

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ**

**LUIZ ANTONIO WANZELER DA SILVA**

**OTIMIZAÇÃO DE UMA CADEIA DE SUPRIMENTOS USANDO A  
METAHEURÍSTICA ENXAME DE PARTÍCULAS**

**CURITIBA**

**2008**

**LUIZ ANTONIO WANZELER DA SILVA**

**OTIMIZAÇÃO DE UMA CADEIA DE SUPRIMENTOS USANDO A  
METAHEURÍSTICA ENXAME DE PARTÍCULAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Pontifícia Universidade Católica do Paraná, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

Orientador: Prof. Dr. Leandro dos Santos Coelho

**CURITIBA**

**2008**

**LUIZ ANTONIO WANZELER DA SILVA**

**OTIMIZAÇÃO DE UMA CADEIA DE SUPRIMENTOS USANDO A  
METAHEURÍSTICA ENXAME DE PARTÍCULAS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Pontifícia Universidade Católica do Paraná, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção e Sistemas.

COMISSÃO EXAMINADORA

---

Prof. Dr. Leandro dos Santos Coelho (Orientador)  
Pontifícia Universidade Católica do Paraná

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Patrícia Alcântara Cardoso  
Pontifícia Universidade Católica do Paraná

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Aurora Trinidad Ramirez Pozo  
Universidade Federal do Paraná

Curitiba, \_\_\_\_\_ de \_\_\_\_\_ de 2008

À minha amada Gleyci.

## **AGRADECIMENTOS**

Ao meu querido orientador, Professor Dr. Leandro, que me auxiliou, ensinou, estimulou e cobrou com fundamental importância em todas as etapas desta pesquisa. Sem o seu apoio a realização deste trabalho seria muito mais difícil. MUITÍSSIMO OBRIGADO!

À Pontifícia Universidade Católica do Paraná, pela oportunidade de fazer esse mestrado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo auxílio concedido.

Aos professores e funcionários da PUC-PR pelos ensinamentos e ajuda.

À minha amada Gleyci pelo apoio, amor e companheirismo incondicionais. De certo, fundamentais.

À minha mãe, Graça, pelo amor e incentivo, sem os quais eu nunca teria chegado até aqui.

Aos meus familiares pelo apoio, compreensão e carinho.

Aos meus amigos, mesmo distantes, que torcem pelo meu sucesso.

A todos os professores e mestres que tive ao longo de toda a minha vida cuja sabedoria e conhecimentos foram importantes para minha formação.

*Um homem precisa viajar por sua conta. (...)  
Precisa viajar por si, com seus olhos e pés,  
para entender o que é seu. (...) Um homem  
precisa viajar para lugares que não conhece,  
para quebrar essa arrogância que nos faz ver o  
mundo como o imaginamos, e não  
simplesmente como é (...)*

Amyr Klink

## RESUMO

A Gestão da Cadeia de Suprimentos (GCS), no cenário atual de competitividade, é importante para o sucesso de uma empresa. Não podendo essa cadeia ser vista fragmentada, mas o desempenho da cadeia como um todo, de forma a ter uma gestão de cadeia integrada, promovendo então o interesse das organizações em implementar esse modelo de gestão em seus negócios. Neste contexto, este trabalho avalia uma cadeia de suprimentos (CS) integrando os sistemas de produção, estoque e distribuição, visando a solução do problema de minimização dos custos de armazenagem, fabricação, transporte e falta de produto para uma cadeia de suprimentos (composta de 3 matérias-primas, 2 produtos, 3 distribuidores e 2 períodos de tempo) pelo método de otimização denominado Otimização por Enxame (ou Nuvem) de Partículas (*Particle Swarm Optimization*, PSO), o qual é inspirado no comportamento social de aves e peixes. Embora, nos últimos anos, o algoritmo PSO tenha sido utilizado em várias áreas de pesquisa, a associação cadeia de suprimentos e PSO é rara. Dessa forma, esta pesquisa também contribui para a validação do algoritmo PSO em práticas de otimização da cadeia de suprimentos. As propostas deste trabalho foram decorrentes primeiramente do uso do PSO padrão. Com o intuito de melhorá-lo, foi proposta uma abordagem que considera os parâmetros de aprendizagem variando com o tempo e diferentes abordagens utilizando distribuição Gaussiana e de Cauchy para o projeto das partes cognitiva e social. E por fim, é realizada ainda uma análise comparativa com os resultados obtidos por Mak e Wong (1995) através do algoritmo genético e *branch and bound*, e aqueles obtidos pelas abordagens do algoritmo PSO propostas neste trabalho. Os resultados mostraram as potencialidades de utilização da técnica PSO para esse tipo de problema.

Palavras-chave: Cadeia de Suprimentos, Gestão da Cadeia de Suprimentos, Otimização por Enxame de Partículas.

## **ABSTRACT**

The Supply Chain Management, in the current scenario of competitiveness, is important for the success of a company. The chain may not be seen piecemeal, but the performance of the chain as a whole, in order to obtain an integrated performance, promoting the interest of the organizations in implementing this model of management in their business. Under this perspective, this work evaluates a supply chain integrating the production-inventory-distribution systems in order to minimizing stocks, production, transportation and shortage costs for a supply chain (comprising 3 raw materials, 2 products, 3 retailers and 2 periods of time) with the aid of the method called Particle Swarm Optimization (PSO), which is a population-based evolutionary computation technique inspired by the social metaphor of birds and fishes. Although, in recent years, the PSO algorithm has been used in several research areas, the association of supply chain and PSO is rare. Thus, this research also contributes to the validation of the algorithm PSO in practice of supply chain optimization. The approaches of this study were primarily resulting from the use of conventional PSO (classical). In order to improve it, was proposed an approach that considers the time-varying acceleration coefficients and other different approaches using Gaussian and Cauchy distributions for the cognitive and social parties project. And finally, it is made a comparison analyze with the results obtained by Mak and Wong (1995) through genetic algorithm and branch and bound approaches, and those obtained by approaches of algorithm PSO proposed in this work. The results revealed the potentiality of using the PSO technique for this kind of problem.

**Keywords:** Supply Chain, Supply Chain Management, Particle Swarm Optimization.

## LISTA DE FIGURAS

Figura 1 – Diagrama da cadeia de suprimentos integrando os sistemas de produção, estoque e distribuição.....	18
Figura 2 – Representação de uma Cadeia de Suprimentos (CS). (Fonte: adaptado de Pires, 2004). .....	22
Figura 3 – Representação esquemática de uma cadeia de suprimentos. (Fonte: adaptado de Lambert, Cooper e Pagh,1998) .....	24
Figura 4 – Grupos das Definições de GCS segundo Mentzer <i>et al.</i> (2001). .....	28
Figura 5 – Estrutura de Gestão da Cadeia de Suprimentos (Fonte: Cooper, Lambert e Pagh, 1997). .....	29
Figura 6 – Modelo de Gestão da Cadeia de Suprimentos (Fonte: adaptado de Cooper, Lambert e Pagh, 1997). .....	30
Figura 7 – Modelo de Gestão da Cadeia de Suprimentos segundo o <i>Supply Chain Council</i> – modelo SCOR (Fonte: Francis, 2007). .....	30
Figura 8 – Modelo de Gestão da Cadeia de Suprimentos. (Fonte: Mentzer <i>et al.</i> , 2001). .....	32
Figura 9 – Analogia do PSO .....	46
Figura 10 – Fluxograma para o algoritmo PSO .....	47
Figura 11 – Número de artigos publicados em cada ano (Dados incompletos para o ano de 2003) (Fonte: Hu, Shi e Eberhart, 2004).....	50
Figura 12 – Convergência do melhor resultado (Tabela 1) para a partícula <i>gbest</i> da população para as abordagens PSO.....	67
Figura 13 – Convergência média (média de 30 experimentos) das melhores partículas da população para as abordagens PSO. ....	68
Figura 14 – Convergência do melhor resultado (Tabela 1) para a partícula <i>gbest</i> da população para as abordagens A-PSO. ....	69
Figura 15 – Convergência média (média de 30 experimentos) das melhores partículas da população para as abordagens A-PSO.....	70

## LISTA DE TABELAS

Tabela 1 – Resultados para a função aval ( $x$ ) da otimização da cadeia de suprimentos (resultados para 30 experimentos).....	64
Tabela 2 – Melhores resultados usando a proposta A-PSO-4.....	65

## LISTA DE QUADROS

Quadro 1 – Definições de GCS. Fonte: Cardoso (2003) .....	26
Quadro 2 – Pressupostos relacionados à GCS.....	27
Quadro 3 – Resumo das propostas.....	60

## LISTA DE ABREVIATURAS E SIGLAS

APICS	<i>American Production Inventory Control Society</i>
A-PSO	<i>proposta Adaptativa do PSO</i>
CS	<i>Cadeia de Suprimentos</i>
ERP	<i>Enterprise Resource Planning</i>
FDFS	<i>First Desired First Served</i>
FSC	<i>Fujitsu-Siemens Computers</i>
GADG	<i>Genetic Algorithm with Dominated Genes</i>
<i>gbest</i>	<i>global best</i>
GCS	<i>Gerenciamento da Cadeia de Suprimentos</i>
GCPSO	<i>Guaranteed Convergence Particle Swarm Optimizer</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
ISMT	<i>Intelligent Supplier Management Tool</i>
ISRMS	<i>Intelligent Supplier Relationship Management System</i>
MSC	<i>Multi-plant Supply Chain</i>
<i>pbest</i>	<i>personal best</i>
P&D	<i>Pesquisa e Desenvolvimento</i>
PSO	<i>Particle Swarm Optimization</i>
PSO-LS	<i>PSO Local Search</i>
SCOR	<i>Supply Chain Operations Reference</i>
st-GA	<i>spanning tree-based Genetic Algorithm</i>

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	15
1.1 Objetivos .....	17
1.1.1 Objetivo geral .....	17
1.1.2 Objetivos específicos.....	17
1.2 Metodologia .....	18
1.3 Motivação e Contribuição.....	19
1.4 Estrutura da Dissertação.....	20
<b>2 REFERENCIAL TEÓRICO</b> .....	21
2.1 Cadeia de Suprimentos (CS) .....	21
2.1.1 Gerenciamento da cadeia de suprimentos (GCS).....	24
2.1.2 A Utilização de heurísticas e metaheurísticas no GCS: uma revisão da literatura .....	34
2.2 Modelagem Matemática do Problema.....	37
2.2.1 Método de penalização .....	41
<b>3 FUNDAMENTOS DE COMPUTAÇÃO EVOLUTIVA E OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS</b> .....	43
3.1 Introdução à Computação Evolutiva .....	43
3.2 Otimização por Enxame de Partículas .....	44
3.2.1 Etapas do algoritmo PSO .....	46
3.2.2 Parâmetros relevantes do projeto de um algoritmo PSO .....	48
3.2.3 Breve apanhado da utilização de PSO em problemas de otimização .....	51
3.2.4 Propostas de PSO .....	57
3.2.4.1 PSO padrão (PSO-1) .....	57

3.2.4.2 Proposta adaptativa do PSO (A-PSO) .....	57
3.2.4.3 Propostas baseadas em distribuição Gaussiana e de Cauchy .....	58
3.2.4.4 Resumo das propostas .....	60
<b>4 UTILIZAÇÃO E RESULTADOS</b> .....	<b>61</b>
4.1 Parâmetros .....	61
4.2 Análise dos Resultados.....	64
<b>5 CONCLUSÃO</b> .....	<b>71</b>
<b>REFERÊNCIAS</b> .....	<b>74</b>

## 1 INTRODUÇÃO

No mercado global envolvente atual, a Gestão da Cadeia de Suprimentos – GCS (*Supply Chain Management*) surge como uma vantagem competitiva, visto que é essencialmente importante produzir os bens, entregá-los nos prazos, local, tempo e custos de uma forma eficiente.

É essencial que as empresas tenham um plano de compra baseado em fornecedores confiáveis e competentes, fortalecendo assim sua estratégia de compras, além de atentar para a localização da planta industrial e do centro de distribuição, próximos dos fornecedores e/ou dos consumidores, facilitando também a logística, em termos de redução de custos e de execução de melhores serviços para os clientes. Embora, muitas empresas optem por terceirizar este setor através de operadores logísticos ou empresas de entrega rápida que tenham uma rede global de atuação.

Com a competitividade atual, de acordo com Lee (1998), é relativamente fácil para as empresas perderem o controle da eficiência da cadeia de suprimentos (CS), uma vez que a variedade de produtos prolifera e o ciclo de vida do produto fica cada vez menor. Os sintomas da perda de controle são os aumentos em custos de estocagem, logística e manufatura, enquanto o nível de serviço para o consumidor deteriora.

Para projetar e implementar uma Cadeia de Suprimentos é necessário um investimento de recursos monetários, assim como para monitorar e operá-la. Um projeto de uma Cadeia de Suprimentos ineficiente pode aumentar os custos pela aplicação inadequada de recursos e prejudicar a tomada de decisões, baseadas em informações incorretas.

Sabendo-se que a tomada de decisão é dificultada pela qualidade dos parâmetros nos quais gestores se baseiam para decidir, é que há tempo são procuradas soluções para contornar os problemas suscitados pela incerteza. Woiler e Mathias (1996) relatam que as diversas alternativas que se pode utilizar para o aperfeiçoamento da análise não satisfazem o ponto fundamental que é a quantificação do risco. Uma solução proposta para o gerenciamento do risco é a de utilizar técnicas de simulação, as quais permitem, através da modelagem de um sistema real, o cálculo de diferentes combinações que probabilisticamente possam

ocorrer. Ao elaborar-se um modelo, estar-se-á, na medida do possível, tentando retratar a realidade, sem sua complexidade e reduzida a proporções manejáveis (WOILER; MATHIAS, 1996).

De acordo com Carson II (2005), a simulação é uma poderosa ferramenta para análise e otimização de sistemas, pois através da modelagem já são fornecidas estruturas para uma análise lógica e consistente, visto que forçam os objetivos a serem explícitos, pensar cuidadosamente sobre variáveis a serem incluídas, quais dados são pertinentes ao modelo e reconhecer restrições, entre tantos outros motivos.

Os modelos de simulação também suportam princípios generalizados, os quais podem ser aplicados para uma variedade de problemas de cadeias de suprimentos reais (TOWILL; MCCULLEN, 1999).

Na Engenharia de Produção, as áreas de Planejamento e Controle da Produção e Logística são, tradicionalmente, as que apresentam maior potencial para o desenvolvimento e aplicação de modelos de otimização. Embora a área de simulação e cadeia de suprimentos sejam assuntos largamente estudados, segundo Vieira (2004), a simulação de cadeia de suprimentos não tem sido tratada com muita frequência, talvez pela sua complexidade.

Embora isso, estudos como os de Leung (1995), Wu (1999), Hsieh (2001), Jeong, Jung e Park (2002), Syarif, Yun e Gen (2002) já vêm demonstrando o interesse em combinar simulação à cadeia de suprimentos para se buscar melhor desempenho na cadeia, porém esses estudos são em parte monopolizados pela técnica de algoritmo genético, um paradigma da computação evolutiva.

Visando ampliar a utilização de modelos de otimização aplicados à cadeia de suprimentos, o presente trabalho propõe a utilização da técnica de Otimização por Enxame (ou Nuvem) de Partículas (*Particle Swarm Optimization - PSO*), proposta inicialmente por Kennedy e Eberhardt (1995a, 1995b).

Além de tentar solucionar o problema e a observação de carência de pesquisa envolvendo simultaneamente cadeia de suprimentos e PSO, a razão do uso da técnica é sustentada pelas potencialidades do algoritmo PSO apresentadas em Svenson *et al.* (2004):

- Fácil implementação. O PSO é implementado com poucas linhas de código e usa essencialmente operações matemáticas básicas;

- Flexibilidade. Frequentemente não se necessita fazer maiores ajustes para adaptar o PSO a um novo problema;
- Robustez. As soluções de PSO são quase independentes da iniciação do enxame. E, além disso, poucos parâmetros devem ser ajustados para obter soluções promissoras;
- Possibilidade de combinar variáveis discretas e contínuas;
- Possibilidade de ajustar facilmente o equilíbrio entre a exploração local e global durante o procedimento de otimização;
- Paralelismo. O PSO é inerentemente melhor adequado para computação paralela. A população de partículas pode ser dividida entre muitos processadores para reduzir o tempo computacional consumido na simulação.

## **1.1 Objetivos**

A seguir são apresentados o objetivo geral e os específicos desta dissertação.

### **1.1.1 Objetivo geral**

Este trabalho tem como objetivo geral o estudo e o projeto de abordagem de otimização baseados em enxame de partículas para uma aplicação em uma cadeia de suprimentos.

### **1.1.2 Objetivos específicos**

Como objetivos específicos, têm-se:

- Introduzir a técnica de enxame de partículas em práticas de otimização de uma cadeia de suprimentos;
- Testar as diferentes configurações de parâmetros de controle e propostas para o algoritmo de enxame de partículas desenvolvido;
- Efetuar um estudo comparativo com resultados de outras técnicas de otimização, tais como algoritmos genéticos e *branch and bound*.

## 1.2 Metodologia

A cadeia de suprimentos utilizada na pesquisa foi baseada no modelo proposto por Mak e Wong (1995). O diagrama esquemático da cadeia de suprimentos analisada é apresentado na Figura 1.

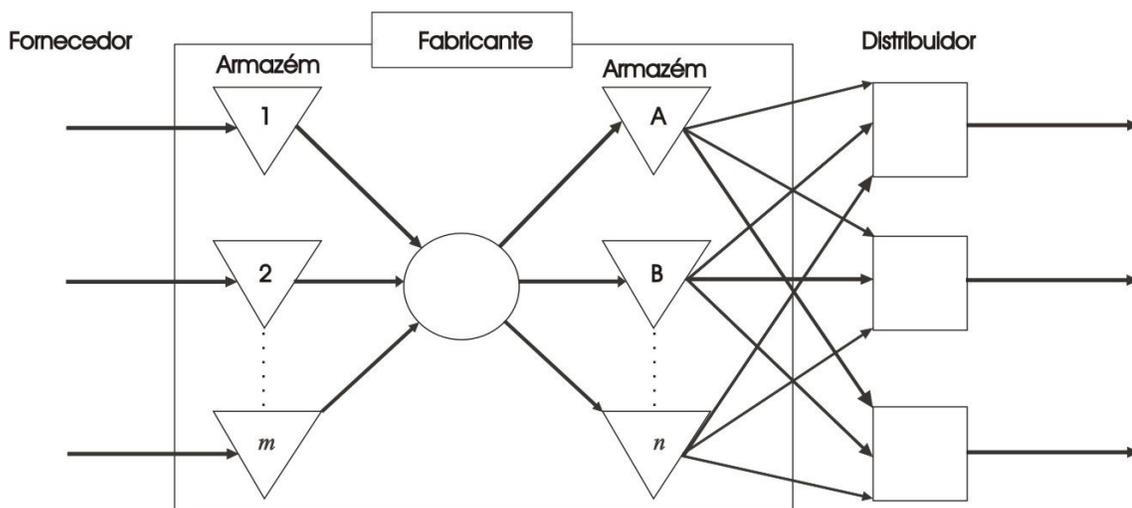


Figura 1 – Diagrama da cadeia de suprimentos integrando os sistemas de produção, estoque e distribuição.

Este diagrama consiste de três setores dispostos de forma serial e abrange os fornecedores, fabricante (e seus armazéns) e revendedores. As matérias-primas são entregues dos fornecedores para o fabricante, onde são armazenadas e os produtos são manufaturados. Os produtos finais são então estocados em armazéns (do fabricante) e distribuídos destes para os revendedores de diferentes regiões.

Para o modelo apresentado, buscou-se por meio da otimização, minimizar o custo total do sistema que é composto por custos de: armazenagem, fabricação, transporte e de falta de produto (que equivale a perda de uma venda).

Em outras palavras, desejou-se determinar os níveis “ótimos” de estoque e das quantidades de produção e de transporte que permitirão atender as demandas a um menor custo possível.

Para cumprir o objetivo do trabalho, esta otimização foi realizada por meio do desenvolvimento e aplicação de diferentes abordagens fundamentadas no método de enxame de partículas.

### **1.3 Motivação e Contribuição**

O sucesso de uma empresa, atualmente, é contingência do gerenciamento de sua cadeia de suprimentos. Tradicionalmente, as várias unidades de negócios ao longo de uma cadeia de suprimentos operam independentemente. Estas unidades têm seus próprios objetivos e estes são freqüentemente conflitantes. A concepção de uma estratégia de coordenação das várias unidades de negócios em uma cadeia de suprimentos para um gerenciamento efetivo nos níveis estratégico, tático e operacional é um aspecto essencial para o sucesso de uma empresa (VENKATESWARAN; KULVATUNYOU, 2002).

