

“Ars Longa, Vita Brevis.”

Hipócrates

Resumo

Gestão de estoques de produtos, estimativas e metas de vendas, apropriação de custos e lucros em uma empresa do setor varejista são algumas das atividades que devem estar diretamente alinhadas à sua área de compras. Sistemas computacionais de gestão integrada do tipo ERPs (*Enterprise Resource Planning*) provêm alguma ajuda nesse sentido. Entretanto, decisões acerca da quantidade de um dado produto a ser comprada, a data da compra, o fornecedor a ser escolhido, entre outras questões, são críticas para o sucesso de uma empresa comercial ao final do seu ciclo de revenda e não necessariamente estão disponíveis nesses aplicativos.

O processo de tomada de decisão relativo à área de compras de uma empresa deve passar pela análise de um conjunto de variáveis, cujo comportamento pode depender de uma série de fatores (*e.g.* metas da empresa, aceitação do produto, eventos sazonais, políticas de preços e prazos). Logo, tanto a quantidade como o comportamento, muitas vezes complexo, de variáveis envolvidas nesse processo podem dificultar uma análise mais minuciosa e efetiva por parte do gestor de compras da empresa.

Para a tomada de uma boa decisão, o gestor de compras, além de bastante experiência, deve dispor de ferramentas capazes de, em meio a um volume muito grande de informações, oferecer indicadores que o auxiliem seu processo de tomada de decisão.

Este trabalho mostra uma aplicação da técnica AGPSO (*Acceleration-Guided Particle Swarm Optimization*) a um modelo do contexto de gestão de compras centralizadas de uma empresa do setor varejista.

Como contribuição científica, esse trabalho apresenta uma nova abordagem para o problema de gestão de compras que implementa alguns conceitos de *swarm intelligence*, no sentido de auxiliar um gerente de compras em uma empresa, oferecendo, entre outros, os seguintes indicadores de longo prazo: quantidade de um dado produto a ser comprada e a data mais adequada para essa compra. Adicionalmente, propomos uma nova heurística para ajudar a solucionar o problema de determinação do preço de revenda de um produto dentro dessa nova abordagem.

Abstract

Inventory management, sales estimates and targets, carrying costs and profits in a retailer company are some of the activities that must be directly aligned to their purchasing area. Computational Systems with an integrated management such as ERPs (Enterprise Resource Planning) could help on that direction. However, decisions about the quantity of a given product to be purchased, date of purchase, the supplier to be chosen, among others, are critical to the success of a business resale cycle; those are not necessarily available in ERPs.

The decision-making process on the purchase area of a company must go through the analysis of a set of variables, whose behavior may depend on a number of factors (*e.g.* goals of the company, acceptance of the product, seasonal events, pricing policies and deadlines). So, both the quantity and the behavior, often complex, of variables involved in this process can refrain proper analyses, *i.e.* more thorough and effective ones, to be performed by the company's purchasing manager.

To make a good decision, the purchase manager, rather than experience, must have also tools that, in the midst of a sea of information, provide indicators that aide their decision-making process as a whole.

In this work we present an application of technical AGPSO (Acceleration-Guided Particle Swarm Optimization), a computational intelligence technique of the swarm intelligence class, to the context of a model of centralized management of purchases of a company in the retail sector. As scientific contributions, this work presents a new approach to the problem of purchasing management that implements some concepts of swarm intelligence, in order to assist a manager of purchases in a company. The proposed approach provides, among others, the following long term indicators: quantity of a given product to be purchased and the date most suitable for this purchase. Additionally, we propose a new heuristic to help on solving the problem of determining the resale price of a product.

Sumário

Índice de Figuras	v
Índice de Tabelas	vi
Tabela de Símbolos e Siglas	vii
1 Introdução	9
1.1 Visão geral do trabalho	9
1.2 Visão geral da solução	10
1.3 Objetivos	10
1.4 Estrutura do trabalho e organização dos capítulos	10
2 Referencial Teórico	12
2.1 Gestão de Compras	12
2.1.1 Gestão de estoque	12
2.1.2 Função compra	13
2.1.3 Gestão da cadeia de suprimento	14
2.2 Otimização com algoritmos de exames	16
2.2.1 Algoritmos de enxames	16
2.2.2 Particle Swarm Optimization (PSO)	17
2.2.3 Acceleration-Guided Particle Swarm Optimization (AGPSO)	20
3 Aplicação de AGPSO à Gestão de Compras Centralizadas	22
3.1 Premissas e notação	22
3.2 Descrição do modelo matemático	24
3.2.1 Lucro total esperado para o fornecedor por unidade de tempo	24
3.2.2 Lucro total esperado para o comprador por unidade de tempo	25
3.2.3 Lucro total esperado para o comprador e fornecedor por unidade de tempo	27
3.2.4 Otimização do modelo matemático	28
3.3 Descrição do modelo computacional	28
4 Estudo de Casos	31
4.1 Caso 1 – Cenário com apenas um produto e uma filial	31
4.2 Caso 2 – Cenário com apenas um produto e várias filiais	33
4.3 Caso 3 – Cenário com vários produtos e apenas uma filial	36
4.4 Caso 4 – Cenário com vários produtos e várias filiais	38
4.5 Análise comparativa de resultados com PSO e GA	40
5 Conclusão	42
5.1 Resumo da Contribuição	42
5.2 Trabalhos relacionados	43
5.3 Discussão	43
5.4 Trabalhos Futuros	44

Índice de Figuras

Figura 1 – Admitindo-se um <i>mark-up</i> de 17%	14
Figura 2 – Modelo <i>beer distribution</i> adaptado de Brian <i>et al.</i> [4]	15
Figura 3 – Cadeia de suprimento <i>multi-echelon</i>	16
Figura 4 – Fluxograma para o PSO adaptado de Niu [33]	19
Figura 5 – Seqüência de passos do AGPSO aplicado ao problema de gestão de compras	29
Figura 6 – Lucro total obtido analiticamente e experimentalmente	33
Figura 7 – Estrutura em escalão para uma empresa com várias filiais e apenas um produto	34
Figura 8 – Estrutura em escalação para uma empresa com apenas uma filial e vários produtos	36
Figura 9 – Preço de compra e venda, respectivamente, para todos os produtos	37
Figura 10 – Estrutura em escalão de uma empresa com várias filiais e vários produtos	38
Figura 11 – Parcela de contribuição de cada produto para o lucro total do modelo	39
Figura 12 – Análise comparativa da curva de convergência para GA, PSO e AGPSO	41

Índice de Tabelas

Tabela 1. Experimentos realizados para o para o caso 1	32
Tabela 2. Valores dos parâmetros de configuração a_{ik} e δ_{ik} para os experimentos do caso 2	35
Tabela 3. Resultados dos experimentos para o caso 2	35
Tabela 4. Experimentos realizados para o caso 3	37
Tabela 5. Valores dos parâmetros de configuração a_{ik} e δ_{ik} para os experimentos do caso 4	39
Tabela 6. Preços sugeridos para revenda dos produtos em cada uma das filiais	39
Tabela 7. Resultados comparativos entre GA, PSO e AGPSO	40

Tabela de Símbolos e Siglas

(Dispostos em ordem alfabética)

ACO – *Ant Colony Optimization*

AGPSO – *Acceleration-Guided Particle Swarm Optimization*

EOQ – *Economic Order Quantity*

ERP – *Enterprise Resource Planning*

JIT – *Just-in-Time*

MRP – *Materials Requiriments Planning*

MRP 2 – *Manufacturing Resource Planning*

PSO – *Particle Swarm Optimization*

Agradecimentos

Agradeço primeiramente aos meus pais que, mesmo distantes, sempre estiveram próximos e presentes. É a eles que dedico este trabalho.

Obrigado a todos os professores do Departamento de Sistemas Computacionais por, desempenhando seus trabalhos com competência, seriedade e compromisso, contribuírem para minha formação acadêmica e moral. Agradecimentos especiais ao Prof. Fernando Buarque por seus ensinamentos e orientações tanto na Iniciação Científica, como neste trabalho. Ao Prof. Renato Fernandes, que também me orientou na Iniciação Científica.

A todos os colegas e amigos com quem convivi. Essa vivência, somada às dificuldades e desafios da academia, foi enriquecedora para todos.

Por fim, a todos os que, direta ou indiretamente, ajudaram a enriquecer esse trabalho com sugestões, críticas e apoios técnicos.

Capítulo 1

Introdução

1.1 Visão geral do trabalho

Estimativas e metas de custos e lucros de uma empresa devem estar diretamente alinhadas à sua área de compras [7]. Para se ter uma dimensão da importância dessa área para as empresas como um todo, atualmente, segundo Gaither e Frazier [13]:

“Em média, cerca de 60% do dinheiro das vendas das fábricas é pago a fornecedores por materiais comprados. Por exemplo, os fabricantes de automóveis gastam cerca de 60% de suas receitas em compras de materiais...”.

Com isso, a área de compras assume um papel estratégico nas empresas, já que suas decisões podem afetar diretamente os custos e lucros e, conseqüentemente, possíveis metas de uma empresa varejista.

Segundo Pooler [35], a quantidade de variáveis envolvidas no processo de decisão de um gerente de compras é um fator crítico e ao mesmo tempo é muito importante para a escolha da decisão mais alinhada ao perfil da empresa. A escolha de qual produto a se adquirir, quais empresas devem fornecer e ainda por quais preços e termos devem ser negociados são exemplos de preocupações inerentes ao setor de compras de uma empresa do mercado revendedor.

A decisão de quando comprar e quanto comprar representa um grande impacto na composição de custos e desejáveis lucros em negócios varejistas. Este tipo de decisão é normalmente apoiada por métodos determinísticos que se baseiam principalmente em três indicadores: quantidade atual no estoque, nível mínimo do estoque e um histórico do consumo para um dado produto [7]. No entanto, essa decisão pode tornar-se ainda mais complexa quando existem muitos locais de estoque, condições de consumo variáveis e políticas para a escolha de fornecedores são levadas em consideração [37], [23].

Visando reduzir a complexidade e o custo desse tipo de decisão, segundo Cavinato *et al.*: “parcerias mais estratégicas com um número relativamente pequeno de fornecedores é comumente aceito em teoria como uma melhor prática...” [7]. Em conseqüência disso, Cavinato *et al.* [7] afirmam que:

“Para competir com sucesso no futuro, companhias irão integrar além dos limites de suas próprias organizações e alinhar seus processos centrais e funções de negócio com um modelo empresarial estendido consistindo de fornecedores, clientes e prestadores terceirizados.”.

Portanto, o modelo matemático de um ambiente de compras adotado neste trabalho segue a abordagem do “modelo empresarial estendido”, consistindo de fornecedor e comprador.

1.2 Visão geral da solução

Modelos matemáticos propostos para descrever um ambiente de compras no intuito de especificar com precisão pontos de máximo para uma função compra ainda são restritos em termos do número de variáveis envolvidas e de escalabilidade. Isso se deve à (i) quantidade de variáveis normalmente presentes em um ambiente de compras e, conseqüentemente, (ii) à complexidade envolvida no cálculo de funções cujo número de variáveis é relativamente grande (e.g. da ordem de 100 variáveis).

Nesse contexto, técnicas computacionais de busca conhecidas como *swarm intelligence* (e.g. *Particle Swarm Optimization – PSO*, *Ant Colony Optimization – ACO*) podem ser bastante úteis, uma vez que são implementadas com o intuito de manipular um volume relativamente grande de informações, além de serem escaláveis de forma computacionalmente barata.

Assim sendo, este trabalho estende o modelo matemático de um ambiente de compras [17], incorporando ao cenário a existência de filiais e mais de um produto por filial de um único comprador. Tudo isso visando dotar a contribuição de ainda mais realismo e, conseqüentemente, melhorar a sua aplicabilidade em situações práticas vivenciadas por um gerente de compras em seu processo de tomada de decisões. Além disso, este trabalho propõe a aplicação de uma variante do PSO original, denominada AGPSO (*Acceleration-Guided Particle Swarm Optimization*) ao problema de maximização do lucro obtido pela avaliação da função compra do modelo comprador-fornecedor.

1.3 Objetivos

O principal objetivo deste trabalho é produzir um novo modelo que ofereça indicadores de longo prazo para auxiliarem no processo de decisão de um gerente de compras acerca (i) do melhor momento para a compra de produtos, (ii) da quantidade de produtos a serem comprados, (iii) do preço de revenda de produtos para diferentes filiais de uma empresa e (iv) da quantidade de lotes de produtos a serem fabricados por um fornecedor. Tudo isso pode ser de grande valia para um gerente em seu planejamento estratégico de médio e longo prazos.

1.4 Estrutura do trabalho e organização dos capítulos

No Capítulo 2, são introduzidos alguns conceitos e técnicas necessários para o entendimento da solução proposta. Inicialmente, no Capítulo 2, o enfoque à área de gestão de compras é direcionado para a gestão de estoque e gestão da cadeia de suprimento (duas das principais áreas gerenciais relativas à área de compras abordadas nesse trabalho). Ainda no Capítulo 2, são discutidos os principais conceitos de algoritmos de enxames e, mais detalhadamente, PSO e quais mudanças foram incorporadas por AGPSO.

No Capítulo 3, são descritas as formulações matemática e computacional da contribuição científica deste trabalho. O modelo matemático a ser descrito é uma extensão do modelo descrito por Ho *et al.* [17].

No Capítulo 4, são realizados alguns estudos de casos elaborados com a finalidade de demonstrar aspectos importantes da solução proposta. Para o Capítulo 4, inicialmente, o modelo proposto no Capítulo 3 é avaliado por meio de uma comparação com os resultados obtidos pela avaliação matemática do modelo originalmente proposto [17]; o novo modelo é avaliado para diferentes cenários e os resultados apresentados são discutidos e comparados com os de outras técnicas.

Algumas considerações, discussões e conclusões quanto aos resultados obtidos por meio de estudos de casos realizados no Capítulo 4, além de sugestões para trabalhos futuros são apresentados no Capítulo 5.

Capítulo 2

Referencial Teórico

Neste capítulo são feitos alguns esclarecimentos sobre conceitos e técnicas da área de gestão de compras, voltados mais especificamente para a gestão de estoques e gestão da cadeia de suprimentos. Em seguida, é dada uma visão geral de uma área da computação inteligente chamada inteligência de enxames (*swarm intelligence*) [30] e dentro desse contexto, são apresentadas a técnica PSO e sua variante AGPSO.

2.1 Gestão de Compras

As decisões de um gerente de compras têm impacto direto sobre vários setores dentro e fora da empresa, o que justifica a relevância e complexidade de seus trabalhos [6]. Logo, seu trabalho de gerência acaba por englobar outras áreas que não só a de compras. Nesta seção, serão apresentadas duas dessas áreas: estoque e cadeia de suprimento.

2.1.1 Gestão de estoque

O principal objetivo da gestão de estoque é equilibrar três fatores: (i) custos devido à apropriação de produtos, (ii) vantagens com a compra de grandes quantidades de produtos e (iii) a necessidade do consumidor por um determinado produto ou serviço. O tópico (i), assim como o modelo EOQ (*Economic Order Quantity*) para controle de estoque, e os principais conceitos que podem ser aplicados à gestão de estoques são abordados nesta seção.

