame de Partículas é melhor do que Algoritmos Genéticos para resolver problemas dessa natureza. Ambos os algoritmos foram testados com base em um histórico de compras e vendas realizado, não sendo feita nenhuma análise para projeção futura.

Referências

- Afify, B., Ray, S., Soeanu, A., Awasthi, A., Debbabi, M., & Allouch, M. (2019). Evolutionary learning algorithm for reliable facility location under disruption. *Expert Systems with Applications*, 115, 223-244.
- Araújo, S. A. de, Librantz, A. F. H., & Alves, W. A. L. (2009). Algoritmos genéticos na estimação de parâmetros em gestão de estoque. *Exacta*, 7(1), 21-29.



- Ballou, R. H. (2006). *Gerenciamento da cadeia de suprimentos/logística empresarial*. Porto Alegre: Bookman.
- Banzhaf, W., Nordin, P., Keller, R. E., & Francone, F. D. (1998). *Genetic Programming - An introduction*. São Francisco: Morgan Kaufmann.
- Barreto, J. M. (2001). *Inteligência artificial no limiar do século XXI*. Florianópolis: Duplic.
- Braz, A. C., De Mello, A. M., Gomes, L. A. V., Nascimento, P. T. N. (2018). The bullwhip effect in closed-loop supply chains: A systematic literature review. *Journal of Cleaner Production*, 202, 376-389.
- Boctor, F., & Bolduc, M. (2018). The inventory replenishment planning and staggering problem: a bi-objective approach. *4OR*, 16(2), 199-224.
- Bushuev, M. A. (2018). Delivery performance improvement in two-stage supply chain. *International Journal of Production Economics*, 195, 66-73.
- Chopra, S. & Meindl, P. (2010) *Gerenciamento da cadeia de suprimentos*. São Paulo: Pearson.
- Chopra, S., & Meindl, P. (2012). *Supply chain management: strategy, planning and operation*. 5 ed. Prentice Hall PTR, UpperSaddle River.
- Eberhart, R. C., & Shi, Y. (2001). Particle swarm optimization: developments, applications and resources. *Proceedings of the IEEE Congress on Evolutionary Computation*, 1, 81-86.
- Falcone, M. A. G. (2004). *Estudo comparativo entre algoritmos genéticos e evolução diferencial para otimização de um modelo de cadeia de suprimento simplificada*. Dissertação de mestrado, Pontifícia Universidade Católica do Paraná, Curitiba, PR, Brasil.
- Fahimnia, B., Tang, C. S., Davarzani, H., & Sarkis, J. (2015). Quantitative models for managing supply chain risks: A review. *European Journal of Operational Research*, 247(1), 1-15.
- Faustino, C. A., Amorim, M. H. S., Oliveira, L. C. de, & Gohr, C. F. (2018). Colaboração em cadeias de suprimentos: revisão, análise e lacunas da literatura. *Exacta*, 16(1), 55–70.
- Kennedy, J., & Eberhart, R. C. (2001). *Swarm intelligence*. São Francisco: Morgan Kaufmann.
- Lambert, D. M., Cooper, M. C., & Pagh, J. D. (1998). Supply chain management: implementation issues and research opportunities. *The International Journal of Logistics Management*, 9(2), 1-19.
- Lei, L., DeCandia, L., Oppenheim, R., & Zhao, Y. (2017). *Managing supply chain operations*. Singapore: World Scientific.
- Lu, P., Wu, M., Tan, H., Peng, Y., & Chen, C. (2018). A genetic algorithm embedded with a concise chromosome representation for distributed and flexible job-shop scheduling problems. *Journal of Intelligent Manufacturing*, 29, 19-34.
- Michalewicz, Z. (1996). *Genetic algorithms + data structures = evolution programs*. Nova Iorque: Springer-Verlag.

- 
- Mital, M., Del Guidice, M., & Papa, A. (2017). Comparing supply chain risks for multiple product categories with cognitive mapping and Analytic Hierarchy Process. *Technological Forecasting and Social Change*, 119, 128-139.
- Munir, M., Jajja, M. S. S., Chatha, K. A., & Farooq, S. (2020). Supply chain risk management and operational performance: The enabling role of supply chain integration. *International Journal of Production Economics*, 227, 1-14.
- Pires, S. R. I. (2009). *Gestão da cadeia de suprimentos*. São Paulo: Atlas.
- Ramish, A., & Aslam, H. (2016). Measuring supply chain knowledge management (SCKM) performance based on double/triple loop learning principle. *International Journal of Productivity and Performance Management*, 65(5), 704-722.
- Sakawa, M. (2001). *Genetic algorithms and fuzzy multiobjective optimization*. Norwell: Kluwer Academic Publishers.
- Silva, L. A. W. (2008). *Otimização de uma cadeia de suprimentos usando a metaheurística enxame de partículas*. Dissertação de mestrado, Pontifícia Universidade Católica do Paraná, Curitiba, PR, Brasil.
- Slack, N. (1993). *Vantagem competitiva em manufatura*. São Paulo: Atlas.
- Teles, R. M. (2011). *Um estudo de técnicas da inteligência artificial aplicadas na distribuição de recursos em áreas geográficas*. Dissertação de mestrado, Universidade Federal de Goiás, Goiânia, GO, Brasil.
- Wang, D., Tan, D., & Liu, L. (2018). Particle swarm optimization algorithm: an overview. *Soft Computing*, 22, 387-408.
- Wu, D., Huo, J., Zhang, G., & Zhang, W. (2018). Minimization of Logistics Cost and Carbon Emissions Based on Quantum Particle Swarm Optimization. *Sustainability*, 10(10), 1-15.
- Xu, M., Cui, Y., Hu, M., Xu, X., Zhang, Z., Liang, S., & Qu, S. (2019). Supply Chain Sustainability Risk and Assessment. *Journal of Cleaner Production*, 225, 857-867.
- Yavari, M., & Isvandi, S. (2018). Integrated decision making for parts ordering and scheduling of jobs on two-stage assembly problem in three level supply chain. *Journal of Manufacturing Systems*, 46, 137-151.
- Zhang, Y., Gao, X., Smith, K., Inial, G., Liu, S., Conil, L. B., & Pan, B. (2019). Integrating water quality and operation into prediction of water production in drinking water treatment plants by genetic algorithm enhanced artificial neural network. *Water Research*, 164, 1-12.