Nesta perspectiva, o interesse em usar a simulação para estudar as projeções de uma cadeia de suprimentos e atingir resultados satisfatórios, torna-se a principal ferramenta para atender ao problema de gerenciamento de uma cadeia de suprimentos. Neste caso, ainda contribuindo para introduzir a técnica de PSO em práticas de otimização da cadeia de suprimentos, além de traçar um comparativo dos resultados com outras técnicas já testadas e apresentadas em Mak e Wong (1995).

A contribuição deste trabalho consiste no fato de que a técnica utilizada para o modelo proposto é diferente das técnicas aplicadas e mencionadas na literatura. Além desta, a dificuldade de se encontrar pesquisas correlacionando modelo de cadeia de suprimentos, otimização e metaheurística permitiu um levantamento bibliográfico que permitiu, entre outras coisas, identificar trabalhos

recentes relacionando otimização de cadeia de suprimentos com simulação e quanto ao uso da técnica de PSO em problemas de otimização.

#### **1.4 Estrutura da Dissertação**

Esta dissertação está dividida em cinco capítulos. O primeiro capítulo foi uma introdução sobre o trabalho, trazendo seu objetivo, um resumo da metodologia utilizada para alcançar o objetivo, as motivações e contribuições.

O segundo capítulo apresenta alguns conceitos sobre Cadeia de Suprimentos e seu gerenciamento e algumas técnicas de computação evolutiva já utilizadas para a sua otimização. E, termina com a apresentação da modelagem matemática para o problema proposto pelo trabalho.

O terceiro capítulo faz uma introdução sobre Computação Evolutiva e uma revisão sobre Otimização por Enxame de Partículas e seu uso em problemas de otimização presentes na literatura. Este capítulo fornece a base para o entendimento da metaheurística utilizada no trabalho. Neste capítulo ainda são detalhadas as propostas de PSO que foram utilizadas no desenvolvimento do trabalho.

O quarto capítulo apresenta a análise dos resultados.

O quinto e último capítulo apresenta a conclusão do trabalho e propostas de trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

### 2.1 Cadeia de Suprimentos (CS)

Cooper, Lambert e Pagh (1997) discutiram sobre as fronteiras no uso de termos como Logística, Cadeia de Suprimentos e o Gerenciamento da cadeia de suprimentos, que ainda mantinham-se próximas ou envoltas em confusão de seus significados. A razão para existir uma cadeia de suprimentos é que muitas companhias – atualmente ainda mais, sob a ótica do foco nas competências centrais (*core*) – não conseguem produzir seus produtos finais para um consumidor final sem a assistência de outras companhias como fornecedoras e distribuidoras, envolvendo assim uma rede de atividades (como compra, manufatura e distribuição) para produzir produtos e/ou serviços.

Pires (2004) mostra que o significado para Cadeia de Suprimentos segundo o dicionário da APICS (*American Production Inventory Control Society*) de Coxer *et al.* (1995), pode ser entendido como sendo o processo de ligação entre organizações envolvidas no processo de produção de um tipo de bem, do processo da compra inicial de materiais até o último consumidor de um produto final; e ainda como as funções da cadeia de valores que são responsáveis por produzir e oferecer serviços aos clientes.

Uma definição mais recente provém de Mentzer *et al.* (2001), definindo CS como um conjunto de três ou mais entidades (organizações ou indivíduos) diretamente envolvidas nos fluxos a montante e jusante de produtos, serviços, financeiro e/ou de informação desde a fonte primária até o consumidor final.

A Figura 2 representa uma cadeia de suprimentos, indicando também os dois sentidos básicos dos relacionamentos que a empresa foco<sup>1</sup> pode conduzir: Montante (no sentido de seus fornecedores) e Jusante (no sentido do cliente final). Percebe-se então nesse exemplo, que a correnteza de um rio é

---

<sup>1</sup> Entende-se por empresa foco, a empresa que serve de parâmetro para o estudo da cadeia de suprimento correspondente a ela. Não confundir com empresa líder da cadeia, uma vez que, na prática, a empresa líder pode estar à montante ou jusante da empresa foco.

utilizada para se fazer uma analogia direta com os sentidos dos relacionamentos da cadeia: rio acima (montante) e rio abaixo (jusante).

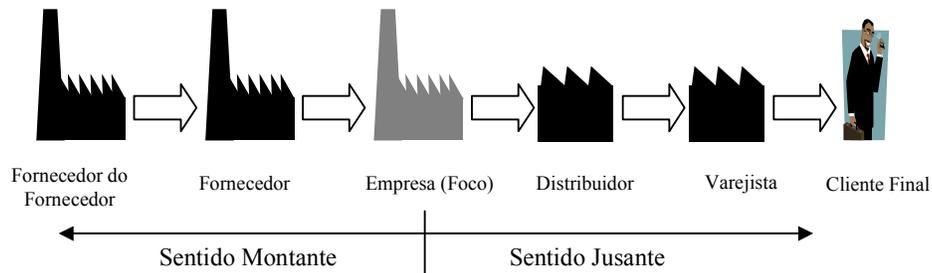


Figura 2 – Representação de uma Cadeia de Suprimentos (CS).  
(Fonte: adaptado de Pires, 2004).

Em 1998, Lambert, Cooper e Pagh, após discussões sobre os conceitos logísticos envolvendo Cadeia de Suprimentos e seu Gerenciamento, sugeriram ainda a classificação dos membros de uma CS em primários e de apoio. Sendo os primários aquelas empresas autônomas ou estratégicas de negócios que executam, de fato, atividades operacionais e/ou administrativas nos processos empresariais designadas a produzir um bem específico (produto e/ou serviço), agregando valor ao produto. Por outro lado, os membros de apoio da cadeia de suprimentos são aquelas empresas cuja função é fornecer recursos, conhecimento, utilidades ou ativos para os membros primários. Pires (2004) destaca ainda que uma empresa pode, simultaneamente, realizar papel de membro primário ou de apoio dependendo da CS em que estiver inserida ou executar os dois papéis em CSs distintas. Tendo em vista a classificação sugerida por Lambert, Cooper e Pagh (1998) em membros primários e de apoio, é possível definir o ponto de origem e o ponto de consumo de cadeia de suprimentos. O ponto de origem vai ocorrer onde não existirem outros fornecedores primários, ou seja, todos aqueles membros anteriores serão de apoio. O ponto de consumo é onde nenhum valor a mais é adicionado ao produto, ou seja, onde o produto é efetivamente consumido.

Ainda de acordo com Lambert, Cooper e Pagh (1998), as dimensões estruturais de uma cadeia ou rede são essenciais para descrever, analisar e gerenciar uma cadeia de suprimentos. Essas dimensões são: a estrutura horizontal, a estrutura vertical e a posição horizontal da empresa focal dentro da cadeia de suprimentos.

- Estrutura Horizontal: se refere ao número de níveis existentes ao longo da cadeia. A cadeia de suprimentos representada na Figura 3 seria composta por três níveis de fornecedores e três níveis de compradores (Centro de Distribuição, Revendedores e Zona Consumidora) em relação à empresa focal (Fabricante).
- Estrutura Vertical: se refere ao número de fornecedores/compradores existentes dentro de cada nível da CS.
- Posição Horizontal da Empresa Focal: uma empresa pode estar posicionada horizontalmente mais próxima ao ponto de origem, ou mais próxima ao ponto de consumo ou entre o início e o fim da cadeia de suprimentos.

As cadeias de suprimentos, segundo Mason-Jones e Towill (1999), são ainda construídas baseadas em dois principais fluxos: o de informação e o de material. Essas requerem estratégias operacionais, as quais integrem e complementem as características individuais de ambos os fluxos.

A Figura 3 mostra uma representação esquemática adaptada de Lambert, Cooper e Pagh (1998) para uma Cadeia de Suprimentos, ilustrando ainda os sentidos em que ocorrem os fluxos de informação e material dentro da cadeia (vale lembrar que a Figura 3 não considera fluxos reversos). E, dando ainda prioridade em considerar o fluxo principal de informação (informações sobre a demanda) no sentido montante. Cabe aqui também uma observação quanto à denominação “nível”, pois esta em nada tem a ver com a qualidade do fornecedor ou do produto (suprimento) fornecido, sendo meramente uma forma de classificá-los seguindo a estrutura horizontal proposta por esses mesmos autores. Há autores, entre os quais Pires (2004), que para não induzir a uma má interpretação, preferem substituir a palavra “nível” por “camada”, sendo assim os fornecedores de 1ª camada, 2ª camada e assim sucessivamente.

Ainda sobre fluxos em uma CS, Mentzer *et al.* (2001), no seu modelo de gestão da cadeia de suprimentos, apontam outros fluxos acontecendo nos dois sentidos da cadeia, sendo estes de: produtos, serviços, informação e recursos financeiros; no sentido montante: demanda; e no sentido jusante: previsão.

É bom lembrar, como Mentzer *et al.* (2001) e Cardoso (2003) destacam, que está implícito nas definições o fato de cadeia de suprimentos existir

independentemente de estar sendo gerenciada, ou seja, mesmo sem existir o gerenciamento da cadeia, esta continua a existir.

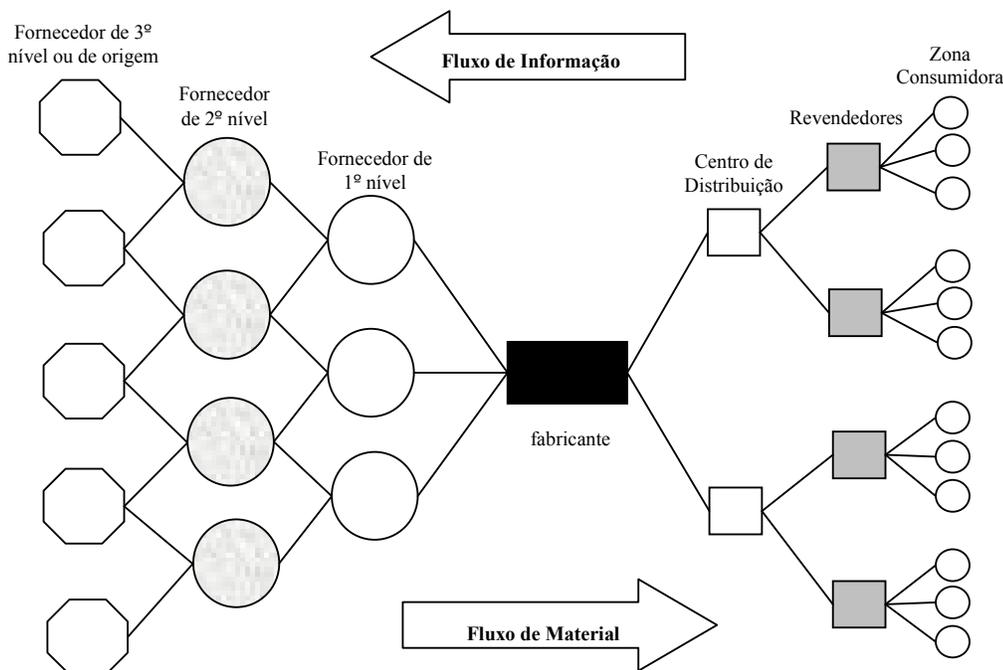


Figura 3 – Representação esquemática de uma cadeia de suprimentos  
(Fonte: adaptado de Lambert, Cooper e Pagh, 1998)

### 2.1.1 Gerenciamento da cadeia de suprimentos (GCS)

Cooper, Lambert e Pagh (1997) destacaram a confusão cometida entre GCS e Logística, acreditando que a coordenação de atividades e processos dentro e entre organizações na cadeia de suprimentos se estende além da logística, anteriormente tratadas como sinônimos. Na época, o termo “Cadeia de Suprimentos” ainda era relativamente novo na literatura, aparecendo pela primeira vez em Oliver e Webber (1992).

O Conselho de Profissionais de Gestão da Cadeia de Suprimentos (*Council of Supply Chain Management Professionals*) define GCS como sendo a coordenação e colaboração entre todos os parceiros envolvidos, os quais podem ser fornecedores, fabricantes, varejistas e os consumidores. Em essência, GCS integra fornecimento e gestão de demanda dentro e fora da empresa.

De acordo com Morini e Pires (2005), basicamente, o objetivo da GCS é o de otimizar a integração entre as partes envolvidas da cadeia, bem como torná-la realidade, de forma a atender o consumidor final mais eficientemente, tanto por meio de redução de custos, quanto por meio de agregação de valor aos produtos finais.

Cardoso (2003) compilou as definições de diversos autores sobre a definição acerca de Gerenciamento da Cadeia de Suprimentos, conforme mostrado no Quadro 1.

Quadro 1 – Definições de GCS

<b>Fonte</b>	<b>Definição</b>
Jones e Riley (1985)	“GCS lida com o fluxo total de materiais desde fornecedores até consumidores finais”
Houlihan (1988) e Novack e Simco (1991)	“GCS envolve o fluxo de bens do fornecedor até o produtor e do produtor até o consumidor final.”
Stevens (1989)	“O objetivo do gerenciamento da cadeia de suprimentos é sincronizar os requisitos do cliente com o fluxo de materiais desde o fornecedor para balancear o que é normalmente visto como metas conflitantes, até o alto nível de serviço ao cliente, baixo nível de estoque e baixo custo unitário.”
Stevens (1990)	“Controle do fluxo de materiais desde os fornecedores, por meio de processos que agregam valor (produção) e canais de distribuição, até os clientes.”
Ellram e Cooper (1990)	“GCS é uma filosofia integrativa para gerenciar o fluxo total do canal de distribuição desde o fornecedor até o consumidor.”
Langley e Holcomb (1991)	“GCS foca enfoca as interações dos membros do canal para produzir um produto/serviço final que fornecerá o melhor valor comparativo para o consumidor”.
Cavinato (1991)	“... as atividades completas de busca, de agregação de valor e de marketing de todos os elos do fornecedor da empresa até o consumidor.”
Lee e Billington (1992)	“Redes de plantas de produção e distribuição que adquirem matérias-primas, as transformam em produtos intermediários e acabados, e distribuem os produtos acabados aos clientes”.
Turner (1993)	“... técnica que atenta para todos os elos da cadeia desde os fornecedores de matérias-primas mediante vários níveis de manufatura, de armazenagem, de distribuição até o consumidor.”
Ellram e Cooper (1993)	“GCS é uma abordagem em que toda a rede desde os fornecedores até o consumidor é analisada e gerenciada para se alcançar o melhor resultado de todo o sistema”
Johannson (1994)	“GCS é realmente uma abordagem operacional da aquisição. Ele requer que todos os membros da cadeia de suprimentos estejam devidamente informados.”
Cooper, Lambert e Pagh (1997)	“GCS é uma filosofia para gerenciar o fluxo total de um canal de distribuição desde o fornecedor até o consumidor.”
	continua

	continuação
Lambert, Cooper e Pagh (1998)	“GCS é a integração de processos chave de negócio desde consumidores até fornecedores da última camada de matéria-prima, os quais fornecem produtos, serviços e informações que agregam valor para clientes e outros interessados ( <i>stakeholders</i> )”.
Monczka, Trent e Handfield (1998)	“GCS é um conceito cujo principal objetivo é integrar e gerenciar a aquisição, fluxo e controle de materiais usando a perspectiva de sistema por intermédio de múltiplas funções e de múltiplas camadas de fornecedores.”
Bowersox, Closs e Stank (1999)	“GCS é o processo feito pela organização para posicionar e alinhar estrategicamente sua capacidade de distribuição a fim de ganhar e manter vantagem competitiva.”
Mentzer <i>et al.</i> (2001)	“GCS é a coordenação estratégica e sistêmica das funções empresariais tradicionais e as táticas entre essas funções dentro de uma empresa, em particular, e entre negócios dentro da cadeia de suprimentos com a finalidade de melhorar o desempenho, em longo prazo, das empresas individuais e da cadeia de suprimentos como um todo.”

Fonte: Cardoso (2003)

Dessas definições pode-se constatar que:

- O objetivo da gestão da cadeia de suprimentos é ser eficiente e eficaz em relação aos custos ao longo de todo o sistema. Os custos, do transporte e da distribuição aos estoques de matérias-primas, de estoque em processo e de produtos acabados, devem ser minimizados. Desta maneira, a ênfase não está somente em diminuir os custos de transportes e reduzir os estoques, mas especialmente, em buscar uma abordagem sistêmica para a gestão da cadeia de suprimentos.
- Pelo fato da GCS compreender a eficiente integração entre fornecedores, fabricantes, depósitos e armazéns, esta abrange as atividades da empresa nos níveis estratégico, tático e operacional.
- A gestão da cadeia de suprimentos leva em consideração todos os aspectos que tenham impacto nos custos e desempenham um papel na fabricação de um produto de acordo com as exigências do cliente, desde as instalações do fornecedor e do fabricante, passando pelos depósitos e centros de distribuição, até os varejistas e lojistas.

Portanto, a cadeia de suprimentos não deve ser visualizada de forma fragmentada, pois cada unidade da cadeia não deve somente se preocupar com a competitividade do produto perante o consumidor final, mas também com o desempenho da cadeia como um todo, de forma a ter uma gestão de cadeia integrada. Basta imaginar o impacto positivo no processo produtivo e nos estoques de um fornecedor, se ele conhecer com antecedência as futuras demandas de seus clientes principais. Por outro lado, também é possível imaginar o impacto positivo que haverá na produção e no serviço ao cliente da empresa compradora, quando se obtém este sincronismo com o fornecedor. Isso leva a concordar com os pressupostos apontados por Filho *et al.* (2004) relacionados à GCS, apresentados no Quadro 2.

Quadro 2 – Pressupostos relacionados à GCS.

A competição deve ocorrer entre cadeias e não mais entre empresas isoladas
Os benefícios devem ser distribuídos a todos os integrantes da cadeia. Não deve haver, na cadeia, empresas “vencedoras” e empresas “perdedoras”.
As estratégias competitivas das empresas participantes da cadeia devem estar alinhadas
Os fornecedores devem estar organizados hierarquicamente, com um número relativamente pequeno de fornecedores em cada nível da cadeia.
As atividades e os processos, mesmo aqueles distribuídos por várias empresas, devem estar integrados na cadeia de suprimentos.
Os fluxos de materiais, serviços e informações devem ser bidirecionais, ocorrendo entre todas as empresas pertencentes à cadeia.
Cada empresa, em cada elo da cadeia, deve buscar eficiência operacional, tendo em vista a otimização das atividades da cadeia como um todo.
As relações entre as empresas devem ser cooperativas e de longo prazo.

Fonte: adaptado de Filho *et al.* (2004).

Mentzer *et al.* (2001), cientes da vasta abordagem de visão que existe acerca do assunto, propuseram uma divisão das definições de GCS em três grupos, de acordo com a Figura 4.



Figura 4 – Grupos das Definições de GCS segundo Mentzer *et al.* (2001).

No primeiro grupo (GCS como uma Filosofia de Gerenciamento), as definições de GCS assumem uma abordagem sistêmica. Sendo, a cadeia de suprimentos visualizada como uma entidade única, ao invés de partes fragmentadas.

O segundo grupo (GCS como um Conjunto de Atividades para implementar uma Filosofia de Gerenciamento), considera que as empresas devem estabelecer práticas gerenciais que permitam a elas agir ou comportar-se consistentemente com a filosofia de gerenciamento adotada. Identifica ainda sete atividades necessárias para implementar com sucesso uma filosofia de GCS (Conduta integrada; Informações compartilhadas mutuamente; Riscos e ganhos compartilhados mutuamente; Cooperação; Mesmo objetivo e o mesmo foco no atendimento aos clientes finais; Integração de processos; e Parceiros para construir e manter relacionamentos de longo prazo).

O terceiro grupo (GCS como um Conjunto de Processos de Gerenciamento), sugere que para implementar com sucesso uma GCS – de acordo com Cooper, Lambert e Pagh (1997) – as empresas dentro de uma cadeia de suprimentos devem superar-se de seus próprios silos funcionais e adotar uma abordagem de processo, reorganizando as funções dentro de uma cadeia de suprimentos como processos-chave. Sendo alguns dos processos-chave: Gestão do relacionamento com o cliente (CRM), Gestão do serviço ao cliente, Gestão da demanda, Atendimento dos pedidos, Gestão do fluxo de Manufatura, o *Procurement*, Desenvolvimento e comercialização de produtos e Retornos.

Cooper, Lambert e Pagh, em 1997, além de fornecer uma discussão sobre os conceitos acerca das definições de GCS, propuseram ainda uma estrutura de gestão da cadeia de suprimentos, conforme mostra a Figura 5.