Níveis de estoque elevados representam custos financeiros indesejáveis em alguns cenários econômicos. Por outro lado, níveis de estoque muito baixos podem significar perda de vendas para a empresa, o que é igualmente indesejável. Por meio de uma gestão de estoque apropriada, um gerente, operando em um ambiente dinâmico (*e.g.* demanda e preços variáveis), deve controlar a quantidade de produtos que compõem o seu *mix*, de acordo com metas a serem cumpridas (*i.e.* lucro, parceria com fornecedores). No entanto, para que haja um equilíbrio entre demanda e estoque é fundamental a escolha de uma política correta de reposição e um modelo adequado para o controle do estoque.

As duas políticas de reposição de estoque mais comuns são: política de revisão contínua e política de revisão periódica [16]. Para a política de revisão contínua, o estoque é constantemente monitorado e quando cai a um nível, definido previamente como ponto de reposição, uma ordem de compra de Q unidades é gerada para restaurar o nível do estoque. Para a política de revisão

periódica, as revisões do estoque e as decisões de compra são feitas em intervalos fixos de tempo T e, para cada revisão, uma quantidade Q' de produtos é ordenada para trazer o nível do estoque de volta ao valor inicial R .

Aliado a uma política de revisão, pode ser usado um modelo para controle do estoque. Como uma abordagem popular para o cálculo da quantidade de produtos que irão compor uma ordem, o modelo EOQ determina a quantidade que implica um menor custo. O cálculo da quantidade a ser comprada para um produto é dado por [7]:

$$Q = \sqrt{\frac{2(A \times S)}{I \times C}}. \quad (2.1)$$

Onde,

A = Consumo anual em unidade

S = Custo de uma ordem de compra, por ordem

I = Porcentagem anual do custo de manuseamento

C = Custo por unidade

Q = Quantidade a ser comprada

No entanto, o modelo EOQ é mais adequado quando: a demanda é relativamente constante e conhecida, o produto é comprado em lotes, custo da ordem e o custo de manuseamento são conhecidos e o *lead time* é constante [7].

Análise ABC, MRP (*Materials Requirements Planning*), MRP 2 (*Manufacturing Resource Planning*), JIT (*Just-in-Time*) e ERP (*Enterprise Resource Planning*) são exemplos de outros modelos para controle de estoque.

Existem vários custos marginais normalmente associados à apropriação de produtos. Custo de armazenamento, segurança, custo do capital aplicado e taxas obsolescência são apenas alguns deles. Algumas dessas despesas recaem tanto sobre o comprador como sobre o fornecedor, na medida em que ao longo da duração do ciclo de consumo ou de produção há a possibilidade de dano, roubo, etc, e a necessidade de armazenamento, controle, etc, de produtos. A maioria das estimativas de custos com o manuseamento do estoque varia de 10% a 25% do valor do estoque [7].

Algumas técnicas comuns para redução de custos marginais, que fazem parte do gerenciamento do estoque, são: melhorar a comunicação entre as entidades da cadeia de suprimento, negociar entregas mais freqüentes, priorizar os fornecedores com melhores tempos de entrega, entre outras [7].

2.1.2 Função compra

Decisões oriundas da área de compras têm importância significativa para a composição de modelos de custos e lucros de empresas revendedoras (*retailer*). Transações que envolvem a compra de uma quantidade q , em uma data d , de um produto por um valor v e a venda do mesmo, em uma data d' , por outro valor p , tal que $p > v$, são a fonte da maior parte do lucro dessas empresas. A diferença entre p e v é normalmente chamada de *mark-up* [29]. A Figura 1 ilustra o conceito de *mark-up*.




Figura 1. Admitindo-se um *mark-up* de 17%.

Por meio do *mark-up* é possível perceber a influência do preço v , pago pelo revendedor ao fornecedor pela compra de mercadorias, sobre o preço de revenda p dessas mercadorias. Da Figura 1, pode-se afirmar que a margem de lucro da empresa revendedora será menor que 17%, uma vez que, segundo Lepsch [29], o lucro da empresa está embutido no valor do *mark-up*. Logo, cabe a um gerente de compras definir adequadamente um valor para o *mark-up* com vistas a pagar custos devido à aquisição de produtos e garantir um lucro ao final do processo de revenda.

Baseado em Lepsch [29], pode-se concluir de que o valor p de venda de um produto é constituído em sua maior parte pelo valor de compra v . Com isso, a margem de lucro da empresa está direta e fortemente atrelada ao valor v . Logo, é fundamental para um gerente de compras determinar adequadamente valores para q , d , v , d' e p no intuito de maximizar o lucro da empresa.

Ao modelo de decisão, adotado por um gerente de compras, que pondera fatores para tomada de decisões acerca das variáveis acima citadas, dá-se o nome de função compra (*purchasing function*). Negociação de preços e prazos com fornecedores, níveis de estoque para os itens comprados e política de compra são exemplos desses fatores [34].

Quando a responsabilidade para a tomada dessa decisão se concentra em uma unidade central sob o controle de um gerente, tem-se uma função compra centralizada. Por sua vez, quando essa responsabilidade se distribui ao longo de várias unidades operacionais que compõem uma organização, fica caracterizado um modelo de compra descentralizado. Ainda que não haja uma regra que especifique o percentual de centralização que deveria existir em uma organização, são normalmente aceitos vários argumentos que justificam essa prática [7]. É importante destacar, dentre esses argumentos, (i) a vantagem de coordenar mais facilmente políticas de interesse global para empresa, (ii) a capacidade de negociar preços menores com os fornecedores, devido à quantidade de produtos para uma ordem ser normalmente maior que aquela resultante de uma política descentralizada e (iii) a facilidade para lidar com outras funções administrativas centralizadas, tais como fornecedores. Jorgensen *et al.* [21] fazem um estudo comparativo entre os dois modelos aplicados a dois problemas comuns em gestão de compras: políticas para definição de preços (*pricing*) e de reposição de estoque.

2.1.3 Gestão da cadeia de suprimento

Várias entidades interligadas através de uma infra-estrutura de transporte e comunicação compõem uma rede ao longo da qual bens de consumo, por meio da adição de valores, fluem do estágio inicial (matéria-prima) ao estágio final (consumidor). A essa complexa rede de entidades chama-se cadeia de suprimento.

Maximizar a satisfação do consumidor e minimizar os custos das entidades envolvidas são os principais objetivos do gerenciamento da cadeia de suprimento, que consiste no gerenciamento de informação, reserva financeira e o fluxo de produtos de um ponto de origem para um ponto de

consumo [7]. Dos três elementos-chave mencionados acima, *i.e.* (i) a noção de informação, reserva financeira e o fluxo de produtos entre as entidades, (ii) maximizar a satisfação do consumidor e (iii) minimizar os custos das entidades envolvidas, apenas o (iii) será considerado em detalhes nesse trabalho.

Segundo Martins [31], muitas empresas passaram a usar a denominação gerenciamento da cadeia de suprimentos, ao invés de simplesmente função compra, substituindo um conceito voltado para transações em si por outro voltado para processo. A idéia de processo é mais adequada quando se observa a área de compras de uma empresa interligada aos demais níveis de uma cadeia de suprimento. A Figura 2 ilustra o modelo *beer distribution* [18] de uma cadeia de suprimentos multi-nível.

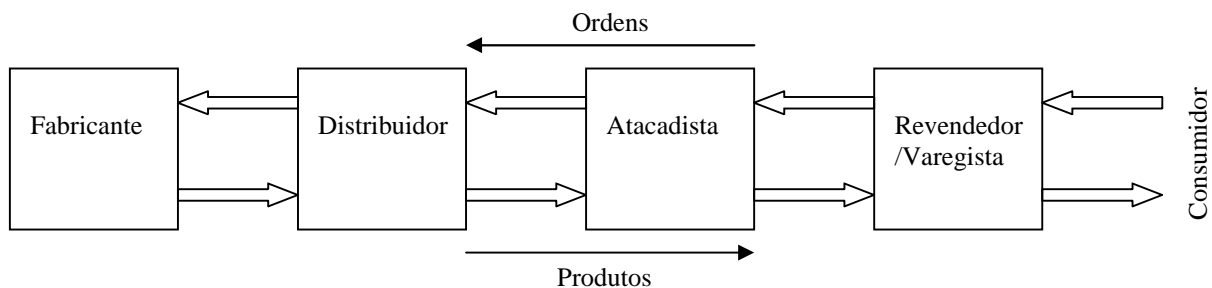


Figura 2. Modelo *beer distribution* adaptado de Brian *et al.* [4].

O modelo *beer distribution* inclui quatro níveis: fabricante, distribuidor, atacadista e revendedor e, nesse sistema, as ordens se propagam dos consumidores para o fabricante. Ou seja, um revendedor tenta prever a demanda oriunda dos consumidores e efetua um pedido para o atacadista baseado nessa análise; cabe ao atacadista decidir a quantidade a ser ordenada para o próximo nível. Essas ordens se propagam até o fabricante, que deve decidir quantas unidades deve produzir. Em resposta às ordens, os produtos fluem do fabricante para o revendedor, sendo armazenados em cada um dos níveis acima. Por fim, o consumidor pode novamente dar continuidade ao ciclo.

Outra importante forma de classificar a estruturação de uma cadeia de suprimento é com relação à presença de escalões (*echelon*) nos níveis de distribuição dessa cadeia. Uma estrutura adequada para a cadeia de suprimento é uma questão estratégica para todas as entidades que a integram. “Uma cadeia de suprimento com estrutura complexa é, às vezes, uma das causas para variabilidades na demanda e baixo desempenho de políticas de gestão de estoque.” [22]. A Figura 3 representa uma cadeia de suprimento multi-escalão (*multi-echelon*).

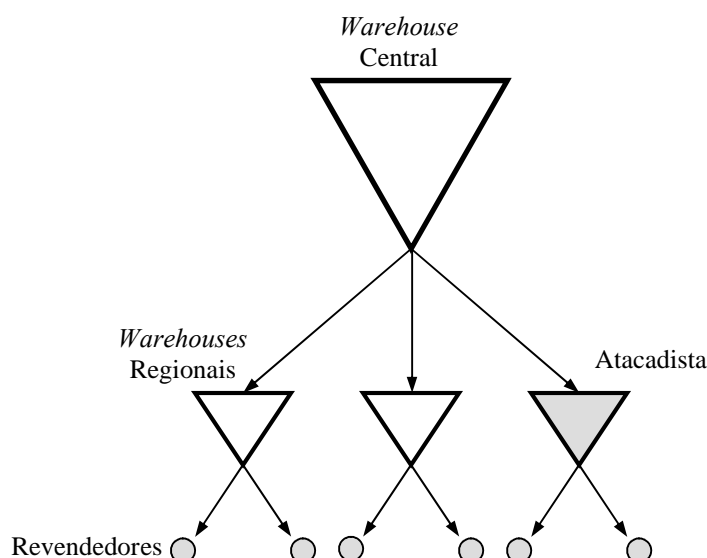


Figura 3. Cadeia de suprimento *multi-echelon*.

Por meio da Figura 3 pode-se perceber a disposição hierárquica de entidades ao longo dos níveis de uma cadeia de negócio e/ou ao longo de um mesmo nível. Segundo essa disposição, no nível mais baixo, revendedores são abastecidos por *Warehouses* setoriais, localizadas em regiões estratégicas, que, por sua vez, são abastecidas por uma *Warehouse* central.

Estudos (Cachon *et al.* [5], Chen *et al.* [9], D’Amours *et al.* [10], Lee *et al.* [26][27][28], Simchi-Levi *et al.* [39], Zhao *et al.* [42]) têm mostrado que os benefícios da visibilidade de informações através dos níveis de uma cadeia de suprimento (*information sharing*) podem contribuir com vantagens (*e.g.* redução de custo, redução de estoque, aumento na confiabilidade de entregas) que tornem as empresas mais competitivas. Além disso, parcerias entre empresas e fornecedores são uma importante arma na busca por condições de negócio mais estáveis e lucrativas para ambos, evitando situações caóticas (*e.g.* muitos fornecedores, diferentes tempos de entrega) que são responsáveis por elevações nos custos com o gerenciamento de estoque e da cadeia de suprimento [25]. A respeito de parcerias estratégicas entre entidades de uma cadeia de negócio, Cavinato *et al.* [7] afirmam que:

“À medida que essas parcerias estratégicas para reduzir custos da cadeia de suprimento se difundem, nós iremos começar a ver competições entre cadeias de suprimentos, em acréscimo à competição entre companhias.”.

2.2 Otimização com algoritmos de enxames

Nesta seção são discutidos, de um modo geral, alguns conceitos relativos a algoritmos de enxames e a sua aplicação a problemas de otimização. As técnicas de otimização PSO e sua variante AGPSO são tratadas em detalhe.

2.2.1 Algoritmos de enxames

Algoritmos pertencentes a essa abordagem são inspirados no comportamento coletivo emergente de um grupo de animais (*e.g.* formigas, abelhas, lobos). Esses animais, no modelo, ainda que

sejam dotados de capacidades individuais bastante limitadas, são capazes de, por meio de cooperação, realizar diversas tarefas relativamente complexas. A mais comum delas é uma tarefa de busca. Ou seja, dados um objetivo e um espaço de busca a ser explorado, as entidades de um enxame devem, cooperativamente, encontrar uma solução que satisfaça o objetivo. Quando essa busca é realizada visando encontrar um valor ótimo (*i.e.* de acordo com a necessidade imposta por um dado objetivo: maximizar ou minimizar uma função, por exemplo) para uma função matemática não-linear, tem-se um problema de otimização.

Duas das principais vantagens do uso de algoritmos de enxames em problemas de otimização são que, devido à baixa complexidade associada a cada entidade do enxame e à sua capacidade de cooperação, (i) o custo computacional para abordar problemas relativamente complexos é baixo comparado ao de outras técnicas analíticas como derivadas parciais e (ii) os comportamentos de cada uma das partículas que compõem o enxame, embora usufruam da cooperação, são, no entanto, independentes entre si. Em termos de modelagem computacional, a independência mencionada em (ii) pode resultar facilmente em processamento paralelo, o que representa um ganho significativo de desempenho em relação à computação seqüencial.

2.2.2 Particle Swarm Optimization (PSO)

Sejam:

1. g uma função matemática contínua e não-linear.
2. $D(g)$ o seu conjunto domínio.
3. $S_0 \subset D$ escolhido aleatoriamente.
4. $n = \#S_0$.
5. $P \in S_i \therefore P = (x_1, x_2, \dots, x_d)$.
6. $f: D \rightarrow D \therefore f(P_i) = P_{i+1}$.
7. $F: D^* \rightarrow D^* \therefore F(S_i) = \{f(P_1), f(P_2), \dots, f(P_n)\} = S_{i+1}$.

