

MARCO AURÉLIO GUIA FALCONE

**ESTUDO COMPARATIVO ENTRE
ALGORITMOS GENÉTICOS E EVOLUÇÃO
DIFERENCIAL PARA OTIMIZAÇÃO DE UM
MODELO DE CADEIA DE SUPRIMENTO
SIMPLIFICADA**

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.

CURITIBA

2004

MARCO AURÉLIO GUIA FALCONE

**ESTUDO COMPARATIVO ENTRE
ALGORITMOS GENÉTICOS E EVOLUÇÃO
DIFERENCIAL PARA OTIMIZAÇÃO DE UM
MODELO DE CADEIA DE SUPRIMENTO
SIMPLIFICADA**

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.

Área de Concentração: Gerência de Produção e Logística

Orientador: Prof. Dr. Leandro dos Santos Coelho

CURITIBA

2004

TERMO DE APROVAÇÃO

MARCO AURÉLIO GUIA FALCONE

ESTUDO COMPARATIVO ENTRE ALGORITMOS GENÉTICOS E EVOLUÇÃO DIFERENCIAL PARA OTIMIZAÇÃO DE UM MODELO DE CADEIA DE SUPRIMENTO SIMPLIFICADA

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Curso de Mestrado em Engenharia de Produção e Sistemas, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, do Centro de Ciências Exatas e de Tecnologia da Pontifícia Universidade Católica do Paraná, pela seguinte banca examinadora:



Presidente da Banca
Prof. Dr. Leandro dos Santos Coelho (Orientador)



Prof. Dr. Marco Antonio Barbosa Cândido (Membro Titular)



Prof. Dr. Mauricio Kuehne Júnior (Membro Titular)

Curitiba, 15 de setembro de 2004.



Falcone, Marco Aurélio Guia

Estudo comparativo entre algoritmos genéticos e evolução diferencial para otimização de um modelo de cadeia de suprimento simplificada. Curitiba, 2004. 81p.

Dissertação – Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Engenharia de Produção e Sistemas.

1. Cadeia de suprimento 2. Otimização 3. Algoritmos genéticos 4. Evolução diferencial. I. Pontifícia Universidade Católica do Paraná. Centro de Ciências Exatas e de Tecnologia. Programa de Pós-Graduação em Engenharia de Produção e Sistemas.

Agradecimentos

Ao professor Leandro dos Santos Coelho pela orientação, paciência e dedicação demonstradas nas etapas do desenvolvimento desta dissertação.

A Sérgio Lisboa e Mathias Hofmann pelo apoio na defesa da liberação dos recursos necessários para a execução deste trabalho.

A Tritec Motors pelo apoio financeiro para a realização do mestrado.

A todos que, direta ou indiretamente, colaboraram para a realização deste trabalho.

E, em especial, a minha esposa Regina e ao meu filho Lucas que possibilitaram a finalização desta dissertação.

Sumário

Agradecimentos	i
Sumário	ii
Lista de Figuras	iv
Lista de Tabelas	v
Lista de Abreviaturas	vi
Resumo	vii
Abstract	viii

Capítulo 1

Introdução	1
1.1 Revisão bibliográfica	3
1.2 Objetivos	26
1.3 Descrição da Proposta	26
1.4 Contribuição	27
1.5 Organização da Dissertação	27

Capítulo 2

Descrição do problema	29
2.1 Formalização matemática de um problema de otimização	30
2.2 Algumas formulações e terminologias dos algoritmos evolucionários em problemas de otimização	31
2.2.1 Espaço de busca	31
2.2.2 Representação	32
2.3 Modelagem matemática do problema	33
2.4 Conclusão do capítulo	36

Capítulo 3	
Metodologia de resolução	37
3.1 Computação evolucionária (ou evolutiva)	37
3.2 Algoritmos genéticos	39
3.2.1 Componentes de um algoritmo genético	42
3.2.2 Funcionamento dos algoritmos genéticos	48
3.2.3 Parâmetros dos algoritmos genéticos	49
3.3 Evolução diferencial	50
3.3.1 Parâmetros da evolução diferencial	53
3.4 Conclusão do capítulo	54
Capítulo 4	
Resultados	55
4.1 Introdução	55
4.2 Análise dos resultados	58
4.3 Conclusão do capítulo	65
Capítulo 5	
Conclusões	66
Referências Bibliográficas	70

Lista de Figuras

Figura 1.1	Visão geral das atividades de planejamento na manufatura	5
Figura 1.2	Desenho esquemático do planejamento de necessidades de materiais	6
Figura 1.3	Exemplos de estruturas de produto	7
Figura 1.4	Representação esquemática de uma cadeia de suprimento	11
Figura 2.1	Diagrama da cadeia de suprimento integrando os sistemas de produção, estoque e distribuição	29
Figura 2.2	Relações entre C , S e R	32
Figura 3.1	Fluxograma de um AG	42
Figura 3.2	Operadores genéticos de cruzamento e mutação	47
Figura 3.3	Fluxograma da evolução diferencial	52
Figura 4.1	Desempenho on-line ED(1)	61
Figura 4.2	Desempenho off-line ED(1)	61
Figura 4.3	Desempenho off-line ED(1) considerando o desvio padrão	61
Figura 4.4	Desempenho on-line AG(2)	62
Figura 4.5	Desempenho off-line AG(2)	62
Figura 4.6	Desempenho off-line AG(2) considerando o desvio padrão	62
Figura 4.7	Desempenho on-line ED(2)	63
Figura 4.8	Desempenho off-line ED(2)	63
Figura 4.9	Desempenho off-line ED(2) considerando o desvio padrão	63
Figura 4.10	Desempenho on-line AG(7)	63
Figura 4.11	Desempenho off-line AG(7)	63
Figura 4.12	Desempenho off-line AG(7) considerando o desvio padrão	64

Lista de Tabelas

Tabela 4.1	Resumo dos resultados para 10 experimentos.....	59
Tabela 4.2	Parâmetros determinados pela melhor função objetivo de cada abordagem de ED e AG da Tabela 4.1.....	59
Tabela 4.3	Comparação entre os melhores representantes dos algoritmos propostos e os resultados obtidos por Mak e Wong (1995).....	64

Lista de Abreviaturas

AE	Algoritmo Evolucionário
AG	Algoritmo Genético
B&B	<i>Branch and Bound</i>
CE	Computação Evolucionária
CLSP	<i>Capacitated Lot-sizing and Scheduling Problem</i>
CSLP	<i>Continuous Set-up Lot-sizing and Scheduling Problem</i>
DLSP	<i>Discrete Lot-sizing and Scheduling Problem</i>
ED	Evolução Diferencial
GLSP	<i>General Lot-sizing and Scheduling Problem</i>
MPS	<i>Master Production Scheduling</i>
MRP	<i>Material Requirements Planning</i>
MSCLS	<i>Multistage Capacitated Lot-sizing</i>
NFL	<i>No Free Lunch</i>
NP	Não Polinomial
PLSP	<i>Proportional Lot-sizing and Scheduling Problem</i>
PLSPST	<i>Proportional Lot-sizing and Scheduling Problem with Set-up Times</i>
PMP	Plano Mestre da Produção
SCM	<i>Supply Chain Management</i>

Resumo

O sucesso de uma empresa, atualmente, é contingência do gerenciamento de sua cadeia de suprimento. Assim, o planejamento e a modelagem dos sistemas de produção, estoque e distribuição de uma cadeia de suprimento é uma ferramenta importante de suporte à decisão em um mercado competitivo. As abordagens de modelagem para representação de uma cadeia de suprimento podem ser classificadas em cinco classes: (i) projeto da rede de suprimento, (ii) otimização baseada em programação inteira-mista, (iii) programação estocástica, (iv) métodos heurísticos, e (v) métodos baseados em simulação. Recentemente são apresentadas na literatura diversas abordagens de algoritmos evolucionários para otimização de cadeias de suprimento, onde os algoritmos genéticos monopolizam quase todas as aplicações. A contribuição desta dissertação é apresentar um estudo comparativo de algoritmos evolucionários (algoritmos genéticos e evolução diferencial) para a otimização de uma cadeia de suprimento simplificada. Os algoritmos evolucionários desenvolvidos visam a solução do problema de minimização dos custos de armazenagem, fabricação, transporte e falta de produto para o modelo de cadeia de suprimento simplificada com 3 materiais, 2 produtos, 3 distribuidores e 3 períodos de planejamento. A análise dos resultados permite afirmar que a evolução diferencial se mostrou superior aos algoritmos genéticos testados em relação aos indicadores de qualidade da resposta, análise de convergência e tempo computacional consumido.

Palavras-Chave: Cadeia de suprimento, otimização, algoritmos genéticos, evolução diferencial.

Abstract

The company' success is, nowadays, due to the management of its supply chain(s). So, the planning and modelling of an integrated production inventory distribution system is an important tool to support the strategic decisions in a competitive market. The different approaches for modelling the supply chain framework can be classified in five classes: (i) supply chain design, (ii) optimization based on integer programming, (iii) stochastic programming; (iv) heuristics methods, and (v) simulation. Recently, the scientific literature presents a lot of different approaches of evolutionary algorithm to optimize supply chains, and the genetic algorithm is the main approach applied. This dissertation contributes with a related study of evolutionary algorithms (genetic algorithm and differential evolution) for a supply chain optimization. The evolutionary algorithms developed have the purpose of minimizing the inventory, production, transportation and shortage costs for a simplified supply chain model with 3 raw materials, 2 products, 3 retailers and 3 periods. According to the results, differential evolution had a better performance than genetic algorithms considering the indicators: quality of answer, convergence and computation time.

Keywords: Supply chain, optimization, genetic algorithm, differential evolution.

Capítulo 1

Introdução

O ambiente competitivo da maioria das empresas de diversos setores industriais exige a necessidade de obtenção de melhor desempenho em relação a indicadores de qualidade, rapidez, confiabilidade, flexibilidade e custo.

A competição, além de ocorrer no plano das organizações individualmente, se dá também, no plano das cadeias ou rede de organizações. Desta forma, não basta uma empresa ser eficaz em seu estrito ambiente competitivo, a cadeia na qual está inclusa também deve ser eficaz.

Uma cadeia de suprimento (ou abastecimento) engloba todos os estágios envolvidos, direta ou indiretamente, no atendimento do(s) pedido(s) de cliente(s) (Chopra & Mendl, 2003). O sucesso de uma empresa, atualmente, é contingência do gerenciamento de sua cadeia de suprimento. Tradicionalmente, as várias unidades de negócios ao longo de uma cadeia de suprimento operam independentemente. Estas unidades têm seus próprios objetivos e estes são frequentemente conflitantes. A concepção de uma estratégia de coordenação das várias unidades de negócios em uma cadeia de suprimento para um gerenciamento efetivo nos níveis estratégico, tático e operacional é um aspecto essencial para o sucesso de uma empresa (Venkateswaran & Kulvatunyou, 2002).

A cadeia de suprimento não inclui apenas fabricantes e fornecedores, mas também transportadoras, depósitos, varejistas e os clientes (Chopra & Mendl, 2003). A eficiência de uma cadeia de suprimento é influenciada por diversos fatores, tais como gerenciamento dos níveis de estoque, planejamento da capacidade produtiva, custos de produção, concepção de métodos eficientes de escalonamento, estratégia(s) de distribuição do produto e demanda do consumidor (Silver *et al.*, 1998).

O planejamento e modelagem dos sistemas de produção, estoque e distribuição de uma cadeia de suprimento é uma ferramenta importante de suporte à decisão em um mercado competitivo (Banks *et al.*, 2002; Enns & Suwanruji, 2003). As abordagens de

modelagem para representação de uma cadeia de suprimento podem ser classificadas em cinco classes: (i) projeto da rede de suprimento, (ii) otimização baseada em programação inteira-mista, (iii) programação estocástica, (iv) métodos heurísticos, e (v) métodos baseados em simulação (Dong, 2001). O propósito de modelar uma cadeia de suprimento é geralmente para (i) analisar a sua dinâmica, identificar as estratégias para minimizar esta dinâmica e (ii) validar um modelo preciso para representar a cadeia de suprimento.

A otimização de uma cadeia de suprimento é um problema de otimização inteira ou mesmo mista inteira com restrições e dependendo se sua formulação pode ser configurada em um problema de difícil solução para os métodos clássicos de otimização. Com esta abordagem, diversas metodologias para otimização de cadeias de suprimento têm sido propostas na literatura. Fu (2002) identifica quatro abordagens principais para otimização que abrangem (i) aproximação estocástica (métodos baseados em gradiente) (Kleywegt & Shapiro, 2001), (ii) metodologia usando meta-modelos, tais como superfície de resposta (Fu, 2001), redes neurais artificiais (Gupta & Pochampally, 2004) e sistemas nebulosos (Berkstresser *et al.*, 2000), e (iii) métodos baseados em busca aleatória. Neste contexto, a literatura é rica em trabalhos usando *branch and bound* (Goldbarg & Luna, 2000), plano de corte (Miller, 1999), métodos aproximados (Li, 1992), *branch and bound* modificado (Dakin, 1965), *busca tabu* (Lourenço, 2001), *simulated annealing* (Baydar, 2002), *scatter search* (Lourenço, 2001) e algoritmos evolucionários (Zhou *et al.*, 2002).

Recentemente são apresentadas na literatura diversas abordagens de algoritmos evolucionários para otimização de cadeias de suprimento, onde os algoritmos genéticos monopolizam quase todas as aplicações (Disney *et al.*, 2000; Syarif *et al.*, 2002; Ding *et al.*, 2003; Berning *et al.*, 2004). Por outro lado, novos métodos de algoritmos evolucionários foram desenvolvidos e têm obtido destaque pela sua eficiência na solução de problemas de otimização estática. Neste contexto, um estudo comparativo entre as técnicas de algoritmos genéticos e evolução diferencial para uma cadeia de suprimento simplificada no processo de minimização dos custos totais de estoque, produção, transporte e falta de produtos foi o elemento motivador para a realização deste trabalho.

Neste capítulo procura-se situar o leitor através de uma revisão bibliográfica e da descrição dos objetivos, da proposta, da contribuição esperada e da organização dos capítulos desta dissertação.

1.1 Revisão bibliográfica

Gestão da Produção

Desde os primórdios, o homem lida com as atividades relacionadas à Gestão da Produção, e à medida que a produção de utensílios ganhou maior escala surgiram novos conhecimentos para auxiliar o homem na gerência dos fatores relacionados à produção.

Com os conhecimentos provenientes da administração científica, da teoria clássica e da linha de montagem seriada criaram-se os fundamentos básicos da atual Gestão da Produção.

Esses fundamentos foram beneficiados com o desenvolvimento computacional (sistemas de informação, técnicas de planejamento como o planejamento de necessidade de materiais, entre outros), possibilitando avanços na gestão de recursos para a otimização da produção.

Conforme Tubino (1997), os sistemas produtivos devem exercer uma série de funções operacionais, desempenhadas por pessoas, que vão desde o projeto dos produtos, até o controle dos estoques, recrutamento e treinamento de funcionários, aplicação de recursos financeiros, distribuição de produtos, etc. De forma geral, essas funções podem ser agrupadas em três funções básicas: Finanças, Produção e *Marketing*. O sucesso de um sistema produtivo depende da forma como essas três funções se relacionam, cabendo à Gestão da Produção uma administração eficaz das atividades envolvidas (produtivas ou não).

A função Produção apresenta três aspectos importantes (Slack *et al.*, 1999):

- apoiar a estratégia empresarial;
- implementar a estratégia empresarial (fazer a estratégia acontecer); e
- impulsionar a estratégia empresarial (fornecer os meios para a obtenção de vantagem competitiva).

Conforme Slack *et al.* (1999), a vantagem competitiva pode ser alcançada pela função produção através de **cinco objetivos de desempenho**:

- **objetivo de qualidade:** fazer as tarefas corretamente, possibilitar o aumento da confiabilidade e reduzir custos;
- **objetivo de rapidez:** reduzir estoques e diminuir o risco de uma previsão incorreta;

- **objetivo de confiabilidade:** fazer as tarefas em tempo conforme prometido ou programado, economizar o tempo disponível, economizar capital e fornecer a estabilidade (previsibilidade);
- **objetivo de flexibilidade:** ser capaz de mudar a operação de alguma forma, agilizando a resposta, maximizando o tempo e fornecendo estabilidade. Existem 4 tipos de exigências: flexibilidade de produto/serviço, exigências de combinação de itens, de volume e de entrega;
- **objetivo de custo:** fazer as tarefas a um custo reduzido, isto é, reduzir custos de materiais e serviços, custos de tecnologia e/ou instalações e custos de funcionários. Este objetivo é afetado pelos outros objetivos de desempenho, pois custos menores permitem a redução dos preços e/ou o aumento do lucro.

O planejamento operacional da função Produção pode ser dividido em três grupos, conforme Davis *et al.* (2001):

- planejamento estratégico (longo prazo): foco nos assuntos estratégicos relativos à capacidade, ao processo de seleção e a localização da fábrica;
- planejamento tático (médio prazo): foco nos assuntos táticos pertinentes à mão-de-obra agregada e aos materiais necessários para o ano seguinte;
- planejamento operacional e de controle (curto prazo): define as escalas diárias de trabalhadores para tarefas específicas em determinados postos de trabalho.