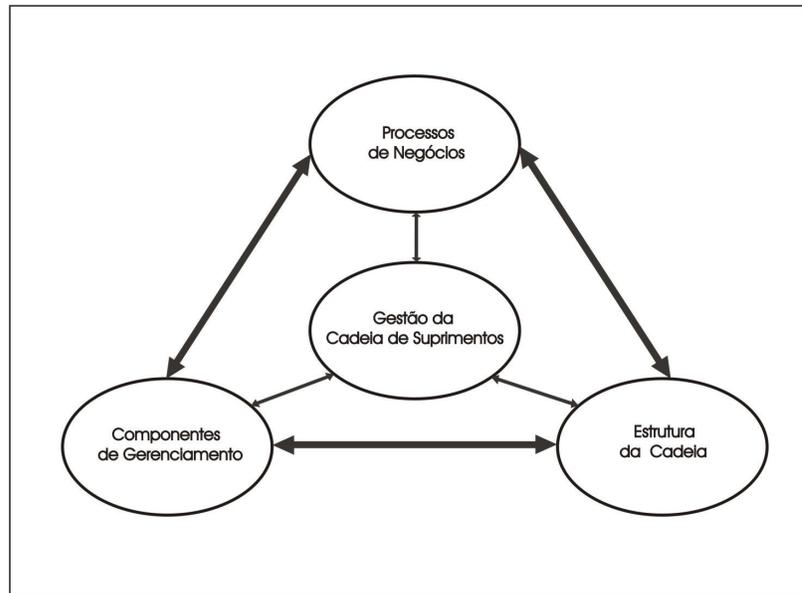


Figura 5 – Estrutura de Gestão da Cadeia de Suprimentos (Fonte: Cooper, Lambert e Pagh, 1997).

A estrutura da Figura 5 inclui três elementos: (1) os Processos de Negócios (são os mesmos processos já apresentados no parágrafo anterior como sendo os Processos de Gerenciamento, uma vez que são baseados em Cooper, Lambert e Pagh, 1997); (2) os Componentes de Gerenciamento para a coordenação dos processos de negócios entre as empresas (planejamento e controle, estrutura dos processos de trabalho, estrutura organizacional, estrutura para fluxo de produto, estrutura para fluxo de informação, estrutura de produto, métodos de gerenciamento, estrutura de poder e liderança, estrutura de risco e recompensas, cultura e atitude); e (3) a Estrutura da Cadeia.

A Figura 6 mostra a Gestão da cadeia de suprimentos sendo realizada para identificar as interações e atividades nas interfaces das empresas (denominadas e representadas por “silos” pelos autores) e delinear Componentes de Gerenciamento comuns para sua gestão e apoio aos Processos de Negócios e atividades de valor da empresa a eles relacionadas.

Embora este modelo seja o mais difundido, existem outros, como o desenvolvido pelo *Supply Chain Council*, também lançado em 1997 e popular nos Estados Unidos e no meio empresarial, o modelo SCOR (*Supply Chain Operations Reference*), o qual segundo Francis (2007) ajuda as empresas a entenderem o funcionamento da cadeia de suprimentos, o que precisa ser realizado e como medir os *outputs* da cadeia. A Figura 7 apresenta o modelo SCOR.

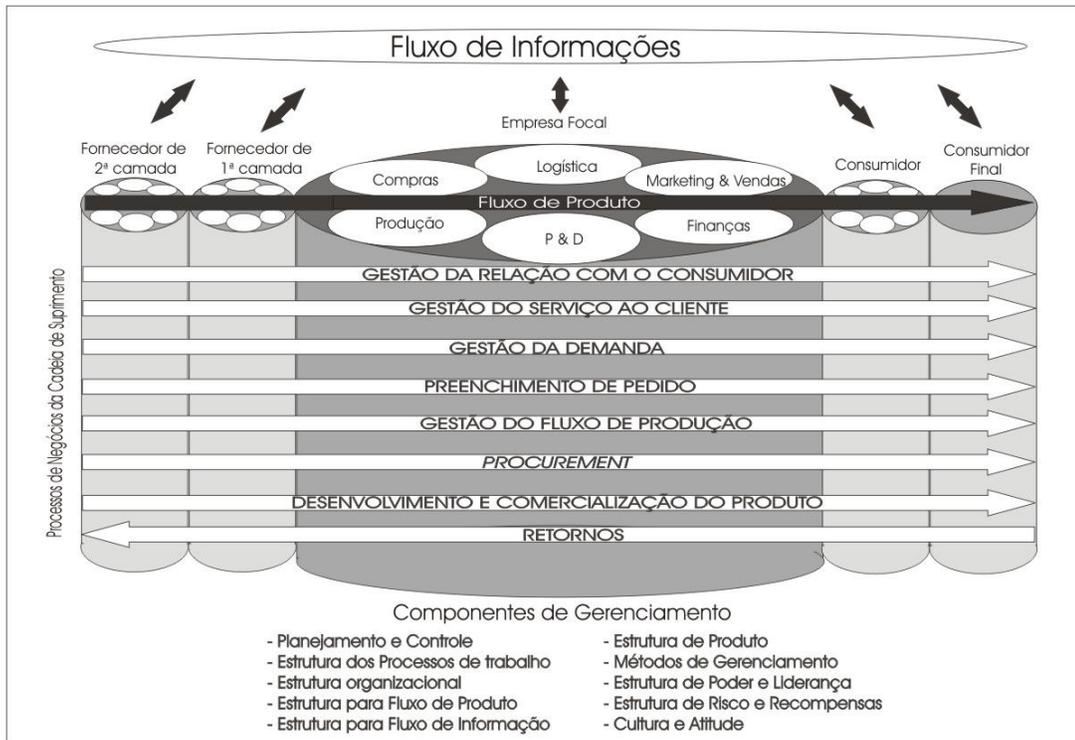


Figura 6 – Modelo de Gestão da Cadeia de Suprimentos (Fonte: adaptado de Cooper, Lambert e Pagh, 1997).

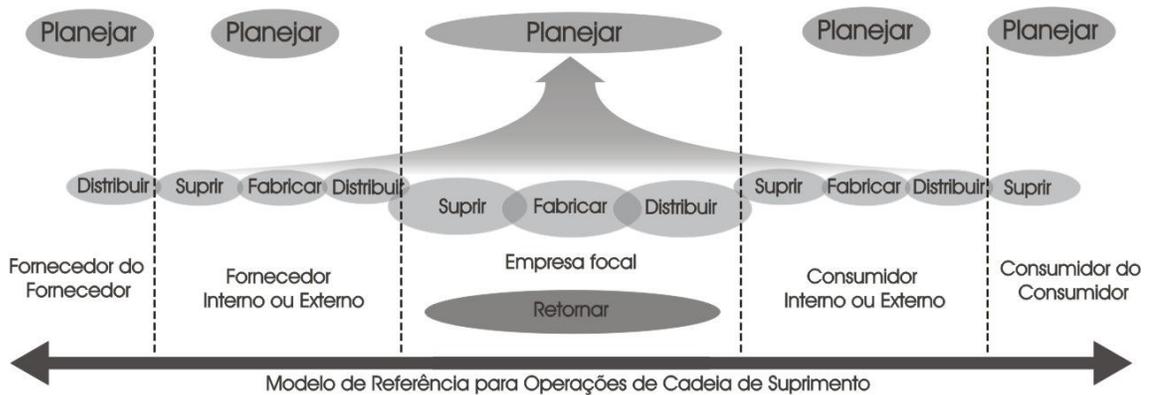


Figura 7 – Modelo de Gestão da Cadeia de Suprimentos segundo o *Supply Chain Council* – modelo SCOR (Fonte: Francis, 2007).

Este modelo conta com cinco processos:

- **Planejar:** realiza o balanceamento entre as demandas com os recursos e materiais disponíveis, elaborando planos para toda a cadeia de suprimentos. Nesta atividade são planejadas as melhores soluções para as áreas de

estoques, compras, produção, distribuição e retornos, compatibilizando com os planos financeiros e de *marketing*. Sendo ainda definidos os indicadores de desempenho e as normas e regulamentos a serem atendidos.

- **Suprir:** envolve o processo de identificação e definição de fontes para obtenção dos materiais necessários para a execução dos planos de produção. Compreende atividades de programação de estoques e entrega de produto para satisfazer as demandas. Além de monitorar as fontes de suprimentos através de indicadores de desempenho e da gestão de contratos.
- **Fabricar:** envolve todos os processos de transformação e montagem para produzir, através da utilização dos recursos, os bens e serviços para atender a demanda. Compreende atividades como programar, abastecer, inspecionar e embalagem.
- **Distribuir:** envolve os processos de entrega de produtos. Compreende as atividades de gerenciamento dos pedidos dos clientes, logística de armazenagem, separação, faturamento, expedição e distribuição de produtos acabados, escolha do transportador e cobrança dos clientes.
- **Retornar:** envolve os processos associados à devolução e ao retorno de materiais e produtos. Compreende atividades como emissão de retorno de produto defeituoso, agendamento do retorno, recebimento, inspeção, correta disposição do produto defeituoso e substituição do produto ou emissão de crédito.

Esses processos são comuns a todos os elementos da cadeia. Eles permitem que o modelo seja utilizado para representar qualquer cadeia de suprimentos, das mais simples às mais complexas. Atualmente, o modelo se encontra na versão 8.0, mas até a versão 4.0 eram somente quatro processos. A partir da versão 5.0 foi acrescentado o processo de Retornar.

Um outro modelo é apresentado por Mentzer *et al.* (2001), conforme a Figura 8.

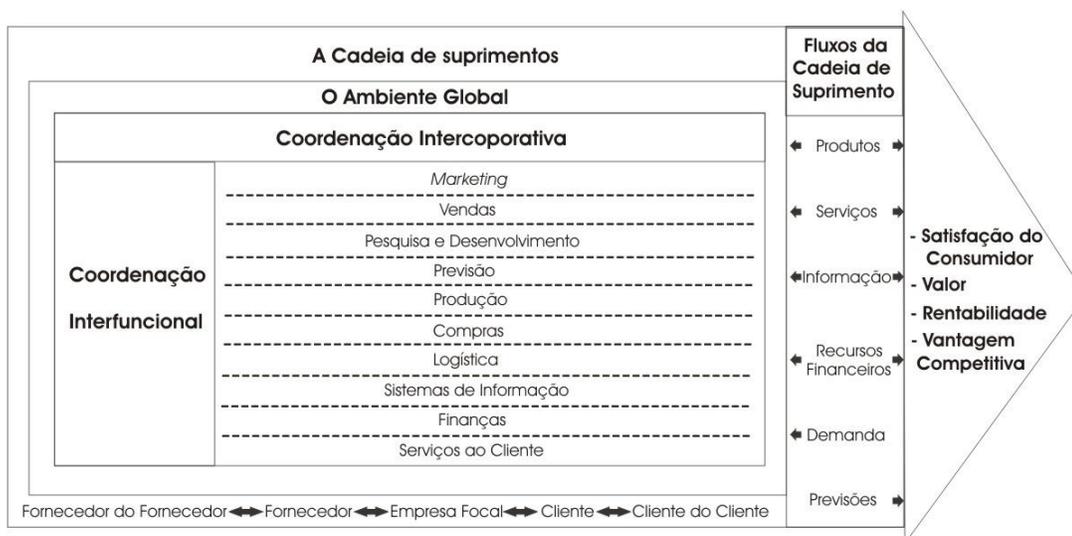


Figura 8 – Modelo de Gestão da Cadeia de Suprimentos. (Fonte: Mentzer *et al.*, 2001).

Segundo esse modelo, a cadeia de suprimentos pode ser vista como um encanamento, com os fluxos que ocorrem ao longo da cadeia (produtos, serviços, informação, recursos financeiros, demanda e previsões). Estes fluxos são gerenciados e realizados desde o fornecedor do fornecedor até o consumidor do consumidor pelas funções tradicionais de *marketing*, vendas, pesquisa e desenvolvimento, previsão, produção, compras, logística, sistemas da informação, finanças e serviços, fornecendo valor e satisfação ao cliente.

A Figura 8 também mostra o papel crítico do valor percebido pelo cliente e sua satisfação para alcançar vantagem competitiva e rentabilidade para as empresas na cadeia e a cadeia de suprimentos como um todo.

A Coordenação Interfuncional presente no modelo inclui uma avaliação dos papéis de confiança, comprometimento, risco, dependência e comportamentos na viabilidade de compartilhamento e coordenação das funções internas. Enquanto que a Coordenação Intercorporativa inclui a mudança funcional dentro da cadeia de suprimentos, o papel desempenhado pelos terceirizados, como as relações entre companhias deveria ser gerenciado, e a viabilidade de diferentes estruturas de cadeia de suprimentos.

Além da abordagem sobre conceitos e definições, faz-se importante também ressaltar as razões atuais que justificam o interesse pelo GCS, apontados por Simchi-Levi, Kaminsky e Simchi-Levi (2003), sendo eles:

- Empresas de diferentes setores industriais têm concentrado suas atividades e recursos (incluindo competências) em determinadas atividades específicas, notadamente naquelas que representam diferenciais competitivos para as mesmas;
- Processo de desverticalização, o qual faz crescer a importância relativa dos materiais adquiridos externamente por cada empresa, ou seja, em vez de comprar itens específicos, as empresas passam a comprar subconjuntos montados;
- Com a desverticalização, as possibilidades de redução de custos por peça e melhoria das operações passam, crescentemente, a se situar além das fronteiras de cada empresa individual;
- A coordenação e sincronização dos fluxos de materiais deixam de ter sentido apenas dentro de cada empresa e passa a se referir à cadeia como um todo;
- O desenvolvimento e consolidação de uma “visão global” para o entendimento, gestão e operação dos sistemas de operações, que supera a idéia de otimização ou melhoria local (em cada máquina, posto de trabalho ou empresa isolada), consolidou-se em uma série de práticas e teorias de gestão, situadas dentro de um paradigma sistêmico-processual;
- Os avanços da tecnologia de informação têm descortinado novas possibilidades para: a) a modelagem analítica, de maneira que a geração e resolução de modelos matemáticos têm se tornado cada vez mais correntes, economicamente viáveis e rápidos com o incremento da capacidade computacional e o desenvolvimento de novos métodos matemáticos; b) a integração dos fluxos de dados transacionais e a automação de processos entre empresas, permitindo que determinados processos possam ser implementados (ERP e *e-business*) em diferentes empresas, reduzindo *lead times* e gerando dados que podem ser utilizadas na gestão da cadeia.

Muitos gestores, segundo Montebeller (2002), defendem a idéia de redução de custos para investimentos em Logística, mas há os que preferem defender a idéia de redução de tempo, estreitando os laços com seus fornecedores, através da confiança e de produtos dentro das especificações e no tempo certo.

Para desfazer qualquer confusão que ainda possa existir no que se refere aos significados mencionados por Cooper, Lambert e Pagh em 1997, o *Council of Supply Chain Management Professionals*, define Logística como sendo

a parte do processo da cadeia de suprimentos que planeja, implementa e controla de forma eficiente e eficaz o fluxo e o armazenamento de produtos, serviços e as informações entre o ponto de origem e o ponto de consumo, em razão de atender os requisitos dos consumidores.

### **2.1.2 A Utilização de heurísticas e metaheurísticas no GCS: uma revisão da literatura**

Um fator de desajuste na cadeia de suprimentos pode ser causado pelo que se denomina de Efeito Chicote (*Bullwhip Effect*), um fenômeno de distorção na percepção da informação da demanda ao longo da cadeia de suprimentos estudado por Forrester desde a década de 60, quando da criação do conceito de Dinâmica de Sistemas. O estudo mostra que a variação entre a demanda conhecida na empresa-cliente (a que envia o pedido) e a demanda conhecida na empresa-fornecedora (a que recebe o pedido) cresce a cada transferência (FURTADO; CARVALHO, 2005). Visando minimizar este efeito negativo da distorção da informação, Balan, Vrat e Kumar (2007), utilizaram um sistema neuro-nebuloso e Wu (1999) propôs uma rede neural artificial para prever a correta leitura das informações que sofrem um atraso na cadeia de suprimentos. Nesta técnica, ele empregou uma rede neural perceptron multicamadas com treinamento pelo método de retropropagação do erro para realizar a relação entre a informação atrasada e a informação correta.

Ainda segundo a ótica de redes neurais artificiais, Leung (1995) examina algumas aplicações em GCS para dar suporte à tomada de decisão.

Quanto à previsões de demanda, Jeong, Jung e Park (2002), apresentaram um sistema computacional para implementação de atividades de previsão de demanda em uma GCS. Utilizando um modelo genérico de previsão de demanda para GCS (modelo linear), seus coeficientes são eficientemente determinados usando duas abordagens de algoritmos genéticos. O sistema

computacional foi desenvolvido para implementar as funções de previsão de demanda e é utilizado com sucesso numa fábrica de vidro.

Para encontrar o melhor projeto de produção/distribuição num sistema multi-estágio de logística para a determinação da escolha das fábricas e dos centros de distribuição a serem abertos, além do desenho da rede de distribuição para satisfazer a demanda com custo mínimo, foi proposto por Syarif, Yun e Gen (2002) a utilização de um *spanning tree-based Genetic Algorithm* (st-GA) e com a ajuda do número de *Prüfer* (conhecido por ser uma eficiente maneira para representar vários problemas de rede). A eficácia e eficiência deste método são demonstrados pela comparação de seus resultados numéricos com outros mais tradicionais, tais como algoritmo genético baseado em matriz e métodos numéricos presentes no *software* LINDO.

Nesta mesma linha de pesquisa, em querer determinar o número de centros de distribuição e das rotas dos veículos, Hwang (2002) desenvolveu um modelo de otimização com base em algoritmos genéticos que foi testado com problemas *benchmark* do tipo caixeiro viajante, mostrando-se eficiente.

No esforço de projetar uma rede de cadeia de suprimentos que mantenha o melhor equilíbrio entre o custo de transporte e o nível de serviço, Zhou, Min e Mitsuo (2002) propuseram um novo modelo baseado na “*naïve balanced star spanning forest formulation*”. Este modelo vai além da tradicional programação matemática, incorporando um algoritmo genético. O modelo de programação e planejamento de processo integrado para uma MSC (*Multi-plant Supply Chain*), o qual se comporta como uma única companhia através da forte coordenação e cooperação em relação aos objetivos mútuos, foi proposto por Moon, Kim e Hur (2002), o problema é formulado como um modelo matemático que considera máquinas e seqüências alternativas e a configuração de seqüências dependentes. O objetivo do modelo é decidir as programações para minimizar atraso total através da análise da seleção de máquinas alternativas e seqüência de operações em MSC. Em virtude de obter uma boa solução de aproximação, foi desenvolvido um algoritmo genético utilizando experimentos para demonstrar a eficiência da técnica proposta.

Quanto aos aspectos que se referem à análise de fornecedores, Choy, Lee e Lo (2002) propuseram uma ferramenta denominada ISMT (*Intelligent Supplier Management Tool*) com a intenção de melhorar a prática corrente de

processo de seleção de fornecedores. Com a assimilação usando uma técnica de raciocínio baseado em casos e também uma rede neural, avaliou-se a prioridade de potenciais fornecedores usando uma rede neural treinada, para aprender com experiências passadas, mostrando-se como uma técnica favorável para a injeção progressiva do ISMT, o qual auxilia o processo de tomada de decisão na escolha de fornecedores. E, ainda segundo Choy, Lee e Lo (2003), melhoraram essa abordagem com a utilização do que denominaram de ISRMS (*Intelligent Supplier Relationship Management System*) usando híbrido de raciocínio baseado em casos e redes neurais para selecionar e fazer validação de potenciais fornecedores. E, ainda fizeram um estudo de caso na empresa *Honeywell* (empresa de aquecedores, umidificadores, purificador de ar, entre outros) baseados na abordagem de ISRMS proposta.

Ding *et al.* (2004) propuseram uma ferramenta denominada “ONE” para dar suporte aos tomadores de decisão para a avaliação, projeto e melhoria da cadeia de suprimentos, respeitando os critérios econômicos, sociais e ambientais, através de uma técnica de otimização com múltiplos objetivos.

A abordagem de algoritmo genético com múltiplos objetivos também foi abordada por Joines *et al.* (2002) para a otimização de uma cadeia de suprimentos.

A otimização por algoritmo genético também foi proposta, para um procedimento de controle de estoque que determina um compromisso entre capacidade, demanda e nível mínimo de estoque, por Disney, Naim e Towill (2000).

O algoritmo genético e redes neurais também são propostos como métodos de otimização por vários autores para a análise e melhoria de programação da produção e planejamento da cadeia produtiva como os propostos por Rhode (2004), Berning *et al.* (2004) e por Chan, Chung e Chan (2005) que utiliza a técnica do gene dominante (*Genetic Algorithm with Dominated Genes – GADG*).

Silva *et al.* (2005), discutiram as metodologias que podem ser usadas para otimizar o processo logístico de uma dada cadeia de suprimentos como um problema de programação. Primeiramente, um modelo de sistema baseado em um modelo real (na *Fujitsu-Siemens Computers - FSC*) é apresentado. Uma nova função objetivo chamada de *Global Expected Lateness* é proposta, em razão de descrever a otimização baseada em múltiplos objetivos. Por fim, três diferentes metodologias de otimização foram propostas:

- a) Despacho padrão;
- b) Despacho com uso de Algoritmo Genético;
- c) Despacho com uso de Colônia de Formigas.

Estas metodologias são comparadas no que tange aos aspectos de política de despacho no exemplo real do estudo de caso. Os resultados mostram que heurísticas de despacho baseadas em FDFS (*First Desired, First Served*) são melhoradas pelo Algoritmo Genético e Colônia de Formigas. É mostrado também que estes detêm estatisticamente soluções idênticas de programação e do ponto de vista de desempenho da otimização, sendo equivalentes no uso de qualquer uma dessas metaheurísticas.