Baseado-se em simulações de modelos que representavam o comportamento social de populações (*e.g. fish school, bird flock*), Kennedy e Eberhart [24] propuseram uma técnica de computação evolutiva denominada *Particle Swarm Optimization* (PSO). Segundo essa técnica, cada partícula P pertencente a um enxame S_i representa uma possível solução para a função matemática g a ser otimizada. Além disso, cada partícula possui velocidade e aceleração próprias e sua posição é alterada pela função f , descrita pela Equação (2.2):

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (2.2)$$

$$v_i(t+1) = \omega v_i(t) + c_1 r_1 (P_i(t) - x_i(t)) + c_2 r_2 (P_g(t) - x_i(t)). \quad (2.3)$$

A cada iteração i , tem-se um novo enxame de partículas S_{i+1} gerado a partir da aplicação de f a cada partícula P em S_i . Na Equação (2.3), P_i e P_g representam as melhores soluções local, para cada partícula individualmente, e global para o problema, respectivamente. ω é um fator de inércia que representa o peso da velocidade na iteração anterior sobre a atual. c_1 e c_2 são constantes conhecidas como coeficiente cognitivo e coeficiente social, respectivamente, e determinam a influência de P_i e P_g sobre a nova velocidade da partícula. Ou seja, c_1 representa a influência de um máximo local de uma partícula sobre o seu processo de busca especificamente. c_2 representa a influência de um máximo global sobre o processo de busca de todas as partículas do enxame. r_1 e r_2 são valores randômicos uniformemente distribuídos entre 0 e 1. O cooperação entre as partículas se dá por meio do conhecimento compartilhado acerca da melhor solução

global para o problema, ou seja, P_g . A Figura 4 ilustra a seqüência de passos que compõem o fluxo de execução do PSO.

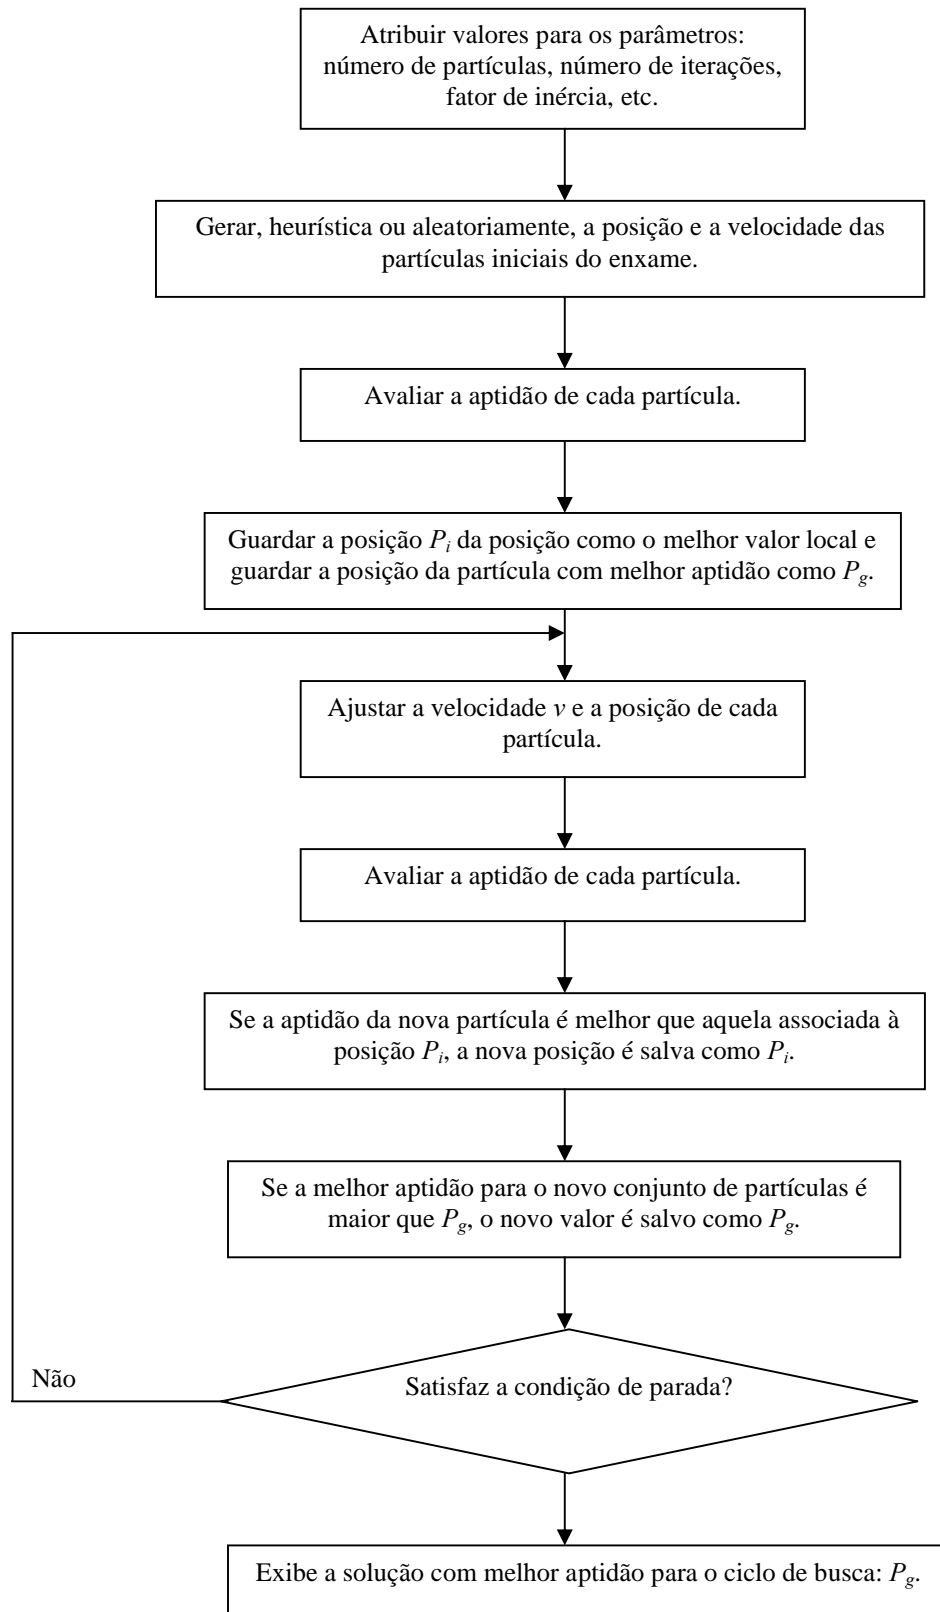


Figura 4. Fluxograma para o PSO adaptado de Niu [33].

Apesar de bastante simples, em termos de implementação, custo computacional e de operadores matemáticos, PSO tem se mostrado uma boa opção quando se deseja explorar o

conjunto domínio de funções não-lineares multimodais de alta dimensionalidade na busca por pontos de máximo (*i.e.* otimizações). Otimizações multi-objetivo [8], [19], treinamento de redes neurais artificiais [8], [38] e controle de tensão [12] são exemplos de aplicações bem sucedidas de PSO.

Da Equação (2.3) é possível perceber que a velocidade de uma partícula depende de sua posição quanto aos pontos de máximo local e global. Logo, à medida que uma partícula se aproxima de um ponto de máximo, sua velocidade diminui e, conseqüentemente, sua mobilidade no domínio ficará restrita à vizinhança desses pontos. Devido a isso, o PSO poderá convergir prematuramente para valores de máximo locais que não representam uma boa solução para o problema, especialmente para aqueles mais complexos em que $d \gg n$, ou g é uma função com muitos pontos de máximo locais.

2.2.3 Acceleration-Guided Particle Swarm Optimization (AGPSO)

Buscando solucionar o problema de convergência prematura do PSO, assim como analisar matematicamente as condições de convergência, Zeng *et al.* [41] desenvolveram uma nova versão do PSO denominada *Acceleration-Guided Particle Swarm Optimization* (AGPSO). A melhoria proposta no AGPSO consiste em usar, ao invés da variação da posição, a variação da velocidade da partícula para determinar a sua nova aceleração. Reescrevendo a Equação (2.2) para explicitar a aceleração, tem-se:

$$v_i(t+1) = \omega v_i(t) + a_i(t+1), \quad (2.4)$$

$$a_i(t+1) = c_1 r_1 (P_i(t) - x_i(t)) + c_2 r_2 (P_g(t) - x_i(t)) = \varphi_1 v_{ir1}(t) + \varphi_2 v_{ir2}(t). \quad (2.5)$$

Na Equação (2.5), φ_1 representa a influência da velocidade em direção a um máximo local de uma partícula e φ_2 representa a influência da velocidade em direção a um máximo global. Logo, adaptando a Equação (2.5) para incorporar a mudança sugerida, tem-se agora:

$$a_i(t+1) = a_{i1}(t) + a_{i2}(t) = \varphi_1 (v_{ir1}(t) - v_i(t)) + \varphi_2 (v_{ir2}(t) - v_i(t)), \quad (2.6)$$

$$v_i(t) = x_i(t) - x_i(t-1). \quad (2.7)$$

Combinando as Equações (2.6) e (2.4), tem-se:

$$v_i(t+1) = \omega v_i(t) + \varphi_1 (P_i(t) - 2x_i(t) + x_i(t-1)) + \varphi_2 (P_g(t) - 2x_i(t) + x_i(t-1)). \quad (2.8)$$

Por fim, a nova função f para o AGPSO é dada por:

$$x_i(t+1) = (\omega - \varphi_1 - \varphi_2)v_i(t) + (1 - \varphi_1 - \varphi_2)x_i(t) + \varphi_1 P_i + \varphi_2 P_g, \quad (2.9)$$

$$v_i(t+1) = (\omega - \varphi_1 - \varphi_2)v_i(t) - (\varphi_1 + \varphi_2)x_i(t) + \varphi_1 P_i + \varphi_2 P_g. \quad (2.10)$$

Demonstra-se [41] que a condição de estabilidade para a solução proposta é descrita por:

$$\varphi = \varphi_1 + \varphi_2, \quad (2.11)$$

$$\frac{\omega - 1}{2} < \varphi < \frac{\omega + 3}{2}. \quad (2.12)$$

Logo, se a escolha de valores para os parâmetros φ e ω nas equações (2.9) e (2.10) se der de tal forma que a condição descrita pela Equação (2.12) seja satisfeita, a solução será dita estável. A condição de estabilidade é importante para garantir o comportamento de convergência das partículas no modelo do AGPSO resultante.

A faixa de valores resultantes da análise da condição de estabilidade para o AGPSO pode ser muito útil, uma vez que, restringindo o conjunto domínio de valores para os parâmetros φ e ω , pode agilizar o processo de escolha dos melhores valores para aqueles parâmetros.

O ajuste dos parâmetros φ e ω , para o momento ideal de convergência global das partículas, que pode variar para cada problema de busca, é muito importante para garantir que o domínio da função seja explorado adequadamente. Se $\varphi_1 > \varphi_2$, o tempo de convergência das partículas para um máximo global é relativamente maior. No entanto, o espaço de busca é explorado mais amplamente. Esse modo de exploração é chamado de *exploration*. Caso contrário, se $\varphi_2 > \varphi_1$, as partículas podem convergir rapidamente para um possível máximo local e o processo de busca se concentrará ao longo da vizinhança desse ponto. Por sua vez, esse modo de exploração é chamado de *exploitation*.

Entende-se por um processo de busca adequado, aquele que é capaz, de acordo com a topologia resultante da função a ser otimizada, de obter soluções razoáveis para cada problema de busca especificamente. AGPSO, usando esses dois modos de exploração em conjunto e garantindo a convergência global das partículas no processo de busca, pode representar uma boa escolha para problemas de otimização.

Capítulo 3

Aplicação de AGPSO à Gestão de Compras Centralizadas

Neste capítulo, inicialmente, será deduzida a solução matemática para avaliação da função compra para um cenário de compras bi-escalão (*two-echelon*). Uma vez apresentadas as equações que regem o modelo, é feita uma breve discussão acerca da complexidade para otimização do modelo matemático proposto. Por último, como uma alternativa à aplicação de métodos analíticos para otimização da solução matemática proposta, é apresentado um modelo heurístico que implementa a técnica de otimização AGPSO para encontrar uma configuração para um cenário de compras que maximize a avaliação da função compra resultante.

3.1 Premissas e notação

Para a modelagem do ambiente de decisão de um gerente de compras foram concebidas e assumidas algumas premissas, assim como foram usadas notações para termos específicos do contexto de compras. A lista a seguir é uma extensão daquela proposta por Ho *et al.* [17]:

1. Há apenas um fornecedor e um comprador para q produtos em b filiais pertencentes ao comprador.
2. Baixos níveis de estoque (*i.e.* *Shortages*) não são permitidos.
3. Os custos despendidos com a propriedade de um produto i para o fornecedor e para o comprador são dados por r_{Vi} e r_{Bi} , respectivamente.
4. O desconto oferecido pelo fornecedor sobre o preço de compra de um produto i quando este é pago no prazo M_1 é representado por β_i ($0 < \beta_i < 1$). Caso o produto seja pago no prazo M_2 ($M_2 > M_1 \geq 0$), o valor total do preço de compra será cobrado.
5. O custo do fornecedor por unidade produzida é dado por c_i e o preço de venda é dado por v_i . Por sua vez, o preço do comprador para a revenda do produto é dado por p_{ik} , tal que k representa a filial em questão. A relação entre esses valores é dada por: $p_{ik} > v_i > (1 - \beta_i)v_i > c_i$.
6. O intervalo de tempo entre a entrega e o pagamento do produto, consequência da política de crédito do fornecedor, implica um custo de oportunidade para o fornecedor a uma taxa de I_{Vpi} .