Assim, após a definição do planejamento estratégico, os planejamentos a médio e a curto prazo podem ser desenvolvidos. Destaca-se no médio prazo, a elaboração do planejamento agregado da produção, responsável pela ligação básica entre o planejamento estratégico de longo prazo e as atividades de médio prazo. Cabe ao planejamento agregado da produção encontrar qual combinação dos níveis de mão-de-obra mensal (ou trimestral) e dos níveis de estoques minimizam os custos totais relativos de produção, no período de planejamento considerado, buscando simultaneamente atender à demanda prevista para o(s) produto(s).

A partir do planejamento agregado da produção elabora-se o plano mestre da produção (PMP ou MPS – *Master Production Scheduling*). O PMP é responsável pela programação semanal de produtos finais específicos, estes necessários para os próximos trimestres.

Finalmente, chega-se ao planejamento de curto prazo, mais especificamente ao planejamento das necessidades de materiais (MRP – *Material Requirements Planning*). O plano de materiais especifica quando a produção e os pedidos de compra devem ser colocados para cada peça e para as submontagens, para que os produtos sejam concluídos segundo o PMP.

A Figura 1.1 (Davis *et al.*, 2001) fornece uma visão geral das atividades do planejamento da manufatura descritos anteriormente.

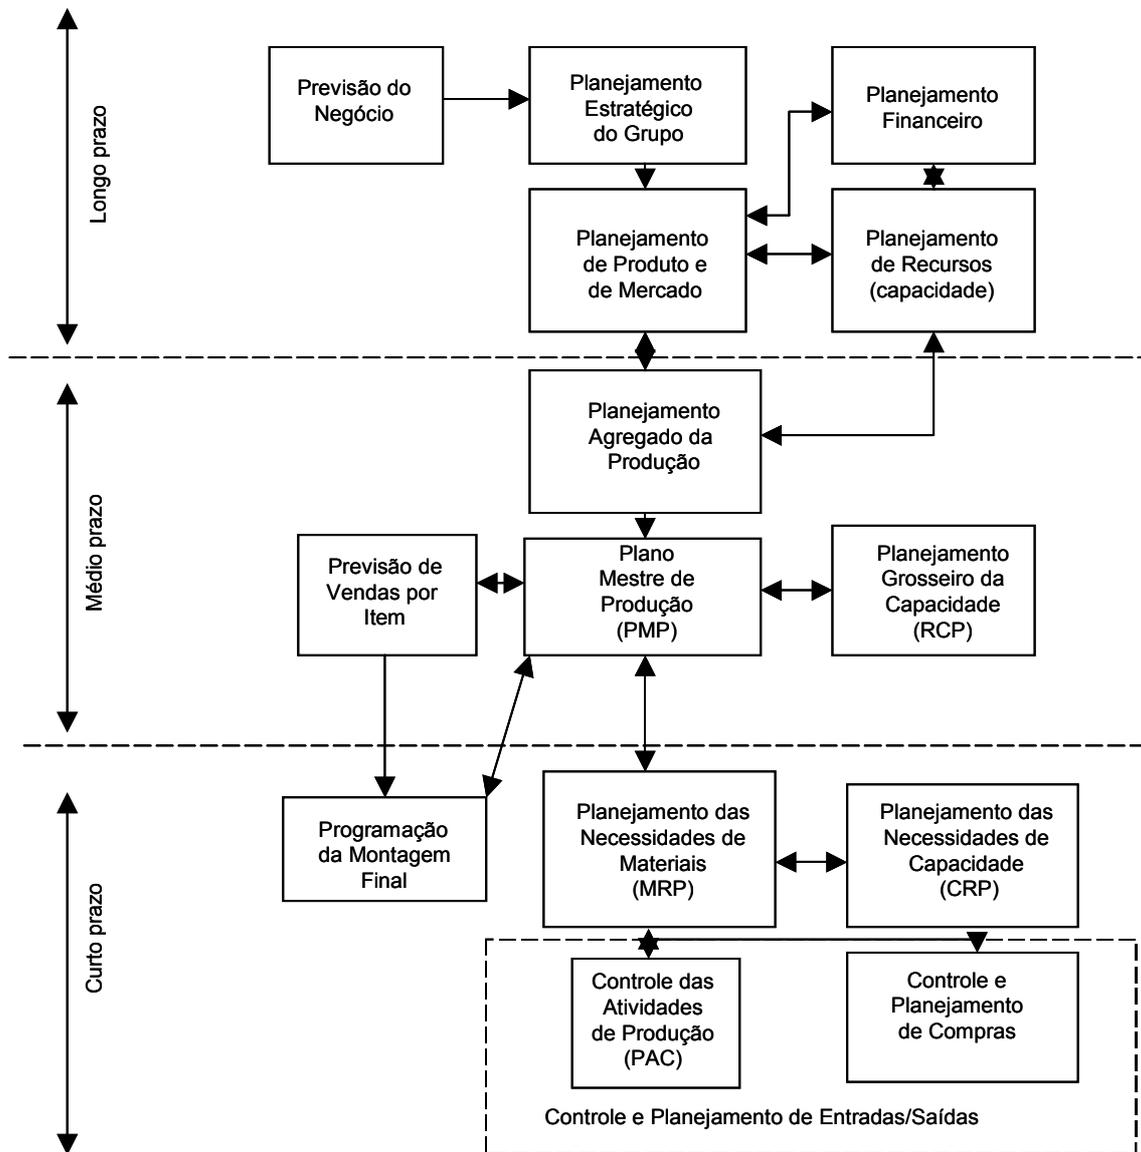


Figura 1.1 Visão geral das atividades do planejamento na manufatura.

MRP

A utilização do programa de *Material Requirements Planning* (MRP) para o planejamento da necessidade de materiais a partir de uma previsão de demanda tornou-se comum para indústrias de diferentes portes em diversos setores, desde o início de sua utilização nos anos 60.

O MRP permite que as empresas calculem quantos materiais de determinado tipo são necessários e em que momento. Pode-se considerar como entradas principais do MRP o plano mestre da produção, destacando-se neste a previsão de vendas e a carteira de pedidos, a lista de materiais utilizada para a produção do item final e os registros de estoque. Como saídas do programa, o MRP fornece os planos de materiais, as ordens de compra e as ordens de trabalho. A Figura 1.2 apresenta esta configuração (Slack *et al.*, 1997).

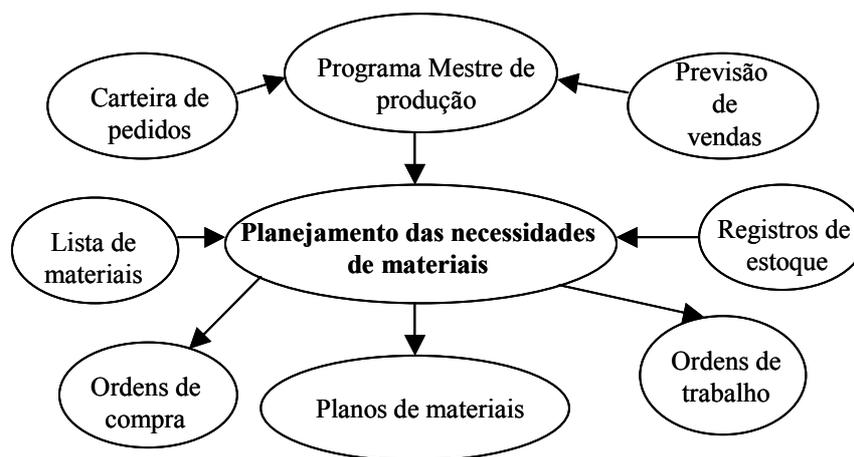


Figura 1.2 Desenho esquemático do planejamento de necessidades de materiais.

Os registros de estoque contêm os dados vitais para o funcionamento do MRP, incluindo a identificação inequívoca de cada componente, sua localização, quantas unidades há em estoque e que transações de recebimento e envio foram registradas para qualquer dos itens (Slack *et al.*, 1997).

O processo de cálculo do MRP determina as necessidades dos itens de nível mais alto, através das estruturas de produtos, levando em conta os estoques e os *lead times* em cada nível. A estrutura do produto mostra que alguns itens formam outros, que por sua vez, formam terceiros. A Figura 1.3 apresenta três exemplos de estruturas de produto. Para cada exemplo, o produto final é representado pelo algarismo 1 e os demais algarismos identificam os componentes existentes na estrutura.

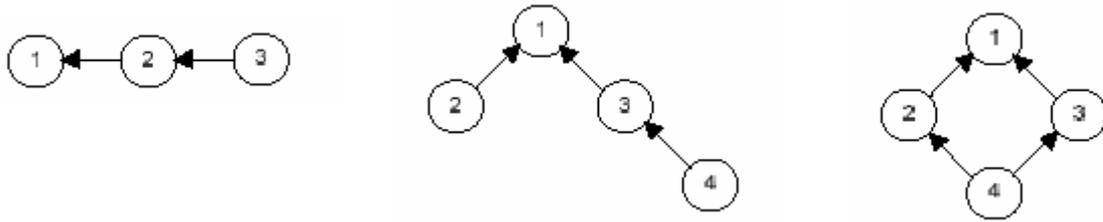


Figura 1.3 Exemplos de estruturas de produto.

Os sistemas de MRP assumem um ambiente de produção fixo, utilizando *lead times* fixos para calcular quando os materiais devem chegar ao próximo centro de trabalho. Entretanto, as condições de carga de trabalho e outros fatores fazem com que os *lead times* sejam na realidade bastante variáveis, comprometendo assim, a eficiência do MRP para esta situação (Slack *et al.*, 1997).

O MRP também apresenta limitações ao desconsiderar as restrições de capacidade produtiva e os custos referentes à produção, preparação (*set up*) e inventário. Sendo assim, a solução fornecida pelo programa pode ser impraticável em termos de capacidade produtiva e/ou apresentar elevados custos (Rodrigues, 2000). Para um ambiente altamente competitivo como o atual, esta solução pode influenciar negativamente o desempenho da organização.

O problema de dimensionamento de lotes (*lote sizing*) trata essencialmente dessas questões, ou seja, seu objetivo é determinar o tamanho dos lotes de produção de forma a minimizar os custos envolvidos, sujeito a um conjunto de restrições. Ele determina a quantidade e o período para produzir cada item num dado horizonte de tempo de tal modo que a demanda seja atendida. Em sistemas de produção multiestágios, o planejamento de cada item ainda depende do planejamento de outros itens situados em níveis hierárquicos inferiores (Rodrigues, 2000).

Considerar os custos e tempos de preparação diferentes de zero, faz com que, matematicamente, o problema seja modelado como um problema de programação matemática inteiro-mista de difícil solução, tornando difícil a obtenção de um plano factível. Entretanto, esta inclusão se faz necessária para que se tenha o consumo real dos recursos (Rodrigues, 2000).

Gestão de Estoques

O gerenciamento dos níveis de estoque objetiva o planejamento e o controle dos estoques, definindo os tamanhos de lotes, a forma de reposição e os estoques de segurança.

Os tipos de estoque podem ser divididos em itens de matérias-primas, de componentes comprados ou produzidos, de produtos acabados, de produtos em processo, de ferramentas, entre outros. Os estoques apresentam os seguintes objetivos:

- garantir a independência entre as etapas produtivas (quando da existência de gargalos de produção);
- permitir uma produção constante;
- possibilitar o uso de lotes econômicos;
- reduzir os lead times produtivos;
- fornecer segurança; e
- obter vantagem de preço.

Dois tipos principais de modelos de estoque recebem destaque na literatura, conforme Arrow (2002):

- **dinâmico, mas determinístico:** o estoque não utilizado em um período está disponível para o uso futuro e a demanda é considerada constante. Quando o nível de estoque abaixar até um patamar definido ocorre a reposição do estoque para o nível inicial;
- **estocástico, mas estático:** considera-se apenas um período e a demanda é imprevisível. A empresa não deseja solicitar material em excesso, uma vez que o custo de compra é diretamente proporcional à quantidade adquirida. Por outro lado, a empresa pode ser penalizada caso a quantidade solicitada não atenda a demanda.

Como os estoques não agregam valor aos produtos, quanto menor o nível de estoques com que um sistema produtivo consegue trabalhar, mais eficiente é o sistema. Segundo Christopher (1998), “os estoques devem ser tratados como uma estratégia de redução de custos empresariais”. De acordo com Filho (2002), “a relevância dos estoques reside no fato de que seu correto gerenciamento interfere, positiva ou negativamente, nos resultados financeiros obtidos pela organização durante seu exercício financeiro. Os estoques devem ser visualizados, pela logística, diferentemente da visão dos executivos financeiros. A gestão da

produção deve focalizar os esforços de planejamento e o controle sobre itens individuais, situados em determinados pontos de estocagem ao longo da cadeia logística. Os investimentos em estoques e seus quocientes de rotação são menores ou maiores, dependendo da qualidade de inúmeras decisões específicas, em relação a centenas de pontos de estocagem por toda a cadeia logística. Portanto, o ideal seria calcular-se o “giro” para cada tipo de estoque existente dentro da cadeia e não apenas dos estoques de produtos acabados”.

E, finalmente, conforme Viana (2000), os estoques “concorrem com mais de 50% do custo do produto vendido, o que faz com que os recursos alocados a estoques devam ser empregados sob a forma mais racional possível”.

Para uma interessante revisão sobre o desenvolvimento da teoria de estoques, sugere-se os trabalhos de Arrow (2002) e de Scarf (2002). Ambos os autores dedicaram-se ao estudo e ao desenvolvimento da política de inventário ótimo com trabalhos desenvolvidos a partir de 1949.

Logística e Gerenciamento da Cadeia de Suprimento

Até este momento, apresentou-se de forma sucinta a abrangência da Gestão da Produção e sua aplicação no gerenciamento das funções de produção internas às empresas. É importante expandir esta abrangência além dos limites de uma unidade fabril, considerando as inter-relações entre as empresas na produção de bens/serviços e, conseqüentemente, no atendimento dos consumidores finais. Desta forma, como citado por Bonadio (2002), “além das possíveis relações entre processos e as funções internas às empresas, é preciso considerar de modo geral as relações entre as organizações. Parte-se em geral da idéia ou pressuposto de que a competição, além de ocorrer no plano das organizações individualmente, se dá também no plano das cadeias ou rede de organizações. Assim, não basta uma empresa ser eficaz em seu restrito ambiente competitivo, a cadeia na qual está inclusa deve ser eficaz também”.

Segundo Lourenço (2001), nas últimas duas décadas, a logística e a cadeia de suprimento se tornaram o centro das atenções das organizações na busca de novos caminhos para criar e enviar valor para os clientes. Há um maior reconhecimento que através de um gerenciamento efetivo da função logística e da cadeia de suprimento, a meta de redução de custo e garantia do serviço podem ser alcançadas.

Também, conforme Geoffrion e Powers (1995), o reconhecimento corporativo da função logística mudou drasticamente durante as últimas duas décadas. Em muitas empresas,

a função logística passou de uma situação de negligência para uma situação de destaque e respeito devido a influência sobre a lucratividade e ao seu atual posicionamento estratégico. Além disso, os autores ressaltam que a década de 90 foi marcada pela evolução da terceira fase da logística, ou seja, a integração externa entre companhias. A observação fundamental para essa abordagem é que, de uma ou de outra maneira, cada companhia paga pelas ineficiências de seus fornecedores e de seus consumidores.

De acordo com Johnson e Pyke (1999), o gerenciamento da cadeia de suprimento (*Supply Chain Management* - SCM) tem gerado interesse nos anos recentes, também, pelo fato de que muitos gerentes se deram conta que ações tomadas por um membro da cadeia pode influenciar a lucratividade dos outros membros da cadeia. As companhias estão, fortemente, competindo como parte de uma cadeia contra outras cadeias, ao invés de uma simples companhia contra outras companhias individualmente.

A importância da gestão da cadeia de suprimento está fundamentada nas seguintes causas, segundo Buosi e Carpinetti (2002):

- diminuição da integração vertical das empresas, forçando-as à especialização e à busca de fornecedores que possam prover baixos preços, além de matérias-primas e produtos de qualidade;
- aumento da competição nacional e internacional fazendo com que a diminuição de riscos e custos de manter estoques ganhem destaque estratégico;
- busca pelo aumento do desempenho do negócio como um todo;
- crescente compartilhamento de informações entre os fornecedores e os compradores;
- mudança de produção em massa para produção customizada;
- aumento simultâneo da confiança entre os fornecedores e os clientes e uma diminuição do número de fornecedores;
- grande ênfase em flexibilidade organizacional e de processos;
- necessidade de coordenar processos entre diferentes componentes da cadeia;
- pressão para introdução de produtos rapidamente;
- necessidade de informações em tempo real para a tomada de decisão.