Ainda sob os aspectos logísticos, Ko e Evans (2007) apresentaram um modelo de integral mista de programação não-linear para o projeto de uma rede dinâmica integrada de distribuição, apresentando um algoritmo genético que ajudaria na determinação de vários recursos para capacidade de materiais, equipamentos e recursos humanos.

Ding, Benyoucef e Xie (2003) apresentaram uma abordagem de simulação aliada à otimização usando algoritmos genéticos para o problema de seleção de fornecedores em uma cadeia de suprimentos. Enquanto que Lee, Jeong e Moon (2002) utilizaram o algoritmo genético como proposta de otimização de um sistema de planejamento e escalonamento para o processamento de pedidos dos consumidores.

## **2.2 Modelagem Matemática do Problema**

O modelo matemático que descreve o sistema à ser otimizado neste trabalho pode ser concebido de forma simplificada para fins de comparação entre algoritmos de otimização. Neste caso, o modelo é governado por uma função objetivo a ser otimizada e restrições a serem satisfeitas (MAK; WONG, 1995), ou seja,

$$\text{minimizar } \text{aval}(x) = C_{\text{armazenagem}} + C_{\text{fabricação}} + C_{\text{transporte}} + C_{\text{falta}} \quad (1)$$

tal que:

$$C_{\text{armazenagem}} = \sum_{r=1}^R \sum_{p=1}^P \sum_{t=2}^{T+1} H_{rp}^R K_{rpt} + \sum_{p=1}^P \sum_{t=2}^{T+1} H_p^P J_{pt} + \sum_{m=1}^M \sum_{t=2}^{T+1} H_m^M I_{mt} \quad (2)$$

$$C_{\text{fabricação}} = \sum_{p=1}^P \sum_{t=1}^T C_p^P \left[ J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] \quad (3)$$

$$C_{\text{transporte}} = \sum_{r=1}^R \sum_{p=1}^P \sum_{t=1}^T C_{rp}^D Z_{rpt} + \sum_{m=1}^M \sum_{t=1}^T C_m^M \left\{ I_{m,t+1} + \sum_{p=1}^P \theta_{mp} \left[ J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] - I_{mt} \right\} \quad (4)$$

$$C_{\text{falta}} = \sum_{r=1}^R \sum_{p=1}^P \sum_{t=1}^T C_{rp}^S \left[ D_{rpt} - (K_{rpt} + Z_{rpt} - K_{rp,t+1}) \right] \quad (5)$$

sujeito a

$$K_{rpt} + Z_{rpt} - K_{rp,t+1} \geq 0 \quad (6)$$

$$K_{rpt} + Z_{rpt} - K_{rp,t+1} \leq D_{rpt} \quad (7)$$

$$J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \geq 0 \quad (8)$$

$$\sum_{p=1}^P B_p \left[ J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] \leq \beta_t \quad (9)$$

$$\sum_{r=1}^R \sum_{p=1}^P W_p^P Z_{rpt} \leq \omega_t^P \quad (10)$$

$$I_{m,t+1} + \sum_{p=1}^P \theta_{mp} \left[ J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] - I_{mt} \geq 0 \quad (11)$$

$$\sum_{m=1}^M W_m^M \left\{ I_{m,t+1} + \sum_{p=1}^P \theta_{mp} \left[ J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] - I_{mt} \right\} \leq \omega_t^M \quad (12)$$

onde (FALCONE, 2004):

- $B_p$  é o tempo de processamento de manufatura de cada unidade do  $p$ -ésimo produto;
- $\beta_t$  é tempo de capacidade total para manufatura no  $t$ -ésimo período;
- $C_{rp}^D$  é o custo de envio de cada unidade do  $p$ -ésimo produto do fabricante para o  $r$ -ésimo distribuidor;
- $C_m^M$  é o custo de envio de cada unidade do  $m$ -ésimo material do fornecedor para o fabricante;
- $C_p^P$  é o custo de fabricação de cada unidade do  $p$ -ésimo produto;
- $C_{rp}^S$  é o custo de falta (*shortage*) de cada unidade do  $p$ -ésimo produto do fabricante para o  $r$ -ésimo distribuidor;
- $D_{rpt}$  é a demanda do  $p$ -ésimo produto do fabricante para o  $r$ -ésimo distribuidor no  $t$ -ésimo período;
- $H_m^M$  é o custo de armazenagem de cada unidade do  $m$ -ésimo material mantido no estoque de entrada do fabricante;
- $H_p^P$  é o custo de armazenagem de cada unidade do  $p$ -ésimo produto mantido no estoque de saída do fabricante;
- $H_{rp}^R$  é o custo de armazenagem no distribuidor de cada unidade do  $p$ -ésimo produto do fabricante para o  $r$ -ésimo distribuidor;
- $I_{mt}$  é a quantidade armazenada do  $m$ -ésimo material no estoque de entrada do setor de fabricação no início do  $t$ -ésimo período;
- $J_{pt}$  é a quantidade armazenada do  $p$ -ésimo produto no setor de fabricação no início do  $t$ -ésimo período;

- $K_{rpt}$  é a armazenagem do  $p$ -ésimo produto mantido no  $r$ -ésimo distribuidor no início do  $t$ -ésimo período;
- $W_m^M$  é o peso de cada unidade do  $m$ -ésimo material;
- $W_p^P$  é o peso de cada unidade do  $p$ -ésimo produto;
- $\omega_i^M$  é o limite de carregamento dos materiais transportados do fornecedor para o fabricante no  $t$ -ésimo período;
- $\omega_i^P$  é o limite de carregamento dos produtos transportados do fabricante para o distribuidor no  $t$ -ésimo período;
- $Z_{rpt}$  é a quantidade enviada do  $p$ -ésimo produto do fabricante para o  $r$ -ésimo distribuidor no  $t$ -ésimo período;
- $\theta_{mp}$  é a quantidade do  $m$ -ésimo material necessário para fabricar cada unidade de quantidade do  $p$ -ésimo produto.

A função objetivo (1) minimiza a soma dos custos de armazenagem, fabricação, transporte e falta de produto. As equações (2), (3), (4) e (5) indicam a composição dos custos de armazenagem, fabricação, transporte e falta de produto respectivamente. A inequação (6) impõe a positividade das vendas. A inequação (7) limita esta venda até o valor da demanda do produto para cada período e distribuidor. A inequação (8) impõe a positividade da produção. A inequação (9) limita a capacidade produtiva a um valor máximo estipulado. A inequação (10) limita o peso total da quantidade de produtos a serem transportados. A inequação (11) impõe a positividade da quantidade de matéria-prima enviada entre fornecedores e fabricante. A inequação (12) limita o peso total da matéria-prima a ser transportada.

As variáveis de decisão que compõem o vetor  $x$  a ser otimizado são as variáveis inteiras:

$$\begin{cases} I_{mt} \ (m = 1,2,\dots,M; t = 2,3,\dots,T) \\ J_{pt} \ (p = 1,2,\dots,P; t = 2,3,\dots,T) \\ K_{rpt} \ (r = 1,2,\dots,R; p = 1,2,3,\dots,P; t = 2,3,\dots,T) \\ Z_{rpt} \ (r = 1,2,\dots,R; p = 1,2,3,\dots,P; t = 2,3,\dots,T) \end{cases}$$

onde  $I_{mt}, J_{pt}, K_{rpt}, Z_{rpt} \geq 0$ .

### 2.2.1 Método de penalização

A literatura propõe vários métodos para o manuseio de restrições em algoritmos evolutivos e abordagens de inteligência coletiva (DEB, 2000 e COELLO COELLO, 2002). Estes métodos podem ser agrupados em quatro categorias: métodos que preservam a viabilidade da solução (comentar), métodos baseados em penalidade, métodos que distinguem claramente entre soluções viáveis e inviáveis e métodos híbridos (MICHALEWICZ; SCHOENAUER, 1996).

Em técnicas de otimização é comum manusear as restrições baseadas no conceito de funções de penalidade, a qual penaliza soluções inviáveis (MICHALEWICZ; SCHOENAUER, 1996).

Isto é, tenta-se resolver um problema sem restrição no espaço de busca  $F$  usando uma função modificada da função *fitness*, tal como:

$$aval(x) = \begin{cases} f(x), & \text{se } x \in F \\ f(x) + penalidade(x), & \text{senão} \end{cases} \quad (12)$$

onde *penalidade(x)* é zero se nenhuma restrição é violada; e positiva se do contrário. Geralmente a função penalidade é baseada em uma medida de distância para a solução mais próxima na região viável  $F$  ou em um esforço para reparar a solução.

A metodologia proposta para manusear as restrições é dividida em duas etapas. A primeira consiste em encontrar soluções para as variáveis de decisão que se situam dentro dos limites máximo (*lmax*) e mínimo (*lmin*) definidos pelo usuário,  $x \in [lmax, lmin]$ . Sempre que as restrições de um limite máximo ou um limite mínimo não são satisfeitas, uma regra de reparo é aplicada, de acordo com as Equações 13 e 14, respectivamente:

$$x_i = x_i + w \cdot rand[0,1] \cdot \{lmax(x_i) - lmin(x_i)\} \quad (13)$$

$$x_i = x_i - w \cdot rand[0,1] \cdot \{lmax(x_i) - lmin(x_i)\} \quad (14)$$

onde  $w \in [0,1]$  é um parâmetro definido pelo usuário e  $rand[0,1]$  é um valor gerado por distribuição uniforme entre 0 e 1.

Na segunda etapa, as variáveis de decisão são consideradas como inequações ( $g_i(x) \leq 0$ ). Neste trabalho, a função *fitness* é maximizada segundo:

$$aval(x) = \begin{cases} f(x), & \text{quando } g_i(x) \leq 0 \\ f(x) + r \cdot q \cdot \sum_{i=1}^n g_i(x), & \text{quando } g_i(x) > 0 \end{cases} \quad (15)$$

onde  $q$  é uma constante positiva (arbitrariamente fixada em 5.000) e  $r$  é o número de restrições  $g_i(x)$  que não foram satisfeitas.

### 3 FUNDAMENTOS DE COMPUTAÇÃO EVOLUTIVA E OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS

#### 3.1 Introdução à Computação Evolutiva

A Computação Evolutiva é baseada em mecanismos evolutivos encontrados na natureza. Segundo Silva *et al.* (2005), estes mecanismos foram descobertos e formalizados por Darwin em sua teoria da evolução natural, no qual a vida na Terra é resultado de um processo de evolução, no qual somente os indivíduos mais aptos e adaptados sobrevivem e têm mais chances de se reproduzirem.

Uma das primeiras aplicações na área de Computação Evolutiva foi relacionada ao que denominaram de algoritmos genéticos. Foram desenvolvidos por Holland (1975), em que os indivíduos estavam sujeitos a operações de seleção, recombinação e mutação.

De acordo com Eiben (2005), a Computação Evolutiva possui três idéias básicas:

a) A criação de uma população de soluções – É necessário que haja uma população inicial de soluções possível para o problema proposto. Essa população pode ser gerada aleatoriamente ou através de alguma técnica. Cada indivíduo dessa população terá registrado em si os parâmetros que descrevem a sua respectiva solução para o problema.

b) A criação de uma função de avaliação – A função de avaliação terá o trabalho de julgar a aptidão de cada indivíduo da população. A função é definida através da codificação das soluções para o problema para que se possa avaliar se o indivíduo está ou não apto.

c) A criação dos operadores de seleção, cruzamento e mutação – É necessário gerar novas populações para que se encontre o mais apto. Essas são chamadas de gerações e são obtidas através da aplicação de três operadores: seleção, cruzamento e mutação. Na seleção escolhem-se os indivíduos mais aptos para

gerarem descendentes. Essa reprodução pode ocorrer de duas formas: um indivíduo gera a descendência ou um par de indivíduos geram a descendência. O primeiro caso simula uma reprodução assexuada e o segundo uma reprodução sexuada. É importante destacar que os descendentes serão diferentes de seus antecedentes. No cruzamento ocorre a troca de material genético entre o par de antecedentes definindo assim a carga genética dos descendentes. Dessa forma, cada descendente desse par herdará uma parte do material genético de seus antecedentes escolhidos de forma aleatória. E na mutação ocorrem mudanças aleatórias no material genético do indivíduo. A simulação da passagem de gerações ocorre na repetição deste ciclo, ou seja, a cada iteração.

Os estudos relacionados à Computação Evolutiva não pararam. Outras áreas surgiram e ganharam importância no meio científico. Recentemente, novas concepções de metaheurísticas, como Colônia de Formigas e Enxame de Partículas, surgiram. Essas propostas também têm uma forte motivação biológica tais como bandos de pássaros, cardumes e enxames.

### **3.2 Otimização por Enxame de Partículas**

A Otimização por Enxame de Partículas (*Particle Swarm Optimization* – PSO) é uma técnica estocástica de otimização baseada em população de indivíduos ou agentes desenvolvida inicialmente por Kennedy e Eberhart (1995a, 1995b), inspirado pelo comportamento social de pássaros e peixes.

Imagine um grupo de pássaros procurando aleatoriamente por comida em uma área. Há somente um pedaço de comida na área de busca. Os pássaros não sabem onde a comida está, mas eles sabem quão longe a comida está e a posição de seus parceiros (os outros pássaros). Então, qual é a melhor estratégia para encontrar a comida? Uma estratégia eficiente é seguir o pássaro que estiver mais próximo da comida. Nestes grupos, existe um líder que guia o movimento de todo o enxame, havendo um revezamento entre os indivíduos da população. O movimento de todos os indivíduos é baseado no líder e em seu próprio conhecimento (ANDRÉS; LOZANO, 2006).

O algoritmo PSO utiliza este cenário para resolver os problemas de otimização. Cada solução é tratada como um “pássaro” no espaço de busca, o qual é devidamente chamado de “partícula”. Todas as partículas possuem valores de *fitness* e velocidades que direcionam o vôo das partículas. Estas voam através do espaço do problema acompanhando as partículas que obtiveram as melhores soluções até o momento.

Então, uma vez baseado na natureza, as partículas (indivíduos) assumem um compromisso entre a sua memória individual e a social.

PSO compartilha de muitas similaridades com as técnicas de computação evolutiva, tais como os algoritmos genéticos. É inspirado pela natureza, baseando-se no fato de que a experiência de animais em um grupo contribui para a experiência do grupo todo.

Da mesma forma como acontece com os algoritmos genéticos, o PSO é uma ferramenta de otimização baseada em uma população, onde cada indivíduo é visto como uma partícula, e, cada partícula assume uma forte solução para o problema analisado. Para cada partícula no algoritmo PSO é associada uma velocidade aleatória, movendo-se pelo espaço de busca do problema.

Entretanto, ao contrário de algoritmo genético, PSO é distintivamente diferente de outros métodos evolutivos, visto que não se utiliza de operações de cruzamento e/ou mutação e os membros de toda a população são mantidos ao longo do procedimento de busca. PSO não se utiliza do conceito de sobrevivência dos indivíduos mais aptos, mas implementa a simulação do comportamento social.

As soluções potenciais, denominadas partículas, voam através do espaço do problema seguindo as melhores partículas atuais. Cada partícula mantém-se a par de suas coordenadas no espaço do problema que são associadas com a melhor solução encontrada.

O espaço de solução do problema é formulado como um espaço de busca. Cada posição no espaço de busca é uma solução correlacionada do problema. As partículas cooperam para descobrir a melhor posição (*best solution*) no espaço de busca.

Em cada iteração, as partículas se movem para o *pbest* (*personal best*) e o *gbest* (*global best*). (SHA; HSU, 2006). O *pbest* é a melhor posição

encontrada por cada partícula (cada partícula tem o seu próprio  $pbest$ ) e  $gbest$  é a melhor posição encontrada em todo o enxame dessas partículas, conforme mostrado na Figura 9.

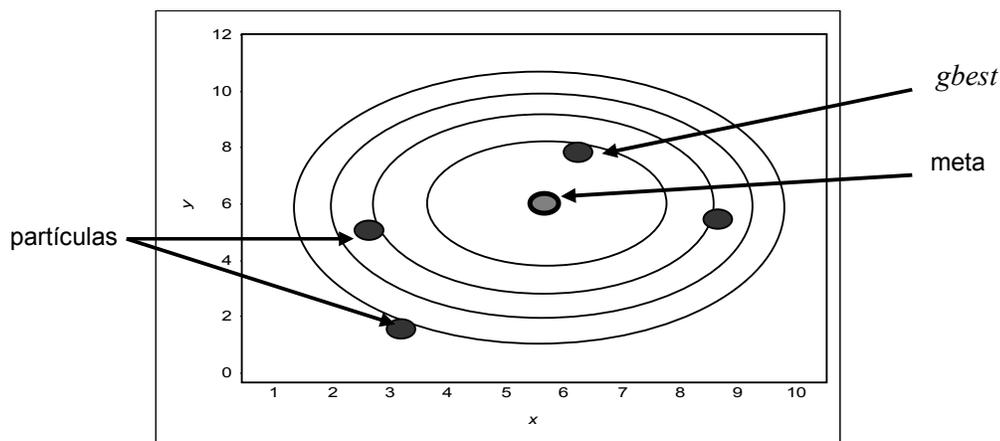


Figura 9 – Analogia do PSO

Em outras palavras, cada partícula utiliza dois importantes tipos de informação no processo de decisão. A primeira é a própria experiência da partícula (ela tentou suas próprias escolhas e sabe quais delas foram melhores até a geração atual e quão satisfatórias também). A segunda é baseada na experiência de outra partícula (cada partícula tem conhecimento de como as outras ao redor delas se comportaram), a propósito, elas sabem quais das escolhas que suas vizinhas encontraram são mais positivas até agora. Ou seja, em PSO, cada partícula faz a sua decisão de acordo às suas próprias experiências e às experiências do grupo.

### 3.2.1 Etapas do algoritmo PSO

O procedimento de implementação do PSO, baseado em Sha e Hsu (2006), é mostrado na Figura 10.

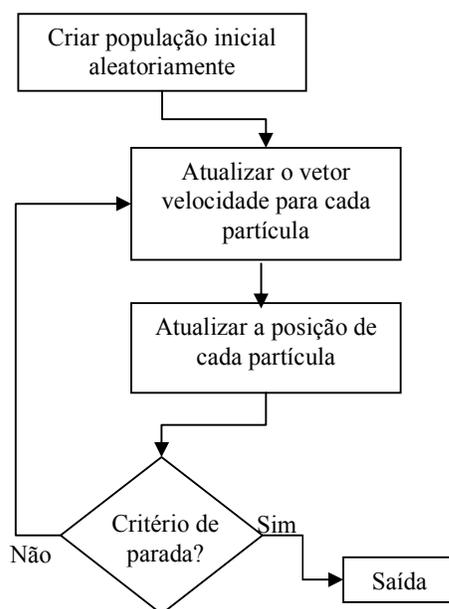


Figura 10 – Fluxograma para o algoritmo PSO

Para atualizar a velocidade e a posição de cada partícula  $k$  e dimensão  $j$ , são utilizadas as Equações (16) e (17):

$$v_{k,j}(t+1) = w \cdot v_{k,j}(t) + c_1 \cdot r_1 \cdot (pbest_{k,j} - x_{k,j}(t)) + c_2 \cdot r_2 \cdot (gbest_j - x_{k,j}(t)) \quad (16)$$

$$x_{k,j}(t+1) = x_{k,j}(t) + v_{k,j}(t) \quad (17)$$

onde:

- $t$  é a iteração atual;
- $w$  é o fator de inércia da partícula;
- $r_1$  é variável aleatória para a parte cognitiva;
- $r_2$  é variável aleatória para a parte social;
- $c_1$  é o parâmetro de confiança para a parte cognitiva;
- $c_2$  é o parâmetro de confiança para a parte social.

Segundo Sha e Hsu (2006), a partícula se move de acordo sua velocidade. As velocidades são geradas aleatoriamente para  $pbest$  e  $gbest$ .

Nas Equações (16) e (17),  $v_{k,j}$  é a velocidade da partícula  $k$  na dimensão  $j$ , e  $x_{k,j}$  é a posição da partícula  $k$  na dimensão  $j$ . O  $pbest_{k,j}$  é o  $pbest$  da partícula  $k$  na dimensão  $j$ , e o  $gbest_j$  é a melhor posição do enxame na dimensão  $j$ .

Então, o procedimento de implementação do PSO em etapas, é realizado como segue:

Etapa 1 – Iniciar uma população de partículas com posições geradas aleatoriamente e velocidades no espaço  $n$  dimensional;

Etapa 2 – Avaliar o *fitness*;

Etapa 3 – Atualizar a velocidade de cada partícula de acordo com a Equação (16);

Etapa 4 – Atualizar a posição de cada partícula, de acordo com a Equação (17);

Etapa 5 – Mapear a posição de cada partícula dentro do espaço de solução e avaliar o valor da função *fitness*. E ao mesmo tempo, atualizar o  $pbest$  e  $gbest$  se necessário;

Etapa 6 – Voltar à Etapa 2 até que o critério seja encontrado. Geralmente esse critério é um *fitness* suficientemente bom ou atingiu um número máximo de iterações.