7. Caso o produto seja pago no prazo M_1 , uma constante f_{Vci} será usada durante o intervalo $[M_1, M_2]$ para quantificar a vantagem da antecipação do pagamento para o fornecedor.
8. O comprador usa o capital obtido pela revenda dos produtos para lucrar durante o período de crédito (*i.e.* M_1 ou M_2) a uma taxa I_{Bei} . Ao final desse período, com o montante pago ao fornecedor relativo à compra dos produtos, o comprador passa a pagar um custo de oportunidade, a uma taxa de I_{Bpi} , para os itens em estoque.
9. A taxa de demanda do mercado para o item é uma função do preço de revenda e é dada por $D_{ik}(p_{ik}) = a_{ik} p_{ik}^{-\delta_{ik}}$, tal que $a_{ik} > 0$ é uma constante que representa um valor de escala para a demanda e $\delta_{ik} > 1$ é uma constante para graduar a influência da elasticidade do preço sobre a demanda final do consumidor por filial. Com isso, é possível representar a tolerância de consumidores a vários preços em diferentes filiais da empresa.
10. A duração do ciclo de reposição do estoque do comprador para um produto i é dada por T_i .
11. $Q_{ik} = D_{ik}T_i$ representa a quantidade do produto i que deve ser considerada para a filial k .
12. O tempo de duração do estoque do comprador é dado por T_i , logo, se Q_i é a quantidade de um determinado produto a ser comprada em uma ordem de compra, $Q_i = \sum_{k=1}^b Q_{ik}$.
13. Os produtos serão entregues em um centro de distribuição do comprador para, em seguida, serem distribuídos pela cadeia de revenda. Por conveniência, os custos de armazenamento nos centros de distribuição, bem como questões relativas à logística do processo, serão omitidos nesse modelo.
14. O custo por ordem e por produto para o comprador é expresso por S_{Bi} .
15. O tamanho dos lotes a serem produzidos pelo fornecedor é dado por $n_i Q_i$ (onde n_i é um número inteiro). O custo para o fornecedor por produto associado a essa política de lotes é de S_{Vi} . Uma vez que o fornecedor produz o primeiro lote, ele é enviado ao comprador, o qual continuará recebendo Q_i unidades do produto i a cada T_i unidades de tempo.
16. O fornecedor possui q processos de produção, o que lhe permite fabricar os q produtos em paralelo.
17. $D_i = Q_i / T_i = \sum_{k=1}^b D_{ik}$ é a demanda total pelo produto i .
18. A capacidade de utilização ρ_i é definida como $\rho_i = D_i / R_i$, onde R_i é a taxa de produção. Por definição, ρ_i é uma constante tal que $\rho_i < 1$.
19. $\vec{n} = (n_1, n_2, \dots, n_q)$ vetor de quantidades de lotes dos produtos de um fornecedor.
20. $\vec{T} = (T_1, T_2, \dots, T_q)$ vetor de duração dos ciclos de reposição dos produtos.
21. $\vec{p}_i = (p_{i1}, p_{i2}, \dots, p_{ib})$ vetor de preços de um produto i para todas as b filiais.
22. $\vec{p} = (\vec{p}_1, \vec{p}_2, \dots, \vec{p}_q) = (p_{11}, p_{12}, \dots, p_{1b}, p_{21}, p_{22}, \dots, p_{2b}, \dots, p_{qb})$ vetor de preços dos produtos para todas as filiais da empresa.

3.2 Descrição do modelo matemático

3.2.1 Lucro total esperado para o fornecedor por unidade de tempo

Dado que o custo total do fornecedor para dividir $n_i Q_i$ produtos em n_i lotes é S_{V_i} e a duração do ciclo de reposição para um produto i é dada por T_i , então o custo de configuração da política de lote por unidade de tempo é dado por:

$$\frac{S_{V_i}}{n_i T_i}. \quad (3.1)$$

O cálculo dos custos associados à propriedade de produtos, seguindo-se a mesma abordagem de Joglekar [20], pode ser obtido por:

$$(c_i r_{V_i} + c_i I_{V_{pi}}) \frac{D_i T_i}{2} [(n_i - 1)(1 - \rho_i) + \rho_i] = (c_i r_{V_i} + c_i I_{V_{pi}}) \frac{Q_i}{2} [(n_i - 1)(1 - \rho_i) + \rho_i]. \quad (3.2)$$

O custo de oportunidade por unidade de tempo para o fornecedor devido à política de crédito é calculado pela Equação (3.3).

$$(1 - g_j \beta_i) v_i I_{V_{pi}} D_i M_j \quad \therefore j = 1, 2; g_1 = 1, g_2 = 0. \quad (3.3)$$

A demanda, como uma função do tempo, multiplicada pela duração do ciclo de revenda do produto i resulta na quantidade total de produtos vendidos durante o período M_j . Logo, o valor total obtido pela revenda de uma quantidade $D_i M_j$ de produtos é dado por $(1 - g_j \beta_i) v_i D_i M_j$. Com isso, a uma taxa $I_{V_{pi}}$, o fornecedor paga um custo de oportunidade dado pela Equação (3.3).

Para o caso em que o pagamento é feito no prazo M_1 , durante o período $(M_2 - M_1)$ o fornecedor pode usar o valor total resultante para gerar lucros. Logo, a uma taxa $f_{V_{ci}}$ de flexibilidade do capital, o ganho por unidade de tempo é dado por:

$$(1 - \beta_i) v_i f_{V_{ci}} D_i (M_2 - M_1). \quad (3.4)$$

O valor obtido da venda dos produtos por unidade de tempo é calculado da seguinte forma:

$$(1 - g_j \beta_i) v_i D_i. \quad (3.5)$$

Por fim, o custo para a produção dos produtos do fornecedor por unidade de tempo é dado por:

$$c_i D_i. \quad (3.6)$$

Sendo assim, o lucro total esperado para o fornecedor é expresso pela lei de formação:

$$VP_j(n_i, T_i) = \{(3.5) - (3.6) - (3.1) - (3.2) - (3.3) + g_j(3.4)\} \therefore j = 1, 2; g_1 = 1, g_2 = 0, \quad (3.7)$$

$$TVP_j(\vec{n}, \vec{T}) = \sum_{i=1}^q \{VP_j(n_i, T_i)\} \therefore j = 1, 2; g_1 = 1, g_2 = 0 \quad (3.8)$$

$$= \sum_{i=1}^q \left\{ \begin{aligned} & (1 - g_j \beta_i) v_i D_i - c_i D_i - \frac{S_{Vi}}{n_i T_i} - \frac{Q_i c_i (r_{Vi} + I_{Vpi})}{2} [(n_i - 1)(1 - \rho_i) + \rho_i] \\ & - (1 - g_j \beta_i) v_i I_{Vpi} D_i M_j + g_j (1 - \beta_i) v_i f_{Vci} D_i (M_2 - M_1) \end{aligned} \right\}.$$

3.2.2 Lucro total esperado para o comprador por unidade de tempo

O custo total do comprador associado a cada ordem por unidade de tempo é:

$$\frac{S_{Bi}}{T_i}. \quad (3.9)$$

Tomando-se $\frac{Q_{ik}}{2}$ como o nível médio do estoque para uma filial durante um ciclo de reposição, o custo pela propriedade do i -ésimo produto por unidade de tempo é:

$$\sum_{k=1}^b \frac{(1 - g_j \beta_i) v_i r_{Bi} Q_{ik}}{2} = \frac{(1 - g_j \beta_i) v_i r_{Bi} T_i}{2} \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}}. \quad (3.10)$$

Na Equação (3.10), o termo $\sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}}$ representa o somatório de todas as demandas para o produto i em cada uma das filiais nas quais ele é revendido. O objetivo desse somatório é calcular o valor total da demanda pelo produto i para, em seguida, multiplicá-lo pela duração do ciclo de reposição desse produto. Com isso, tem-se a quantidade total do produto i que será necessária para suprir a demanda de cada uma das filiais durante todo o ciclo de revenda T_i . Da mesma forma que para o fornecedor, o custo de apropriação do produto i é calculado sobre o valor total pago pelo comprador a uma taxa de r_{Bi} .

Independentemente da forma de pagamento escolhida pelo comprador, existem dois possíveis casos para a duração do ciclo de reposição de um produto: (i) $T_i < M_j$ e (ii) $T_i \geq M_j$, $j=1, 2$. Para o primeiro caso, todos os produtos são vendidos antes do fim do prazo para o pagamento, logo não há custo de oportunidade para o comprador, uma vez que o capital que será empregado na compra dos produtos ainda está disponível. Ainda para o primeiro caso, durante todo o período do ciclo de reposição do produto, o comprador usa o valor obtido com a revenda dos produtos para obter lucro a uma taxa de I_{Bei} . Logo, o lucro total do comprador por unidade de tempo obtido durante o ciclo de reposição através do capital disponível é:

$$\frac{1}{T_i} \left[\sum_{k=1}^b \left\{ p_{ik} I_{Bei} \int_0^{T_i} D_{ik} t dt + p_{ik} I_{Bei} D_{ik} T_i (M_j - T_i) \right\} \right] = I_{Bei} (M_j - \frac{T_i}{2}) \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik} + 1}. \quad (3.11)$$

Para o caso (ii), quando o comprador deve pagar pelos produtos antes do período estimado para o fim do estoque, haverá um custo de oportunidade a uma taxa de I_{Bpi} que será considerado durante o período $[M_j, T_i]$. Esse custo é calculado como:

$$\frac{(1 - g_j \beta_i) v_i I_{Bpi}}{T_i} \sum_{k=1}^b \left\{ \int_{M_j}^{T_i} D_{ik} (t - M_j) dt \right\} = \frac{(1 - g_j \beta_i) v_i I_{Bpi} (T_i - M_j)^2 \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}}}{2T_i}. \quad (3.12)$$

No entanto, durante o período $[0, M_j]$ o comprador dispõe de um capital devido à venda dos produtos e, assim como no caso (i), lucra a uma taxa I_{Bei} sobre o capital disponível. O lucro total por unidade de tempo durante esse período é dado por:

$$\frac{I_{Bei}}{T_i} \left[\sum_{k=1}^b \left\{ p_{ik} \int_0^{M_j} D_{ik} t dt \right\} \right] = \frac{I_{Bei} M_j^2 \sum_{k=1}^b \{ a_{ik} p_{ik}^{-\delta_{ik}+1} \}}{2T_i}. \quad (3.13)$$

O custo do comprador por unidade de tempo com os produtos adquiridos é:

$$(1 - g_j \beta_i) v_i D_i. \quad (3.14)$$

A venda dos produtos contribui com um valor total por unidade de tempo que é dado por:

$$\sum_{k=1}^b p_{ik} D_{ik} = \sum_{k=1}^b p_{ik} (a_{ik} p_{ik}^{-\delta_{ik}}) = \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}+1}. \quad (3.15)$$

A Equação (3.16) expressa o lucro total esperado para o comprador por unidade de tempo.

$$TBP_j(\vec{p}, \vec{T}) \therefore j = 1, 2, \quad (3.16)$$

tal que

$$TBP_j(\vec{p}, \vec{T}) = \sum_{i=1}^q \left[BP_j(\vec{p}_i, T_i) = \begin{cases} BP_{j1}(\vec{p}_i, T_i) & \text{se } T_i < M_j \\ BP_{j2}(\vec{p}_i, T_i) & \text{se } T_i \geq M_j \end{cases} \right], \quad (3.17)$$

onde

$$BP_{j1}(\vec{p}_i, T_i) = \{ (3.15) - (3.14) - (3.9) - (3.10) + (3.11) \} \\ = \left\{ \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}+1} - (1 - g_j \beta_i) v_i D_i - \frac{S_{Bi}}{T_i} - \frac{(1 - g_j \beta_i) v_i r_{Bi} T_i}{2} \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}} \right. \\ \left. + I_{Bei} (M_j - \frac{T_i}{2}) \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}+1} \right\}, \quad (3.18)$$

$$BP_{j2}(\vec{p}_i, T_i) = \{ (3.15) - (3.14) - (3.9) - (3.10) + (3.13) - (3.12) \} \quad (3.19)$$

$$= \left\{ \begin{aligned} & \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}+1} - (1 - g_j \beta_i) v_i D_i - \frac{S_{Bi}}{T_i} - \frac{(1 - g_j \beta_i) v_i r_{Bi} T_i}{2} \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}} \\ & + \frac{I_{Bei} M_j^2 \sum_{k=1}^b \{a_{ik} p_{ik}^{-\delta_{ik}+1}\}}{2T_i} - \frac{(1 - g_j \beta_i) v_i I_{Bpi} (T_i - M_j)^2 \sum_{k=1}^b a_{ik} p_{ik}^{-\delta_{ik}}}{2T_i} \end{aligned} \right\}.$$

3.2.3 Lucro total esperado para o comprador e fornecedor por unidade de tempo

Uma vez definidos os lucros esperados para o comprador e para o fornecedor, cabe agora definir a função que expressa o lucro total esperado para o modelo comprador-fornecedor:

$$\Pi_j(\vec{n}, \vec{p}, \vec{T}) = (3.7) + (3.16) \therefore j = 1, 2, \quad (3.20)$$

ou

$$\Pi_j(\vec{n}, \vec{p}, \vec{T}) = \sum_{i=1}^q \left[\begin{cases} \Pi_{j1}(n_i, \vec{p}_i, T_i) & \text{se } T_i < M_j \\ \Pi_{j2}(n_i, \vec{p}_i, T_i) & \text{se } T_i \geq M_j \end{cases} \right], \quad (3.21)$$

onde

$$\Pi_{j1}(n_i, \vec{p}_i, T_i) = VP_j(n_i, T_i) + BP_{j1}(\vec{p}_i, T_i) = (3.7) + (3.18), \quad (3.22)$$

$$\Pi_{j2}(n_i, \vec{p}_i, T_i) = VP_j(n_i, T_i) + BP_{j2}(\vec{p}_i, T_i) = (3.7) + (3.19). \quad (3.23)$$

É importante ratificar que, uma vez escolhida uma política de pagamento para o modelo descrito pela Equação (3.20), ou seja, tendo-se estabelecido o valor de j , essa política será aplicada a todos os produtos. Logo, a função Π_j pode ser reescrita como:

$$\Pi_1(\vec{n}, \vec{p}, \vec{T}) = \sum_{i=1}^q \left[\begin{cases} \Pi_{11}(n_i, \vec{p}_i, T_i) & \text{se } T_i < M_1 \\ \Pi_{12}(n_i, \vec{p}_i, T_i) & \text{se } T_i \geq M_1 \end{cases} \right]. \quad (3.24)$$

e, para $j = 2$, tem-se:

$$\Pi_2(\vec{n}, \vec{p}, \vec{T}) = \sum_{i=1}^q \left[\begin{cases} \Pi_{21}(n_i, \vec{p}_i, T_i) & \text{se } T_i < M_2 \\ \Pi_{22}(n_i, \vec{p}_i, T_i) & \text{se } T_i \geq M_2 \end{cases} \right]. \quad (3.25)$$

Logo, se para uma dada escolha de valores para $(\vec{n}, \vec{p}, \vec{T})$, $\Pi_1 > \Pi_2$ então o pagamento antecipado do comprador no prazo M_1 é a política de pagamento que garante o maior lucro para o modelo comprador-fornecedor. Caso contrário, o pagamento do valor integral, sem desconto, no prazo M_2 será a melhor política de pagamento.

3.2.4 Otimização do modelo matemático

Para otimizar matematicamente o modelo descrito pela Equação (3.20) faz-se necessário o uso de técnicas para o cálculo de máximos e mínimos de funções de mais de uma variável. Uma técnica bastante conhecida para o cálculo de pontos críticos para funções de alta ordem são os Multiplicadores de Lagrange. Considerando a aplicação de Multiplicadores de Lagrange a um problema de otimização de uma função $f(x,y,z)$, uma condição necessária e suficiente para a existência de um ponto crítico é:

$$\frac{\partial f}{\partial x} = \frac{\partial f}{\partial y} = \frac{\partial f}{\partial z} = 0. \quad (3.26)$$

Como exemplo de um possível cenário para o problema de maximização do lucro do modelo comprador-fornecedor, considerando uma situação em que uma empresa, em parceria com um fornecedor, oferece 50 produtos em 3 filiais, a função Π_j para esse modelo possuiria a seguinte quantidade de variáveis:

$$\underbrace{(n_1, n_2, \dots, n_q, p_{i1}, p_{i2}, \dots, p_{qb}, T_1, T_2, \dots, T_q)}_{\substack{50 \quad 50 \times 3 \quad 50 \\ 50+150+50=250}}. \quad (3.27)$$

Sendo assim, para que fosse aplicada a técnica dos Multiplicadores de Lagrange ao cenário acima descrito na busca por pontos de máximo, a condição analítica [3] seria estendida para:

$$\frac{\partial \Pi_j}{\partial n_1} = \frac{\partial \Pi_j}{\partial n_2} = \dots = \frac{\partial \Pi_j}{\partial p_{i1}} = \frac{\partial \Pi_j}{\partial p_{i2}} = \dots = \frac{\partial \Pi_j}{\partial p_{qb}} = \frac{\partial \Pi_j}{\partial T_1} = \frac{\partial \Pi_j}{\partial T_2} = \dots = \frac{\partial \Pi_j}{\partial T_q} = 0. \quad (3.28)$$

Logo, seriam necessárias 250 operações de derivação parcial e a resolução de 250 sistemas homogêneos para que se tenha com precisão os pontos críticos do cenário acima proposto. Uma possível solução para lidar com o grau de escalabilidade necessário seria o uso de computadores vetoriais e clusters, uma vez que esse problema é relativamente difícil de ser tratado pela computação convencional. No entanto, há que se estudar o custo e o nível de complexidade necessários para a implantação de um sistema que usa essas tecnologias.