Finalmente, pode-se argumentar que um importante desafio para o Gerenciamento da Cadeia de Suprimento é a integração e a coordenação de todas as atividades da cadeia,

destacando-se o **gerenciamento dos estoques** para a minimização do custo total do sistema (Lourenço, 2001).

Os termos logística e gerenciamento da cadeia de suprimento começam a se destacar no trabalho e merecem ser definidos, conforme sua descrição na literatura.

O Conselho de Gerenciamento de Logística (*Council of Logistics Management*) define Logística como “parte do processo da cadeia de suprimento que planeja, implementa e controla de maneira eficiente e eficaz o fluxo e o armazenamento de produtos, serviços e a informação relacionada do ponto de origem até o ponto de consumo, para o atendimento dos requerimentos dos consumidores”.

A Figura 1.4 representa uma cadeia de suprimento.

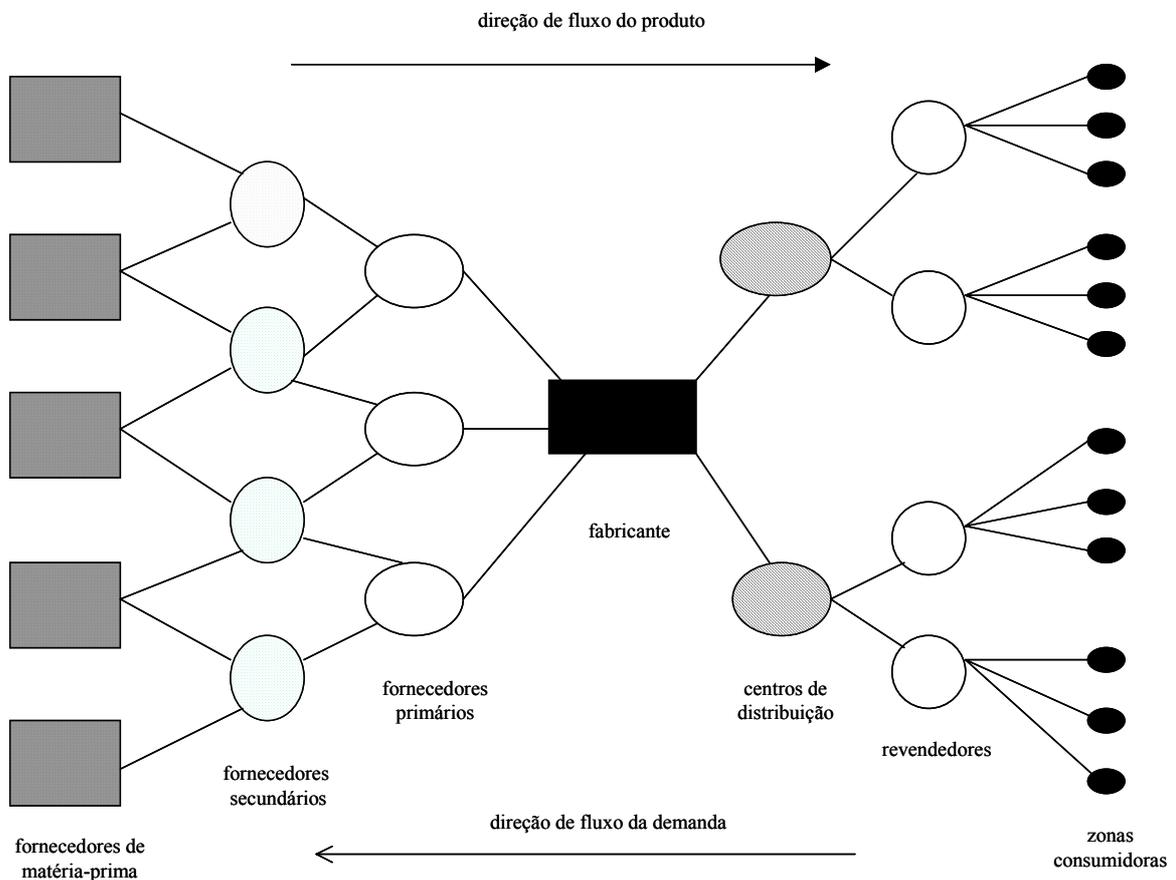


Figura 1.4 Representação esquemática de uma cadeia de suprimento.

Conforme Johnson e Pyke (1999), o Gerenciamento da Cadeia de Suprimento é o termo usado para descrever o gerenciamento do fluxo de materiais, informação e capital através de toda a cadeia de suprimento, desde fornecedores para produtores de componentes,

montadores finais, distribuidores (centros de distribuição e varejistas), até finalmente chegar ao consumidor.

Lourenço (2001) destaca a falta de consenso sobre a definição de SCM, entretanto relata a existência de um entendimento na literatura que assume o gerenciamento da Cadeia de Suprimento como sendo uma série de atividades interconectadas envolvendo planejamento, coordenação e controle de materiais, partes e produtos finais de fornecedor para consumidor.

Outra definição encontrada no trabalho de Lourenço (2001) cita o SCM como um conjunto de abordagens utilizadas para integrar, eficientemente, fornecedores, produtores, centros de distribuição e lojas para que produtos sejam produzidos e distribuídos nas quantidades desejadas, para os locais corretos e nos tempos esperados, minimizando custos sistêmicos e satisfazendo os requisitos do nível de serviço.

Conforme Johnson e Pyke (1999), o Gerenciamento da Cadeia de Suprimento engloba um grande número de tópicos de diversas disciplinas e emprega ferramentas quantitativas e qualitativas, podendo ser dividido em 12 áreas:

- localização: inclui modelos para localização de plantas, sistemas de informação geográfica, diferenças entre países, taxas, custos de transporte específicos e incentivos governamentais;
- transporte e logística: envolve questões relacionadas ao fluxo de produtos através da cadeia de abastecimento, incluindo transporte, armazenamento e movimentação de materiais;
- inventário e modelos de previsão: inclui os modelos tradicionais de inventário e previsão, além dos modelos de multi-escalão (*multi-echelon*);
- *marketing* e transações comerciais: direcionada às questões comerciais com os consumidores e, também aos impactos da variação da demanda na cadeia de abastecimento;
- compras e gerenciamento de fornecedores: direcionada às questões comerciais/contratos e às medidas de desempenho com os fornecedores;
- tecnologia da informação: uso da tecnologia da informação para reduzir inventário e possibilitar o comércio eletrônico;
- desenho de produto e introdução de novos produtos: trata de questões relacionadas à customização em massa, atraso de montagem do produto final, desenvolvimento de módulos e outras questões relacionadas à introdução de novos produtos;

- serviços associados ao pós-venda: relacionada às questões de prestação de serviços e fornecimento de peças de reposição;
- logística reversa e impactos ambientais;
- terceirização dos serviços logísticos e alianças estratégicas: examina o impacto da terceirização dos serviços logísticos;
- indicadores de desempenho: examina as questões relacionadas à medição de desempenho, organização e economia;
- operações globais: estuda como todas as categorias anteriores são afetadas quando empresas operam em diferentes países.

Refletindo uma uniformidade na categorização de assuntos analisados pelo Gerenciamento da Cadeia de Suprimento, Lourenço (2001) apresenta a seguinte divisão:

- integração da cadeia de suprimento;
- localização de plantas e desenho da rede;
- transportes e roteamento de veículos;
- movimentação de materiais e separação de pedidos;
- serviço ao consumidor;
- desenho do produto;
- logística de produção e operações;
- gerenciamento de depósito e estratégias de distribuição;
- gerenciamento de estoque;
- sistemas de informação e de suporte à tomada de decisão;
- comércio eletrônico e logística eletrônica;
- logística reversa e impactos ambientais.

Destas divisões, destaca-se a logística de produção e operações responsável pelo gerenciamento de um conjunto de atividades que geram os produtos e os serviços. Sua interação com o SCM é grande, uma vez que a produção de bens/serviços dependem de matérias-primas para a confecção de um produto que deverá ser distribuído. Lourenço (2001) destaca também a necessidade de uma coordenação entre as áreas para se obter uma cadeia de suprimento eficiente.

A utilização de heurísticas e metaheurísticas no SCM

Além da uniformidade na divisão de categorias para o Gerenciamento da Cadeia de Suprimento, Lourenço (2001) enfatiza a importância de modelos quantitativos e de ferramentas computacionais para a tomada de decisão no ambiente empresarial e, especialmente, para o Gerenciamento da Cadeia de Suprimento. Segundo Lourenço (2001), a chave para o sucesso do Gerenciamento da Cadeia de Suprimento requer ênfase na integração de atividades, cooperação, coordenação e divisão de informação através de toda a cadeia, dos fornecedores até os consumidores. Para estar apto a responder ao desafio da integração há a necessidade do suporte de sofisticados sistemas de decisão baseados em modelos matemáticos e técnicas de solução juntamente com os avanços das tecnologias de informação e comunicação. E assim, a área de técnicas heurísticas (ou métodos metaheurísticos) tem sido objeto de estudos intensivos nas últimas décadas como uma nova e poderosa técnica direcionada para solucionar problemas que não se consegue resolver em tempo polinomial. Portanto, de um lado existe a necessidade de sofisticados sistemas de suporte de decisão logística para capacitar as organizações a responder de forma rápida às questões do Gerenciamento da Cadeia de Suprimento, e do outro lado, existem os avanços na área de metaheurística que podem fornecer uma resposta efetiva a problemas complexos. Existe assim um campo fértil para as aplicações dessas técnicas para o Gerenciamento da Cadeia de Suprimento e, também, para o desenvolvimento de sistemas de informação para o suporte de decisões logísticas.

Segundo Rodrigues (2000), devido a dificuldade prática de se resolver de forma ótima um grande número de problemas de otimização combinatória, como o dimensionamento de lotes envolvendo custos e tempos de preparação, começaram a surgir algoritmos que forneciam soluções satisfatórias num tempo de cálculo razoável. Estes algoritmos são denominados heurísticas, do grego *heuriskein* que significa encontrar ou descobrir.

Conforme Lourenço (2001), um algoritmo exato (ou ótimo) em otimização refere-se a um método que fornece uma solução ótima. Um algoritmo heurístico é um método de solução que não garante uma solução ótima, mas em geral, tem um “bom” desempenho em termos de qualidade da solução e convergência. Esta autora menciona que as heurísticas podem ser construtivas (produzindo uma solução simples), de busca local (iniciando de uma ou de um conjunto de soluções e movendo-se iterativamente para outro conjunto de soluções) ou uma

combinação das anteriores (construindo uma ou mais soluções e usando-as como início para a busca local).

O fácil entendimento e a possibilidade de maiores flexibilizações nas características do problema são vantagens das heurísticas em relação às técnicas exatas, conforme Rodrigues (2000).

Apresenta-se a seguir uma classificação das heurísticas de acordo com o modo em que buscam e constroem soluções (Rodrigues, 2000):

- **Métodos construtivos:** Esses métodos constroem uma solução passo a passo, sendo geralmente utilizados para fornecer uma solução inicial para a aplicação de outros tipos de métodos;
- **Métodos de decomposição:** Dividem o problema em subproblemas menores, sendo a saída de um a entrada do seguinte, de modo que, ao resolver todos os subproblemas tem-se a solução do problema original. Podem ser subdivididos em métodos de decomposição (quando os subproblemas são dependentes) e de partição (quando os subproblemas são independentes entre si);
- **Métodos de redução:** Simplificam o problema, identificando alguma característica que presumidamente a solução ótima possui, com isso conseguem, por exemplo, fixar o valor de alguma variável do problema;
- **Manipulação do modelo:** Modificam a estrutura do modelo a fim de se obter um modelo simples de resolver, deduzindo, a partir desta solução, a solução do modelo original. Podem, por exemplo, aumentar ou diminuir o número de restrições, baseando-se no comportamento esperado da solução ótima;
- **Métodos de busca em vizinhanças:** Esses métodos partem de uma solução inicial, e iterativamente através de alterações dessa solução, vão passando para outras de sua vizinhança, em busca de melhores soluções, até que um critério de parada seja satisfeito ou até que não haja mais possibilidades de busca. Um conceito fundamental destes métodos é como passar de uma solução factível para outra. Para isso, define-se $N(s)$ como sendo a vizinhança da solução s , que é o conjunto de soluções para as quais é possível obter uma solução $s' \in N(s)$, com apenas uma operação elementar, denominada movimento sobre s . Em geral, esses métodos buscam entre os elementos da vizinhança algum elemento que tenha um melhor valor do que a solução atual, e

repetem este processo até que não existam melhores soluções no conjunto ou algum critério de parada seja satisfeito.

Rodrigues (2000) cita que um dos grandes inconvenientes dessas técnicas é a existência de diversos ótimos locais em diferentes regiões. Dependendo do modo como a heurística foi construída, a busca pode ficar estagnada, o que acarreta a impossibilidade de atingir diferentes ótimos locais.

De acordo com Noronha (2001), as metaheurísticas ou heurísticas modernas são mega-heurísticas, mais flexíveis, situadas em domínios ainda pouco explorados pela literatura. São heurísticas genéricas que se adaptam facilmente as estruturas paralelas e são direcionadas à otimização global de um problema, podendo conter diferentes procedimentos heurísticos de busca local na solução a cada passo. Em outras palavras, essas mega-heurísticas quando aplicadas a problemas de otimização, tem como um de seus objetivos, gerar procedimentos de buscas em vizinhanças que evitem uma parada prematura em ótimos locais, proporcionando soluções melhores.

E de forma uniforme, tem-se a definição de metaheurística fornecida por Rodrigues (2000): “Metaheurística é um guia para as heurísticas e objetiva direcionar suas buscas permitindo a exploração de diferentes regiões, tentando obter diferentes ótimos locais, através de uma busca eficiente”.

Aplicação de heurísticas e metaheurísticas na área de Planejamento e Programação da Produção

Conforme Lourenço (2001) pode-se encontrar uma vasta quantidade de aplicações de metaheurísticas na área de planejamento e programação da produção. Entretanto, a maior parte das aplicações são direcionadas a problemas específicos (como por exemplo, *job-shop* e *flow-shop*) e pouca atenção é dada para a integração do planejamento da produção da cadeia de abastecimento. As pesquisas recentes mostram que para muitos problemas, a aplicação de algoritmos heurísticos é uma promissora técnica de solução para os problemas de planejamento e programação da produção. Apesar dos esforços da pesquisa acadêmica nesta área, ainda existe uma lacuna na aplicação prática das técnicas desenvolvidas pela academia. Por fim, Lourenço (2001) cita que os problemas de programação da produção já são de difícil solução e a necessidade de se considerar os aspectos de toda a cadeia de suprimento aumenta, consideravelmente, a sua complexidade. Além disso, em muitas cadeias de suprimento, a

capacidade de produção é limitada e, assim, o planejamento e o gerenciamento eficientes da produção e da sua programação são de extrema importância para se obter uma cadeia eficiente.

Os modelos de dimensionamento de lotes e sequenciamento, relacionados diretamente à área de planejamento e programação da produção, têm recebido grande interesse por parte de pesquisadores e, conseqüentemente, pode-se encontrar uma disponibilidade de trabalhos com diferentes enfoques e abordagens de solução. Uma pequena parcela desta literatura é apresentada com o intuito de exemplificar alguns trabalhos desenvolvidos. Em sua grande maioria, o objetivo principal é a obtenção de melhores respostas em um menor tempo computacional e para tanto, diversas abordagens são desenvolvidas e testadas.

Uma revisão dos modelos de dimensionamento de lotes multi-estágio foi apresentada por Gupta (1990).

Harrison e Lewis (1996) também realizaram um levantamento dos trabalhos desenvolvidos na área de dimensionamento de lotes relacionados às situações de múltiplos itens e múltiplos estágios. Em seu resumo, as estruturas estudadas eram não-lineares e lineares com abordagens de solução envolvendo otimização e também heurísticas. Além disso, desenvolveram uma nova heurística para o problema de dimensionamento de lote multi-item e multi-estágio com múltiplas restrições de capacidade para sistemas de montagem em série.

Em um trabalho mais recente, Staggemeier e Clark (2001) sintetizaram as definições dos modelos de dimensionamento de lote e sequenciamento e os respectivos trabalhos desenvolvidos para cada definição com ênfase nos casos de mono-estágio. De acordo com os autores, existem muitos modelos envolvendo diferentes considerações, como por exemplo a presença de uma ou de múltiplas máquinas. Para o último caso, o arranjo dessas máquinas pode ser em paralelo (em um único estágio), em seqüência (multi-estágio) ou uma combinação de ambos. O enfoque pode envolver custos de *set up*, e os tempos de *set up* podem ser fixos ou variáveis por produto ou pela seqüência de produção. Outra consideração refere-se à demanda que pode ser constante ou variável sobre períodos regulares ou variável sobre períodos irregulares. Tem-se ainda as restrições de capacidade e a presença ou não de ordens de produção não realizadas. Em relação às abordagens adotadas, Staggemeier e Clark (2001) constataram a utilização de programação matemática, *simulated annealing*, algoritmos evolucionários (ou evolutivos), busca tabu e heurísticas simples.