Os componentes da Equação (16) para a atualização da velocidade das partículas são dados conforme apresentado a seguir.

### 3.2.2 Parâmetros relevantes do projeto de um algoritmo PSO

O  $pbest$  é a melhor posição encontrada por cada partícula. Podendo ser vista como a memória da partícula.

Muitas restrições podem ser aplicadas para a definição da melhor posição, adaptando para diferentes problemas. Isso não diminuirá a habilidade de

busca e desempenho. Por exemplo, em problemas de otimização não linear – como nos trabalhos de Hu, e Eberhart (2002c) e El-Gallad, El-Hawary e Sallam (2001) – as partículas somente lembram aquelas posições no espaço viável e desconsidera soluções inviáveis. Em uma otimização de múltiplos objetivos, a melhor posição é determinada pela eficiência de Pareto, como nos trabalhos de Coello Coello e Lechuga (2002) e Hu e Eberhart (2002b). E, em ambientes dinâmicos, como em Hu e Eberhart (2002a) e Carlisle e Dozier (2002), o *pbest* será reiniciado para o valor atual se o ambiente mudar, seguindo a técnica de reinício de memória (*memory reset*).

O *gbest* é a melhor posição encontrada em todo o enxame.

Tradicionalmente, PSO utiliza um conjunto predeterminado de partículas no enxame. O número de partículas ou o tamanho do enxame afetará a velocidade de convergência do algoritmo. Um grande enxame fará as partículas convergirem mais rapidamente, enquanto o contrário ajudará a prevenir que as partículas convirjam prematuramente.

Os parâmetros de confiança  $c_1$  e  $c_2$  na Equação (16) representam a ponderação dos termos estocásticos de aceleração que empurram cada partícula em direção às posições de *pbest* ou *gbest* (EBERHART; SHI, 2001), pois indicam o quanto uma partícula confia em si ( $c_1$ ) – parte cognitiva; e no enxame ( $c_2$ ) – parte social. De um ponto de vista psicológico, o termo cognitivo representa a tendência de indivíduos duplicarem comportamentos passados que provaram ter obtido sucesso, uma vez que o termo social representa a tendência em seguir o sucesso dos outros.

Na maioria das vezes, os valores para os parâmetros de confiança  $c_1$  e  $c_2$  são iguais. Kennedy (1997) investigou dois casos extremos, separadamente o modelo cognitivo e o modelo social, e descobriu que ambas as partes são essenciais para o sucesso da pesquisa em enxame de partículas.

O fator de inércia  $w$  foi proposto por Shi e Eberhart (1998a, 1998b *apud* SHA; HSU, 2006) e é usado para controlar a exploração e utilização. Um valor alto facilita um comportamento mais global, enquanto um valor baixo facilita um comportamento mais local. Um maior  $w$  pode prevenir as partículas de ficarem “presas” num ponto ótimo, e um  $w$  menor incita às partículas a utilizarem a mesma área de busca.

O  $r_1$  e  $r_2$  são variáveis aleatórias geradas usando distribuição uniforme entre 0 e 1.

Hu, Shi e Eberhart (2004) revisaram o desenvolvimento do método PSO nos últimos anos – e apesar de ser um paradigma evolucionário relativamente novo, PSO tem crescido muito. Conforme a Figura 11, nota-se que mais e mais pesquisadores estão interessados neste algoritmo. Desde 2002, PSO cresceu muito rapidamente com mais de 100 publicações por ano e de 1995 até 2004 já contava com mais de 300 publicações.

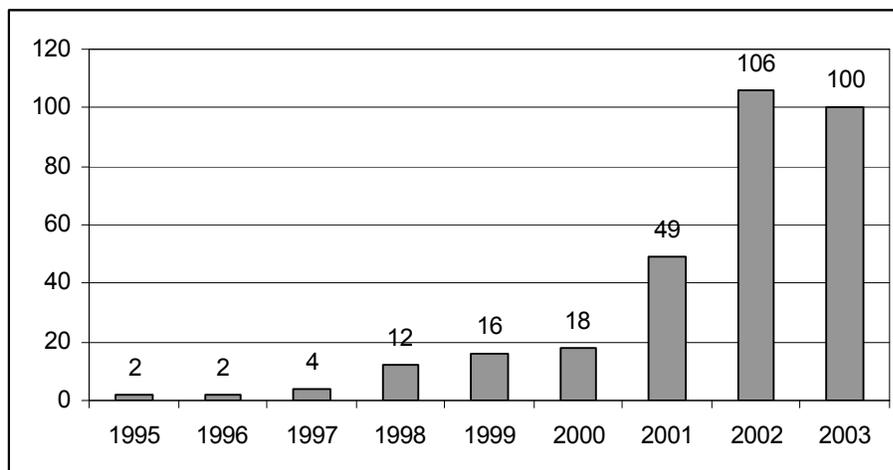


Figura 11 – Número de artigos publicados em cada ano (Dados incompletos para o ano de 2003)  
(Fonte: Hu, Shi e Eberhart, 2004)

Com o crescente interesse por otimização de partículas, o primeiro IEEE *Swarm Intelligence Symposium* foi realizado em Indianápolis, nos Estados Unidos, em abril de 2003. Autores de vários países apresentaram mais de 30 artigos em áreas como: treinamento de rede neural artificial, interação com outros métodos computacionais, otimização de parâmetros e seleção de recursos.

Segundo Hu, Eberhart e Shi (2003), PSO foi aplicado com sucesso em muitas pesquisas e áreas de aplicação. O PSO utilizado no trabalho deles demonstrou resultados melhores, mais rápidos e mais baratos do que outros apresentados na literatura. Uma outra razão para PSO ser atrativo é que há poucos parâmetros para ajustar. Além disso, PSO tem seu mérito no conceito simples e baixo custo computacional (TASGETIREN; LIANG, 2003).

### 3.2.3 Breve apanhado da utilização de PSO em problemas de otimização

Tasgetiren e Liang (2003) apresentaram um algoritmo binário cujo objetivo era encontrar quantidades de pedidos as quais minimizariam o total de pedidos e os custos de compra e armazenagem.

No campo da programação da produção do chão de fábrica, Sha e Hsu (2006), aplicaram o PSO para buscar melhores resultados daqueles que há décadas já vinham sendo praticados através de algoritmos genéticos, busca tabu e outros métodos, enquanto que Lian, Jiao e Gu (2006) utilizaram algoritmos de PSO similares aos da literatura, entretanto, propondo alguns novos operadores, os quais mostraram melhores resultados.

Xia e Wu (2005) após observarem a existência de um grande número de trabalhos com problemas de programação da produção do chão de fábrica, resolveram diferenciar utilizando o problema de múltiplos objetivos para programação flexível de chão de fábrica para a pesquisa deles, a qual apresentou um algoritmo híbrido de PSO e *Simulated Annealing* (algoritmo de busca local, baseado numa analogia com a termodinâmica, que emprega determinadas probabilidades para prevenir a formação de armadilhas num ponto ótimo e tem sido provado ser eficiente para uma variedade de situações, incluindo programação e sequenciamento). O algoritmo híbrido foi testado para três exemplos representativos oriundos de Kacem, Hammadi e Borne (2002a) e Kacem, Hammadi e Borne (2002b), sendo ainda o seu desempenho comparado com os obtidos por esses mesmos autores, mostrando a eficácia do algoritmo proposto.

De uma forma mais genérica, Prado e Saramago (2005) aplicaram vários problemas para ilustrar a metodologia usada em otimização por enxame de partículas e compararam os resultados obtidos com as soluções encontradas em algoritmos genéticos.

Seljerri *et al.* (2006) ilustraram três variações no algoritmo de PSO padrão, denominados de Meta PSO, Meta PSO Modificado e Meta PSO Modificado Estabilizado, todos eles com o intuito de aumentar a capacidade de busca global. A pesquisa ainda utilizou o Meta PSO para a otimização de um filtro de microondas do tipo *microstrip-line*, alcançando o ramo da eletromagnética. Assim como o estudo

feito por Robinson e Rahmat-Samii (2004), que utilizaram um exemplo de otimização para um determinado tipo de antena.

Com o intuito de melhorar ainda mais a variação do PSO padrão para aumentar a precisão da solução sem sacrificar significativamente a velocidade da solução, Chatterjee e Siarry (2004) propuseram uma nova variação de modelo de PSO, onde é proposto um novo método de variação de introdução não-linear ao longo do fator de inércia com uma antiga velocidade da partícula para melhorar a velocidade de convergência, tão bem quanto uma boa consonância na busca em espaço multidimensional.

Quanto ao problema de alocação de recursos, o qual tem muitas aplicações, tais como alocação de produtos, distribuição de recursos, orçamento de projetos, teste de softwares, alocação de recursos para a saúde, etc., Yin e Wang (2006) apresentaram um algoritmo PSO para o problema não linear de alocação de recursos. Para garantir que todas as restrições de recurso fossem atingidas, foi proposta uma técnica adaptativa de limites de recursos para orientar a busca e promover soluções viáveis. Os resultados mostraram que o método proposto supera o algoritmo baseado em algoritmo genético, o qual produz soluções piores e necessita de um tempo computacional maior. Foi ainda realizada uma análise da pior das hipóteses para proporcionar uma garantia de desempenho confiável.

Segundo Guo, Yu e Xu (2006), de acordo com a visão industrial e o seu desenvolvimento, a máquina e/ou o sistema de produção se tornaram mais complicados. Falhas em diagnósticos por tão amplo sistema transformou-se igualmente difícil. Nesse contexto, Guo, Yu e Xu (2006) apresentaram uma metodologia inteligente para diagnosticar incipientes falhas em máquinas rotativas.

Na intenção de desenvolver um modelo inteligente para tomada de decisão em relação a estoques, Nenortaitė e Simutis (2005), integraram rede neural e PSO, o primeiro é usado para analisar o histórico de retorno do estoque e calcular um possível lucro mais adiante, enquanto o PSO é aplicado para treinamento da rede neural, considerando diferentes formas de modelos de tomada de decisão, tais como variáveis de entrada, diferentes estruturas de redes neurais, etc. E, observaram um resultado positivo da aplicação melhor que a média praticada.

Trabalhos como os propostos por Yao (1999), Settles, Rodebaugh e Soule (2003) e Zhang, Shao e Li (2000) reportam o uso de PSO para substituir o algoritmo de aprendizagem por retropropagação em redes neurais artificiais,

mostrando que PSO é um método promissor para treinar redes neurais artificiais. Como em Lu, Fan e Lo (2003), que utilizaram PSO para treinar a rede neural e aplicar o método para prever níveis de poluentes na área central da cidade de Hong Kong. Um outro trabalho ligado a treinamento de redes neurais é o desenvolvido por van den Bergh e Engelbrecht (2000).

Além do treinamento da rede neural, PSO tem sido combinado com várias outras técnicas para resolver diferentes problemas. He *et al.* (1998) utilizaram o PSO com o sistema nebuloso e Shi e Eberhart (2001) utilizaram o PSO com um fator de inércia nebuloso-adaptativo. Enquanto que Paquet e Engelbrecht (2003) utilizaram PSO para treinar máquinas de suporte vetorial.

Utilizando a teoria de sistemas caóticos, Coelho e Mariani (2007) propuseram o que chamaram de “PSO caótico”, combinando-o com um método de busca local com filtragem implícita para resolver problemas de despacho econômico de energia elétrica. A nova metodologia híbrida é usada para produzir soluções boas em potencial, e a filtragem implícita para aperfeiçoar o resultado final do PSO. Um trabalho anterior envolvendo também teoria do caos e PSO pode ser encontrado em Coelho (2006).

O PSO caótico também foi utilizado com um modelo nebuloso de Takagi-Sugeno por Coelho e Herrera (2007).

No campo da eletricidade, Abido (2001) e Abido (2002a) aplicaram o algoritmo PSO para otimizar configurações de parâmetros de estabilizadores de sistema de potência e Abido (2002b) para o problema de fluxo ótimo de potência. Anterior a isso, Yoshida *et al.* (1999) já haviam utilizado o PSO para sistemas de potência. Seguidos por problemas semelhantes em Yoshida *et al.* (2000), Fukuyama e Yoshida (2001) e Yoshida *et al.* (2001).

O algoritmo PSO também foi adaptado para resolver problema de despacho econômico de energia elétrica nos trabalhos de El-Gallad *et al.* (2001a), Park *et al.* (2005) e Gaing (2003), sendo que este último compara o desempenho obtido pelo PSO com o algoritmo genético para o mesmo problema.

Já em El-Gallad *et al.* (2001b), o algoritmo PSO foi usado para treinar uma rede neural para a proteção do transformador de potência. O objetivo era desenvolver um modelo que fosse capaz de distinguir de forma inteligente entre corrente de energização magnética e corrente de defeito interno nos transformadores de potência.

Para mais detalhes quanto às aplicações do algoritmo PSO em sistemas de potência elétrica, AlRashidi e El-Hawary (2006) oferecem um ótimo levantamento das publicações realizadas, dividindo-as e comentando-as por área de pesquisa nas quais estão inseridas. É, de fato, um importante instrumento de consulta e pesquisa para tomar conhecimento sobre o que já vem sendo feito nessa área, além claro de fornecer idéias para pesquisas futuras que envolvam este segmento e a melhoria da solução do PSO em geral.

Em aplicações de Engenharia Elétrica, Brandstatter e Baumgartner (2002), desenvolveram uma analogia entre o movimento de uma partícula do enxame e um sistema massa-mola, com o intuito de mostrar como regiões inviáveis no parâmetro espaço pode ser tratada eficientemente.

Liao, Tseng e Luarn (2005) apresentaram um algoritmo PSO para programação de *flowshop*. No algoritmo proposto, as partículas e as velocidades eram redefinidas e uma eficiente abordagem foi desenvolvida para mover uma partícula para uma nova seqüência. Foram ainda realizadas comparações com dois algoritmos genéticos. Os resultados computacionais mostraram que o algoritmo PSO proposto é superior. Sendo, além disso, incorporado um esquema de busca local, chamado de PSO-LS (PSO *Local Search*), em que os resultados mostraram que a busca local pode ser realmente guiada pelo PSO nessa abordagem.

Ainda sobre o aspecto do problema de programação de *flowshop*, Lian, Gu e Jiao (2006) criaram um novo PSO combinando operadores de algoritmo genético. Este trabalho implementa um novo algoritmo de PSO para o problema de programação de *flowshop* para minimizar *makespan* e apresenta a combinação de alguns operadores oriundos do algoritmo genético. Os experimentos foram realizados em diferentes tamanhos, mostrando a superioridade do método PSO. Outros problemas relacionados à *flowshop* são encontrados ainda em Tasgetiren *et al.* (2004a), Tasgetiren *et al.* (2004b), Ucar e Tigestiren (2006) e Tigestiren *et al.* (2007), este dois últimos para resolver problema de permutação de sequenciamento de *flowshop*.

Van den Bergh e Engelbrecht (2002) propuseram um algoritmo chamado GCPSO (*Guaranteed Convergence Particle Swarm Optimizer*), o qual tem uma maior convergência se comparada com o PSO básico, especialmente quando enxames menores são usados. O GCPSO somente afeta a atualização da equação da melhor partícula global, assim ele pode ser usado em conjunto com um número

maior de outros parâmetros feitos para o algoritmo básico do PSO. Esse mesmo algoritmo GCPSO foi utilizado por Peer, van den Bergh e Engelbrecht (2003) para investigar o seu desempenho usando diferentes topologias de vizinhança. Os desempenhos obtidos com essas diferentes topologias foram posteriormente usados como referência para comparar os resultados alcançados pelo algoritmo híbrido proposto em Esquivel e Coello Coello (2003), o qual utiliza um operador de mutação não uniforme proveniente de algoritmos evolutivos. Os resultados do modelo de algoritmo híbrido indicaram um melhor desempenho do que o melhor resultado alcançado por Peer, van den Bergh e Engelbrecht (2003), sendo este em alguns casos ainda mais complexos.

Kennedy (1999) utilizou a idéia de Stanley Milgram, que na década de 60 realizou o experimento de “Pequenos Mundos” sobre a conectividade entre as pessoas – atualmente é conhecido como a Teoria dos Seis Graus de Separação (versa que no mundo são necessários no máximo seis laços de amizade para que duas pessoas quaisquer estejam ligadas) –, para estudar a estrutura do enxame, conforme quatro tipos de configurações topológicas de vizinhança, buscando iniciar uma discussão sobre a melhor estrutura para as partículas.

A topologia de vizinhança acaba por identificar as propriedades da população, pois o fluxo de informação entre os indivíduos é afetado por alguns aspectos como o grau de conectividade entre o número de vizinhos em comum da teia que se configura o enxame, a quantidade de agrupamento e a média da menor distância de um nó para outro, visto que permite determinar a transmissão da informação através da rede.

Um outro trabalho nesse aspecto é o desenvolvido por Kennedy (2000) para melhorar o desempenho do PSO com uma análise de agrupamento. Enquanto que Kennedy e Mendes (2002) apresentaram uma pesquisa para identificar algumas estruturas que oferecem um melhor desempenho para o algoritmo PSO.

Salman, Ahmad e Al-Madani (2002) adaptaram a estratégia de PSO para o problema de designação de tarefas em sistemas de computação, mostrando que o algoritmo é uma abordagem viável para este tipo de problema.

Com o intuito de melhorar o algoritmo padrão, Suganthan (1999) propôs em seu trabalho um número de técnicas para isso, tais como aumentar gradualmente a vizinhança local do enxame, variação nos valores do fator de inércia

e dois esquemas alternativos para determinar a solução do *pbest* para cada partícula.

Em Shi e Eberhart (1999), o desempenho do algoritmo PSO com o fator de inércia decrescendo linearmente foi extensivamente investigado usando quatro funções não lineares (Esfera, Rosenbrock, Rastrigrin e Griewank), o que mostrou que o PSO converge rapidamente em todos os casos, mas diminui a velocidade de sua convergência quando alcança o ótimo.

Uma variação do algoritmo PSO foi proposta por Miranda e Fonseca (2002), que utilizaram uma característica do algoritmo evolutivo para o algoritmo PSO. Do ponto de vista da computação evolutiva, existe a introdução de um novo operador na fase de replicação (onde cada indivíduo é duplicado), o qual gera novas e promissoras soluções no espaço de busca através do movimento da partícula. Do ponto de vista do PSO, existe uma auto-regulagem adaptativa do algoritmo pelo ajustamento evolutivo dos parâmetros do movimento que controlam cada partícula. Outra variante para o algoritmo PSO pode também ser encontrado em Ting *et al.* (2003), onde utilizaram um dos operadores de algoritmos genéticos, a mutação, para acelerar a convergência do PSO. Sendo a mutação um processo genético no qual pressões do meio ambiente e mudanças bioquímicas acarretam em uma mudança na estrutura de um cromossomo, isso pode mostrar-se tanto construtivo como destrutivo. Ao mudar um simples gene, pode acontecer de um membro super adaptado da população converter-se em um membro fraco. E, pelo fato da mutação ocorrer tão raramente na natureza, o algoritmo genético usa então uma taxa geralmente de 0.1 ou menor, em razão de imitar o processo de evolução. No novo algoritmo híbrido, o operador mutação é usado para avaliar o valor *pbest*, fornecendo uma diversidade na busca. Outros algoritmos híbridos para PSO são encontrados também em Naka *et al.* (2003) e Ting, Rao e Loo (2006).

Trabalhos recentes, como os de Wei *et al.* (2002), Secrest e Lamont (2003), Kennedy (2003), Higashi e Iba (2003), Stacey, Jancic e Grundy (2003) e Coelho e Krohling (2005), utilizaram distribuições de probabilidade Gaussiana e de Cauchy para gerar os números aleatórios da equação de atualização da velocidade do PSO ao invés de distribuição uniforme, presente no PSO padrão.

Silva e Coelho (2007) propuseram a aplicação de um algoritmo PSO para uma cadeia de suprimentos, a qual incluía estoques, produção, transporte e

distribuição. O trabalho comparou resultados oriundos do PSO padrão e um PSO adaptativo (o qual considera uma variação dos parâmetros de aprendizagem da partícula ao longo do tempo de simulação) com resultados de outras técnicas presentes na literatura.

### **3.2.4 Propostas de PSO**

A seguir são apresentadas as propostas para o algoritmo de PSO validadas neste trabalho.

#### **3.2.4.1 PSO padrão (PSO-1)**

O PSO padrão é o algoritmo que segue os valores e ajustes-padrão para a técnica utilizada, no sentido de minimizar o problema proposto neste trabalho, sendo nomeado de PSO-1.