Em vista do exposto, uma solução alternativa que possibilita abordar o problema acima por meio da computação convencional (*i.e.* em termos de exigência de *hardware*) é utilizando técnicas de computação inteligente para implementação de buscas heurísticas por pontos de máximo da função Π_j .

3.3 Descrição do modelo computacional

Uma vez justificada a utilização da técnica de busca heurística AGPSO aplicada ao modelo matemático do ambiente de compras no qual as decisões de um gerente são tomadas, pode-se então definir a formulação computacional da solução proposta neste trabalho.

Tem-se que uma decisão no ambiente de compras do problema é expressa matematicamente como $(\vec{n}, \vec{p}, \vec{T})$. Com o objetivo de encontrar a decisão para a qual o lucro de

um comprador-fornecedor, que é expresso pela Equação (3.20), é máximo, o resultado da avaliação da função compra foi escolhido como alvo para avaliar a aptidão de uma solução (*i.e.* função *fitness*) para o problema de otimização. Logo, se cada partícula de um enxame representa uma possível decisão de um gerente no ambiente de compras do problema e é possível avaliar por meio da Equação (3.20) quão boa é essa decisão, ao final do processo de busca do AGPSO a partícula com melhor *fitness* representará a melhor decisão a ser tomada, para aquele ciclo de busca específico. Assim como todo método heurístico, o AGPSO apresentará diferentes resultados para cada ciclo de busca. No Capítulo 4 serão apresentados e discutidos alguns desses resultados.

Como o objetivo da solução é maximizar o valor de uma soma (lucro do comprador somado ao lucro do fornecedor), o lucro máximo obtido pela avaliação da função compra para o comprador pode resultar em um valor negativo. Para que essa situação indesejada aconteça, basta que o preço p de revenda sugerido para alguns produtos seja menor que o preço de compra v . Isso é facilmente explicado, uma vez que o objetivo proposto é encontrar o lucro máximo para modelo que integra comprador e fornecedor. Logo, como o valor do lucro calculado para o fornecedor necessariamente é bem superior ao do comprador, o AGPSO de fato encontrou um valor de máximo, no entanto, um máximo local para o fornecedor. Com o objetivo de evitar situações em que $p \leq v$ ou o lucro de alguma das entidades do modelo é negativo, foi adotado um critério de penalidade para as partículas. A Equação (3.29) mostra o critério usado. Heuristicamente, os melhores resultados foram obtidos para $\alpha = 0,991$.

$$restrição(\vec{n}, \vec{p}, \vec{T}) = \begin{cases} \Pi_j(\vec{n}, \vec{p}, \vec{T}) & \text{se } p_{ik} > v_i \\ \alpha \times \Pi_j(\vec{n}, \vec{p}, \vec{T}) & \text{se } p_{ik} \leq v_i \end{cases} \quad \therefore 0 < \alpha < 1. \quad (3.29)$$

Da mesma forma que esse critério foi implementado, outros critérios também podem ser criados (*e.g.* margem mínima de lucro para o preço de revenda, menor valor de revenda para uma determinada filial) com o objetivo de melhorar, para o AGPSO, o processo de convergência para uma solução mais adequada e, para a empresa, ajustar a solução às necessidades estratégicas do gerente de compras.

Na Figura 5 há um diagrama de fluxo que ilustra a seqüência de passos do AGPSO, no entanto aplicada ao contexto de gestão de compras, como descrito acima.

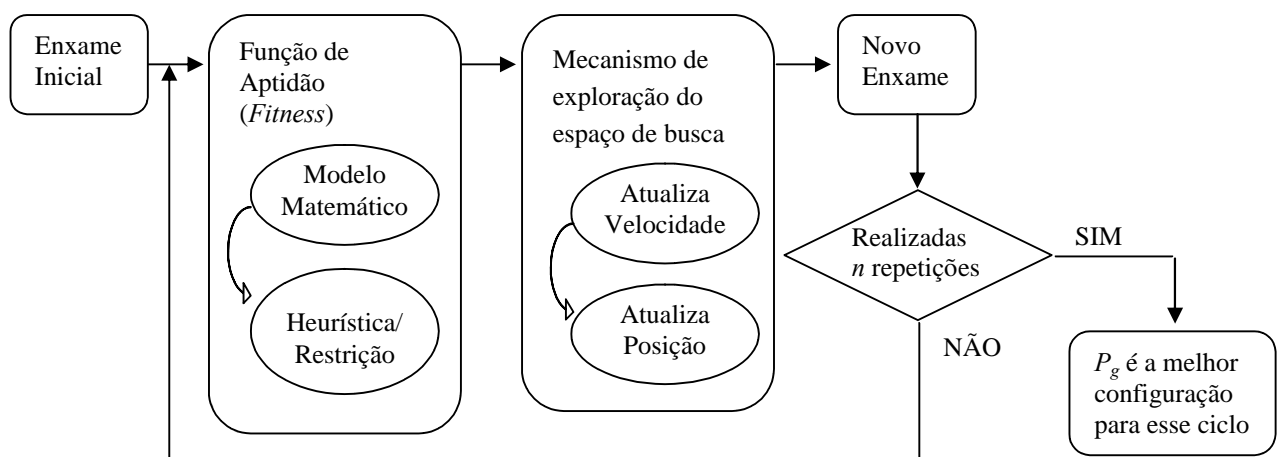


Figura 5. Seqüência de passos do AGPSO aplicada ao problema de gestão de compras.

Inicialmente, um enxame de partículas é criado, estando essas partículas dispostas aleatoriamente no domínio da função descrita pela Equação (3.20). Cada partícula, expressa matematicamente como $(\vec{n}, \vec{p}, \vec{T})$, representa uma possível decisão para o novo cenário de compras proposto neste trabalho. Em seguida, o modelo matemático, dado pela Equação (3.20), é usado para avaliar cada partícula. O resultado dessa avaliação, ou seja, o lucro total do comprador somado ao do lucro total fornecedor, serve de base para atualizar as respectivas componentes de exploração do espaço de busca (*i.e.* aceleração, velocidade e posição) para cada partícula, de acordo com as Equações (2.9) e (2.10). Se ainda não houverem sido realizadas as n repetições previstas para esse ciclo de busca específico, o novo enxame, ou seja, o novo conjunto de possíveis decisões, é avaliado. Uma vez realizadas as n iterações, chega-se ao fim do ciclo de busca e o máximo global, para esse ciclo de busca, representa a melhor decisão sugerida pelo algoritmo, ou seja, aquela que resultará no maior lucro para o comprador e para o fornecedor somados.

Logo, ajustando-se adequadamente os modos de exploração (*i.e.* *exploitation* e *exploration*) para o AGPSO aplicado ao problema de decisão acerca de $(\vec{n}, \vec{p}, \vec{T})$, para novo cenário de compras proposto neste trabalho, tem-se um método potencialmente útil. Especialmente em cenários com quantidades relativamente grandes de filiais e produtos.

Capítulo 4

Estudo de Casos

Para este capítulo, inicialmente será feita uma comparação dos resultados obtidos por Ho *et al.* [17] para alguns dos diferentes cenários avaliados naquele trabalho. O objetivo é demonstrar que AGPSO aplicado ao problema de gestão de compras centralizadas pode oferecer resultados satisfatórios (*i.e.* próximos àqueles obtidos por meio da avaliação do modelo usando métodos analíticos). Em acréscimo, o AGPSO é aplicado a diferentes cenários propostos de um ambiente de compra, visando demonstrar empiricamente que os resultados obtidos são condizentes com os resultados esperados para cada um dos cenários. Para isso, são apresentadas algumas hipóteses acerca do impacto esperado sobre variáveis de decisão (*e.g.* preço de revenda, duração do ciclo de reposição) devido à variação de alguns dos parâmetros de configuração do cenário. Essas hipóteses foram criadas intuitivamente e algumas delas seguem o mesmo princípio usado para elaboração de alguns estudos numéricos originalmente propostos [17].

Como critério de referência para avaliar os resultados em cenários para mais de um produto e mais de uma filial, foi escolhida a comparação com os resultados obtidos pela aplicação de Algoritmos Genéticos (*Genetic Algorithm* – GA [15]) e PSO.

O modelo adotado para cada um dos experimentos possui apenas um comprador e um fornecedor. Para os experimentos originalmente descritos [17] e em todos os experimentos que se seguem foram usados os seguintes parâmetros de configuração do ambiente de compras: $\rho_i = 0,9$, $S_{Vi} = \$1000/\text{setup}$, $S_{Bi} = \$300/\text{ordem}$, $r_{Vi} = 0,05$, $r_{Bi} = 0,08$, $I_{Vpi} = 0,09/\$/\text{ano}$, $I_{Bpi} = 0,16/\$/\text{ano}$, $I_{Bei} = 0,18/\$/\text{ano}$, $f_{Vci} = 0,17/\$/\text{ano}$ e $\beta_i = 2\%$, para todos os produtos.

O valor ω do coeficiente de inércia do AGPSO varia linear e decrescentemente no intervalo $[0,4;1]$. Essa é a mesma configuração adotada por Zeng *et al.* [41] em seus experimentos e essa foi também a melhor configuração para alguns experimentos iniciais em cenários de compra. O número de iterações, partículas, os valores de configuração e o número de vezes em que o experimento é repetido adotados em simulações com o AGPSO foram escolhidos de acordo com a complexidade do experimento.

4.1 Caso 1 – Cenário com apenas um produto e uma filial

O cenário estudado neste caso corresponde ao mais simples possível, *i.e.* uma empresa que, em parceria com um fornecedor, oferece um único produto em apenas uma filial. Essa situação,

como explicado anteriormente, é puramente ilustrativa e visa comparar os resultados obtidos experimentalmente com aqueles obtidos analiticamente.

Ho *et al.* [17] realizaram diversos estudos numéricos que buscavam avaliar o impacto da variação de diferentes parâmetros (*i.e.* M_1 , M_2 , β) sobre o lucro total resultante da avaliação da função compra. Os valores de configuração de alguns desses estudos foram usados nesta seção para criar diferentes instâncias e, para cada uma delas, o AGPSO é aplicado objetivando comparar resultados.

Os valores dos parâmetros de configuração do modelo deste cenário foram: $a_{11} = 250000$, $\delta_{11} = 1,25$, $c_1 = \$2/\text{unid}$, $v_1 = \$4.5/\text{unid}$. O número de iterações, partículas e o número de vezes em que o experimento é repetido usados pelo AGPSO para a realização desses experimentos foram 5000, 30 e 50 respectivamente.

Os experimentos foram realizados para diferentes valores de M_1 e M_2 , representando possíveis termos de crédito a serem acordados em parcerias entre a empresa e fornecedor. A Tabela 1 contém dez experimentos, cada um composto por duas linhas de dados. Na primeira, os valores são os obtidos por Ho *et al.* [17], *i.e.* pela avaliação matemática do modelo. Na segunda linha estão os resultados obtidos pela aplicação do AGPSO implementado nesse trabalho.

Devido à existência de apenas um fornecedor, um comprador e um produto, a notação a ser usada nesse estudo para T_1 (tempo de reposição do estoque), p_{11} (preço de revenda do produto) e Q_1 (quantidade a ser ordenada pelo comprador) será: $p = p_{11}$, $n = n_1$, $T = T_1$ e $Q = Q_1$.

Tabela 1. Experimentos realizados para o caso 1.

M_1 (dias)	M_2 (dias)	Melhor época para pagamento	n	p	T (dias)	Q	Lucro (\$)		
							Comprador	Fornecedor	Total
0	0	-	12	10,78	$T = 69,77$	2446	77499	30862	108361
		-	13	10,86	$T = 60,38$	2098	78857	29491	108348
0	30	30	14	10,62	$T_2 = 62,00$	2214	77941	31048	108988
		0	20	10,48	$T_{12} = 60,72$	2206	77501	31611	109112
10	30	10	12	10,52	$T_{12} = 68,61$	2481	77987	31076	109063
		10	12	10,52	$T_{12} = 67,30$	2434	78019	31042	109062
20	30	20	13	10,57	$T_{12} = 66,03$	2373	78529	30471	109000
		20	10	10,56	$T_{12} = 72,90$	2623	78512	30463	108975
0	60	60	17	10,51	$T_1 = 49,51$	1792	79276	31088	110365
		60	29	10,57	$T_1 = 45,34$	1629	79485	30780	110265
10	60	60	17	10,51	$T_{21} = 49,51$	1792	79276	31088	110365
		60	20	10,68	$T_{21} = 42,48$	1507	79802	30505	110307
20	60	60	17	10,51	$T_{21} = 49,51$	1792	79276	31088	110365
		60	26	10,68	$T_{21} = 41,57$	1475	78814	30454	110268
0	90	90	17	10,52	$T_1 = 49,53$	1790	81370	30609	111979
		90	22	10,66	$T_1 = 43,25$	1540	81791	30139	111930
10	90	90	17	10,52	$T_{21} = 49,53$	1790	81370	30609	111979
		90	24	10,52	$T_{21} = 48,30$	1746	81370	30566	111936
20	90	90	17	10,52	$T_{21} = 49,53$	1790	81370	30609	111979
		90	19	10,61	$T_{21} = 45,29$	1620	81666	30294	111960

A Figura 6 ilustra comparativamente os valores presentes na Tabela 1 referentes ao lucro total.




Figura 6. Lucro total obtido analiticamente e experimentalmente.

Ao analisar a Tabela 1, pode-se observar que os resultados obtidos experimentalmente, para todas as situações de termos de crédito e para todos os valores sugeridos, foram bastante próximos daqueles obtidos analiticamente. Algumas divergências mais significativas em relação ao valor sugerido n se devem especificamente ao comportamento da função para essa variável, que permite variações relativamente grandes desse valor sem que isso resulte em impactos tão significativos para o lucro total. Ho *et al.* [17] realizaram um estudo mais detalhado desse comportamento isoladamente.