O problema de dimensionamento de lote está relacionado com a lógica do MRP para a determinação dos lotes a serem produzidos para cada item da estrutura do produto. O objetivo do problema é determinar o conjunto de tamanhos de lote para cada nível que, de forma conjunta, minimiza o total de custos fixos e de estoques existentes no sistema. De acordo com Afentakis *et al.* (1984), o planejamento do dimensionamento de lotes de produção em um ambiente multi-estágio é um problema fundamental em muitos sistemas de MRP.

O problema de dimensionamento de lote multi-estágio é, freqüentemente, caracterizado por uma rede descrevendo os passos de produção que fornecem um item final, onde um nó, correspondente a um componente ou item, e seus arcos denotam como os componentes são montados (Vickery e Markland, 1986).

Apresenta-se a seguir uma descrição resumida de alguns modelos propostos para o problema de dimensionamento de lote e sequenciamento, entretanto as formulações matemáticas não são mencionadas. Para maiores detalhes, consultar o trabalho de Staggemeier e Clark (2001):

- *Multistage Capacitated Lot-sizing* (MSCLS): modelo direcionado para a determinação de tamanhos de lote de produção em sistemas de MRP multi-estágio e com restrição de capacidade. Tem como proposta minimizar a soma dos custos de produção, *set up* e estoque. É um problema NP-completo, ou seja, não existe uma solução ótima para problemas com um número de variáveis próximo de situações vivenciadas na prática industrial;
- *Capacitated Lot-sizing and Scheduling Problem* (CLSP): modelo para um sistema de um único estágio e multi-produto. Para este modelo, muitos itens podem ser produzidos por período. Considera-se longos períodos e a função objetivo procura minimizar a soma dos custos de *set up* e estoque;
- *Discrete Lot-sizing and Scheduling Problem* (DLSP): para este caso, pelo menos um item pode ser produzido por período, mas considera-se curtos períodos de produção. O sistema trabalha com a capacidade total;
- *Continuous Set-up Lot-sizing and Scheduling Problem* (CSLP): similar ao modelo anterior, mas permite que o sistema produza aquém de sua capacidade total;
- *Proportional Lot-sizing and Scheduling Problem* (PLSP): derivado do modelo anterior, ocorre quando o CSLP não utiliza a capacidade total de um período. Assim,

com esta capacidade remanescente, pode-se planejar um segundo item para um período particular;

- *Proportional Lot-sizing and Scheduling Problem with Set-up Times* (PLSPST): para este modelo, a restrição de capacidade considera o tempo de *set up*;
- *General Lot-sizing and Scheduling Problem* (GLSP): modelo para múltiplos produtos, custos de *set up* para uma única máquina e dependentes da seqüência, curtos períodos de tempo e desconsiderando tempos de *set up* e ordens não cumpridas. Para este modelo duas variações foram mencionadas, uma envolvendo a conservação do estado de *set up* (GLSP-CS) e outra desconsiderando o estado de *set up* (GLSP-LS).

Os trabalhos mencionados são complementares e objetivam resumir parte do que foi aplicado e publicado sobre o problema de dimensionamento de lotes e sequenciamento.

Além destes trabalhos pode-se destacar alguns estudos que ilustram o quão vasta é a produção científica nesta área.

Em ambientes com demanda conhecida, mas variável, a fórmula de lote econômico não garante uma solução que minimiza os custos totais e, devido a esta lacuna, Wagner e Whitin (1959) desenvolveram um algoritmo capaz de fornecer a solução ótima para o problema de dimensionamento de lote econômico de um item (*single stage*), considerando os custos de *set up* e estoque em um ambiente com demanda conhecida, mas variável por período.

Outro trabalho interessante e precursor do termo *multi-echelon*, presente em vários trabalhos posteriores, foi apresentado por Clark e Scarf (1960). Os autores desenvolveram uma formulação matemática para a determinação da quantidade ótima de um item em um modelo multi-instalação (*multi-echelon*), objetivando a minimização dos custos de estoque de cada instalação e da quantidade em trânsito entre as instalações. Os custos de *set up* podem ser considerados apenas para a primeira instalação fornecedora do sistema.

Conforme Blackburn e Millen (1984), duas abordagens básicas para o problema de dimensionamento de lote multi-estágio podem ser encontradas na literatura. A primeira refere-se ao desenvolvimento de algoritmos que fornecem a solução ótima, apesar das penalizações envolvidas, como por exemplo, os custos computacionais. Além disso, ocorre a necessidade de uma função de planejamento centralizada. A segunda abordagem consiste, como na maioria dos sistemas de MRP em uso, de heurísticas que ignoram a interdependência entre estágios do processo e aplicam, seqüencialmente, o método de dimensionamento de lote mono-estágio. Esta abordagem sub-ótima, apesar de computacionalmente simples, pode

incorrer em substanciais penalidades nos custos. Assim, os autores propuseram uma terceira abordagem para o problema, na qual realiza-se uma aplicação seqüencial do algoritmo de dimensionamento de lote mono-estágio com um conjunto de custos modificados para atender a contabilização das interdependências dos estágios. Estes custos modificados são, funcionalmente, similares aos preços de transferência, cuja intenção é alcançar a coordenação das decisões de diferentes estágios do processo sem um planejamento central ditando o sequenciamento da produção. Uma vez que essas modificações podem ser aplicadas para a maioria das heurísticas de dimensionamento de lote mono-estágio, a lógica e a eficiência computacional dos sistemas de MRP atuais são mantidas. Pelos resultados obtidos, a heurística desenvolvida merece destaque.

Uma nova formulação do problema de dimensionamento de lote em sistemas de montagem multi-estágio, considerando a idéia de estoque de escalão, aplicando relaxação Lagrangeana e o algoritmo *Branch and Bound* pode ser verificada no trabalho de Afentakis *et al.* (1984). Um destaque para a aplicação da heurística em estruturas de produto com 15 níveis, resultando em valores com divergência inferior a 1% aos valores ótimos e com tempo computacional também inferior a 1% do tempo necessário para se obter uma solução ótima.

Uma aplicação prática de um modelo de dimensionamento de lote multi-objetivo em uma indústria farmacêutica pode ser encontrado no trabalho de Vickery e Markland (1984). Os autores desenvolveram e implementaram o modelo considerando um sistema em série, múltiplas restrições de capacidade em vários estágios e os tempos de *set up*, através de uma abordagem de programação inteira.

O desenvolvimento dos limites inferiores e superiores para o problema de estoque multi-estágio e multi-período (estocástico) com a produção de soluções de aproximação foi apresentada por Karmarkar (1987).

Roll e Karni (1991) apresentaram o desenvolvimento de uma heurística para o problema de dimensionamento de lote multi-item e multi-estágio com uma restrição de capacidade em um ambiente de planejamento finito, considerando custos de *set up* e de carregamento.

Toklu e Wilson (1992) propuseram uma heurística simples para o problema de dimensionamento de lote multi-nível com restrição de um centro de trabalho que fornece respostas rápidas e de qualidade. A heurística foi aplicada a um produto com estrutura em paralelo (conjunto de estruturas em série que possuem um centro de trabalho em um dos estágios), assumindo-se *lead times* entre estágios iguais a zero, demanda conhecida e

constante para os itens finais, ausência de demanda para itens intermediários, ausência de pedidos não cumpridos, entre outros. A mesma foi comparada a métodos que utilizaram programação inteira com relaxação Lagrangeana e apresentou soluções de razoável qualidade em uma fração de tempo menor.

Os mesmos autores, em um trabalho posterior, aplicaram a heurística desenvolvida com congelamento de períodos de programação em um ambiente com ampliação do horizonte de planejamento (*rolling schedule environment*). Os resultados comparativos podem ser consultados em Toklu e Wilson (1995).

Outra contribuição para a questão da determinação do tamanho de lote de produção para o balanceamento dos custos de *set up* e de estoque em processo em um ambiente de MRP multi-estágio foi realizada por Clark e Armentano (1995). Os autores incrementaram a configuração do problema de dimensionamento de lotes multi-estágio, considerando *lead times* de produção, múltiplos recursos e restrições de capacidade em um ambiente com ampliação do horizonte de planejamento.

Alguns trabalhos se propuseram a avaliar o desempenho de diferentes heurísticas aplicadas a problemas de sequenciamento da produção com restrição de capacidade. No caso de Hartmann e Kolisch (1998), o estudo dos blocos de construção (esquemas de geração de sequenciamento, regras de prioridade, representações de programação, operadores e estratégias de busca) e da forma como esses blocos de construção são combinados nos métodos *X-pass* e nas diferentes metaheurísticas consideradas (*simulated annealing*, algoritmos genéticos e busca tabu) para os problemas de sequenciamento/programação de atividades de projeto com precedência de tarefas e restrições de capacidade resultou na constatação de um melhor desempenho para os trabalhos testados que continham *simulated annealing* e algoritmo genético.

Foram apresentados alguns trabalhos que exemplificam a aplicação de metaheurísticas em problemas de planejamento e programação da produção situados em contextos internos de uma unidade fabril. Em seguida, são apresentadas algumas aplicações que relacionam o uso de metaheurísticas em cadeias de suprimento.

Modelos de SCM

A literatura apresenta definições diferentes para o problema de dimensionamento de lote quando aplicado a mais de um estágio. Os sistemas de estoque em série, multi-estágio, multi-

escalão, sistema integrado de produção e distribuição foram algumas das especificações encontradas. Apesar das diferenças referem-se ao mesmo problema.

Além das diferentes especificações, constatou-se também na literatura pesquisada a utilização de diferentes modelos de uma cadeia de suprimento. Estes modelos variam conforme os objetivos a serem atendidos e o número de elos e características consideradas.

Os modelos utilizados na análise de sistemas de cadeias de suprimento podem ser classificados, segundo Ganapathy *et al.* (2003), em:

- **modelos analíticos:** as variáveis são conhecidas e especificadas. O objetivo é determinar uma solução analítica através de técnicas de programação matemática. Estes modelos fornecem soluções prescritivas sob certas considerações e são limitadas a uma representação estática do sistema;
- **modelos estocásticos:** pelo menos uma variável é desconhecida e uma determinada distribuição estatística é assumida. Também são limitadas a uma representação estática do sistema, apesar de apresentarem comportamentos mais realistas da cadeia de suprimento devido às representações estocásticas consideradas;
- **modelos econômicos:** centram sua atenção na relação comprador-fornecedor da cadeia de suprimento sob uma perspectiva de custos;
- **modelos de simulação:** utilizam representações virtuais para modelar as relações entre os elementos da cadeia de suprimento. Permitem uma representação dinâmica do comportamento do sistema quando da inclusão de novas informações ou cenários;
- **modelos de simulação-otimização:** esta classificação adicional é encontrada nos trabalhos de Hicks (1999), Chwif e Barretto (2002), Fu (2002) e Joines *et al.* (2002). Neste último trabalho, estes modelos são definidos como a combinação de uma sequência de configurações sistêmicas até a eventual obtenção de uma configuração que fornece uma solução ótima ou próxima do ótimo. Conforme Hicks (1999), as técnicas de modelagem de simulação-otimização são utilizadas para ajudar nas decisões estratégicas relacionadas à cadeia de suprimento.

Trabalhos recentes relacionados a SCM

Uma heurística para o problema de dimensionamento de lote para sistemas de estoque em série foi apresentada por Atkins e Sun (1995). Os autores consideraram uma demanda

conhecida e constante e também a possibilidade de ocorrência de pedidos não cumpridos. O método apresentado forneceu, nos piores casos, uma solução heurística com valores equivalentes entre 94 a 98% da solução ótima.

Disney *et al.* (2000) descreve um procedimento de controle de estoque que determina um compromisso entre capacidade, demanda e nível mínimo de estoque com otimização por algoritmos genéticos.

Um modelo de dimensionamento de lote para uma rede de produção/distribuição multi-produto, multi-planta com demandas determinísticas e estacionárias é encontrado em Bramel *et al.* (2000). No modelo são considerados *lead times* desbalanceados (onde os componentes do produto apresentam tempos de produção/transporte diferentes até a chegada no fabricante) e, de acordo com os autores, a heurística pode ser aplicada a qualquer configuração de rede. Em contrapartida, ela perde sua eficiência para redes em série.

Sambasivan e Schmidt (2002) apresentaram um procedimento heurístico para solucionar os problemas de dimensionamento de lote multi-planta, multi-item e multi-período considerando as transferências entre as unidades. Para o maior problema considerado com 4 plantas, 6 períodos e 10 itens obteve-se uma solução heurística média equivalente a 96,4% da solução ótima.

Outro tema pertinente a SCM foi abordado por Hwang (2002) e refere-se a determinação do número de depósitos ou centros de distribuição e das rotas dos veículos sujeitos a níveis de serviço requeridos. O autor desenvolveu um modelo de otimização com base em algoritmos genéticos que foi testado com problemas *benchmark* do tipo caixeiro viajante e mostrou-se potencialmente eficiente. Nesta mesma linha de pesquisa, Syarif *et al.* (2002) apresentaram um modelo de programação inteira mista com algoritmo genético para a determinação da escolha das fábricas e centros de distribuição a serem abertos, além do desenho da rede de distribuição para satisfazer a demanda com um custo mínimo. Os autores relatam que para problemas relativamente pequenos, o método proposto, na maioria das vezes, é bem sucedido na determinação da solução ótima.

Um algoritmo evolucionário (baseado em algoritmo genético) para encontrar a seqüência de produção de cada fornecedor para múltiplos componentes e o tempo de ciclo de expedição sincronizado que minimizam os custos de transporte, *set up* e de estoque através de uma cadeia de suprimento foi apresentado por Vergara *et al.* (2002). Os resultados encontrados e o tempo computacional consumido pelo algoritmo evolutivo foi comparado ao

desempenho computacional de um procedimento de enumeração, que para o domínio do problema estudado, identifica os mínimos globais. O algoritmo evolucionário se mostrou eficiente ao encontrar, se não a solução ótima, pelo menos uma solução próxima ao ótimo para problemas combinatoriais complexos. O tempo computacional consumido pelo algoritmo evolutivo foi muito menor quando comparado ao procedimento de enumeração para as configurações (número de componentes *versus* número de fornecedores) testadas.

Joines *et al.* (2002) apresentaram uma abordagem de algoritmo genético com múltiplos objetivos para otimização de uma cadeia de suprimento.

Lee *et al.* (2002) consideraram um sistema avançado de planejamento e escalonamento para processamento de pedidos de consumidores. Neste caso, uma heurística baseada em algoritmos genéticos foi proposta para resolução do problema de otimização.

Uma abordagem limitada às estratégias de distribuição de produtos (parte do gerenciamento da cadeia de abastecimento) foi apresentada por Ribeiro e Lourenço (2003). Três diferentes estratégias de distribuição foram analisadas e tiveram seu modelo matemático e procedimento heurístico baseados na metaheurística de busca local iterativa. A primeira estratégia é a abordagem clássica de determinação da rota econômica de um veículo, refletindo somente os custos de transporte e objetivando a minimização destes custos. A segunda estratégia é mais voltada ao consumidor e busca determinar rotas mestras que garantam a política de *marketing*, onde cada consumidor é servido sempre pelo mesmo motorista (fortalecimento do princípio de relacionamento com o consumidor). Por último, uma estratégia mista com dois objetivos (minimizar custos e aumentar o nível de serviço percebido pelo consumidor) é desenvolvida. Esta estratégia é um problema de otimização combinatorial e com múltiplos objetivos. A conclusão principal do trabalho é que a última estratégia fornece várias soluções não dominantes, resultado de um balanço entre a otimização dos custos de transporte e do nível de serviço esperado. Assim, cabe ao tomador de decisão escolher a solução mais adequada à necessidade do negócio no momento considerado, uma vez que a minimização dos custos de transporte não é a única questão a ser considerada no gerenciamento da distribuição.

Ding *et al.* (2003) apresentaram uma abordagem de simulação aliada a otimização usando algoritmos genéticos para o problema de seleção de fornecedores em uma cadeia de suprimentos.

Berning *et al.* (2004) apresentaram o estudo da otimização cooperativa de uma cadeia de suprimento considerando aspectos de escalonamentos de produção interdependentes, produção com múltiplos estágios com múltiplos propósitos e cadeia de produção.

Smirnov *et al.* (2004) propuseram uma plataforma multi-agente para resolução do problema de configuração dinâmica de cadeias de suprimento cooperativas e os algoritmos genéticos foram utilizados para determinação de uma solução para o problema de negociação e cooperação eficiente entre as cadeias de suprimento.