#### **3.2.4.2 Proposta adaptativa do PSO (A-PSO)**

Com o intuito de melhorar o algoritmo padrão e os resultados obtidos, é proposto um PSO no qual os parâmetros de confiança  $c_1$  e  $c_2$  variam com o tempo, baseado no trabalho de Ratnaweera, Halgamuge e Watson (2004). O objetivo é reforçar a busca global na parte inicial da otimização e encorajar as partículas a convergirem em direção ao *gbest* no final da busca.

Com um parâmetro de aprendizagem cognitivo alto e o social baixo no início da otimização, as partículas podem se mover pelo espaço de busca, ao invés de se moverem em direção ao *pbest*. Por outro lado, um baixo parâmetro de

aprendizagem cognitivo e um social alto, permite às partículas convergirem para o *gbest* na parte final da otimização.

Matematicamente falando, esta modificação pode ser representada da seguinte forma:

$$c_1 = (c_{1f} - c_{1i}) \cdot \frac{t}{t_{\max}} + c_{1i} \quad (18)$$

$$c_2 = (c_{2f} - c_{2i}) \cdot \frac{t}{t_{\max}} + c_{2i} \quad (19)$$

onde  $c_{1i}$ ,  $c_{1f}$ ,  $c_{2i}$  e  $c_{2f}$  são constantes,  $t$  é o número da iteração atual e  $t_{\max}$  é o número máximo de iterações permitidas.

A proposta adaptativa é usada também para as abordagens que serão descritas a seguir, na subseção 3.4.3.

### 3.2.4.3 Propostas baseadas em distribuição Gaussiana e de Cauchy

Levando-se em consideração o trabalho de Coelho e Krohling (2005) para gerar números aleatórios para a atualização da Equação (16) da velocidade do PSO utilizando distribuições Gaussiana e de Cauchy – as quais poderiam fornecer uma convergência mais rápida nas buscas realizadas pelas partículas – foram então elaboradas oito propostas para o projeto das partes cognitiva e social, gerando números aleatórios no intervalo  $[0, 1]$ , como mostrado a seguir:

PSO-2: usa a distribuição de Cauchy para a parte cognitiva ( $cd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot cd_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Ud_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (20)$$

onde  $cd$  é um valor gerado para a parte cognitiva com distribuição de Cauchy e normalizado entre  $[0, 1]$ .

PSO-3: usa a distribuição de Cauchy para a parte social ( $Cd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot ud_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Cd_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (21)$$

onde  $Cd$  é um valor gerado para a parte social com distribuição de Cauchy e normalizado entre  $[0,1]$ .

PSO-4: utiliza a distribuição de Cauchy para ambas as partes cognitiva ( $cd$ ) e social ( $Cd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot cd_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Cd_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (22)$$

PSO-5: utiliza distribuição Gaussiana para a parte cognitiva ( $gd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot gd_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Ud_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (23)$$

onde  $gd$  é um valor gerado para a parte cognitiva com distribuição Gaussiana e normalizado entre  $[0,1]$ .

PSO-6: usa distribuição Gaussiana para a parte social ( $Gd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot ud_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Gd_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (24)$$

onde  $Gd$  é um valor gerado para a parte social com distribuição Gaussiana e normalizado entre  $[0,1]$ .

PSO-7: utiliza distribuição Gaussiana para as partes cognitiva ( $gd$ ) e social ( $Gd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot gd_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Gd_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (25)$$

PSO-8: usa distribuição Gaussiana para a parte cognitiva ( $gd$ ) e distribuição de Cauchy para a parte social ( $Cd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot gd_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Ud_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (26)$$

PSO-9: usa distribuição de Cauchy para a parte cognitiva ( $cd$ ) e distribuição Gaussiana para a parte social ( $Gd$ ):

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot ud_{i,j}(t) \cdot [p_i(t) - x_i(t)] + c_2 \cdot Gd_{i,j}(t) \cdot [p_g(t) - x_i(t)] \quad (27)$$

### 3.2.4.4 Resumo das propostas

O Quadro 3 apresenta de forma simplificada as propostas tratadas neste trabalho, levando-se em consideração o tipo de distribuição (Gauss e Cauchy) usada para as partes cognitivas e/ou social. O PSO-1 usa distribuição uniforme. E, a abordagem do A-PSO é combinada com cada uma das abordagens de PSO (o que resulta em A-PSO-1, A-PSO-2, A-PSO-3, e assim por diante).

Quadro 3 – Resumo das propostas

		<b>DISTRIBUIÇÃO</b>			
		<b>Gauss</b>		<b>Cauchy</b>	
		cognitiva	social	cognitiva	social
<b>ABORDAGEM</b>	PSO-1				
	PSO-2			✓	
	PSO-3				✓
	PSO-4			✓	✓
	PSO-5	✓			
	PSO-6		✓		
	PSO-7	✓	✓		
	PSO-8	✓			✓
	PSO-9		✓	✓	
A-PSO: é combinada com cada uma das abordagens de PSO					

## 4 UTILIZAÇÃO E RESULTADOS

### 4.1 Parâmetros

Na modelagem do sistema das simulações de otimização da cadeia de suprimentos, adotou-se que todos os estoques (de matéria-prima e produto final) são nulos e que existe  $M = 3$  matérias-primas,  $P = 2$  produtos,  $R = 3$  distribuidores e  $T = 3$  períodos.

E, os mesmos parâmetros utilizados por Mak e Wong (1995) foram otimizados neste trabalho:

- Previsão de demanda para cada período ( $D_{rpt}$ ):

$$\begin{array}{lll} D_{111} = 80; & D_{112} = 60; & D_{113} = 70; \\ D_{121} = 50; & D_{122} = 50; & D_{123} = 55; \\ D_{211} = 60; & D_{212} = 75; & D_{213} = 65; \\ D_{221} = 45; & D_{222} = 65; & D_{223} = 85; \\ D_{311} = 80; & D_{312} = 70; & D_{313} = 90; \\ D_{321} = 50; & D_{322} = 70; & D_{323} = 40. \end{array}$$

- Tempo de processamento da máquina ( $B_p$ ):

$$(B_1, B_2) = (1, 1);$$

- Tempo permitido para fabricação:

$$(\beta_1, \beta_2, \beta_3) = (800, 800, 800);$$

- Custo de transporte do fabricante para o distribuidor ( $c_{rp}^D$ ):

$$(c_{11}^D, c_{12}^D, c_{21}^D, c_{22}^D, c_{31}^D, c_{32}^D) = (1, 1, 4, 4, 2, 2);$$

- Custo de transporte do fornecedor para o fabricante ( $c_m^M$ ):

$$(c_1^M, c_2^M, c_3^M) = (0,3; 0,3; 0,2);$$

- Custo de fabricação ( $c_p^P$ ):

$$(c_1^P, c_2^P) = (20, 15);$$

- Custo de falta (*shortage*) ( $c_{rp}^S$ ):

$$(c_{11}^S, c_{12}^S, c_{21}^S, c_{22}^S, c_{31}^S, c_{32}^S) = (1000, 500, 1800, 1000, 1000, 1000);$$

- Custo de armazenagem do estoque de entrada ( $H_m^M$ ):

$$(H_1^M, H_2^M, H_3^M) = (5, 8, 6);$$

- Custo de armazenagem do estoque de saída ( $H_p^P$ ):

$$(H_1^P, H_2^P) = (4, 3);$$

- Custo de armazenagem de produtos no distribuidor ( $H_{rp}^R$ ):

$$(H_{11}^R, H_{12}^R, H_{21}^R, H_{22}^R, H_{31}^R, H_{32}^R) = (8, 4, 12, 8, 8, 8);$$

- Peso da matéria-prima ( $w_m^M$ ):

$$(w_1^M, w_2^M, w_3^M) = (3, 2, 2);$$

- Peso do produto ( $w_p^P$ ):

$$(w_1^P, w_2^P) = (7, 13);$$

- Limite de carga do fornecedor para o fabricante ( $\omega_t^M$ ):

$$(\omega_1^M, \omega_2^M, \omega_3^M) = (5000, 5000, 5000);$$

- Limite de carga do fabricante para o distribuidor ( $\omega_t^P$ ):

$$(\omega_1^P, \omega_2^P, \omega_3^P) = (3000, 3000, 3000);$$

- Quantidade de matéria-prima usada nos produtos ( $\theta_{mp}$ ):

$$\left( \theta_{11}, \theta_{12}, \theta_{21}, \theta_{22}, \theta_{31}, \theta_{32} \right) = (1, 3, 2, 1, 1, 2).$$

Para as propostas de PSO (conforme a seção 3.4 deste trabalho) foram realizados 30 experimentos usando os parâmetros mostrados.

Para todos os algoritmos de otimização, os indivíduos são compostos por variáveis de decisão  $I_{mt}, J_{pt}, K_{rpt}, Z_{rpt}$ , as quais são arredondadas para o valor inteiro mais próximo, quando da avaliação da função  $aval(x)$ .

Em Mak e Wong (1995), o espaço de busca não é apresentado. Entretanto, neste trabalho adotou-se para cada variável o seguinte:

$$0 \leq I_{mt} \leq 5$$

$$0 \leq J_{pt} \leq 5$$

$$0 \leq K_{rpt} \leq 5$$

$$\text{Embora, } 0 \leq K_{222} \leq 25 \text{ e } 0 \leq Z_{rpt} \leq 90.$$

Foram realizadas um total de 150.000 avaliações da função *fitness* para uma população de 30 partículas ( $N$ ) e um  $t_{\max}$  igual à 5000 gerações (critério de parada) para todas as propostas de PSO.

Aplicando um alto fator de inércia no início do algoritmo e fazendo-o decair para um valor menor, permite à execução do PSO uma busca mais global no início da simulação, enquanto que no final da execução permite uma busca mais local. Neste trabalho, o fator de inércia  $w$  das propostas de PSO decresce linearmente ao longo de cada simulação, iniciando em 0,90 e terminando em 0,40.

Além disso, foram fixados empiricamente valores para os parâmetros de confiança, conforme mostrado em seguida:

- PSO-1: baseado em experiências anteriores com PSO, a pesquisa adotou  $c_1$  e  $c_2$  iguais a 2,05;
- A-PSO: os valores adotados são  $c_{1i} = c_{2f} = 2,05$  e  $c_{1f} = c_{2i} = 0,40$ ;
- PSO-2 à PSO-9:  $c_1$  e  $c_2$  iguais a 2,05.

## 4.2 Análise dos Resultados

Aqui é feita uma comparação entre os resultados obtidos pelas abordagens adotadas neste trabalho e aquelas disponíveis no trabalho que serve de parâmetro – o de Mak e Wong (1995) –, tais como algoritmo genético e *branch and bound* para a otimização da cadeia de suprimentos proposta.

A Tabela 1 apresenta uma sumarização dos resultados obtidos pelo algoritmo genético, *branch and bound* e as abordagens propostas neste trabalho. Foram realizados 30 experimentos. O tempo médio computacional consumido foi de 521 segundos e de 533 segundos para as propostas PSO e A-PSO, respectivamente. Para a simulação foi utilizado o MATLAB versão 7.2 e um computador Pentium IV de 3.2MHz com 2G de memória.

Tabela 1 – Resultados para a função aval ( $x$ ) da otimização da cadeia de suprimentos (resultados para 30 experimentos)

Método de otimização	Melhor (mínimo)	Pior (máximo)	Média	Mediana	Desvio padrão
Algoritmo Genético	115.495,0	-	-	-	-
<i>Branch and bound</i>	113.584,0	-	-	-	-
PSO-1	114.670,5	616.146,5	172.974,1	122.111,4	155.904,9
PSO-2	109.746,3	623.090,2	169.106,3	119.434,2	159.650,9
PSO-3	111.480,7	615.858,1	168.952,3	120.167,9	157.067,4
PSO-4	108.194,4	615.720,5	219.874,1	124.452,3	208.369,4
PSO-5	111.263,4	624.039,4	170.291,4	119.953,4	159.507,0
PSO-6	112.670,0	122.883,2	117.600,7	118.505,4	<b>3.188,9</b>
PSO-7	112.139,9	125.115,9	118.975,3	119.297,2	4.013,1
PSO-8	108.308,9	610.771,1	167.555,3	117.945,6	155.884,6
PSO-9	112.234,0	134.385,5	119.284,7	118.226,5	6.855,2
A-PSO-1	109.219,2	126.095,8	115.901,3	115.531,4	5.894,4
A-PSO-2	112.419,5	129.221,9	120.690,6	121.425,2	5.705,8
A-PSO-3	107.245,6	126.737,7	115.433,4	114.937,3	5.874,7
A-PSO-4	<b>105.306,4</b>	<b>122.518,2</b>	122.518,1	<b>122.250,3</b>	10.965,3
A-PSO-5	110.196,7	124.256,5	114.444,1	112.363,8	4.956,2
A-PSO-6	108.811,0	127.201,6	116.579,5	114.733,3	5.856,0
A-PSO-7	107.329,0	125.070,5	113.864,9	112.529,5	5.829,5
A-PSO-8	107.357,9	123.239,9	<b>113.528,3</b>	113.432,4	4.738,7
A-PSO-9	109.762,1	127.084,9	118.459,9	118.261,6	6.799,3

Considerando o modelo estudado e os mesmos parâmetros adotados (para permitir uma comparação justa), os resultados da Tabela 1 demonstram que todos os valores obtidos com o PSO, para o valor mínimo, tiveram um desempenho melhor do que o do algoritmo genético, que é a técnica mais difundida no meio acadêmico. O mesmo acontece se comparado com a técnica de *branch and bound*, com exceção apenas do resultado obtido pelo PSO padrão (PSO-1), que obteve um valor intermediário entre as duas propostas presente em Mak e Wong (1995).

Dos resultados, constata-se que a melhor solução encontrada foi a proposta pelo A-PSO-4 (proposta adaptativa do PSO e que utiliza distribuição de Cauchy para atualizar as velocidades da partícula para as partes cognitiva e social) com o valor  $aval(x)$  de 105.306,4 unidades monetárias, sendo 8,82% e 7,29% menor que o valor encontrado pelo algoritmo genético e *branch and bound*, respectivamente.

A Tabela 2 apresenta os valores correspondentes às variáveis de decisão da proposta A-PSO-4, a qual obteve a melhor solução.

Tabela 2 – Melhores resultados usando a proposta A-PSO-4

Variáveis de Decisão			
$I_{mt}$	$J_{pt}$	$K_{rpt}$	$Z_{rpt}$
$I_{11} = 1$	$J_{11} = 4$	$K_{111} = 4$	$Z_{111} = 79$
$I_{12} = 4$	$J_{12} = 3$	$K_{112} = 3$	$Z_{112} = 60$
$I_{13} = 5$	$J_{13} = 1$	$K_{113} = 3$	$Z_{113} = 67$
$I_{14} = 3$	$J_{14} = 3$	$K_{121} = 4$	$Z_{121} = 6$
$I_{21} = 3$	$J_{21} = 4$	$K_{122} = 3$	$Z_{122} = 3$
$I_{22} = 4$	$J_{22} = 3$	$K_{123} = 2$	$Z_{123} = 0$
$I_{23} = 1$	$J_{23} = 3$	$K_{211} = 3$	$Z_{211} = 58$
$I_{24} = 4$	$J_{24} = 3$	$K_{212} = 1$	$Z_{212} = 77$
$I_{31} = 2$		$K_{213} = 3$	$Z_{213} = 62$
$I_{32} = 0$		$K_{221} = 4$	$Z_{221} = 57$
$I_{33} = 2$		$K_{222} = 19$	$Z_{222} = 49$
$I_{34} = 3$		$K_{223} = 5$	$Z_{223} = 78$
		$K_{311} = 4$	$Z_{311} = 79$
		$K_{312} = 4$	$Z_{312} = 68$
		$K_{313} = 3$	$Z_{313} = 86$
		$K_{321} = 2$	$Z_{321} = 51$
		$K_{322} = 3$	$Z_{322} = 68$
		$K_{323} = 1$	$Z_{323} = 37$
Custo total, $aval(x) = 105.306,4$			
Penalidade (melhor $x$ ) = 0 (as restrições não foram violadas)			
Custos			
armazenagem	fabricação	transporte	falta de produto
613,0	17.920,0	3.773,4	83.000,0

Dos dados da Tabela 2, é possível também notar que entre os valores obtidos para os custos de armazenagem, fabricação, transporte e falta de produto, aparece um valor maior referente ao custo deste último. Isso se deve ao fato de tentar aproximar dois objetivos conflitantes: atendimento da demanda e baixo custo operacional. Os resultados encontrados confirmam a lógica do problema com foco na minimização dos custos totais e assim, algumas demandas não foram atendidas.

Uma importante consideração é que as propostas de PSO implementadas, neste trabalho, usaram um método de penalidade para as restrições do modelo. Enquanto que, Mak e Wong (1995) utilizaram um método que preserva a viabilidade de soluções simplesmente descartando soluções inviáveis geradas durante a evolução do algoritmo genético, à custa de um acréscimo computacional na geração de populações.

E ainda, levando-se em consideração que a metaheurística empregada têm sua população inicial gerada de forma aleatória, é interessante não só considerar apenas o desempenho de uma determinada configuração. Portanto, analisar os valores das médias obtidas pelos algoritmos ajuda a alcançar um melhor resultado. Neste caso, o algoritmo A-PSO-8 (proposta adaptativa do PSO e que atualiza as velocidades da partícula seguindo uma distribuição Gaussiana para a parte cognitiva e distribuição de Cauchy para a parte social) aponta como um melhor resultado, tendo como média o valor de 113.528,3 unidades monetárias, conforme dados da Tabela 1.

Analisando ainda os resultados obtidos pelas propostas de PSO entre si, observa-se um número de resultados melhores para os valores de mínimos e da média para as propostas variantes do PSO em relação ao PSO padrão, mostrando a eficiência das abordagens adaptativas e utilização de distribuição Gaussiana e de Cauchy como melhorias que podem ser efetuadas para o PSO padrão. Além disso, pode-se observar melhores resultados da média para as propostas adaptativas do PSO, o que demonstra uma potencialidade da abordagem. Vale observar também que entre os dois grupos de abordagem, o PSO-4 e o A-PSO-4 atingiram os melhores resultado mínimo, ambas utilizando distribuição de Cauchy para as partes cognitiva e social da equação da velocidade da partícula.

A Figura 12 mostra a convergência do melhor resultado encontrado para a partícula *gbest* da população somente para as abordagens do PSO, sem a proposta adaptativa.

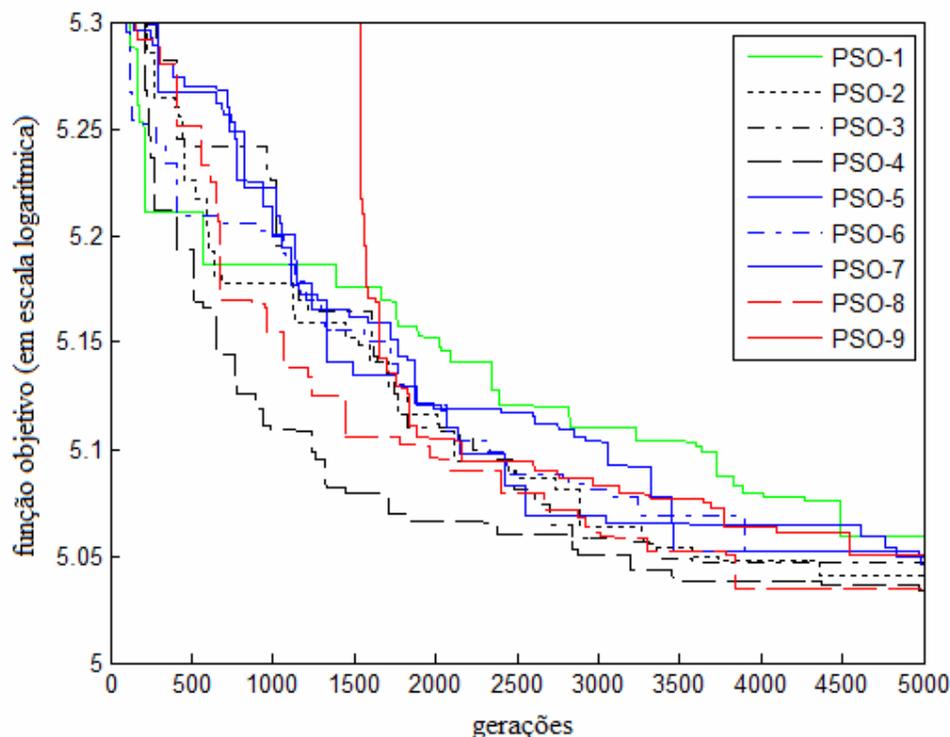


Figura 12 – Convergência do melhor resultado (Tabela 1) para a partícula *gbest* da população para as abordagens PSO.

Nota-se que entre elas, a abordagem que obteve o melhor desempenho foi a do PSO-4 (que utiliza distribuição de Cauchy para ambas as partes cognitiva e social). Sendo seguida pela abordagem PSO-8 (com distribuição Gaussiana para a parte cognitiva e distribuição de Cauchy para a parte social), que na parte final da simulação alcançou os melhores resultados, porém sendo superada pela abordagem PSO-4.