É importante mencionar que, embora o resultado da aplicação de AGPSO para o segundo experimento tenha sido superior àquele obtido analiticamente, o resultado experimental é de fato mais próximo de um máximo global. Por meio de uma análise mais cuidadosa, foi possível determinar que para $\Pi_j(14;10,62;0,1698)$ têm-se os seguintes valores:

$$\Pi_1(14;10,62;0,1698) = 109168,88, \quad (4.1)$$

$$\Pi_2(14;10,62;0,1698) = 108988,16. \quad (4.2)$$

4.2 Caso 2 – Cenário com apenas um produto e várias filiais

Para essa seção, a estrutura do cenário de decisão foi de uma única empresa que oferece apenas um produto em várias de suas filiais. A Figura 7 é um esquema do modelo a ser usado nos experimentos desse estudo de caso.

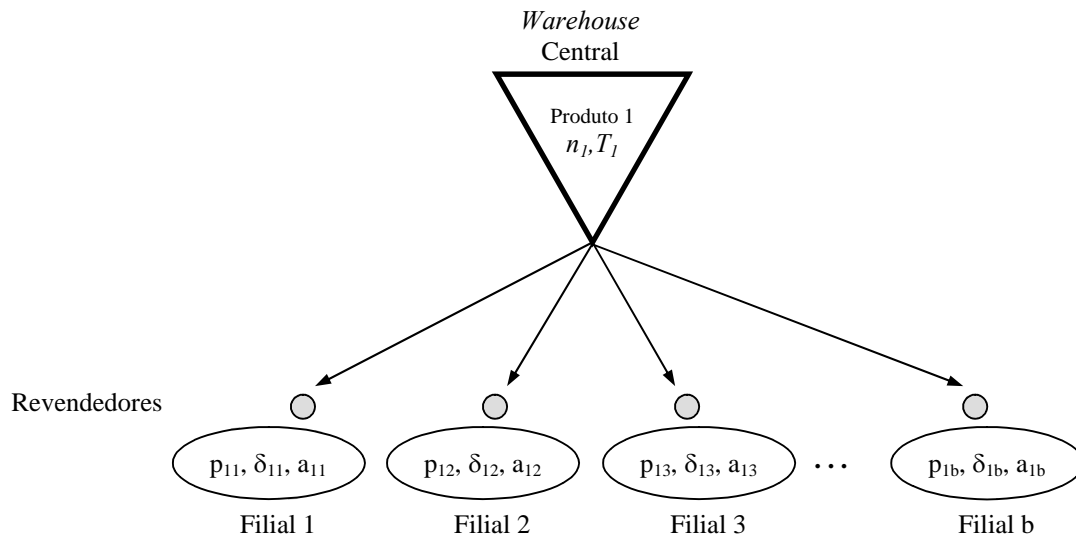


Figura 7. Estrutura em escalon de uma empresa com várias filiais e apenas um produto.

Devido à existência de várias filiais, os experimentos foram realizados variando-se os valores de parâmetros que poderiam estar fortemente relacionados à localização geográfica de cada filial [32], [14].

Matematicamente, pode-se observar que, de $D(p_{ik}) = a_{ik} p_{ik}^{-\delta_{ik}}$, para p_{ik} constante, D é diretamente proporcional a a_{ik} e decrescente quando o valor de δ_{ik} aumenta. Logo, é possível representar por esse modelo uma situação específica em que a tolerância a preços maiores de um mesmo produto em certas regiões é baixa por meio da escolha de diferentes valores de δ_{ik} para cada região. Por exemplo, normalmente, o preço de um produto para filiais que estão localizadas em regiões onde o poder aquisitivo da população é relativamente alto é maior que o preço do mesmo produto em filiais onde o poder de compra da população é relativamente baixo.

Da mesma forma, a demanda por um dado produto em uma filial localizada em uma certa região está normalmente associada à densidade populacional daquela região. Assumindo-se que essa demanda é diretamente proporcional à densidade populacional, pode-se usar o parâmetro a_{ik} para representar essa densidade.

Segundo Mulhern *et al.* [32], “Conhecimentos acerca de quais fatores determinam a sensibilidade a variações de preço podem ajudar revendedores em muitos contextos de tomada de decisão”. Por exemplo, informações sobre a sensibilidade a variações de preço podem ajudar um gerente de compras quanto à decisão de quais níveis de desconto podem ser aplicados a produtos em promoções e quais itens podem suportar um aumento regular no valor de revenda. Ainda sobre variações no preço de revenda de produtos, Mulhern *et al.* [32] afirmam que:

“Além disso, um conhecimento de determinantes de sensibilidade a variações de preço podem ajudar revendedores a implementar estratégias *micro-marketing* com diferentes preços em diferentes lojas ou áreas de mercado revendedor.”.

Assumindo que existem duas possibilidades de comportamento para a densidade populacional (*i.e.* alta ou baixa) e para a sensibilidade a variações de preço (*i.e.* tolerante ou não tolerante) para cada uma das filiais, tem-se um total de $(2 \times 2)^3 = 64$ possíveis experimentos. Entretanto, para este estudo de caso, serão eleitas apenas oito situações representativas do

mesmo. A Tabela 2 mostra a combinação de parâmetros utilizados para a realização dos experimentos. Os valores de a para essa tabela estão representados na escala de milhares. Os resultados obtidos para cada uma das seqüências de valores apresentados são exibidos na Tabela 3.

O objetivo desse estudo é analisar os efeitos de a_{ik} (fator de escala para a demanda) e δ_{ik} (coeficiente de elasticidade do preço de revenda) sobre o lucro total do modelo e sobre o preço final de revenda p_{ik} . Para isso, foram obtidos os resultados da aplicação do AGPSO a esse modelo para diferentes valores de a_{ik} e δ_{ik} .

Para os experimentos realizados nesse estudo, o número de iterações, partículas e o número de vezes em que o experimento é repetido usados pelo AGPSO foram 5000, 30 e 50 respectivamente. Os valores para c , e v são iguais àqueles usados para Seção 4.1. Os prazos que compõem a política de crédito para esse estudo são $M_1 = 10$ dias e $M_2 = 30$ dias. Ainda para os experimentos realizados nessa seção, assumiu-se que o comprador possui três filiais.

Tabela 2. Valores dos parâmetros de configuração a_{ik} e δ_{ik} para os experimentos do caso 2.

a_{11}	a_{12}	a_{13}	δ_{11}	δ_{12}	δ_{13}	Densidade			Sensibilidade		
						Filial 1	Filial 2	Filial 3	Filial 1	Filial 2	Filial 3
250	250	250	1,25	1,25	1,25	-	-	-	-	-	-
350	250	250	1,25	1,25	1,25	Alta	-	-	-	-	-
450	250	250	1,25	1,25	1,25	Alta	-	-	-	-	-
350	350	250	1,25	1,25	1,25	Alta	Alta	-	-	-	-
150	250	250	1,25	1,25	1,25	Baixa	-	-	-	-	-
150	150	250	1,25	1,25	1,25	Baixa	Baixa	-	-	-	-
350	150	250	1,05	1,05	1,25	Alta	Baixa	-	Baixa	Baixa	-
350	350	150	1,45	1,45	1,05	Alta	Alta	Baixa	Alta	Alta	Baixa
350	350	350	1,05	1,05	1,05	Alta	Alta	Alta	Baixa	Baixa	Baixa
150	150	150	1,45	1,45	1,45	Baixa	Baixa	Baixa	Alta	Alta	Alta

Tabela 3. Resultados dos experimentos para o caso 2.

n	p_{11}	p_{12}	p_{13}	Melhor época para pagamento	T_1	Q_{11}	Q_{12}	Q_{13}	Q_1	Lucro (\$)			
										Comprador	Fornecedor	Total	
13	9,16	9,45	13,92		10	105,95	4552	4379	2698	11629	230597	93549	324146
12	10,40	10,62	12,12		30	36,59	1879	1307	1108	4294	267652	101960	369612
22	10,05	9,22	12,77		10	70,18	4837	2991	1992	9820	294467	119796	414263
8	11,93	9,28	10,90		10	55,54	2402	3287	1921	7610	297046	117877	414923
9	10,04	10,53	11,21		10	60,37	1389	2181	2015	5585	235036	91718	326754
19	13,69	10,83	9,78		10	56,25	878	1176	2227	4281	172032	65146	237178
14	48,85	39,55	48,48		30	69,76	1127	1407	1137	3671	778155	45130	823285
26	6,24	7,73	6,94		10	74,76	2159	1583	1853	5595	61039	63425	124464
33	38,43	32,98	12,71		30	67,93	1412	711	1939	4062	447544	51016	498560
11	7,72	6,61	21,29		10	161,55	7991	10000	2676	20667	199787	107829	307616

Analisando a Tabela 3 pode-se considerar que o valor a não exerce influência significativa sobre o valor do preço de revenda do produto. No entanto, é possível constatar que, para esse modelo, o valor do preço de revenda de um dado produto é fortemente influenciado pelo coeficiente de tolerância à variação de preços, δ_{ik} , para cada filial. A respeito da influência desses dois parâmetros sobre os outros valores sugeridos pelo modelo, é necessário um estudo mais detalhado visando esclarecer esse comportamento com mais precisão.

4.3 Caso 3 – Cenário com vários produtos e apenas uma filial

Para um cenário em que uma empresa oferece vários produtos em uma única filial é importante que o gerente de compras mantenha uma relativa diversidade de produtos que lhe assegure um certo grau de flexibilidade quanto a possíveis oscilações de condições de mercado. Por exemplo, considerando-se uma situação em que, devido a intempéries o preço de uma determinada *commodity* sofre um aumento. No entanto, um revendedor, visando diminuir o repasse do aumento para o consumidor final, dilui esse aumento no preço de outros produtos que ofereçam uma relativa margem de elasticidade para seu preço de revenda, de tal forma que o lucro total para ambos, comprador e fornecedor, não seja afetado significativamente. A Figura 8 ilustra o cenário proposto para esse estudo.

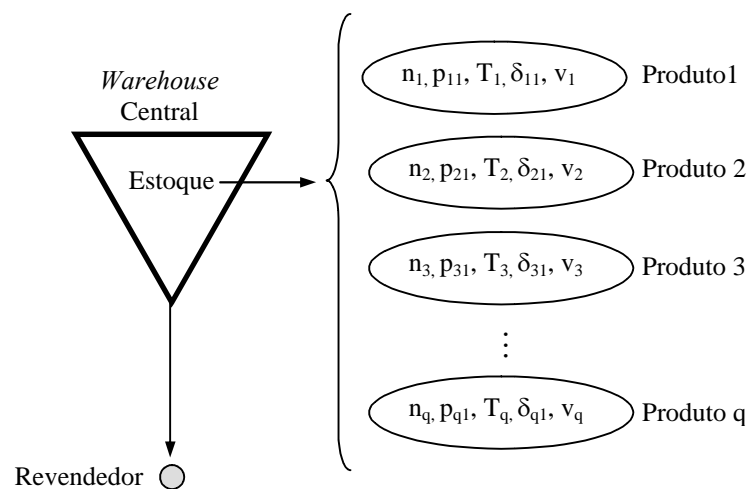


Figura 8. Estrutura em escallão de um empresa com apenas uma filial e vários produtos.

Com o objetivo de analisar o impacto do aumento, por parte do fornecedor, do preço de compra v de um determinado produto sobre as demais variáveis sugeridas para os outros produtos oferecidos pelo revendedor (e.g. p_{ik}, T_i), os experimentos deste estudo foram realizados variando-se o valor de v para um ou mais produtos. A Tabela 4 mostra os resultados obtidos pela aplicação de AGPSO ao cenário acima descrito.

Para os experimentos realizados nesse estudo a configuração para δ segue os valores ($\delta_{11} = \delta_{31} = 1.25, \delta_{21} = 1.15$). O valor do parâmetro a , para todos os produtos é o mesmo utilizado na seção 4.1. O número de iterações e partículas usados pelo AGPSO foram 5000 e 200 respectivamente. Cada experimento foi repetido 100 vezes. Também para os experimentos

realizados nessa seção, assumiu-se que o comprador possui três produtos e que o custo c_i para o fornecedor é dado por: $c_i = \frac{v_i}{2,25}$.

Tabela 4. Experimentos realizados para o caso 3.

v_1	v_2	v_3	n_1	n_2	n_3	p_{11}	p_{21}	p_{31}	T_1	T_2	T_3	Q_{11}	Q_{21}	Q_{31}	Lucro (\$)		
															Comprador	Fornecedor	Total
4,50	8,30	5,80	11	44	42	18,99	20,47	18,00	68,56	19,39	80,05	1185	412	1709	273514	72218	345732
6,75	8,30	5,80	61	47	20	18,78	22,48	18,50	181,00	77,95	345,10	3170	1489	7128	263954	68002	331956
9,00	8,30	5,80	2	3	30	26,09	42,55	12,39	501,06	96,06	50,17	5820	881	1677	259183	69214	328397
4,50	16,60	5,80	6	20	26	14,45	35,95	27,87	836,84	44,81	1044,68	20353	499	13196	248560	59441	308001
4,50	8,30	11,60	5	10	74	16,94	43,78	22,89	961,28	392,11	15,01	19152	3480	240	253043	62739	315783
4,50	8,30	17,20	33	10	41	17,84	27,32	35,88	148,94	946,34	51,79	2782	14441	483	244386	63601	307987
6,75	8,30	7,54	32	38	5	17,60	29,17	19,88	176,61	263,75	615,84	3355	3733	11662	254062	65865	319927

Na Figura 9 são apresentados para todos os produtos os preços de compra seguidos de seus respectivos preços de revenda.

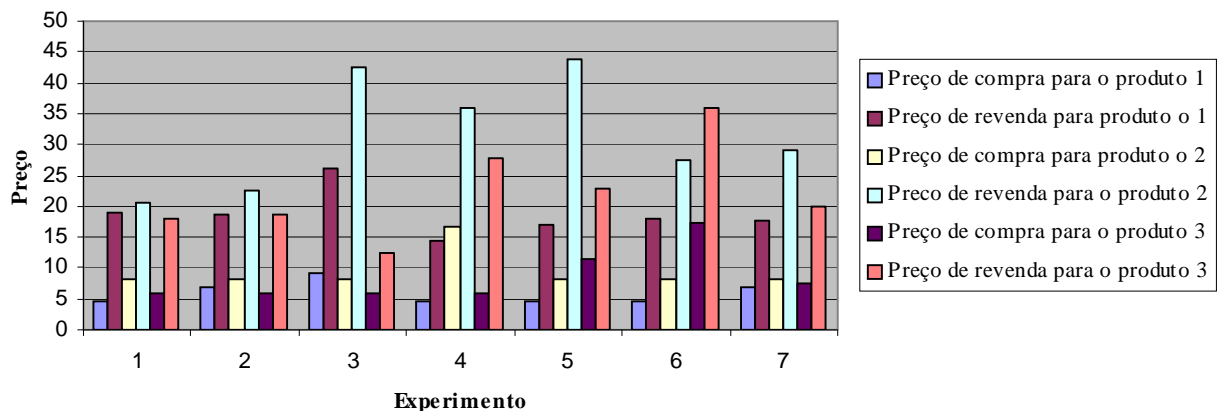


Figura 9. Preço de compra e venda, respectivamente, de todos os produtos.