Apesar do foco desta proposta de dissertação destacar a utilização de metaheurísticas em problemas relacionados a cadeia de suprimento, mais precisamente ao problema de gestão de estoque multi-estágio, torna-se importante salientar que formulações matemáticas para a solução ótima também são desenvolvidas e aplicadas. Alguns exemplos: a criação de um modelo avaliativo de diferentes níveis de integração da cadeia de suprimento foi proposto por Wei e Krajewski (2000). De acordo com os autores, a principal questão do gerenciamento da cadeia de abastecimento é o controle de custos, especialmente para as cadeias com elevado volume de produtos. Os autores realizaram testes experimentais para os custos envolvidos em cadeias de suprimento com quatro níveis diferentes de integração (relacionado com o conhecimento do planejamento pelos membros da cadeia): o primeiro nível foi denominado de *myopic* e considera apenas a flexibilidade de custos interna do representante principal da cadeia (no caso, a planta de manufatura) quando formula as políticas de compras de material e planejamento da produção; em seguida, tem-se o nível intermediário, onde as capacidades de todos os fornecedores primários (diretamente ligados a planta de manufatura) são consideradas; o próximo nível é denominado conjunto crítico, ou seja, este considera as capacidades de todos os fornecedores críticos (aqueles que apresentam os maiores *lead times* em relação ao representante principal), e por último, tem-se o total, onde todos os membros da cadeia até o representante principal são considerados. Duas importantes conclusões devem ser destacadas: as implicações em relação ao custo total do sistema na integração da cadeia de suprimento seguiu, na maioria dos casos, o padrão: integração total com custos menores do que a do conjunto crítico, este por sua vez menor do que fornecedores primários e este, por último menor do que *myopic*, ou seja, quanto maior a integração da cadeia de abastecimento, menor é o valor dos custos totais envolvidos. Além desta conclusão, os autores obtiveram a confirmação experimental de que o aumento da efetividade da previsão da demanda ajuda a reduzir o custo total do sistema, ou seja, quanto melhor a previsão da demanda, menor será o

custo total do sistema. Schaefer *et al.* (2001), a partir de uma situação real da indústria de aço, se propuseram a desenvolver uma formulação com programação linear inteira e com a decomposição de Benders para o problema de *cutting stock*. O trabalho considera três estágios da cadeia de suprimento: compras/fornecimento, produção e distribuição. Uma vez que o planejamento integrado da produção e da distribuição é uma atividade essencial no gerenciamento da cadeia de suprimento, Lee e Kim (2000) abordaram um procedimento híbrido de solução analítica e simulação para solucionar os problemas de planejamento da produção e da distribuição em cadeias de suprimento. O modelo visa minimizar os custos totais do sistema, ou seja, os custos de: produção, transporte, inventário e perda de venda. A solução analítica abordada é baseada em um procedimento de programação linear e a capacidade do sistema é considerada estocástica. O programa busca encontrar a capacidade ótima que atenda as necessidades do sistema, informada e ajustada pelos resultados do modelo de simulação.

1.2 Objetivos

Esta dissertação apresenta como objetivo geral o estudo, a análise e o projeto de algoritmos genéticos e evolução diferencial para uma cadeia de suprimento simplificada. Como objetivos secundários/específicos, tem-se:

- introduzir a técnica de evolução diferencial em práticas de otimização da cadeia de suprimento;
- testar as diferentes configurações de parâmetros de trabalho para o algoritmo genético desenvolvido;
- testar as diferentes configurações de parâmetros de trabalho para a evolução diferencial;
- efetuar um estudo comparativo dos algoritmos evolucionários empregados em relação à qualidade da resposta, análise de convergência e tempo computacional consumido.

1.3 Descrição da Proposta

O estudo de caso avaliado nesta dissertação é o proposto por Mak e Wong (1995), onde o equacionamento da cadeia de suprimento é concebido na forma de um problema de otimização mista inteira usando um modelo analítico e determinístico de otimização mono-objetivo.

O problema de otimização da cadeia de abastecimento pertence à classe de problemas de dimensionamento de lotes em sistemas multiestágios com restrições de capacidade e estes são considerados problemas do tipo NP árdios (problemas que possuem ordem de complexidade exponencial), segundo Clark e Armentano (1995).

Os algoritmos evolucionários aplicados ao modelo são: algoritmos genéticos e evolução diferencial.

O uso da metaheurística dos algoritmos genéticos, estes parte da inteligência artificial, é justificado pelas suas aplicações bem sucedidas na solução de problemas NP-completos e NP-árdios como citado por Ochi (1994) e Hartmann e Kolisch (1998). Os algoritmos genéticos monopolizam quase todas as aplicações de algoritmos evolucionários apresentados na literatura para otimização de cadeias de suprimento e, assim, são um apropriado referencial comparativo para se medir o desempenho da evolução diferencial.

A escolha da evolução diferencial para otimizações numéricas, conforme Cheng e Hwang (2001) é baseada nas seguintes características:

- é um algoritmo de busca estocástica com mecanismos de seleção natural;
- apresenta menor tendência de se concentrar em mínimos locais, pois a busca pelo ótimo global é feita através da manipulação de uma população de soluções ou, em outras palavras, por uma busca simultânea em diferentes áreas do espaço de soluções;
- é muito eficiente para problemas de otimização de funções objetivo que não requerem informações relativas à derivadas;
- permite que os parâmetros de entrada/saída sejam representados como ponto flutuante sem nenhum esforço computacional adicional;
- não necessita manter um tamanho grande de população.

1.4 Contribuição

A contribuição desta dissertação é apresentar um estudo comparativo de algoritmos evolucionários (algoritmos genéticos e evolução diferencial) para a otimização de uma cadeia de suprimento.

1.5 Organização da Dissertação

A presente dissertação é dividida da seguinte forma: uma introdução contendo a revisão bibliográfica, os objetivos do trabalho, a descrição da proposta e a contribuição oferecida. No capítulo 2, a descrição do problema é apresentada, detalhando o modelo de cadeia de suprimento em estudo, a formalização matemática de um problema de otimização, alguns fundamentos dos algoritmos evolucionários e a modelagem matemática desenvolvida. No capítulo 3 são introduzidas as metodologias de resolução, onde as técnicas de algoritmos genéticos e evolução diferencial são detalhadas. No capítulo 4 são evidenciados os resultados obtidos na análise de alguns cenários construídos para testar os algoritmos desenvolvidos. No capítulo 5 são apresentadas as conclusões, bem como algumas propostas para a continuidade desta pesquisa.

Capítulo 2

Descrição do problema

A cadeia de suprimento analisada nesta dissertação foi baseada no modelo proposto por Mak e Wong (1995). O diagrama esquemático da cadeia de suprimento analisada é apresentado na Figura 2.1. Neste esquema não são considerados os estágios que incluem os varejistas e os clientes (Chopra e Meindl, 2003).

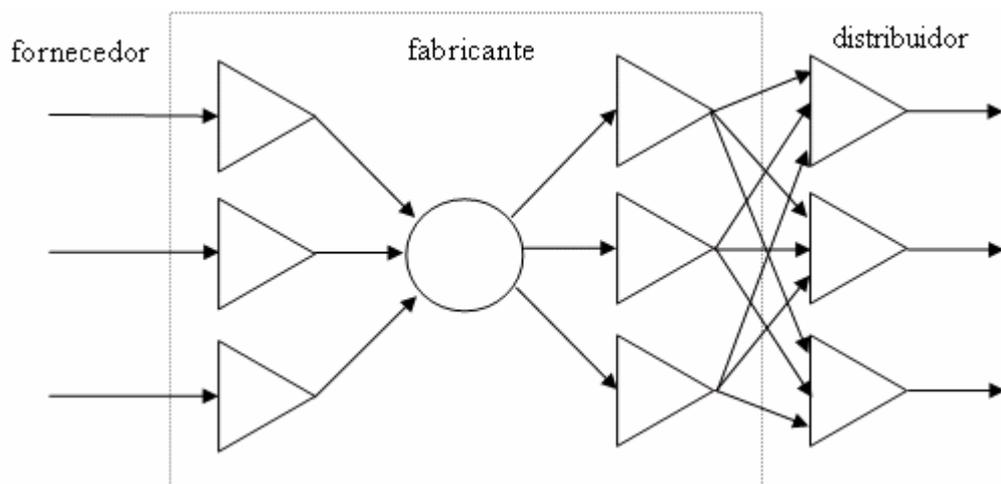


Figura 2.1. Diagrama da cadeia de suprimento integrando os sistemas de produção, estoque e distribuição.

Este diagrama consiste de três setores dispostos de forma serial e abrange os fornecedores, fabricante (e seus armazéns) e revendedores. 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.

Para o modelo apresentado, busca-se através 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, deseja-se determinar os níveis ótimos de estoque e das quantidades de produção e de transporte que permitirão atender as demandas ao menor custo possível. Esta otimização é realizada, através do

desenvolvimento e aplicação de metaheurísticas baseadas em algoritmos genéticos e evolução diferencial.

2.1 Formalização matemática de um problema de otimização

De acordo com Goldberg e Luna (2000), um problema de otimização contínua pode ser formalizado matematicamente da seguinte forma:

Minimizar $f(\mathbf{x})$

sujeito a:

$$h_i(\mathbf{x}) = 0, \quad i = 1, \dots, m_h \quad (2.1)$$

$$g_j(\mathbf{x}) \leq 0, \quad j = 1, \dots, m_g \quad (2.2)$$

Em que $f: \mathfrak{R}^n \rightarrow \mathfrak{R}$, $h: \mathfrak{R}^n \rightarrow \mathfrak{R}$, $g: \mathfrak{R}^n \rightarrow \mathfrak{R}$ são funções contínuas, geralmente diferenciáveis em problemas tratáveis de grande porte. Dado um conjunto finito $E = \{1, 2, 3, \dots, n\}$ e uma coleção de subconjuntos F de E expresso como:

$$\phi \neq F \subseteq 2^{|E|} \quad (2.3)$$

e uma função objetivo:

$$C: F \rightarrow \mathfrak{R} \quad (2.4)$$

um problema de otimização discreta, pode ser entendido como o desejo de obter um conjunto $S^* \in F$ satisfazendo:

$$C(S^*) \geq C(S), \quad \forall S \in F \text{ (problema de maximização)} \quad (2.5)$$

$$C(S^*) \leq C(S), \quad \forall S \in F \text{ (problema de minimização)} \quad (2.6)$$

e sujeito a uma série de restrições.

S é também denominada uma configuração do problema. S^* é chamada a melhor dentre todas as configurações segundo o critério de otimização $C(S)$; F é o espaço das configurações; C é a função objetivo.

De acordo com Bäck e Hammel (1997), os problemas de otimização estão presentes em diversos projetos técnicos, econômicos e científicos envolvendo a minimização de custo, tempo e riscos ou a maximização da qualidade, lucratividade e eficiência.

2.2 Algumas formulações e terminologias dos algoritmos evolucionários em problemas de otimização

Apresenta-se a seguir algumas definições e terminologias dos algoritmos evolucionários (AEs) em problemas de otimização, conforme Coelho (2000).

2.2.1 Espaço de busca

Um problema de busca é caracterizado por um espaço de busca, S — o conjunto de objetos sobre os quais a busca é conduzida — e uma função objetivo, ou seja, o mapeamento de S para o espaço de valores da função objetivo, R , isto é

$$f: S \rightarrow R \quad (2.7)$$

Embora as situações usuais apareçam quando $R = \mathfrak{R}$ (o conjunto dos números reais) e a meta é a minimização ou maximização de f . Contudo, R poderia ser um vetor dos valores das funções objetivo, isto em problemas de otimização com múltiplos objetivos. Observa-se que o conjunto de todos os mapeamentos de S em R são denotados por R^S , assim $f \in R^S$.

Em outras palavras, as aplicações dos AEs, em tarefas de otimização (sem restrições) de parâmetros, requerem que o problema de minimização seja estabelecido por uma dada função $f(x)$ e um conjunto $D \in \mathfrak{R}^{np}$, encontrando um x^* tal que:

$$f_{np}(x^*) = \inf_{x \in D} f_{np}(x) \quad (2.8)$$

onde np é o número de parâmetros do problema e $x = (x_1, x_2, \dots, x_{np})^T$ é um vetor. Para problemas de maximização usualmente substitui-se f por $-f$. Algumas mudanças podem ser

realizadas na função objetivo para adequar-se ao tratamento de restrições ou à inclusão de termos de punitivos para que a eliminação de soluções não-factíveis.

2.2.2 Representação

A seleção de uma representação apropriada é essencial para a busca. A representação de S é um conjunto C (o espaço de representação ou espaço dos cromossomos) de tamanho pelo menos igual a S , junto com uma função g que mapeia C em S , tal que

$$g: C \rightarrow S \quad (2.9)$$

Assim, os valores obtidos para a função objetivo são associados com os pontos no espaço de representação C , através da composição de f com g ,

$$f \circ g: C \rightarrow R \quad (2.10)$$

que é regida por

$$f \circ g(x) = \Delta f(g(x)) \quad (2.11)$$

As relações entre C , S e R são apresentadas na figura 2.2 (Coelho, 2000).

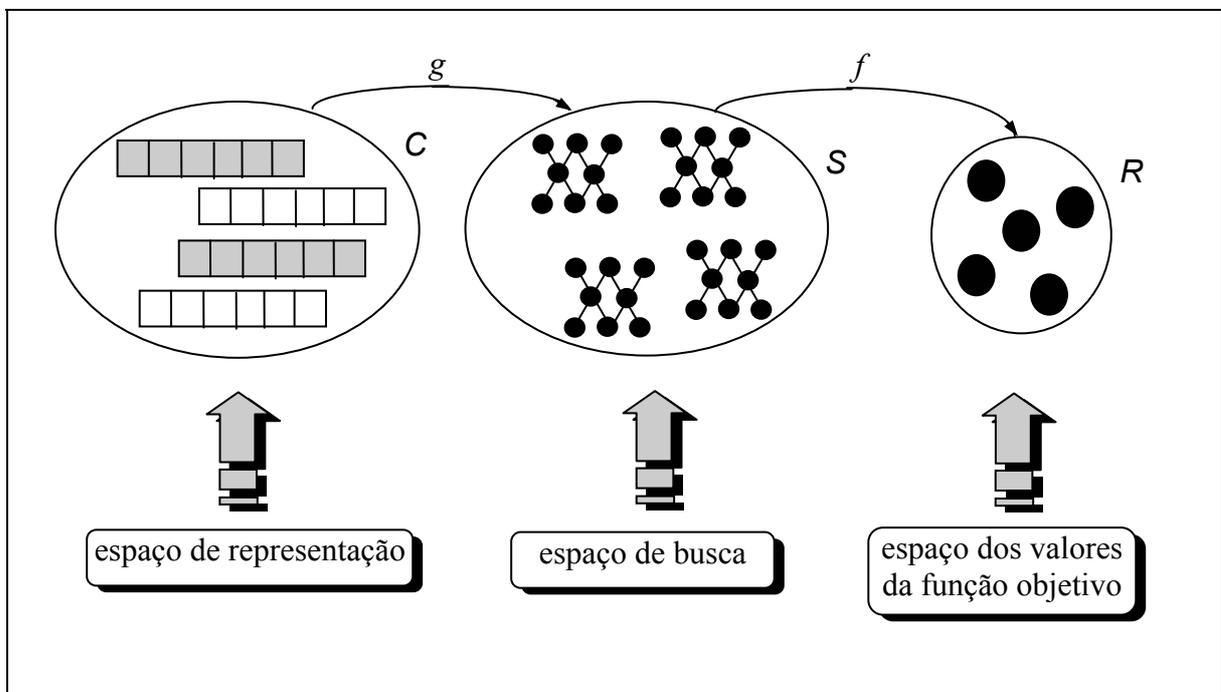


Figura 2.2. Relações entre C , S e R .

2.3 Modelagem matemática do problema

O modelo matemático que descreve tal sistema pode ser concebido de forma simplificada para fins de comparação entre algoritmos de otimização. Neste caso, o modelo pode ser governado por uma função objetivo a ser otimizada e restrições a serem satisfeitas (Mak e Wong, 1995), ou seja,

$$\text{minimizar } \text{aval}(x) = C_{arm} + C_{fabr} + C_{transp} + C_{falta} \quad (2.12)$$

tal que

$$C_{arm} = \sum_{r=1}^R \sum_{p=1}^P \sum_{t=2}^{T+1} H_{rp}^R K_{rpt} + \sum_{p=1}^P \sum_{t=2}^{T+1} H_p^P J_{pt} + \sum_{m=1}^M \sum_{t=2}^{T+1} H_m^M I_{mt} \quad (2.13)$$

$$C_{fabr} = \sum_{p=1}^P \sum_{t=1}^T C_p^P \left[J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] \quad (2.14)$$

$$C_{transp} = \sum_{r=1}^R \sum_{p=1}^P \sum_{t=1}^T C_{rp}^D Z_{rpt} + \sum_{m=1}^M \sum_{t=1}^T C_m^M \left\{ I_{m,t+1} + \sum_{p=1}^P \theta_{mp} \left[J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] - I_{mt} \right\} \quad (2.15)$$

$$C_{falta} = \sum_{r=1}^R \sum_{p=1}^P \sum_{t=1}^T C_{rp}^S \left[D_{rpt} - (K_{rpt} + Z_{rpt} - K_{rp,t+1}) \right] \quad (2.16)$$

sujeito a

$$K_{rpt} + Z_{rpt} - K_{rp,t+1} \geq 0 \quad (2.17)$$

$$K_{rpt} + Z_{rpt} - K_{rp,t+1} \leq D_{rpt} \quad (2.18)$$

$$J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \geq 0 \quad (2.19)$$

$$\sum_{p=1}^P B_p \left[J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] \leq \beta_t \quad (2.20)$$

$$\sum_{r=1}^R \sum_{p=1}^P W_p^P Z_{rpt} \leq \omega_t^P \quad (2.21)$$

$$I_{m,t+1} + \sum_{p=1}^P \theta_{mp} \left[J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] - I_{mt} \geq 0 \quad (2.22)$$

$$\sum_{m=1}^M W_m^M \left\{ I_{m,t+1} + \sum_{p=1}^P \theta_{mp} \left[J_{p,t+1} + \sum_{r=1}^R Z_{rpt} - J_{pt} \right] - I_{mt} \right\} \leq \omega_t^M \quad (2.23)$$

onde

B_p : é o tempo de processamento de manufatura de cada unidade do p -ésimo produto;

β_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;

ω_t^M : é o limite de carregamento dos materiais transportados do fornecedor para o fabricante no t -ésimo período;

ω_t^P : é o limite de carregamento dos produtos transportados do fabricante para o distribuidor no t -ésimo período;

Z_{rpt}^M : é a quantidade enviada do p -ésimo produto do fabricante para o r -ésimo distribuidor no t -ésimo período;

θ_{mp} : é a quantidade do m -ésimo material necessário para fabricar cada unidade de quantidade do p -ésimo produto.