Além disso, é bastante claro perceber que o PSO-9 (distribuição de Cauchy para a parte cognitiva e distribuição Gaussiana para a parte social) teve um comportamento atípico de convergência em relação às outras técnicas testadas.

Já, a Figura 13 mostra a convergência média das melhores partículas da população para as abordagens do PSO sem a proposta adaptativa.

Percebe-se a existência de dois grupos com resultados distintos. O grupo mais acima, composto pelas abordagens do PSO-1, PSO-2, PSO-3, PSO-4, PSO-5 e PSO-8, possuem os piores desempenhos, enquanto que o grupo mais abaixo composto pelas abordagens do PSO-6, PSO-7 e PSO-9 possuem desempenhos melhores, sendo a abordagem do PSO-6 (que utiliza distribuição Gaussiana para a parte social) a de melhor desempenho dentre estas.

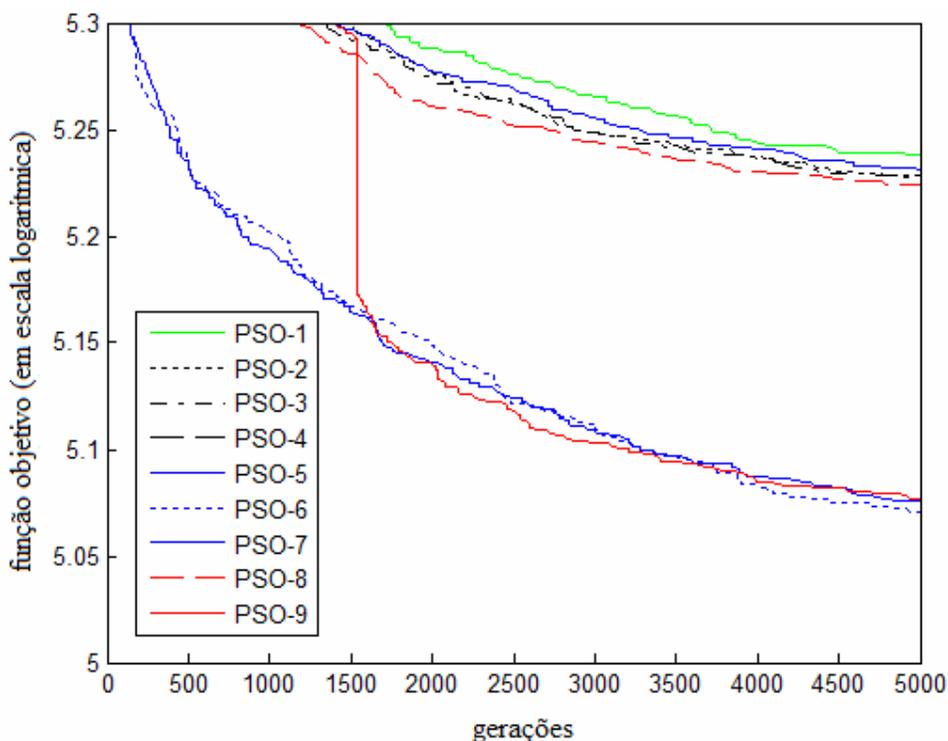


Figura 13 – Convergência média (média de 30 experimentos) das melhores partículas da população para as abordagens PSO.

Entre as abordagens Adaptativas do PSO, a proposta que obtém o melhor resultado para a partícula *gbest* é a do A-PSO-4 (proposta adaptativa do PSO e que utiliza distribuição de Cauchy para atualizar as velocidades da partícula para as partes cognitiva e social). E o pior desempenho aparece para o A-PSO-2 (proposta adaptativa do PSO e que utiliza distribuição de Cauchy somente para a

parte cognitiva). Conforme a Figura 14, que mostra a convergência dos melhores resultados alcançados pelas abordagens A-PSO.

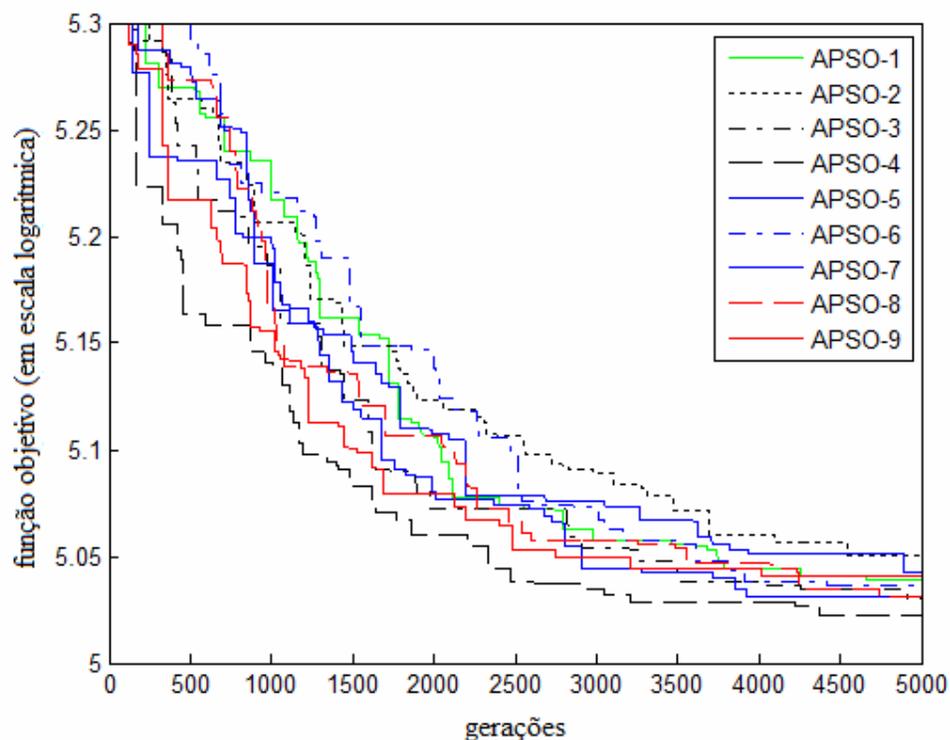


Figura 14 – Convergência do melhor resultado (Tabela 1) para a partícula *gbest* da população para as abordagens A-PSO.

Na análise da Figura 15 (o qual mostra a convergência média das melhores partículas para as abordagens A-PSO) para a os valores da média obtidos pelas abordagens A-PSO, o A-PSO-8 (proposta adaptativa do PSO e que atualiza a velocidade da partícula seguindo uma distribuição Gaussiana para a parte cognitiva e distribuição de Cauchy para a parte social) é o de melhor desempenho.

Nota-se também pela Figura 14 e Figura 15 que os desempenhos alcançados pelas abordagens adaptativas não sofrem tanta diferença de resultados como os mostrados pelas Figuras 12 e 13, em que uma das propostas possui claramente um comportamento diferente das outras e de grupos de resultados muito distintos entre as propostas (Figura 13). O que pode caracterizar uma superioridade da abordagem adaptativa para as propostas de PSO analisadas.

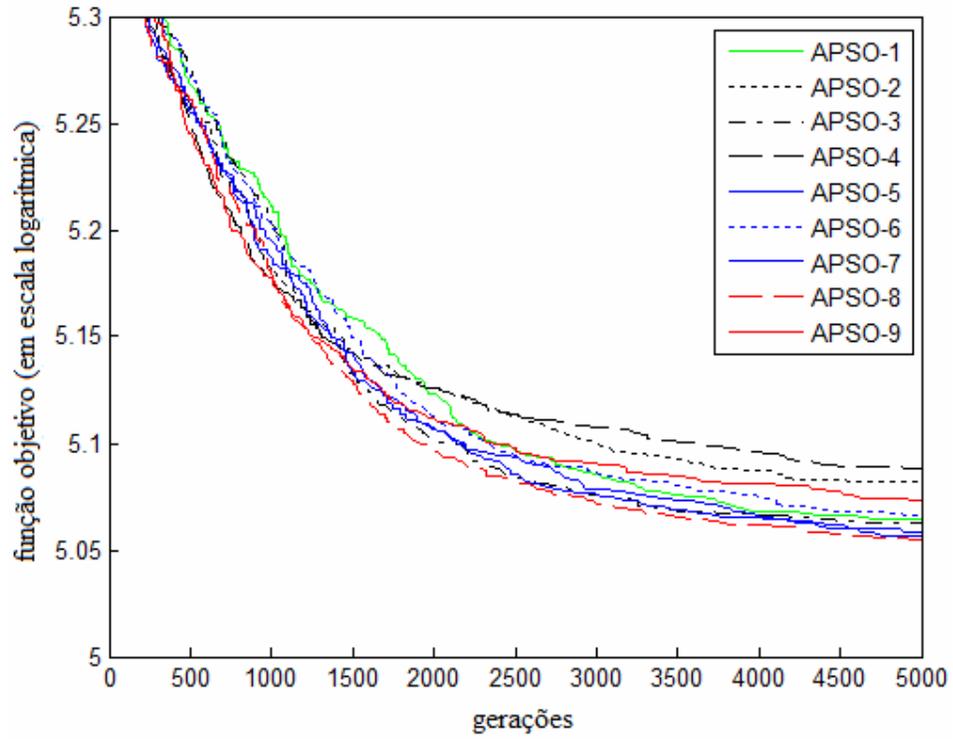


Figura 15 – Convergência média (média de 30 experimentos) das melhores partículas da população para as abordagens A-PSO.

## 5 CONCLUSÃO

Este trabalho apresentou o desenvolvimento de Otimização por Enxame de Partículas (*Particle Swarm Optimization* – PSO) e um estudo comparativo entre as propostas de PSO apresentadas para a otimização de uma cadeia de suprimentos e os resultados obtidos por um algoritmo genético e *branch and bound* em Mak e Wong (1995).

As propostas deste trabalho foram decorrentes primeiramente do uso do PSO padrão. Com o intuito de melhorá-lo, foi proposta uma abordagem que considera os parâmetros de aprendizagem variando com o tempo; e mais diferentes abordagens utilizando distribuição Gaussiana e de Cauchy para as partes cognitiva e social, não necessariamente nessa ordem.

A cadeia de suprimentos foi modelada como um problema de otimização mista inteira, envolvendo a otimização dos custos relacionados à armazenagem, fabricação, transporte e falta de produto (que equivale à perda de uma venda). Os materiais brutos são entregues dos fornecedores para o fabricante onde os produtos são manufaturados. Os produtos finais são então estocados em armazéns (do fabricante) e distribuídos destes para os revendedores de diferentes regiões. A cadeia modelada é composta de 3 matérias-primas, 2 produtos, 3 distribuidores e 2 períodos de tempo.

Desejou-se determinar os níveis ótimos de estoque e das quantidades de produção e de transporte que permitirão atender as demandas a um menor custo possível.

Os resultados encontrados permitem a validação da técnica do PSO no processo de otimização de cadeias de suprimentos. O que contribui para prováveis e futuras pesquisas envolvendo PSO e otimização de cadeia de suprimentos.

Sendo assim, este trabalho difere de outros no mínimo em dois aspectos, a técnica de otimização utilizada para o modelo proposto é diferente das técnicas aplicadas e mencionadas na literatura; além desta, a dificuldade de se encontrar pesquisas correlacionando modelo de cadeia de suprimentos, otimização e metaheurística permitiu um levantamento bibliográfico que possibilitou, entre

outras coisas, identificar trabalhos recentes relacionando otimização de cadeia de suprimentos com simulação e quanto ao uso da técnica de PSO em problemas de otimização.

Como em qualquer outro processo de simulação, esta pesquisa apresenta um número de limitações. A primeira e mais significativa é a limitação em usar modelo de custo e os mesmos parâmetros propostos por Mak e Wong (1995), como demanda, tempo de processamento da máquina, tempo permitido para fabricação, custo de transporte do fabricante para o distribuidor, etc., conforme a seção 4.1 para os parâmetros usados no trabalho. A pesquisa é também limitada por apenas focar em um sistema simplificado de integração entre produção, armazenagem e transporte, ignorando um sistema real, pois busca manter a análise em proporções manejáveis para que se possa compreender o impacto em manipular as variáveis das propostas fornecidas neste trabalho, lembrando também a relevância em aplicar PSO em práticas da cadeia de suprimentos.

Entre algumas das principais simplificações e restrições do modelo estudado estão (1) a não consideração da natureza dinâmica de um sistema real; (2) o nível de serviço é reduzido a atendimento das demandas; (3) é focado somente na minimização dos custos totais; (4) as demandas são previamente conhecidas; (5) o reduzido número de períodos de planejamento, materiais, produtos e participantes da cadeia de suprimentos; (6) a não consideração dos diferentes tempos de fabricação para cada fornecedor; (7) a não consideração dos diferentes modais de transporte; (8) a não consideração de tamanhos de lote de compra padronizados.

Com isso, é perceptível a limitação dos algoritmos desenvolvidos devido às simplificações existentes no modelo. Entretanto, o sucesso no desenvolvimento de modelos complexos é dependente do nível de conhecimento alcançado para modelos simples e, constata-se na literatura espaço para o desenvolvimento deste conhecimento.

A abordagem de enxame de partículas é versátil e robusta, ela pode ser aplicada para muitos tipos de problemas com um mínimo de ajustes necessários. Aqui, ainda foram mostradas algumas maneiras de melhorar o desempenho do algoritmo padrão.

É importante enfatizar que o uso de PSO é ainda muito novo e vem ganhando cada vez mais atenção e interesse. Até aqui, o estudo mostrou somente alguns aspectos da área e o tópico está longe de ser esgotado.

Configuram-se como propostas de continuidade deste trabalho, aperfeiçoamentos gradativos no modelo de Mak e Wong (1995), eliminando as simplificações e ainda uma proposta de hibridização do PSO usando técnica de busca local, tais como *branch and bound* e *simulated annealing*, e um estudo de caso de um problema real.

## REFERÊNCIAS

ABIDO, M. A. **Particle swarm optimization for multimachine power system stabilizer design**. Proceedings of IEEE Power Engineering Society Summer Meeting, Vancouver, Canada, v. 3, p. 1346-1351, 2001.

ABIDO, M. A. **Optimal design of power system stabilizers using particle swarm optimization**. IEEE Transactions on Energy Conversion, v. 17, n 3, p. 406-413, 2002a.

ABIDO, M. A. **Optimal power flow using particle swarm optimization**. International Journal of Electrical Power and Energy Systems, v. 24, n. 7, p. 563-571, 2002b.

ANDRÉS, C.; LOZANO, S. **A particle swarm optimization algorithm for part-machine grouping**. Robotics and Computer-Integrated Manufacturing, v. 22, n. 5-6, p. 468-474, 2006.

BALAN, S.; VRAT, P.; KUMAR, P. **Information distortion in a supply chain and its mitigation using soft computing approach**. Omega, The International Journal of Management Science, 2007.

BERNING, G.; BRANDENBURG, M.; GÜRSOY, K.; KUSSI, J. S.; MEHTA V.; TÖLLE, F. **Integrating collaborative planning and supply chain optimization for the chemical process industry (I) – methodology**. Computer and Chemical Engineering, v. 28, n. 6-7, p. 913-927, 2004.

BRANDSTATTER, B.; BAUMGARTNER, U. **Particle swarm optimization - mass-spring system analogon**. IEEE Transactions on Magnetics, v. 38, n. 2, p. 997-1000, 2002.

CARDOSO, P. A. **O princípio da postergação: um estudo na cadeia de suprimentos das tintas para impressão**. Rio de Janeiro/RJ, 2003. 165p. Tese (Doutorado em Engenharia de Produção) – Pontifícia Universidade Católica do Rio de Janeiro.

CARLISLE, A.; DOZIER, G. **Tracking changing extrema with adaptive particle swarm optimizer**. Proceedings of the 5th Biannual World Automation Congress, v. 13, p. 265-270, 2002.

CARSON II, J. S. **Introduction to modeling and simulation**. Proceedings of the 2005 Winter Simulation Conference, Orlando, FL, USA. Kuhl, M. E.; Steiger, N. M.; Armstrong, F. B.; Joines, J. A. (eds), p. 16-23, 2005.

CHAN, F. T. S.; CHUNG, S. H.; CHAN, P. L. Y. **An adaptive genetic algorithm with dominated genes for distributed scheduling problems**. Expert Systems with Applications, v. 29, n. 2, p. 364-371, 2005.

CHATTERJEE, A.; SIARRY, P. **Nonlinear inertia weight variation for dynamic adaptation in particle swarm optimization**. Computers & Operations Research, v. 33, n. 3, p. 859-871, 2004.

CHOY, K. L.; LEE, W. B.; LO, V. **An intelligent supplier management tool for benchmarking suppliers in outsource manufacturing**. Expert Systems with Application, v. 22, n. 3, p. 213-224, 2002.

CHOY, K. L.; LEE, W. B.; LO, V. **Design of an intelligent supplier relationship management system: a hybrid case based neural network approach**. Expert Systems with Application, v. 24, n. 2, p. 225-237, 2003.

COELHO, L. S. **A quantum particle swarm optimizer with chaotic mutation operator**. Chaos, Solitons & Fractals, 2006. (aceito para futura publicação).

COELHO, L. S.; HERRERA, B. M. **Fuzzy identification based on a chaotic particle swarm optimization approach applied to a nonlinear yo-yo motion system**. IEEE Transactions on Industrial Electronics, v. 54, n. 6, 3234-3245, 2007.

COELHO, L. S.; KROHLING, R. A. **Predictive controller tuning using modified particle swarm optimization based on Cauchy and Gaussian distributions**. Soft Computing: Methodologies and Applications, Springer Engineering series in Advances in Soft Computing, p. 287-298, 2005.

COELHO, L. S.; MARIANI, V. C. **A novel chaotic particle swarm optimization approach using Hénon map and implicit filtering local search for economic load dispatch**. Chaos, Solitons & Fractals, 2007. (aceito para futura publicação).

COELLO COELLO, C. A. **Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art**. Computer Methods in Applied Mechanics and Engineering, v. 191, n. 11-12, p. 1245-1287, 2002.

COELLO COELLO, C. A.; LECHUGA, M. S. **MOPSO: a proposal for multiple objective particle swarm optimization.** Proceedings of the IEEE Congress on Evolutionary Computation, Havaí, USA, v. 2, p. 1051-1056, 2002.

COOPER, M. C.; LAMBERT, D. M.; PAGH, J.D. **Supply chain management: more than a new name for logistics.** The International Journal of Logistics Management, v. 8, n. 1, p. 1-14, 1997.

COUNCIL OF SUPPLY CHAIN MANAGEMENT PROFESSIONALS. Disponível em: <<http://www.cGCSp.org/>>. Acesso em: 20 jun. 2006.

DEB, K. **An efficient constraint handling method for genetic algorithms.** Computer Methods in Applied Mechanics and Engineering, v. 186, p. 311-338, 2000.

DING, H.; BENYOUCEF, L; XIE, X. **A simulation-optimization approach using genetic search for supplier selection.** Proceedings of the 2003 Winter Simulation Conference, New Orleans, LA, USA. Chick, S.; Sánchez, P. J.; Ferrin, D.; Morrice, D. J. (eds.), p. 1260-1267, 2003.

DING, H.; BENYOUCEF, L.; XIE, X.; HAMS, C.; SCHUMACHER, J. **"One" a new tool for supply chain network optimization and simulation.** Proceedings of the 2004 Winter Simulation Conference, Washington, D.C, USA. Ingalls, R. G; Rossetti, M. D.; Smith, J. S.; Peters, B. A. (eds.), p. 1404-1411, 2004.

DISNEY, S. M.; NAIM, M. M.; TOWILL, D. R. **Genetic algorithm optimization of a class inventory control systems.** International Journal of Production Economics, vol. 68, n.3, p. 259-278, 2000.

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

EIBEN, A. E. **Evolutionary computing and automatic computing: shared problems, shared solutions?** Self-Star Properties in Complex Information Systems, Springer, p. 36-48, 2005.

EL-GALLAD, A. I.; EL-HAWARY, M.; SALLAM, A. A. **Swarming of intelligent particles for solving the nonlinear constrained optimization problem.** Engineering Intelligent Systems for Electrical Engineering and Communications, v. 9, n. 3, p. 155-163, 2001.

EL-GALLAD, A. I.; EL-HAWARY, M.; SALLAM, A. A.; KALAS, A. **Swarm intelligence for hybrid cost dispatch problem**. Proceedings of Canadian Conference on Electrical and Computer Engineering, v. 2, p. 753-757, 2001a.

EL-GALLAD, A. I.; EL-HAWARY, M.; SALLAM, A. A.; KALAS, A. **Swarm-intelligently trained neural network for power transformer protection**. Proceedings of Canadian Conference on Electrical and Computer Engineering, v. 1, p. 265-269, 2001b.

ESQUIVEL, S. C.; COELLO COELLO, C. A. **On the use of particle swarm optimization with multimodal functions**. Proceedings of Congress on Evolutionary Computation, Camberra, Austrália, v. 2, p. 1130-1136, 2003.