Tendo como referencial os valores de v e os resultados apresentados para o primeiro experimento, pode-se perceber de uma análise dos resultados presentes na Tabela 4 que um aumento no preço de compra v_i de um único produto implica uma variação no preço p_{ik} de revenda para todos os produtos. No entanto, como já era esperado, essa mudança é distribuída entre os preços dos produtos de acordo com os respectivos valores de δ_{ik} . Ou seja, quanto menor é o valor do coeficiente de elasticidade do preço de revenda do produto, menor é a parcela de aumento que lhe é cabida devido a um aumento no preço de compra de outro produto.

Analisando os valores sugeridos para n_i na Tabela 4, vê-se que, para a maioria dos experimentos o seu comportamento é descendente em relação ao *mark-up* relativo a p_i . No entanto, para os produtos cujo δ_{ik} é relativamente pequeno, esse comportamento não é um padrão.

4.4 Caso 4 – Cenário com vários produtos e várias filiais

Para o último cenário estudado neste trabalho será considerado o modelo mais genérico dentro da proposta apresentada nesta monografia: uma empresa, em parceria com um fornecedor, revende vários produtos em várias filiais localizadas em regiões geográficas diferentes. A Figura 10 representa segundo a estrutura de escalão (*two-echelon*) o objeto de estudo deste caso.

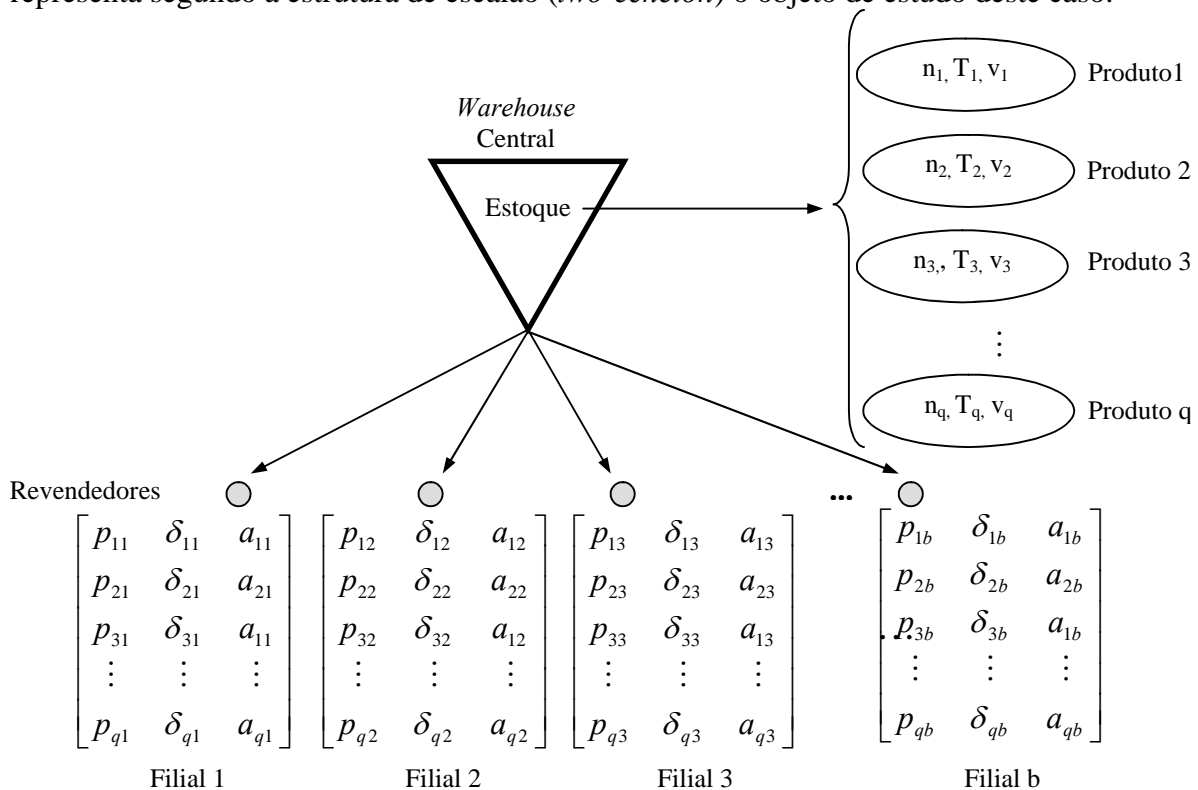


Figura 10. Estrutura em escalão de uma empresa com várias filiais e vários produtos.

Para este cenário, um gerente de compras de uma empresa com essa estrutura, em seu processo de tomada de decisão, deve lidar com um volume muito grande de informações. Em grandes supermercados, por exemplo, o número de produtos que compõem o estoque é superior a 10000 em cada uma de suas lojas [40].

Em um cenário como esse, informações acerca (i) de quais produtos detêm as maiores parcelas de participação no lucro final da empresa são muito importantes para um gerente de compras em seu planejamento estratégico. De posse dessas informações, um gerente pode, por exemplo, decidir-se por estabelecer políticas de compra diferenciadas para os produtos que ele considera mais importantes. A Equação (4.3) descreve a parcela de participação ψ_i sobre o lucro final resultante da avaliação da função compra para o modelo comprador-fornecedor em parceria.

$$\psi_i = \frac{BP_j(\bar{p}_i, T_i)}{\Pi_j(\bar{n}, \bar{p}, \bar{T})} \quad (4.3)$$

Com o objetivo de ratificar a importância da solução proposta, foi realizado apenas um experimento sobre um modelo criado, adicionando-se três filiais ao cenário da Seção 4.3. Dentro desse cenário a informação (i) foi extraída para um único experimento. As parcelas de contribuição de cada um dos produtos revendidos para a composição do montante total do lucro do modelo comprador-fornecedor são apresentadas na Figura 11.

Para o experimento realizado neste caso, os prazos que compõem a política de crédito para esse estudo são $M_1 = 10$ dias e $M_2 = 30$ dias; assumiu-se que o comprador possui três filiais e revende três produtos em cada filial; ($v_1 = 4,50; v_2 = 8,30; v_3 = 5,80$); O número de iterações e partículas usados pelo AGPSO foram 1000 e 100 respectivamente. Cada experimento foi repetido 100 vezes.

Os parâmetros de configuração usados para o experimento deste caso estão descritos na Tabela 5:

Tabela 5. Valores dos parâmetros de configuração a_{ik} e δ_{ik} para os experimentos do caso 4.

Parâmetros	Filial 1			Filial 2			Filial 3		
	Produto 1	Produto 2	Produto 3	Produto 1	Produto 2	Produto 3	Produto 1	Produto 2	Produto 3
δ_{ik}	1,25	1,10	1,15	1,45	1,20	1,20	1,20	1,30	1,15
a_{ik}	250000	250000	250000	200000	200000	200000	210000	210000	210000




Figura 11. Parcela de contribuição de cada produto para o lucro total do modelo.

A Tabela 6 mostra os valores sugeridos para o preço de revenda de cada produto em cada filial.

Tabela 6. Preços sugeridos para revenda dos produtos em cada uma das filiais.

	Filial 1			Filial 2			Filial 3		
	Produto 1	Produto 2	Produto 3	Produto 1	Produto 2	Produto 3	Produto 1	Produto 2	Produto 3
p_{ik}	33,46	35,96	19,94	12,80	15,02	11,40	20,39	17,88	32,59

4.5 Análise comparativa de resultados com PSO e GA

Para esta seção, com o objetivo especificamente de comparar os resultados obtidos pela aplicação de AGPSO ao problema de otimização descrito neste trabalho com os valores resultantes da aplicação de PSO e GA ao mesmo problema, o experimento realizado na Seção 4.4 é novamente abordado, agora pelas duas técnicas mencionadas anteriormente.

Como parâmetros de configuração para GA, PSO e AGPSO foram usados um enxame com 30 partículas (tamanho da população para GA), um número máximo de 1000 iterações e os experimentos foram repetidos 20 vezes. O cenário usado neste estudo foi o mesmo para a realização dos experimentos da Seção 4.4. A Tabela 7 mostra os melhores resultados obtidos pela aplicação das três técnicas ao cenário de compras da Seção 4.4.

As colunas Comprador, Fornecedor e Total da Tabela 7 representam os lucros, em dólar, para o comprador, fornecedor e a soma desses valores, respectivamente. Dado que o critério de convergência adotado exige que o resultado se mantenha constante por 100 iterações, o número médio de iterações necessárias para a convergência é expresso na coluna Média. O desvio padrão para o número de iterações em que o algoritmo convergiu para todas as repetições é dado na coluna Des Padrão. Por fim, o tempo para execução do ciclo completo de busca, em segundos, é dado na coluna Tempo. A configuração da máquina usada para realização dos experimentos foi um Athlon™ 2600+ com 512 MB de memória RAM. A precisão para os resultados, adotada neste estudo, foi de 0,1. Ou seja, dois resultados são considerados iguais se a diferença entre eles for menor ou igual a 0,1.

Tabela 7. Resultados comparativos entre GA, PSO e AGPSO.

	Comprador	Fornecedor	Total	Num Iter Melhor Resultado	Média	Des Padrão	Tempo (s)
GA	3493442	-13	3493429	737	551,75	192,39	10,4
PSO	687571	189358	876929	1000	984,3	64,43	14,8
AGPSO	712151	197523	909674	185	190,80	27,09	3,7

Observando-se os resultados da Tabela 7, pode-se constatar que AGPSO, em um tempo menor, obteve o melhor resultado geral para esse cenário especificamente. A condição de parada, usada neste estudo de caso especificamente, está atrelada à convergência do algoritmo. Ou seja, o ciclo de busca encerra-se quando o algoritmo converge. A Figura 12 ilustra uma comparação entre o processo de convergência de cada técnica, ao longo das iterações, para o ciclo de busca específico em que foram obtidos os melhores resultados.

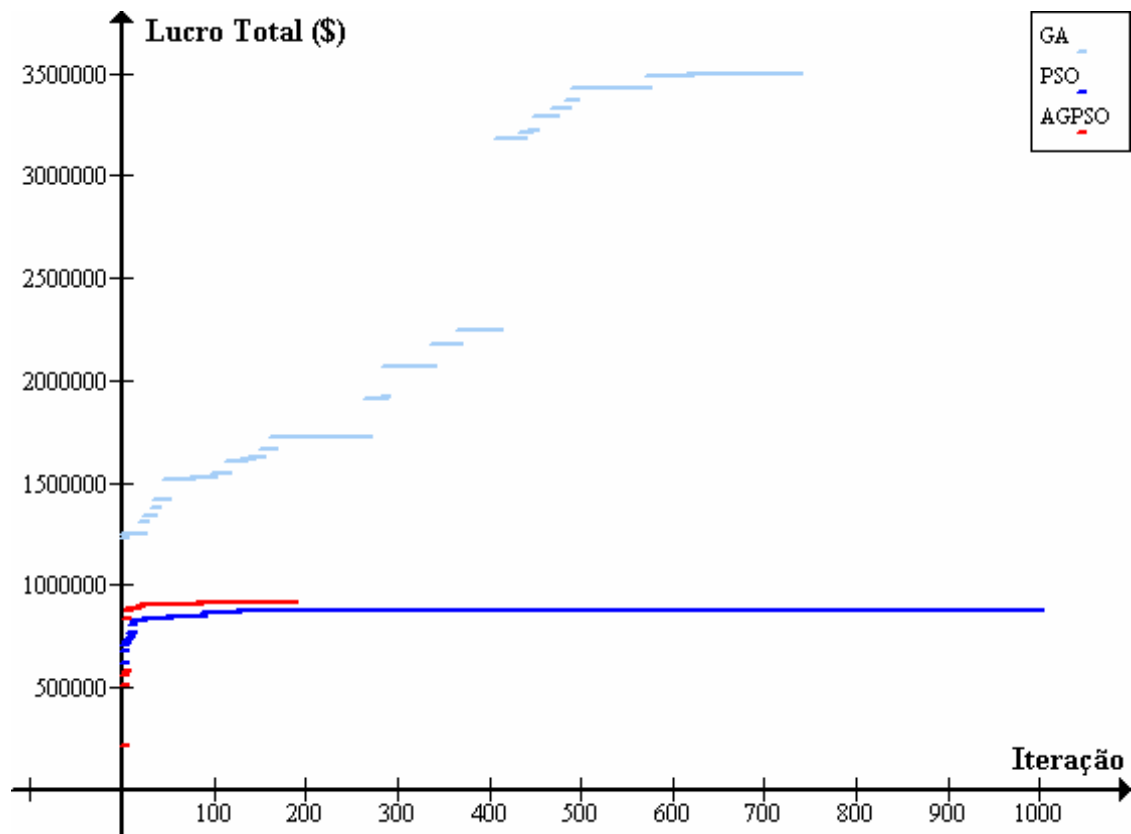


Figura 12. Análise comparativa da curva de convergência para GA, PSO e AGPSO.

Pode-se constatar da Figura 12 que, para o AGPSO, a melhor solução para esse ciclo de busca foi encontrada antes da centésima iteração. É possível notar ainda, com relação ao AGPSO, que foram necessárias apenas algumas dezenas de iterações para, saindo do seu estado inicial, o processo de busca convergir para a vizinhança de um possível máximo local.

Capítulo 5

Conclusão

Este capítulo sintetiza e discute alguns pontos importantes relativos ao trabalho realizado e heurística proposta. Também é efetuada uma comparação da proposta apresentada com outras presentes em trabalhos similares realizados. Por fim, são mencionadas questões relevantes passíveis de serem tratadas em trabalhos posteriores.

5.1 Resumo da Contribuição

Neste trabalho, uma parte da proposta representa uma extensão do modelo desenvolvido por Ho *et al.* [17] para controle de estoque, que propunha a integração de comprador e fornecedor em uma parceria cujo objetivo é maximizar o lucro total para essas duas entidades do negócio. Em seu modelo, Ho *et al.* [17] admitiam que a cadeia de suprimento era composta de apenas um comprador, um fornecedor e um produto. Neste trabalho, aquele modelo foi ampliado para comportar a situação em que uma empresa revende vários produtos em suas filiais.

Adicionalmente, ainda como parte do trabalho, buscou-se aplicar uma variante da técnica PSO chamada AGPSO ao modelo estendido para controle de estoque. O objetivo era oferecer uma técnica, em contrapartida à avaliação analítica do modelo, para maximizar os resultados obtidos da avaliação da função compra do modelo proposto. No entanto, uma vez que essa avaliação é feita usando-se uma simples soma do valor total do lucro para o comprador com o valor total do lucro para o fornecedor, com o intuito de evitar situações em que o preço de revenda sugerido p_{ik} é menor do que o preço de compra v_i , o que implicaria resultados (lucros) ruins para o comprador, adotamos uma heurística para penalizar partículas com essas características.