A função objetivo (2.12) minimiza a soma dos custos de armazenagem, fabricação, transporte e falta de produto. As equações (2.13), (2.14), (2.15) e (2.16) indicam a composição dos custos de armazenagem, fabricação, transporte e falta de produto respectivamente. A inequação (2.17) impõe a positividade das vendas. A inequação (2.18) limita esta venda até o valor da demanda do produto para cada período e distribuidor. A inequação (2.19) impõe a positividade da produção. A inequação (2.20) limita a capacidade produtiva a um valor máximo estipulado. A inequação (2.21) limita o peso total da quantidade

de produtos a serem transportados. A inequação (2.22) impõe a positividade da quantidade de matéria-prima enviada entre fornecedores e fabricante. A inequação (2.23) limita o peso total da matéria-prima a ser transportada.

As variáveis de decisão que compõem o vetor x a ser otimizado pelos algoritmos evolutivos são as variáveis inteiras 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} ($r = 1, 2, \dots, R; p = 1, 2, 3, \dots, P; t = 2, 3, \dots, T$) e Z_{rpt} ($r = 1, 2, \dots, R; p = 1, 2, 3, \dots, P; t = 2, 3, \dots, T$), onde $I_{mt}, J_{pt}, K_{rpt}, Z_{rpt} \geq 0$. A abordagem adotada para este estudo de caso foi formulada como um problema de otimização inteira visando uma análise de desempenho de algoritmos evolucionários (algoritmos genéticos e evolução diferencial) para minimização da função objetivo apresentada na equação (2.12).

2.4 Conclusão do capítulo

O modelo de cadeia de suprimento simplificada, objeto de estudo desta dissertação, sua modelagem matemática, assim como, a função objetivo a ser minimizada e as restrições a serem obedecidas são apresentados neste capítulo.

O objetivo da otimização deste modelo é minimizar a função objetivo que engloba os custos de armazenagem, fabricação, transporte e falta (perda de venda por falta de um produto) através da determinação dos níveis ótimos de estoque e das quantidades de produção e de transporte para atender as demandas apresentadas.

No próximo capítulo, apresenta-se com riqueza de detalhes as duas técnicas de otimização aplicadas ao modelo mencionado: algoritmos genéticos e evolução diferencial.

Capítulo 3

Metodologia de resolução

Segundo Joines *et al.* (2002), os problemas relacionados ao gerenciamento da cadeia de suprimento são freqüentemente complexos e dependentes das interações entre as entidades pertencentes à cadeia, do tamanho da cadeia, dos *lead times* de produção e expedição, das características individuais de cada entidade, da natureza estocástica da demanda, entre outros. Devido a essas complexidades, os poucos modelos analíticos existentes são direcionados a problemas simplificados e considerados de difícil solução pelos métodos de busca tradicionais (programação linear, diferenciação ou mesmo métodos baseados em gradiente local). Esta dificuldade reside no fato de que a maioria dos modelos apresenta uma natureza discreta, não-linear e/ou multivariável. Assim, heurísticas são necessárias para a determinação de “boas” soluções.

Neste capítulo são apresentadas as duas técnicas de computação evolucionária (ou evolutiva) aplicadas ao modelo de cadeia de suprimento simplificada. Preliminarmente é apresentada uma descrição dos fundamentos da computação evolucionária que engloba as técnicas aplicadas para a solução do estudo de caso abordado nesta dissertação.

3.1 Computação evolucionária (ou evolutiva)

Coelho (2000) cita Segundo Coelho (2000), as origens da Computação Evolucionária (CE) podem ser traçadas por trabalhos pioneiros de R.M. Friedberg, H.J. Bremermann, W. Spendley, F.E. Satterthwaite, entre outros, nos anos 50. Após esta fase, este campo do conhecimento permaneceu relativamente desconhecido ou inexplorado pela maioria da comunidade científica, por mais de três décadas. Este fato, deve-se, principalmente, à falta de plataformas computacionais poderosas naquela época, da formalização e caracterização deficiente de cada metodologia evolucionária nos primeiros estudos nesta área. também que a

maioria das abordagens correntes dos algoritmos evolucionários – metodologias da área de CE – descende dos princípios de diferentes metodologias, principalmente:

- (i) *algoritmos genéticos*, desenvolvidos principalmente por A. S. Fraser, H. J. Bremermann, J. Reed e J. H. Holland, entre a década de 50 e 70, com refinamentos posteriores por D. Whitley, D. E. Goldberg, K. De Jong e J. Grefenstette;
- (ii) *programação evolucionária*, desenvolvida por L. J. Fogel, A. J. Owens e M. J. Walsh, nos Estados Unidos, na década de 60, refinada recentemente por D. B. Fogel, G. H. Burgin, P. J. Angeline, V. W. Porto e W. Atmar;
- (iii) *estratégias evolutivas*, desenvolvidas na Alemanha, por I. Rechenberg e H. P. Schwefel, na década de 60, com aprimoramentos posteriores de G. Rudolph, H. G. Beyer, F. Kursawe e T. Bäck;
- (iv) *programação genética*, abordada pelos pesquisadores J. R. Koza, J. P. Rice, K. E. Kinnear e P. J. Angeline;

e adicionalmente a estas metodologias, tem-se como nova contribuição à área de CE:

- (v) *evolução diferencial*, desenvolvida por R. Storn e K. Price em 1995.

De acordo com Dimopoulos e Zalzala (2000), uma grande quantidade de problemas de otimização da produção (sequenciamento e programação - *job shop* e *flow shop problems*, design, manufatura celular e balanceamento de linhas de montagem) tem sido abordada pela CE. Os autores classificam os métodos de CE como meta-heurísticas capazes de varrer grandes regiões do espaço de solução desconsiderando ótimos locais.

Segundo Cruz *et al.* (2002), os métodos de otimização global ou algoritmos de otimização multimodal podem ser divididos em dois grupos gerais: determinístico e estocástico. Apesar de que os AEs (algoritmos genéticos, estratégias evolutivas, programação evolutiva) poderem ser considerados como métodos de busca global heurístico-estocásticos, eles tem recebido atenção limitada da comunidade de pesquisa de otimização global. Uma possível explicação é o entendimento de que todos os AEs não são suficientemente eficientes para solucionar problemas de otimização global contínua. Entretanto, recentemente, novos algoritmos (tais como: evolução diferencial, algoritmos culturais e algoritmos quânticos), inspirados na evolução, tem sido desenvolvidos em uma linha diferente da estrutura de um algoritmo genético simples.

Conforme Dimopoulos e Zalzala (2000), a CE tem sido criticada por utilizar problemas muito mais simples do que os casos reais vivenciados na manufatura. Entretanto, citam que tem ocorrido uma reação acadêmica, pois problemas reais estão sendo considerados nas pesquisas recentemente.

De acordo com Bäck e Schwefel (1997) mesmo que não se conheça a solução final de um problema de otimização global, a identificação de uma melhoria na melhor solução atual pela otimização já é, freqüentemente, um grande avanço na resolução de problemas práticos e em muitos casos, os AEs fornecem um método eficiente e eficaz para determiná-la.

Finalmente, destaca-se mais um comentário do trabalho de Dimopoulos e Zalzala (2000) que ressalta que os AEs tornam-se robustos, ou seja, com um melhor desempenho na busca da solução ótima, quando são mesclados com técnicas de busca local, tais como: *simulated annealing*, busca tabu e métodos baseados em informação do gradiente.

A seguir apresenta-se os fundamentos dos dois AEs abordados nesta dissertação: algoritmos genéticos e evolução diferencial.

3.2 Algoritmos genéticos

Os algoritmos genéticos (AGs) são abordagens de busca probabilística baseados nos processos evolucionários. Assim, são inspirados pelo mecanismo de seleção natural, um processo biológico no qual os indivíduos mais fortes possuem maior chance de sobreviver em um ambiente competitivo. Os indivíduos selecionados produzem uma nova geração e, conseqüentemente, as características hereditárias da espécie são repassadas para essa nova geração, visando-se a preservação das qualidades adquiridas.

Desta maneira, segundo Rodrigues (2000) estabelece-se uma relação analógica entre os componentes de um indivíduo na população e a representação das características de um problema de otimização combinatória. Cada indivíduo na população, denominado cromossomo (no AG canônico ou binário), representa uma solução do problema codificado. Os valores que compõem um indivíduo são denominados genes. Estes genes podem sofrer alterações de uma geração para outra, através da aplicação de operadores de seleção, cruzamento (*crossover*) e mutação.

Ainda, conforme Rodrigues (2000), a principal diferença entre os algoritmos genéticos e as meta-heurísticas em geral, é que estas geram uma única solução em cada iteração, enquanto os algoritmos genéticos geram uma população de soluções. Uma outra característica

importante é que os algoritmos genéticos não utilizam necessariamente informações a respeito do problema durante o processo evolutivo, ou seja, uma vez codificada a solução através de um indivíduo, o processo de melhoria dessa solução é um problema independente do problema original. De acordo com Goldberg (1989), as diferenças dos AGs em relação aos processos de otimização e busca podem ser resumidos pelas seguintes características dos AGs:

1. utilizam um conjunto de parâmetros codificados ao invés dos parâmetros em si;
2. trabalham com uma população de pontos e não com um único ponto;
3. utilizam a informação da função objetivo (função de otimização) sendo a procura baseada em transições aleatórias, feita por amostragem e guiada por soluções parciais;
4. aplicam operadores probabilísticos e não regras determinísticas.

Foram primeiramente propostos por John Holland em 1975, e identificados na literatura como AGs simples, mas estão sendo estudados com maior frequência nos últimos anos.

A lista de tópicos para os quais esta técnica de otimização tem sido aplicada é vasta. Ela inclui programação/planejamento da produção (*scheduling*), o problema do caixeiro viajante, seleção de carteira de ações, agricultura, engenharia de controle, síntese genética, tecnologia VLSI, planejamento estratégico, robótica, entre outros. As referências Goldberg (1989), Ochi (1994), Srinivas e Patnaik (1994), Michalewicz (1996), Man *et al.* (1996), Soares (1997), Jones e Kemp (2001) relatam as aplicações mencionadas. Em síntese, os algoritmos genéticos são aplicações promissoras em problemas com um número elevado de variáveis, não lineares e com natureza discreta. Apresentam, também, uma boa capacidade de solução de problemas com múltiplos objetivos.

Uma vez que se baseiam em uma abordagem probabilística, e, apesar de não garantirem o ponto ótimo global, tendem a alcançá-lo desviando-se das soluções ótimas locais. Além disso, devido a natureza estocástica, o seu desempenho deve ser calculado considerando-se um número médio de simulações ao invés de uma única rodada.

Noronha (2001) menciona que os algoritmos genéticos são uma versão computacional do que se passa na natureza. Um problema a ser resolvido nesta abordagem passa pela identificação de um conjunto de elementos e pela definição de um conjunto de valores a saber:

- geração: uma população num dado instante do tempo;
- população: conjunto de indivíduos;
- indivíduo: definido pelos seus cromossomos (tipicamente um);
- cromossomo: conjunto de genes;
- gene: codificação de um traço podendo tomar diferentes valores;
- função de adaptabilidade (*fitness*): para medir a qualidade do indivíduo;
- cruzamento: troca de material genético entre 2 indivíduos;
- mutação: inserção de material genético novo em indivíduos.

Para seu funcionamento lógico, uma população inicial é gerada contendo um número pré-definido de indivíduos (ou soluções), cada um representado por uma seqüência (*string*) genética (incorporando a informação da variável). Cada indivíduo possui uma medida de aptidão (*fitness*) associada, tipicamente representando um valor objetivo. O conceito de que os indivíduos com melhores aptidões possibilitarão o aparecimento de novas gerações com melhor *fitness* é implementado para possibilitar a reprodução da nova população. A cada geração, indivíduos são escolhidos para reprodução (operador de seleção) e operadores apropriados de *crossover* e de mutação são inseridos para modificar um indivíduo, objetivando-se o desenvolvimento de uma nova geração. Com esta sucessão de atividades, o algoritmo genético, de um lado, identifica os indivíduos com melhor aptidão, transferindo esta característica para as gerações posteriores e, de outro, descarta, progressivamente, os indivíduos com menor valor de aptidão. Este procedimento iterativo continua até que um critério de parada é alcançado. Dentre eles: um valor ótimo (previamente conhecido) ou uma solução aceitável é obtida; um número máximo de gerações é atingido ou ocorre um número conhecido de gerações sem melhora da aptidão.

A Figura 3.1 representa o fluxograma de um AG.

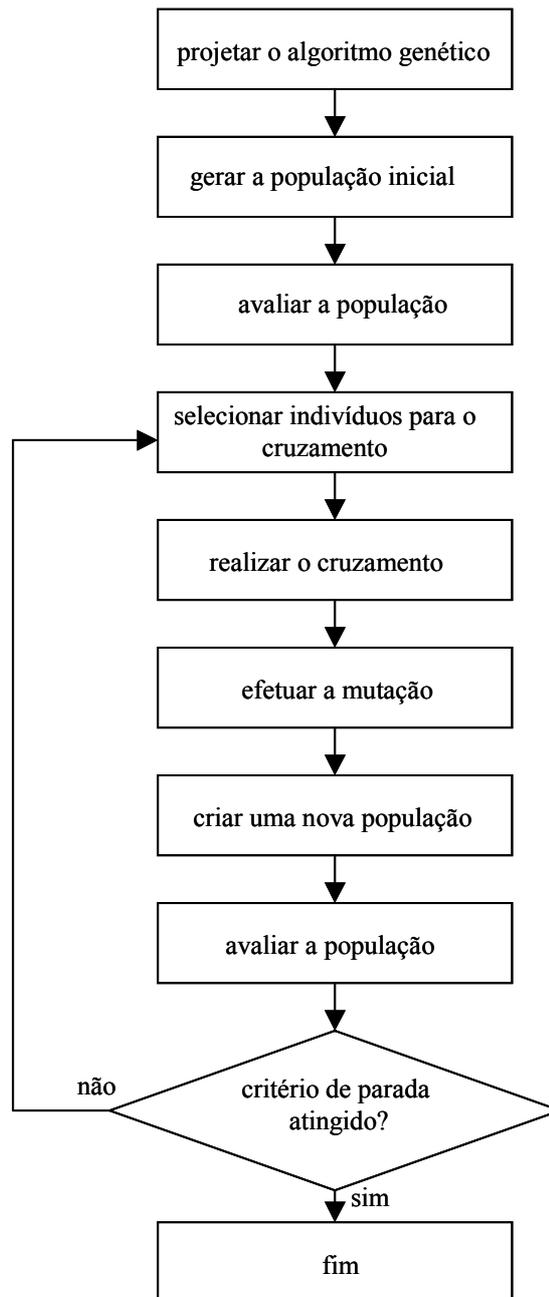


Figura 3.1 Fluxograma de um AG.

3.2.1 Componentes de um algoritmo genético

Um AG consiste basicamente dos seguintes componentes:

- Uma representação genética das soluções do problema;
- A definição da função de aptidão (avaliação ou *fitness*);
- A determinação da população inicial;

- A definição do operador de seleção dos indivíduos;
- A definição dos operadores genéticos (cruzamento e mutação) para a reprodução de novos indivíduos;
- A definição de parâmetros tais como: tamanho da população, critérios de parada do algoritmo, método de seleção, taxa de mutação, entre outros.

Representação da solução

Durante a implementação de um algoritmo genético uma das primeiras atividades a serem definidas refere-se a representação das características de uma solução através de um indivíduo (cromossomo).

Normalmente, uma solução de um problema está associada a um cromossomo p representado por um vetor com m posições, tal que: $p = (x_1, x_2, \dots, x_m)$. Cada componente x_i representa um gene, ou em outras palavras, uma variável da solução.