FALCONE, M. A. G. **Estudo comparativo entre algoritmos genéticos e evolução diferencial para otimização de um modelo de cadeia de suprimento simplificada**. Curitiba/PR, 2004. 93p. Dissertação (Mestrado em Engenharia de Produção e Sistemas) – Pontifícia Universidade Católica do Paraná.

FILHO, A. G. A.; CERRA, A. L.; MAIA, J. L.; NETO, M. S.; BONADIO, P. V. G. **Pressupostos da gestão da cadeia de suprimentos: evidências de estudos sobre a indústria automobilística**. Revista Gestão & Produção, v. 11, n. 3, p. 275-288, 2004.

FRANCIS, J. **Team building with the SCOR model**. Supply Chain Management Review, 2007. Disponível em: <<http://www.supply-chain.org/cs/root/home>>. Acesso em: 15 set. 2007.

FUKUYAMA, Y.; YOSHIDA, H. **A particle swarm optimization for reactive power and voltage control in electric power systems**. Proceedings of the Congress on Evolutionary Computation, Seoul, Korea, v. 1, p. 87-93, 2001.

FURTADO, P. G.; CARVALHO, M. F. H. **Compartilhamento da informação como elemento de coordenação da produção em cadeia de suprimentos**. Revista Gestão & Produção, v. 12, n. 1, p. 39-53, 2005.

GAING, Z. L. **Particle swarm optimization to solving dispatch considering the generator constraints**. IEEE Transactions on Power Systems, v. 18, n. 3, p. 1187-1195, 2003.

GUO, Q.; YU, H.; XU, A. **A hybrid PSO-GD based intelligent method for machine diagnosis**. Digital Signal Processing, v. 16, n. 4, p. 402-418, 2006.

HE, Z.; WEI, C.; YANG, L.; GAO, X.; YAO, S.; EBERHART, R. C.; SHI, Y. **Extracting rules from fuzzy neural network by particle swarm optimization.** Proceedings of IEEE Congress on Computation Intelligence, Anchorage, USA, p. 74-77, 1998.

HIGASHI, N.; IBA, H. **Particle swarm optimization with Gaussian mutation.** Proceedings of IEEE Swarm Intelligence Symposium, Indianapolis, USA, p. 72-79, 2003.

HSIEH, F. **An evolutionary approach for self-organization of contract manufacturing supply chains.** Proceedings of IEEE Transactions on Systems, Man and Cybernetics, Tucson, AZ, v. 2, p. 1058-1063, 2001.

HU, X.; EBERHART, R. C. **Adaptive particle swarm optimization: detection and response to dynamic systems.** Proceedings of the IEEE Congress on Evolutionary Computation, v. 2, p. 1666-1670, 2002a.

HU, X.; EBERHART, R. C. **Multiobjective optimization using dynamic neighborhood particle swarm optimization.** Proceedings of the IEEE Congress on Evolutionary Computation, Havaí, USA, v. 2, p. 1677-1681, 2002b.

HU, X.; EBERHART, R. C. **Solving constrained nonlinear optimization problems with particle swarm optimization.** Proceedings of the 6th World Multiconference on Systemics, Cybernetics and Informatics, Orlando, USA, 2002c.

HU, X.; EBERHART, R. C.; SHI, Y. **Engineering optimization with particle swarm.** Proceedings of IEEE Swarm Intelligence Symposium 2003, Indianapolis, Indiana, USA, p. 53-57, 2003.

HU, X.; SHI, Y.; EBERHART, R. **Recent advances in particle swarm.** Proceedings of the Congress on Evolutionary Computation, San Diego, USA, v. 1, p. 90-97, 2004.

HWANG, H. S. **Design of supply-chain logistics systems considering service level.** Computers & Industrial Engineering, vol. 43, n. 1-2, p. 283-297, 2002.

JEONG, B.; JUNG, H.; PARK, N. **A computerized causal forecasting system using genetic algorithms in supply chain management.** The Journal of Systems and Software, v. 60, n. 3, p. 223-237, 2002.

JOINES, J. A.; GUPTA, D.; GOKCE, M. A.; KING, R. E.; KAY, M. G. **Supply chain multi-objective simulation optimization.** Proceedings of the Winter Simulation

Conference, San Diego, CA, USA. Yücesan, E.; Chen, C. H.; Snowdon, J. L.; Chanes, J. M. (eds.), p. 1306-1314, 2002.

KACEM, I.; HAMMADI, S.; BORNE, P. **Approach by localization and multiobjective evolutionary optimization for flexible job-shop scheduling problems.** IEEE Transactions on Systems, Man, and Cybernetics, v. 32, n. 1, p. 1–13, 2002a.

KACEM, I.; HAMMADI, S.; BORNE, P. **Pareto-optimality approach for flexible job-shop scheduling problems: hybridization of evolutionary algorithms and fuzzy logic.** Mathematics and Computers in Simulation, v. 60, p. 245–276, 2002b.

KENNEDY, J. **Minds and cultures: particle swarm implications.** Socially Intelligent Agents: AAA Fall Symposium, Menlo Park, CA, p. 67-72, 1997.

KENNEDY, J. **Small worlds and mega-minds: effects of neighborhood topology on particle swarm performance.** Proceedings of Congress on Evolutionary Computation, Washington, USA, v. 3, p. 1931-1938, 1999.

KENNEDY, J. **Stereotyping: improving particle swarm optimization performance with cluster analysis.** Proceedings of the Congress on Evolutionary Computation, La Jolla, USA, v. 2, p. 1507-1512, 2000.

KENNEDY, J. **Bare bones particle swarms.** Proceedings of the IEEE Swarm Intelligence Symposium, Indianapolis, USA, p. 80-87, 2003.

KENNEDY, J.; EBERHART, R. C. **Particle swarm optimization.** Proceedings of IEEE International Conference on Neural Networks, Piscataway, NJ, USA, v. 4, p. 1942–1948, 1995a.

KENNEDY, J.; EBERHART, R. C. **A new optimizer using particle swarm theory.** Proceedings of the 6th International Symposium on Micromachine and Human Science, Nagoya, Japan, p. 39-43, 1995b.

KENNEDY, J.; MENDES, R. **Population structure and particle swarm performance.** Proceedings of the Congress on Evolutionary Computation, Honolulu, USA, v. 2, p. 1671-1676, 2002.

KO, H. J.; EVANS, G. W. **A genetic algorithm-based heuristic for the dynamic integrated forward/reverse logistics network for 3PLs.** Computers & Operations Research, v. 34, n. 2, p. 346-366, 2007.

LAMBERT, D. M., COOPER, M. C.; PAGH, J. D. **Supply chain management: implementation issues and research opportunities.** The International Journal of Logistics Management, v. 9, n. 2, p. 1-19, 1998.

LIAN, Z.; GU, X.; JIAO, B. **A novel particle swarm optimization algorithm for permutation flow-shop scheduling to minimize makespan.** Chaos, Solitons and Fractals, vol. 35, n. 5, p. 851-861, 2006.

LIAN, Z.; JIAO, B.; GU, X. **A similar particle swarm optimization algorithm for job-shop scheduling to minimize makespan.** Applied Mathematics and Computation, v.183, n. 2, p.1008-1017, 2006.

LIAO, C.; TSENG, C.; LUARN, P. **A discrete version of particle swarm optimization for flowshop scheduling problems.** Computers and Operations Research, v. 34, n. 10, p. 3099-3111, 2007.

LEE, H. **Postponement for mass customization: satisfying customer demands for tailor-made products.** Strategic supply chain alignment: best practice in supply chain management. Gower, 1998.

LEE, Y. H.; JEONG, C. S.; MOON, C. **Advanced planning and scheduling with outsourcing in manufacturing supply chain.** Computers & Industrial Engineering, vol. 43, n.1-3, p. 351-374, 2002.

LEUNG, H. C. **Neural Networks in Supply Chain Management.** Proceedings of IEEE Annual International Engineering Management Conference, Singapore, p. 347-352, 1995.

LU, W. Z.; FAN, H. -Y.; LO, S. M. **Application of evolutionary neural network method in predicting pollutant levels in downtown area of Hong Kong.** Neurocomputing, v. 51, n. 1, p. 387-400, 2003.

MAK, K. L.; WONG, Y. S. **Design of integrated production-inventory-distribution systems using genetic algorithm.** Proceedings of 1st IEE/IEEE International Conference on Genetic Algorithms in Engineering Systems: Innovation and Applications, Sheffield, UK, v. 414, p. 454-460, 1995.

MASON-JONES, R.; TOWILL, D. R. **Using the information decoupling point to improve supply chain performance.** The International Journal of Logistics Management, v. 10, n. 2, p. 13-26, 1999.

MENTZER, J. T.; DeWITT, W.; KEEBLER, J. S.; MIN, S.; NIX, N. W.; SMITH, C. D.; ZACHARIA, Z. G. **Defining Supply Chain Management.** Journal of Business Logistics, v. 22, n. 2, p. 1-25, 2001.

MICHALEWICZ, Z.; SCHOENAUER, M. **Evolutionary algorithms for constrained parameter optimization problems.** Evolutionary Computation, v. 4, n. 1, p. 1-32, 1996.

MIRANDA, V.; FONSECA, N. **EPSO - evolutionary particle swarm optimization, a new algorithm with applications in power systems.** Transmission and Distribution Conference and Exhibition Asia Pacific, v. 2, p. 745-750, 2002.

MONTEBELLER, L. E. **Controles operacionais de gestão para uma empresa atacadista distribuidora de produtos industrializado: um estudo de caso.** Florianópolis/SC, 2002. 200p. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina.

MOON, C.; KIM, J.; HUR, S. **Integrated process planning and scheduling with minimizing total tardiness in multi-plants supply chain.** Computers & Industrial Engineering, v. 43, n. 1-2, p. 331-349, 2002.

MORINI, C.; PIRES, S. R. I. **Um modelo de decisão sobre a consignação de material estrangeiro em cadeia de suprimentos.** Revista Gestão & Produção, v. 12, n. 1, p. 67-80, 2005.

NAKA, S.; GENJI, T.; YURA, T.; FUKUYAMA, Y. **A hybrid particle swarm optimization for distribution state estimation.** IEEE Transactions on Power Systems, v. 18, n. 1, p. 60–68, 2003.

NENORTAITE, J.; SIMUTIS, R. **Adapting particle swarm optimization to stock markets.** Proceedings of the 5th International Conference on Intelligent Systems Design and Applications, Washington, DC, USA, p. 520-525, 2005.

PAQUET, U.; ENGELBRECHT, A. P. **Training support vector machines with particle swarms.** Proceedings of the International Joint Conference on Neural Networks, Portland, USA, v. 2, p. 1593-1598, 2003.

PARK, J. B.; LEE, K. S.; SHIN, J. R.; LEE, K. Y. **A particle swarm optimization for economic dispatch with nonsmooth cost functions.** IEEE Transactions on Power Systems, v. 20, n. 1, p. 34-42, 2005.

PEER, E. S.; VAN DEN BERGH, F.; ENGELBRECHT, A. P. **Using neighbourhoods with the guaranteed convergence PSO.** Proceedings of IEEE Swarm Intelligence Symposium, Indianapolis, USA, p. 235-242, 2003.

PIRES, S. R. I. **Gestão da cadeia de suprimentos: conceitos, estratégias, práticas e casos.** 1. ed. São Paulo/SP: Atlas, 2004.

PRADO, J. R.; SARAMAGO, S. F. P. **Otimização por colônia de partículas.** Famat em Revista, v. 4, p. 87-103, 2005.

RATNAWEERA, A.; HALGAMUGE, S. K.; WATSON, H. C. **Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients.** IEEE transactions on evolutionary computation, v. 8, n. 3, p. 240-255, 2004.

ROBINSON, J.; RAHMAT-SAMII, Y. **Particle swarm optimization in electromagnetics.** IEEE Transactions on Antennas and Propagation, v. 52, n. 2, p.397-407, 2004.

ROHDE, J. **Hierarchical supply chain planning using artificial neural networks to anticipate base-level outcomes.** OR Spectrum, Springer, v. 26, n. 4, p. 471-492, 2004.

SALMAN, A.; AHMAD, S.; AL-MADANI, S. **Particle swarm optimization for task assignment problem.** Microprocessors and Microsystems, v. 26, n. 8, p. 363-371, 2002.

SECRET, B. R.; LAMONT, G. B. **Visualizing particle swarm optimization - gaussian particle swarm optimization.** Proceedings of the IEEE Swarm Intelligence Symposium, Indianapolis, USA, p. 198-204, 2003.

SELERRI, S.; MUSSETTA, M.; PIRINOLI, P.; ZICH, R. E.; MATEKOVIS, L. **Some insight over new variations of the particle swarm optimization method.** IEEE Antennas and Wireless Propagation Letters, v. 5, n. 1, p. 235-238, 2006.

SETTLES, M. RODEBAUGH, B. SOULE, T. **Comparison of genetic algorithm and particle swarm optimizer when evolving a recurrent neural network.** Lecture Notes in Computer Science (LNCS). Proceedings of the Genetic and Evolutionary Computation Conference, Chicago, IL, USA, p. 151-152, 2003.

SHA, D. Y.; HSU, C. **A hybrid particle swarm optimization for job shop scheduling problem.** Computers & Industrial Engineering, v. 51, n. 4, p. 791-808, 2006.

SHI, Y.; EBERHART, R. C. **Empirical study of particle swarm optimization.** Proceedings of Congress on Evolutionary Computation, Washington, USA, v. 3, p. 1945-1950, 1999.

SHI, Y.; EBERHART, R. C. **Particle swarm optimization with fuzzy adaptive inertia weight.** Proceedings of the Workshop on Particle Swarm Optimization, Indianapolis, IN, USA, 2001.

SILVA, C. A.; SOUSA, J. M. C.; RUNKLER, T.; PALM, R. **Soft computing optimization methods applied to logistic processes.** International Journal of Approximate Reasoning, v. 40, n. 3, p. 280-301, 2005.

SILVA, L. A. W.; COELHO, L. S. **An adaptive particle swarm approach applied to optimization of a simplified supply chain.** Proceedings of the 19th International Conference on Production Research, Valparaíso, Chile, 2007.

SIMCHI-LEVI, D.; KAMINSKY, P.; SIMCHI-LEVI, E. **Cadeia de suprimentos: projeto e gestão.** 1. ed. Porto Alegre/RS: Bookman, 2003.

STACEY, A.; JANCIC, M.; GRUNDY, I. **Particle swarm optimization with mutation.** Proceedings of the IEEE Congress on Evolutionary Computation, Canberra, Australia, p. 1425-1430, 2003.

SUGANTHAN, P. N. **Particle swarm optimizer with neighborhood operator.** Proceedings of the Congress on Evolutionary Computation, Washington, USA, v. 3, p.1958-1962, 1999.

SVENSON, P.; MÅRTENSON, C.; SIDENBLADH, H.; MALM, M. **Swarm intelligence for logistics: background,** 2004. Disponível em: <[www2.foi.se/rapp/foir1180.pdf](http://www2.foi.se/rapp/foir1180.pdf)>. Acesso em: 06 abr. 2007.

SYARIF, A.; YUN, Y.; GEN, M. **Study on multi-stage logistic chain network: a spanning tree-based genetic algorithm approach.** Computers & Industrial Engineering, v. 43, n. 1-2, p. 299-314, 2002.

TASGETIREN, M. F.; LIANG, Y. **A binary particle swarm optimization algorithm for lot sizing problem.** Journal of Economic and Social Research, v. 5, n. 2, p.1-20, 2003.

TASGETIREN, M. F.; LIANG, Y. -C.; SEVKLI, M.; GENÇYILMAZ, G. **Particle swarm optimization algorithm for makespan and maximum lateness minimization in permutation flowshop sequencing problem.** Proceedings of the 4th International Symposium on Intelligent Manufacturing Systems, Sakarya, Turkey, p. 431–441, 2004a.

TASGETIREN, M. F.; LIANG, Y. -C.; SEVKLI, M.; GENÇYILMAZ, G. **Particle swarm optimization algorithm for permutation flowshop sequencing problem.** Lecture Notes in Computer Science, Springer-Verlag, v. 3172, p. 382–390, 2004b.

TASGETIREN, M. F.; LIANG, Y.-C.; SEVKLI, M.; GENÇYILMAZ, G. **A particle swarm optimization algorithm for makespan and total flowtime minimization in the permutation flowshop sequencing problem.** European Journal of Operational Research, v. 177, n. 3, p. 1930-1947, 2007.

TING, T.-O.; RAO, M. V. C.; LOO, C. K. **A novel approach for unit commitment problem via an effective hybrid particle swarm optimization.** IEEE Transactions on Power Systems, v. 21, n. 1, 2006.

TING, T.-O.; RAO, M. V. C.; LOO, C. K.; NGU, S.-S. **A new class of operators to accelerate particle swarm optimization.** Proceedings of the Congress on Evolutionary Computation, Canberra, Australia, v. 4, p. 2406-2410, 2003.

TOWILL, D. R.; MCCULLEN, P. **The impact of an agile manufacturing program on supply chain dynamics.** The International Journal of Logistics Management, v. 10, n. 1, p. 83-96, 1999.

UCAR, H.; TAGESTIREN, M. F. **A particle swarm optimization algorithm for permutation flow shop sequencing problem with the number of tardy jobs criterion.** Proceedings of 5th International Symposium on Intelligent Manufacturing Systems, p. 237-250, 2006.

VAN DEN BERGH, F. ENGELBRECHT, A. P. **Cooperative learning in neural networks using particle swarm optimizers.** South African Computer Journal, v. 26, p. 84-90, 2000.

VAN DEN BERGH, F.; ENGELBRECHT, A. P. **A new locally convergent particle swarm optimizer.** Proceedings of the IEEE International Conference on Systems, Man and Cybernetics, Hammamet, Tunisia, v. 3, p. 96-101, 2002.

VENKATESWARAN, J.; KULVATUNYOU, B. **Investigation of influence of modeling fidelities on supply chain dynamics.** Proceedings of the 2002 Winter Simulation Conference, San Diego. Yücesan, E.; Chen, C. H.; Snowdon, J. L.; Chanes, J. M. (eds.), p. 1183-1191, 2002.

VIEIRA, G. E. **Ideas for modeling and simulation of supply chains with arena.** Proceedings of the 2004 Winter Simulation Conference, Washington, D.C, USA. Ingalls, R. G.; Rossetti, M. D.; Smith, J. S.; Peters, B. A. (eds), p. 1418-1427, 2004.

WEI, C.; HE, Z.; ZHENG, Y.; PI, W. **Swarm directions embedded in fast evolutionary programming.** Proceedings of the IEEE Congress on Evolutionary Computation, Honolulu, USA, p. 1278-1283, 2002.

WOILER, S.; MATHIAS, W. F. **Projetos: planejamento, elaboração e análise.** 1.ed. São Paulo/SP: Atlas, 1996.

WU, C. **Intelligent use of delayed information in the supply chain by artificial neural network.** Proceedings of IEEE International Conference on System, Man and Cybernetics, Tokyo, Japan, v. 2, p. 66-70, 1999.

XIA, W.; WU, Z. **An effective hybrid optimization approach for multi-objective flexible job-shop scheduling problems.** Computers and Industrial Engineering, v. 48, n. 2, p. 409-425, 2005.

YAO, X. **Evolving artificial neural networks.** Proceedings of the IEEE, v. 87, n. 9, p. 1423-1447, 1999.

YIN, P-Y.; WANG, J-Y. **A particle swarm optimization approach to the nonlinear resource allocation problem.** Applied Mathematics and Computation, v. 183, n. 1, p. 232-242, 2006.

YOSHIDA, H.; KAWATA, K.; FUKUYAMA, Y.; TAKAYAMA, S.; NAKANISHI, Y. **A particle swarm optimization for reactive power and voltage control in electric power systems considering voltage security assessment.** Proceedings of IEEE International Conference on Systems, Man and Cybernetics, Tokyo, Japan, v. 6, p. 497-502, 1999.

YOSHIDA, H.; KAWATA, K.; FUKUYAMA, Y.; TAKAYAMA, S.; NAKANISHI, Y. **A particle swarm optimization for reactive power and voltage control considering voltage security assessment.** IEEE Transactions on Power Systems, v. 15, n. 4, p. 1232-1239, 2000.

YOSHIDA, H.; KAWATA, K.; FUKUYAMA, Y.; TAKAYAMA, S.; NAKANISHI, Y. **A particle swarm optimization for reactive power and voltage control considering voltage security assessment.** Proceedings of IEEE Power Engineering Society Winter Meeting, Columbus, USA, v. 2, p. 498-504, 2001.

ZHANG, C.; SHAO, H.; LI, Y. **Particle swarm optimization for evolving artificial neural network.** Proceedings of the IEEE International Conference on Systems, Man and Cybernetics, Nashville, USA, v. 4, p. 2487-2490, 2000.

ZHOU, G.; MIN, H.; MITSUO, G. **The balanced allocation of customers to multiple distribution centers in the supply chain network: a genetic algorithm approach.** Computers & Industrial Engineering, v. 43, n. 1-2, p. 251-261, 2002.