Como indicadores para um gerente de compras de uma empresa, são sugeridos valores para (i) duração do ciclo de reposição do estoque para os n produtos, (ii) quantidade Q de cada produto a ser comprada ao final do período estimado, (iii) quantidade de lotes com Q produtos a serem fabricados pelo fornecedor e (iv) o preço de revenda do produto para cada filial da empresa. Todos os valores sugeridos para cada um dos indicadores mencionados são buscados de tal forma que garantam um bom resultado (lucro) para a empresa em conjunto com o fornecedor.

Para cada um dos diferentes cenários estudados, procurou-se demonstrar a importância de uma ferramenta que auxilie o gerente de compras em seu processo de tomada de decisão, modelando em certo grau a complexidade de um cenário de compras real.

5.2 Trabalhos relacionados

Foram identificados apenas dois trabalhos de autores cujas propostas estão diretamente relacionadas ao tema deste trabalho. Zhao *et al.* [43] desenvolveram um modelo de controle de estoque baseado na técnica EOQ, para controle de estoque, para gerenciamento de aspectos ligados à área de compras de uma empresa (*e.g.* estoque com vários itens, várias lojas nas quais os produtos são vendidos, recursos financeiros limitados, capacidade limitada). No entanto, por meio desse modelo, somente é sugerida a quantidade a ser comprada para um dado produto. A esse modelo é aplicada uma nova variante do PSO que combina o gradiente da aceleração e alguma função para penalidade.

Niu *et al.* [33] propõem um modelo para otimização da gestão de compras e armazenamento para uma usina elétrica. O objetivo daquele trabalho é minimizar o custo baseado em características associadas a um estoque de matérias-primas. A finalidade daquela proposta seria instruir usinas elétricas a comprar matéria-prima adequadamente e, conseqüentemente, garantir uma reserva adequada à demanda. Como indicadores para um gerente de compras, é informada a quantidade a ser comprada de uma única matéria prima. A otimização do modelo é realizada pela aplicação de uma variante do PSO chamada *Hybrid Genetic Particle Swarm Optimization* (HGPSOA), que combina aspectos presentes em Algoritmos Genéticos (*e.g.* mutação, *crossover*, elitismo) às partículas de um enxame.

Tendo em vista as datas recentes das poucas publicações dos trabalhos acima referenciados, pode-ser afirmar que esta é uma área de aplicação ainda muito pouco explorada por soluções baseadas em PSO.

5.3 Discussão

Gestão de compras é uma atividade sobre a qual confluem responsabilidades de várias outras áreas de uma empresa. A solução proposta neste trabalho procurou abordar aspectos de duas dessas áreas: gestão de estoque e, adicionalmente, gestão da cadeia de suprimento, de forma a auxiliar um gerente de compras em seu processo de tomada de decisão.

Baseado na análise dos resultados para o primeiro estudo de caso, é possível afirmar que a solução proposta é de fato uma boa alternativa, quando comparada à análise analítica, para o maximizar o lucro obtido da avaliação da função compra resultante para um cenário com apenas um revendedor, um fornecedor e um produto. Como apresentado na Seção 4.1, os resultados obtidos da aplicação de AGPSO àquele cenário foram relativamente próximos aos apresentados por Ho *et al.* [17] para o seu segundo estudo numérico.

De acordo com a motivação posta para o segundo estudo de caso, (i) densidade populacional da região onde a filial está instalada e (ii) tolerância, por parte do consumidor, a variações no preço de venda do produto na mesma filial, são fatores importantes para a determinação do preço de revenda para aquela filial. Uma vez que foi discutido que apenas o fator (ii) exerce uma influência significativa sobre o preço de revenda de um produto, em seu planejamento estratégico, um gerente de compras deve, segundo a solução proposta, direcionar uma maior atenção à tolerância dos consumidores a variações no preço de revenda.

Um gerente de compras deve estar preparado para lidar com possíveis flutuações nos preços de compra dos produtos. Para isso, seria útil uma política que distribua adequadamente (*i.e.* de acordo com o coeficiente de elasticidade de preço de cada produto) o impacto do aumento sobre o preço de outros produtos. Observando os resultados dos experimentos do terceiro estudo de caso, pode-se afirmar que a solução proposta de fato oferece suporte a essa necessidade.

Para empresas que, em várias filiais, revendem uma quantidade relativamente grande de produtos, informações acerca de quais produtos são mais relevantes para composição dos lucros da empresa representam importantes indicadores para um gerente. Logo, a solução proposta nesse trabalho é relevante no sentido de oferecer esses indicadores estratégicos para um gerente de compras.

Como mostrado neste trabalho, por meio de cinco estudos de caso, a solução proposta pode desempenhar um papel relevante em conjunto com sistemas de apoio à decisão, oferecendo indicadores de médio e longo prazos para auxiliar um gerente em seu processo de tomada de decisão.

5.4 Trabalhos Futuros

Ainda que a solução proposta neste trabalho procure oferecer uma conotação mais real ao modelo originalmente proposto por Ho *et al.* [17], inúmeras questões importantes não foram incorporadas ao modelo. Produtos perecíveis são um problema comum em gestão de estoque [2], [11]. Estender o modelo atual para dar suporte à gestão de compras de produtos perecíveis é uma interessante linha de trabalho a ser seguida.

Para uma adequada gestão de compras, é fundamental ajustar corretamente o comportamento da demanda por um dado produto àquela usada no modelo. O modelo proposto nesse trabalho usa o comportamento de uma demanda que, apesar de depender do preço de revenda do produto, é constante durante todo o ciclo de revenda do produto. Logo, outra importante mudança que poderia ser incorporada a esse modelo diz respeito a demandas com um comportamento que segue uma distribuição de probabilidade e que também dependa do preço de revenda do produto.

A comparação dos resultados obtidos para os experimentos realizados com os de outras técnicas tais como *Sequential Quadratic Programming* (SQP) e *Generalized Reduced Gradient* (GRG) também representa uma importante linha de trabalho a ser seguida, uma vez que essas técnicas especificamente têm um comportamento bastante parecido com o de técnicas analíticas mais precisas, como derivações parciais. A escolha do SQP se deve ao fato de, segundo Rao [36], esse ser o melhor do método de otimização não linear com restrições.

Por fim, tendo em vista que as ferramentas computacionais utilizadas nesse trabalho foram implementadas com o único objetivo de avaliar a solução proposta para diferentes cenários, seria uma importante contribuição a modelagem dessas ferramentas com o intuito de integrá-la a um módulo de um sistema de apoio à decisão.

Referências

- [1] ABAD, P.L.; JAGGI, C.K., 2003. A joint approach for setting unit price and the length of the credit period for a seller when end demand is price sensitive. *International Journal of Production Economics* 83, pp. 115–122.
- [2] ANJOS, Miguel F.; CHENG, Russell C. H.; CURRIE, Christine S. M. Optimal pricing policies for perishable products, *European Journal of Operational Research* Volume 166, Issue 1, Metaheuristics and Worst-Case Guarantee Algorithms: Relations, Provable Properties and Applications, 1 October 2005, pp. 246-254.
- [3] ARFKEN G.; WEBER H. J. *Mathematical Methods for Physicists*. Elsevier Science & Technology Books, 2005.
- [4] BRIAN, H. Hwang; XIE, Na, Understanding supply chain dynamics: A chaos perspective, *European Journal of Operational Research* Volume 184, Issue 3, 1 February 2008, pp. 1163-1178.
- [5] CACHON, G.; FISHER, M., 2000. Supply chain inventory management and the value of shared information. *Management Science* 46, pp. 1032–1048.
- [6] CARR, A.S.; PEARSON, J.N., 1999. Strategically managed buyer-supplier relationships and performance outcomes. *Journal of Operations Management* 17 (5), pp. 497–519.
- [7] CAVINATO, J. L.; KAUFFMAN, R. G. *The Purchasing Handbook: A Guide for the Purchasing and Supply Professional*. McGraw-Hill, 1999.
- [8] CHAU K.W., Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River, *Journal of Hydrology*, Volume 329, Issues 3-4, 15 October 2006, pp. 363-367.
- [9] CHEN, F.; SAMROENGRAJA, R., 2000. The stationary beer game. *Production and Operations Management* 9, pp. 19–30.
- [10] D'AMOURS, S.; MONTREUIL, B.; LEFRANCOIS, P.; SOUMIS, F., 1999. Networked manufacturing: The impact of information sharing. *International Journal of Production Economics* 58, pp. 63–79.
- [11] FERGUSON, Mark; JAYARAMAN, Vaidy; SOUZA, Gilvan C. Note: An application of the EOQ model with nonlinear holding cost to inventory management of perishables, *European Journal of Operational Research* Volume 180, Issue 1, 1 July 2007, pp. 485-490.
- [12] FUKUYAMA, Y.; YOSHIDA, H. “A Particle Swarm Optimization for Reactive Power and Voltage Control in Electric Power Systems”, *Proc. Congress on Evolutionary Computation*, Seoul, Korea, Piscataway, NJ: IEEE Service Center. 2001, pp. 87-93.
- [13] GAITHER, N.; FRAZIER, G. *Administração da produção e operações*. São Paulo, Pioneira/Thomson Learning, 2002.
- [14] GEORGE, Jennifer; MERCER, Alan; WILSON, Helen. Variations in price elasticities, *European Journal of Operational Research* Volume 88, Issue 1, 6 January 1996, pp. 13-22.
- [15] GOLDBERG, D.E. *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, Reading, MA (1989).

- [16] HARIGA, M.; BEN-DAYA, M., 1999. Some stochastic inventory models with deterministic variable lead time. *European Journal of Operational Research* 113, pp. 42–51.
- [17] HO, Chia-Huei; OUYANG, Liang-Yuh; SU, Chia-Hsien. Optimal pricing, shipment and payment policy for an integrated supplier-buyer inventory model with two-part trade credit, *European Journal of Operational Research*, In Press, Corrected Proof, Available online 20 April 2007.
- [18] JARMAIN, W.E., 1963. *Problems in Industrial Dynamics*. MIT Press, Cambridge.
- [19] JANSON, Stefan; MERKLE, Daniel; MIDDENDORF, Martin. Molecular docking with multi-objective Particle Swarm Optimization, *Applied Soft Computing* Volume 8, Issue 1, January 2008, pp. 666-675.
- [20] JOGLEKAR, P.N., 1988. Comments on “A quantity discount pricing model to increase vendor profits”. *Management Science* 34 (11), pp.1391–1398.
- [21] JORGENSEN S.; KORT P. M. Optimal pricing and inventory policies: Centralized and decentralized decision making, *European Journal of Operational Research* Volume 138, Issue 3, 1 May 2002, pp. 578-600.
- [22] KALCHSCHMIDT, Matteo; ZOTTERI, Giulio; VERGANTI, Roberto. Inventory management in a multi-echelon spare parts supply chain, *International Journal of Production Economics* Volumes 81-82, 11 January 2003, pp. 397-413.
- [23] KAWTUMMACHAI, Ruengsak; HOP, Nguyen Van. Order allocation in a multiple-supplier environment, *International Journal of Production Economics* Volumes 93-94, Proceedings of the Twelfth International Symposium on Inventories, 8 January 2005, pp. 231-238.
- [24] KENNEDY J.; EBERHART R.C., "Particle Swarm Optimization", In Proc. of IEEE ICNN, Perth, Australia, 1995, pp. 1942-1948.
- [25] LARSEN, E.R.; Morecroft, J.D.W.; THOMSEN, J.S., 1999. Complex behaviour in a production-distribution model. *European Journal of Operational Research* 119, pp. 61–74.
- [26] LEE, H.L.; PADMANABHAN, V.; WHANG, S.J., 1997a. Information distortion in a supply chain: The bullwhip effect. *Management Science* 43, pp. 546–558.
- [27] LEE, H.L.; PADMANABHAN, V.; WHANG, S.J., 1997b. The bullwhip effect in supply chains. *Sloan Management Review* 38, pp. 93–102.
- [28] LEE, H.L.; SO, K.C.; TANG, C.S., 2000. The value of information sharing in a two-level supply chain. *Management Science* 46, pp. 626–643.
- [29] LEPSCH, Sergio Luiz. *Fixação de Preços em Grandes e Médios Supermercados Brasileiros na Atualidade*. Varejo Competitivo. São Paulo: Editora Atlas. Provar. 1996.
- [30] LIU, Hongbo; ABRAHAM, Ajith; CLERC, Maurice. Chaotic dynamic characteristics in swarm intelligence, *Applied Soft Computing* Volume 7, Issue 3, June 2007, pp. 1019-1026.
- [31] MARTINS, P.G.; ALT, P.R.C. *Administração de materiais e recursos patrimoniais*. São Paulo, Saraiva, 2000.
- [32] MULHERN, Francis J.; WILLIAMS, Jerome D.; LEONE, Robert P. Variability of brand price elasticities across retail stores: Ethnic, income, and brand determinants, *Journal of Retailing* Volume 74, Issue 3, Research Perspective on Retail Pricing, Autumn 1998, pp. 427-446.
- [33] NIU, Dongxiao; GU, Xihua. Application of HGPSOA in Electric Power System Material Purchase and Storage Optimization, *International Conference on Service Systems and Service Management*, 9-11 June 2007, pp.1–7.

- [34] PEARSON, John N. A longitudinal study of the role of the purchasing function: toward team participation, *European Journal of Purchasing & Supply Management*, Volume 5, Issue 2, June 1999, pp. 67-74.
- [35] POOLER, H.V. *Global purchasing: reaching for the world*. New York, Chapman & Hael, 1992.
- [36] RAO, S. *Engineering optimization – theory and practice*, 3a ed., John Wiley & Sons.
- [37] RUIZ-TORRES, Alex J.; MAHMOODI, Farzad. The optimal number of suppliers considering the costs of individual supplier failures, *Omega* Volume 35, Issue 1, February 2007, pp. 104-115.
- [38] SHEN, Qi; SHI, Wei-min; YANG, Xi-ping; YE, Bao-xian, Particle swarm algorithm trained neural network for QSAR studies of inhibitors of platelet-derived growth factor receptor phosphorylation, *European Journal of Pharmaceutical Sciences* Volume 28, Issue 5, August 2006, pp. 369-376.
- [39] SIMCHI-LEVI, D.; ZHAO, Y., 2003. The value of information sharing in a two-stage supply chain with production capacity constraints. *Naval Research Logistics* 50, pp. 888–916.
- [40] TAYLOR, James W. Forecasting daily supermarket sales using exponentially weighted quantile regression, *European Journal of Operational Research* Volume 178, Issue 1, 1 April 2007, pp. 154-167.
- [41] ZENG, Jianchao; HU, Jianxiu; JIE, Jing. Adaptive Particle Swarm Optimization Guided by Acceleration Information. *International Conference on Computational Intelligence and Security*, 2006. Volume 1, Nov. 2006, pp. 351 – 355.
- [42] ZHAO, X.D.; XIE, J.X.; LEUNG, J., 2002. The impact of forecasting model selection on the value of information sharing in a supply chain. *European Journal of Operational Research* 142, pp. 321–344.
- [43] ZHAO, Peixin; WANQ, Hong; GAO, Hongfeng. Improved Particle Swarm Optimization Algorithm for Stochastic EOQ Models with Multi-Item and Multi-Storehouse, *IEEE International Conference on Information Acquisition*, Aug. 2006, pp.1047–1051.