Os tipos de representação mais conhecidos para um cromossomo são: a representação binária (0 – 1), a de ponto flutuante e a representação por inteiros.

A representação binária é a clássica e tem sido utilizada desde o trabalho precursor de Holland com seu AG simples. A representação de ponto flutuante foi introduzida, especialmente, para problemas com parâmetros reais (Man *et al.* 1996) e a por inteiros pode ser mais adequada para problemas que envolvam números inteiros, como análise combinatória, arranjo e permutação (Soares, 1997).

Destaca-se o comentário de Michalewicz (1996) de que a representação de ponto flutuante apresenta maior precisão e capacidade de representação de domínios de um problema. Experimentos indicam que a sua utilização possibilita maior: velocidade de processamento, consistência dos resultados entre rodadas e precisão quando comparada à representação binária.

Definida a representação torna-se necessário caracterizar a solução de acordo com suas qualidades, ou seja, quantificar sua importância para o problema. Este processo é feito utilizando-se uma medida de aptidão.

Função de avaliação (ou *fitness*)

A função objetivo ou a função a ser otimizada fornece o mecanismo para a avaliação de cada *string* ou indivíduo. Uma vez que os valores das *strings* variam conforme o problema

estudado, e para se manter uma uniformidade sobre o domínio dos problemas considerados, utiliza-se a função de avaliação para adequar a função objetivo a um intervalo de 0 a 1. O valor ajustado da função objetivo é a medida de avaliação do *string*, o qual é utilizado pelo mecanismo de seleção para avaliar os *strings* da população.

A função de avaliação deve ser capaz de discriminar os indivíduos bons dos ruins, e além disso, esta diferenciação deve ser significativa; caso contrário, haverá um elevado consumo de tempo computacional.

As restrições são difíceis de incorporar em AGs e, geralmente, a responsabilidade pelo gerenciamento e quantificação das possíveis soluções não factíveis é deixada para a função de avaliação. Mardle e Pascoe (1999) esclarecem que as restrições impactam mais em problemas que apresentam um conjunto pequeno de soluções factíveis do que em um problema com um conjunto grande de soluções factíveis. A função de avaliação deve, geralmente, determinar o nível de não factibilidade e otimizabilidade como uma aptidão estatística. Se soluções factíveis são facilmente determinadas, então a aptidão é facilmente descrita.

Determinação da população inicial

A população inicial é gerada, normalmente, através de procedimentos de geração de números aleatórios com distribuição uniforme, podendo-se utilizar também, heurísticas com esta finalidade.

O tamanho da população influencia o desempenho do algoritmo. Uma população pequena pode reduzir o espaço de busca, diminuindo as possibilidades de se atingir o ótimo global. No outro extremo, as populações grandes acarretam maior consumo de tempo computacional. Este item é abordado novamente no tópico de parâmetros de desempenho de um AG.

Seleção dos indivíduos

O processo de avaliação mede a aptidão de cada solução individual na população e relaciona a ela, um valor conforme um critério de otimização definido. Normalmente para ambientes não lineares essa medida reflete o valor objetivo do modelo proposto. Em uma aplicação prática de AG, uma população de cromossomos é considerada e iniciada. O tamanho da população varia de um problema para outro, apesar da existência de algumas regras.

O primeiro operador a ser aplicado é a **seleção** que, de forma probabilística, busca escolher os indivíduos da população atual para o desenvolvimento da próxima geração. Vários métodos para esta escolha têm sido desenvolvidos, porém todos seguem a idéia básica de que a melhor aptidão tem a maior chance de sobrevivência. Destaca-se a observação de Soares (1997) de que não é uma boa característica favorecer sempre a seleção do melhor, muito menos uma escolha aleatória.

Um dos métodos de se processar a seleção é o **método da roleta** (*roulette wheel*), no qual cada *string* da população tem seu valor de aptidão representado de forma proporcional em relação ao valor total das aptidões encontradas. Em seguida, a roleta, devidamente dividida, é girada e seleciona-se os indivíduos através deste sorteio. Logicamente, os indivíduos com maior participação na roleta apresentam maiores chances de serem selecionados. A cada rodada da roleta, um novo subconjunto é formado.

Segundo Soares (1997) além do método da roleta que possibilita a ocorrência de uma convergência prematura, outros métodos são encontrados na literatura, entre os quais: torneio, *deterministic sampling*, *stochastic remainder sampling* e *stochastic universal sampling*. Goldberg (1989) cita também a tentativa de redução dos erros estocásticos fornecidos pelo método da roleta com a utilização de métodos alternativos, como os citados anteriormente.

Copiar *strings* conforme sua aptidão significa que *strings* com valores maiores tem uma probabilidade maior de contribuir com um ou mais descendentes na próxima geração.

Operador genético de cruzamento (*crossover*)

A operação de **cruzamento** (representação binária) ou recombinação (representação por ponto flutuante ou real) é o processo seguinte que, a partir de dois indivíduos selecionados e de um (ou mais) ponto de cruzamento, origina dois novos indivíduos. Uma reprodução simples pode ser efetuada e como resultado, um indivíduo é gerado na nova geração.

De acordo com Rodrigues (2000), o cruzamento é um procedimento no qual os indivíduos recombina seu material genético para gerar novos indivíduos, provocando assim, a convergência da população ao longo das gerações.

Os seguintes tipos de cruzamento são encontrados na literatura:

- Cruzamento com um ponto de corte: escolhe-se aleatoriamente um ponto de cruzamento (ou seja, uma posição da seqüência que será dividida) de modo que o

material além deste ponto seja trocado pelos pais. Assim, considerando os pais $p_1 = 100111$ e $p_2 = 011001$ e o ponto 3 para cruzamento, são gerados os filhos $f_1 = 100001$ e $f_2 = 011111$;

- Cruzamento com 2 pontos de corte: similar ao cruzamento com um ponto, as posições para corte e troca são escolhidas aleatoriamente, efetuando-se a troca do material genético entre estes pontos. Assim, para os pais p_1 e p_2 já descritos e para os pontos 2 e 4, são gerados os filhos $f_1 = 101011$ e $f_2 = 010101$;
- Cruzamento com n pontos: idéia semelhante às anteriores. Destaque para a variação do ponto de corte, conforme o número de pontos escolhidos. Se algum ponto de corte foi sorteado mais de uma vez, não se procura por outro;
- Cruzamento uniforme: seguindo cada *bit* do primeiro indivíduo, verifica-se se ocorreu um evento com probabilidade de 50%. Se positivo, ali será um ponto de corte, caso contrário, repete-se o procedimento para o próximo *bit*.
- Cruzamento por variável: o cruzamento terá um ponto de corte por variável. Desta maneira, sendo consideradas 3 variáveis tem-se 3 pontos de corte;
- Cruzamento entre vários indivíduos: seleciona-se o indivíduo base e depois, para cada variável, escolhe-se aleatoriamente um parceiro e um ponto de corte.

Além dos tipos de cruzamento mencionados, cita-se também os operadores desenvolvidos para problemas de ordenação, como arranjos e permutações. Para estes problemas a repetição de uma variável no mesmo indivíduo deve ser evitada. Um exemplo de problema clássico onde o cuidado enfatizado deve ser observado é o problema do caixeiro viajante. Para este problema objetiva-se fornecer a ordem de visita para um número de cidades de modo que o percurso total seja mínimo. Para os problemas desta espécie foram desenvolvidos e classificados alguns operadores genéticos conforme a sua forma de representação dos cromossomos. Desta maneira, tem-se:

- Operadores que utilizam representação por adjacências;
- Operadores que utilizam representações ordinais;
- Operadores que utilizam representações por caminhos.

Cada tipo de cruzamento tem seu grupo preferencial de problemas. O mesmo tipo de cruzamento pode ser adequado para um problema e não para outro. De uma forma geral, o

método de cruzamento com um ponto de corte é considerado fraco experimentalmente, segundo Man *et al.* (1996).

Para maiores detalhes sobre métodos de cruzamento, sugere-se os trabalhos de Ochi (1994) e Soares (1997).

Operador de mutação

O próximo estágio principal de um AG é a operação de **mutação** (operador genético secundário) que modifica aleatoriamente os genes de um indivíduo através de uma taxa (ou probabilidade) de mutação. Este estágio introduz maior aleatoriedade dentro da população para esta escapar de mínimos (ou máximos) locais, ou seja, o operador genético mutação previne a perda prematura de informações.

Consiste da escolha de pontos aleatórios de um indivíduo (ou solução), e no caso da representação binária, da troca do valor deste gene por 0 ou 1, dependendo do caso e sujeito a uma probabilidade de ocorrência.

Para problemas que envolvem ordenação e permutação, o operador mutação deve evitar que haja repetição de variáveis num mesmo indivíduo. Uma troca que ocorre com uma certa probabilidade pode ser aplicada e, a partir da escolha de duas variáveis, troca-se as posições de ambas.

A Figura 3.2 representa os operadores genéticos de cruzamento e mutação.

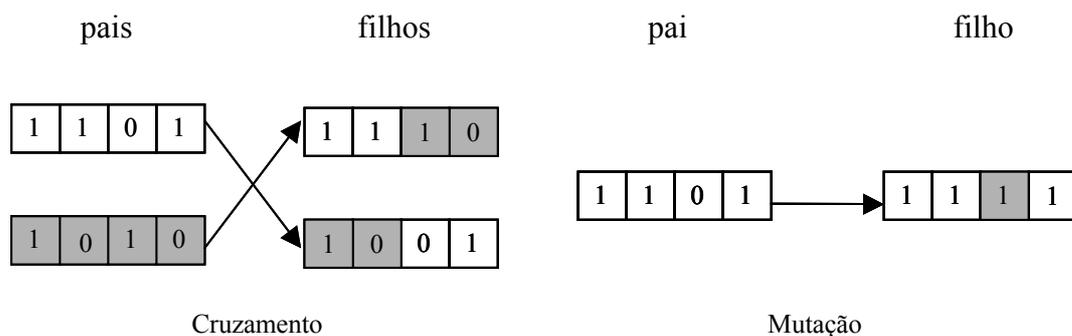


Figura 3.2 Operadores genéticos de cruzamento e mutação.

De acordo com Filho *et al.* (1994), tem sido introduzido um número de diferentes operadores genéticos desde que Holland propôs seu modelo básico. Eles são, em geral, versões do cruzamento e alteração dos processos genéticos adaptados às necessidades de

problemas específicos. Alguns exemplos são: inversão, dominância e *genetic edge recombination*.

3.2.2 Funcionamento dos algoritmos genéticos

Para o entendimento do funcionamento de um AG torna-se necessário explicar, de forma resumida, alguns conceitos importantes como: esquema, blocos de construção, teorema fundamental dos algoritmos genéticos e paralelismo implícito.

Os trabalhos de Goldberg (1989), Srinivas & Patnaik (1994), Tomassini (1995), Tomassini (1999) e Soares (1997) são boas indicações para um maior aprofundamento dos conceitos mencionados.

Uma vez que existe um grande número de similaridades a serem exploradas em uma população de *strings*, os AGs se direcionam para o ponto ótimo através da procura por semelhanças na codificação dos indivíduos de bom desempenho.

Considerando-se a forma binária, um **esquema** é uma representação que descreve um conjunto de seqüências com certas posições similares. Ele representa um subconjunto de todas as seqüências possíveis que apresentam os mesmos bits para certas posições. Um esquema tem uma estrutura composta pelos elementos 0, 1 e *, onde o símbolo * pode ser 0 ou 1. O esquema **000 representa as seqüências com zeros nas últimas três posições, ou o subconjunto formado por 00000, 01000, 10000 e 11000. Cada seqüência representada pelo esquema é conhecida como **instância do esquema**.

As posições fixas de um esquema são as posições representadas por 0 ou 1. Assim, o esquema **111 possui a terceira, a quarta e a quinta posição fixa. O número de posições fixas de um esquema é denominado de **ordem do esquema**. O exemplo anterior é de ordem 3.

O **comprimento de definição de um esquema** é a distância entre as posições fixas extremas do esquema. No exemplo **111, o comprimento é igual a dois, pois a terceira e quinta posições são os extremos considerados.

Outra característica importante do esquema é o seu desempenho medido pela média aritmética da aptidão entre todas as suas instâncias, para uma dada população e geração.

Para k posições fixas, existe 2^k esquemas distintos que representam todas as seqüências possíveis. O AG procura solucionar a competição de todos os esquemas, localizando o melhor esquema para um conjunto de posições fixas. Conforme Srinivas e Patnaik (1994), **esquemas com elevado valor de aptidão, ordem baixa e pequeno comprimento de definição crescem exponencialmente com o tempo** (essência do teorema fundamental dos AGs). Estes

esquemas são amostrados e recombinados como **blocos de construção** (*building blocks*), formando cadeias de caracteres de mais alto valor de aptidão, segundo Soares (1997). Os operadores genéticos *crossover* e mutação geram, promovem e posicionam os *building blocks* para formar seqüências ótimas.

Um comentário final, destacado do trabalho de Srinivas e Patnaik (1994) alerta que a hipótese dos *building blocks* assume que a justaposição de bons blocos de construção geram boas seqüências e, que isto não é sempre verdadeiro. Dependendo da natureza da função objetivo, seqüências muito ruins podem ser geradas quando da atuação dos blocos de construção.

Em relação ao **paralelismo implícito**, a cada geração de um AG n indivíduos são processados, mas n^3 esquemas são verificados paralelamente. E desta forma, segundo Noronha (2001) as técnicas de computação evolucionária operam sobre uma população de candidatos em paralelo. Assim, elas podem fazer a busca em diferentes áreas do espaço de solução, alocando um número de membros apropriado para a busca em várias regiões.

3.2.3 Parâmetros dos algoritmos genéticos

Uma das linhas de pesquisa sobre AGs citada por Soares (1997) é conhecida como análise de desempenho. Ela procura por mecanismos, parâmetros e outros artifícios que auxiliem os AGs a melhorarem seu desempenho na resolução de problemas.

Srinivas e Patnaik (1994) relatam que a escolha de parâmetros de controle é debatida em investigações analíticas e empíricas, resultando nas seguintes conclusões:

- O aumento da probabilidade de cruzamento aumenta a combinação dos blocos de construção, mas ele também aumenta a possibilidade da quebra de boas soluções;
- O aumento da taxa de mutação tende a transformar a busca genética em uma busca probabilística, mas isto também auxilia na reintrodução de material genético perdido;
- O aumento da população aumenta sua diversidade e reduz a probabilidade de convergência prematura de um AG para um ponto ótimo local, mas, por outro lado, ele acarreta também no aumento do tempo necessário para a população convergir para a região ótima do espaço de busca.

Os parâmetros de controle, segundo os autores, dependem da natureza da função objetivo e da interação dos operadores genéticos. Apesar destas conclusões, os pesquisadores Man *et al.* (1996), Srinivas e Patnaik (1994) sugerem um conjunto de parâmetros que garantem uma boa solução, desde que alguns testes com as funções objetivo sejam realizados. Eles destacam dois conjuntos de parâmetros: um conjunto com uma pequena população e, relativamente, altas taxas de cruzamento e mutação. Outro com uma grande população, mas baixas taxas de cruzamento e mutação. Valores típicos destes conjuntos são:

- taxa de cruzamento de 0,9; taxa de mutação de 0,01 e tamanho da população de 30; e
- taxa de cruzamento de 0,6; taxa de mutação de 0,001 e tamanho da população de 100.

Em Soares (1997) o parâmetro comprimento do cromossomo l na representação binária deve ser escolhido conforme a precisão desejada. Quanto maior o comprimento l , maior o domínio de otimização, porém mais precisa será a solução. Algumas constatações referentes ao desempenho de AGs sob parametrizações específicas podem ser verificadas no trabalho do autor.

3.3 Evolução diferencial

A evolução diferencial é um paradigma da CE desenvolvido por Rainer Storn e Kenneth Price para problemas de otimização. Na evolução diferencial, cada variável é representada por um valor real (ponto flutuante) e o seu procedimento de otimização é regido pelas seguintes etapas:

- (i) gerar uma população inicial aleatória, com distribuição uniforme, de soluções factíveis à resolução do problema em questão, onde é garantido por regras de “reparo” que os valores atribuídos as variáveis estão dentro das fronteiras delimitadas pelo projetista;
- (ii) um indivíduo é selecionado, de forma aleatória, para ser substituído e outros três diferentes indivíduos são selecionados como genitores (pais);
- (iii) um destes três indivíduos é selecionado como genitor principal;
- (iv) com alguma probabilidade, cada variável do genitor principal é modificada. Neste caso, pelo menos uma variável deve ser alterada;

- (v) a modificação (mutação) é realizada adicionando-se ao valor atual da variável uma taxa, F , regida pela diferença entre dois valores desta variável nos outros dois genitores. Em outras palavras, o vetor denominado genitor principal é modificado baseado no vetor de variáveis de dois outros genitores. Este procedimento de alteração das variáveis representa o operador de cruzamento na evolução diferencial. Esta operação é similar a recombinação aritmética dos algoritmos genéticos com representação real ou de ponto flutuante;
- (vi) se o vetor resultante apresenta uma flutuação de aptidão (fitness) melhor que o escolhido à substituição, ele o substitui; caso contrário, o vetor escolhido para ser substituído é mantido na população. Este procedimento representa o processo de seleção da evolução diferencial;

Em outras palavras, adotando-se um formalismo de explicação matemático, na evolução diferencial uma solução, l , na geração w é um vetor multidimensional $\bar{x}_{G=w}^l = (x_1^l, \dots, x_N^l)^T$. Uma população, $P_{G=k}$, na geração $G = k$ é um vetor de M soluções, onde $M > 4$. A população inicial, $P_{G=0} = \{\bar{x}_{i,G=0}^1, \dots, \bar{x}_{i,G=0}^M\}$ é gerada inicialmente, com distribuição uniforme, adotando-se

$$x_{i,G=0}^l = \lim_{\inf}(x_i) + rand_i[0,1] * (\lim_{\sup}(x_i) - \lim_{\inf}(x_i)), \quad (3.1)$$

onde $\lim_{\inf}(x_i)$ e $\lim_{\sup}(x_i)$ são os limites inferior e superior de valores admissíveis para a variável x_i , respectivamente, M é o tamanho da população, N é a dimensão da solução e $rand_i[0,1]$ gera um número aleatório, com distribuição uniforme, no intervalo entre 0 e 1.

A seleção é realizada para escolher quatro diferentes índices de soluções r_1, r_2, r_3 e $j \in [1, M]$. Os valores de cada variável, na solução descendente, são modificados com uma mesma probabilidade de cruzamento, p_m , para

$$\forall i \leq N, x_{i,G=k}^l = \begin{cases} x_{i,G=k-1}^{r_3} + F * (x_{i,G=k-1}^{r_1} - x_{i,G=k-1}^{r_2}) \\ \quad \text{se } (rand[0,1] < p_c \wedge i = i_{rand}) \\ x_{i,G=k-1}^j, \quad \text{nos outros casos} \end{cases} \quad (3.2)$$

onde $F \in (0,1)$ é uma taxa de “perturbação” a ser adicionada a solução escolhida aleatoriamente denominada genitor principal. A nova solução substitui a solução anterior (antiga) se ela for melhor que a anterior e pelo menos uma das variáveis tenha sido modificada. Esta solução é representada na evolução diferencial pela seleção aleatória de uma

variável, $i_{rand} \in (1, N)$. Depois da operação de cruzamento, se uma ou mais variáveis na nova solução estão fora das fronteiras (limites) uma regra de “reparo” é aplicada, sendo esta regida pela equação

$$x'_{i,G=k} = \begin{cases} \left[x_{i,G}^j + \lim_{\inf}(x_i) \right] / 2, & \text{se } x_{i,G+1}^j < \lim_{\inf}(x_i) \\ \lim_{\inf}(x_i) + \left[x_{i,G}^j - \lim_{\sup}(x_i) \right] / 2, & \text{se } x_{i,G+1}^j > \lim_{\sup}(x_i) \\ x_{i,G+1}^j, & \text{nos outros casos.} \end{cases} \quad (3.3)$$

A Figura 3.3 representa o fluxograma da evolução diferencial.

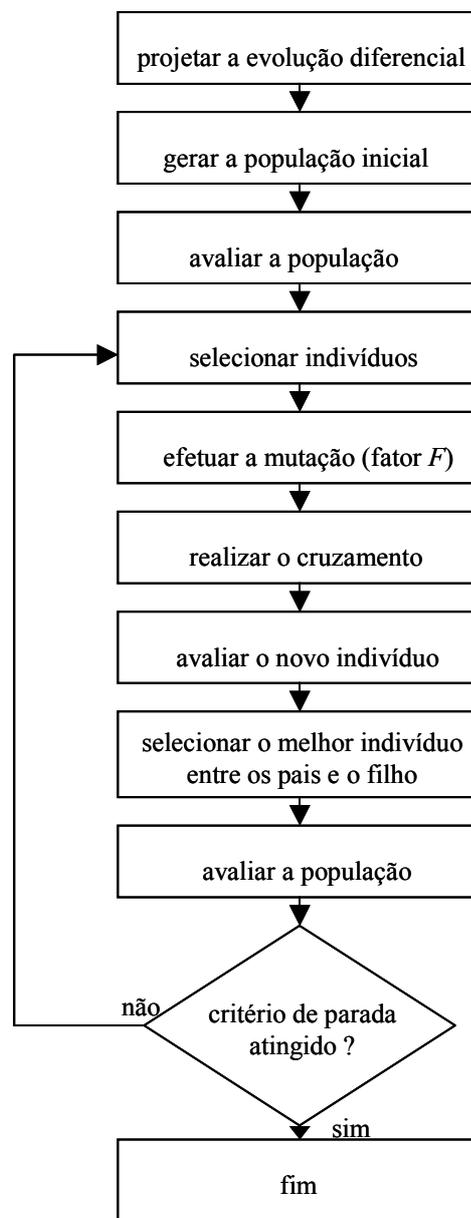


Figura 3.3 Fluxograma da evolução diferencial.

Segundo Storn e Price (1997) a evolução diferencial é uma nova heurística para a minimização de funções não-lineares e não-diferenciáveis no espaço contínuo. No mesmo trabalho, os autores comprovaram que a evolução diferencial, em muitas instâncias, foi o melhor algoritmo evolutivo (entre *simulated annealing* adaptativo, *Nelder* e *Mead* com *Annealing*, *AG breeder*, estratégia evolutiva e equações diferenciáveis estocásticas) para abordagens de minimização em relação ao número de avaliações necessárias para localizar o mínimo global das funções teste utilizadas no experimento.

A pesquisa realizada por Cruz *et al.* (2002) mostrou que a evolução diferencial se destacou em termos de eficiência quando comparado ao *AG breeder*. Cita também que em contraste com a maioria dos AEs, onde muitos parâmetros precisam ser ajustados, na evolução diferencial apenas três parâmetros (tamanho da população, constante de cruzamento e coeficiente de variação diferencial) precisam ser selecionados. Conforme os autores, os dois algoritmos de evolução diferencial investigados solucionaram os problemas *benchmark* do trabalho de forma apropriada e eficiente, apresentando desempenho similar ao algoritmo de programação dinâmica iterativa (não evolutivo).

3.3.1 Parâmetros da evolução diferencial

O seguinte conjunto de regras da linguagem tem surgido como ajuda para a escolha das variáveis de controle F (fator de valor constante e real), CR (probabilidade de cruzamento) e NP (tamanho da população), conforme Storn (1996):

- a população inicial deve ser gerada o mais próximo possível da superfície da função objetivo;
- freqüentemente a probabilidade de cruzamento $CR \in [0,1]$ deve ser considerada menor do que um (por exemplo 0,3). Caso não ocorra convergência, uma $CR \in [0,8; 1]$ pode ajudar;
- para muitas aplicações NP de $10 * D$ (onde D é igual a dimensão ou ao número de variáveis) é uma boa escolha. F é, normalmente, escolhido no intervalo $[0,5; 1,0]$;
- quanto maior for o tamanho da população escolhida, menor é o valor de F ;
- tem-se um bom sinal de convergência quando os parâmetros do melhor membro da população varia muito de geração para geração, especialmente durante o início do processo de minimização. Mesmo se o seu valor da função objetivo decrescer lentamente;

- não há necessariamente um desempenho inapropriado, quando o valor da função objetivo do melhor membro da população apresentar platôs durante o processo de minimização. Entretanto, isto indica que a minimização levará um tempo maior até encontrar o mínimo global (ou próximo dele) ou que o aumento do tamanho da população poderá ser benéfico para a convergência;
- o valor da função objetivo do melhor membro da população não pode cair de forma brusca. Caso aconteça, a otimização está em um mínimo local;
- a escolha apropriada da função objetivo é crucial. Quanto maior for a inclusão do conhecimento sobre o problema na função objetivo, maior será a possibilidade de uma convergência suave e adequada.

3.4 Conclusão do capítulo

Neste capítulo comentou-se sobre a complexidade dos problemas relacionados ao gerenciamento da cadeia de suprimentos, a limitação dos modelos analíticos empregados e a difícil solução destes modelos através dos métodos de busca tradicionais. Desta forma, justificou-se a necessidade da aplicação de técnicas metaheurísticas para a obtenção de boas soluções nos problemas de otimização da cadeia de suprimentos.

Em seguida, uma breve descrição da área de computação evolucionária e os seus paradigmas constituintes, os algoritmos evolucionários, foi apresentada para possibilitar a introdução da fundamentação teórica das técnicas de algoritmos genéticos e evolução diferencial utilizadas no estudo de caso desta dissertação.

Capítulo 4

Resultados

4.1 Introdução

Os parâmetros usados na otimização da cadeia de abastecimento, conforme Mak e Wong (1995) são os seguintes:

- demanda de produto durante o período de planejamento, D_{rpt} :

$$D_{111} = 80; \quad D_{112} = 60; \quad D_{113} = 70; \quad D_{121} = 50; \quad D_{122} = 50; \quad D_{123} = 55;$$

$$D_{211} = 60; \quad D_{212} = 75; \quad D_{213} = 65; \quad D_{221} = 45; \quad D_{222} = 65; \quad D_{223} = 85;$$

$$D_{311} = 80; \quad D_{312} = 70; \quad D_{313} = 90; \quad D_{321} = 50; \quad D_{322} = 70; \quad D_{323} = 40.$$

- tempo de processamento de máquina, B_p : $(B_1, B_2) = (1, 1)$
- tempo permitido para fabricação, β_t : $(\beta_1, \beta_2, \beta_3) = (800, 800, 800)$
- custo de envio 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 envio 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, $(H_1^M, H_2^M, H_3^M) = (5, 8, 6)$

- 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 do material, 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 carregamento do fornecedor para o fabricante, $\omega_t^M :$

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

- limite de carregamento do fabricante para o distribuidor, $\omega_t^P :$

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

- quantidade material dos produtos, $\theta_{mp} :$

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

Foram adotados nas simulações de otimização da cadeia de suprimentos, estoques de material e produtos inicialmente não nulos na modelagem do sistema e $R = 3$ distribuidores, $P = 2$ produtos, $T = 3$ períodos de planejamento, e $M = 3$ materiais. Com o objetivo de estudar o desempenho das abordagens de AEs descritas, foram realizados 10 experimentos com cada AE usando os parâmetros mencionados para a cadeia de suprimentos. O indivíduo nos AEs é composto pelas variáveis $I_{mt}, J_{pt}, K_{rpt}, Z_{rpt}$. e seus valores são arredondados para o valor inteiro mais próximo para avaliação da função $aval(x)$, necessária para o cálculo da função $fitness$. O espaço de busca adotado para cada variável foi $0 \leq I_{mt} \leq 20$, $0 \leq J_{pt} \leq 20$, $0 \leq K_{rpt} \leq 30$ e $0 \leq Z_{rpt} \leq 120$. Na tabela 1 são apresentados os resultados das simulações com os AEs para otimização da cadeia de suprimentos.

O tamanho de população adotado foi de 30 indivíduos e um critério de parada de 5000 gerações, ou seja, 150000 avaliações da função de $fitness$. A mesma população inicial foi utilizada para cada uma das 11 configurações de AEs testadas. Os parâmetros adotados para cada AE são os seguintes:

- (i) ED(1): constante de cruzamento CR igual a 0,80 e fator de perturbação F igual a 0,40;
- (ii) ED(2): constante de cruzamento CR igual a 0,80 e fator de perturbação F gerado aleatoriamente com distribuição uniforme entre 0,05 e 1,50 a cada geração;
- (iii) ED(3): constante de cruzamento CR igual a 0,80 e fator de perturbação F gerado aleatoriamente com distribuição uniforme entre 0,02 e 1,20 a cada geração;
- (iv) ED(4): constante de cruzamento CR igual a 0,80 e fator de perturbação F gerado aleatoriamente com distribuição uniforme entre 0,10 e 1,20 a cada geração;

- (v) AG(1): probabilidade de cruzamento e probabilidade de mutação de 0,80 e 0,10, respectivamente;
- (vi) AG(2): probabilidade de cruzamento e probabilidade de mutação de 0,80 e 0,01, respectivamente;
- (vii) AG(3): probabilidade de cruzamento e probabilidade de mutação de 0,90 e 0,10, respectivamente;
- (viii) AG(4): probabilidade de cruzamento e probabilidade de mutação de 0,90 e 0,01, respectivamente;
- (ix) AG(5): probabilidade de cruzamento e probabilidade de mutação de 0,80 e 0,001, respectivamente;
- (x) AG(6): probabilidade de cruzamento e probabilidade de mutação de 0,90 e 0,001, respectivamente;
- (xi) AG(7): probabilidade de cruzamento e probabilidade de mutação de 0,70 e 0,10, respectivamente;

Para os AEs desenvolvidos com algoritmos genéticos utilizou-se:

- representação binária ou canônica;
- cruzamento com 1 ponto de corte;
- seleção por roleta e estratégia elitista (mantendo o melhor indivíduo da população).

Para os AEs desenvolvidos com evolução diferencial utilizou-se a representação de ponto flutuante.

Para todos os algoritmos utilizou-se a seguinte forma de penalização:

$\beta = 500000$;

função custo = função custo + (nº de restrições não atendidas) * β ;

fitness = $k / (1 + \text{função custo})$, onde $k = \text{constante}$.

4.2 Análise dos resultados

De acordo com os resultados apresentados na Tabela 4.1, todos os valores referentes ao desempenho de uma determinada geração para o valor total da função objetivo obtidos pelos AEs baseados em evolução diferencial foram melhores do que os obtidos pelos AEs baseados em algoritmos genéticos considerando o modelo em estudo e os parâmetros adotados. O melhor resultado foi obtido pelo ED(1) com o valor $aval(x)$ de 98.368,90 unidades financeiras, enquanto que o melhor valor fornecido pelos algoritmos genéticos foi o do AG(2) igual a 130.349,50 unidades financeiras. O valor fornecido pelo ED(1) é 24,53% menor do que o valor alcançado pelo AG(2), diferença relevante para uma função de minimização.

Uma vez que as metaheurísticas empregadas têm sua população inicial gerada de forma aleatória, não é academicamente correto considerar apenas o desempenho de uma determinada configuração. Assim, a média de todos os valores obtidos a cada geração para as diferentes configurações dos algoritmos testados expressa um melhor resultado em relação à convergência de cada algoritmo. Este indicador reforça, novamente, o desempenho superior dos algoritmos baseados em evolução diferencial sobre os baseados em algoritmos genéticos. Todos os EDs apresentaram melhor desempenho em relação à convergência, destacando-se o ED(2) com uma média de 101.900,45 unidades financeiras. O melhor resultado dos AGs foi obtido pelo AG(7) no valor de 149.136,70. O valor fornecido pelo ED(2) é 31,67% menor do que o valor alcançado pelo AG(7).

Em relação ao tempo médio computacional consumido pelos AEs para a minimização da função objetivo com critério de parada de 5000 gerações, nota-se pelos resultados da Tabela 4.1 que os EDs também se destacaram neste item. O melhor resultado em relação ao tempo médio computacional consumido foi apresentado pelo ED(1) no valor de 858,87 segundos. O melhor AG neste quesito foi o AG(1) com o valor de 925,98 segundos.

Os algoritmos foram testados em um computador com processador AMD Athlon 1,09 GHz e memória de 112 MB RAM.

Tabela 4.1: Resumo dos resultados para 10 experimentos.

técnica	resultado da minimização da função objetivo (média dos experimentos após 5000 gerações)				tempo médio*
	melhor	média	pior	desvio padrão	segundos
ED(1)	98368,90	102861,70	106092,90	3381,05	858,87
ED(2)	98867,50	101900,45	107696,00	3986,15	865,93
ED(3)	99290,00	103122,82	106132,30	3184,32	862,25
ED(4)	99328,00	105144,00	105144,00	2612,53	867,76
AG(1)	180432,50	202793,40	251193,60	33259,20	925,98
AG(2)	130349,50	155064,50	176588,00	19417,93	927,30
AG(3)	198589,30	208820,90	227170,00	12594,74	938,11
AG(4)	141776,00	153365,12	166367,20	11056,33	950,52
AG(5)	141676,30	200912,72	250066,80	50672,84	967,19
AG(6)	184858,70	207915,75	258524,30	34120,26	1077,20
AG(7)	136245,80	149136,70	174580,90	17318,72	927,69

A Tabela 4.2 apresenta os parâmetros (56) e seus respectivos valores determinados pela melhor função objetivo de cada abordagem de ED e AG considerada.

Tabela 4.2: Parâmetros determinados pela melhor função objetivo de cada abordagem de ED e AG da Tabela 4.1.

variável	ED(1)	ED(2)	ED(3)	ED(4)	AG(1)	AG(2)	AG(3)	AG(4)	AG(5)	AG(6)	AG(7)
I_{11}	5	5	5	5	3	5	3	5	5	5	1
I_{12}	0	0	0	0	4	0	3	0	0	0	0
I_{13}	0	0	0	0	5	1	5	0	0	0	0
I_{14}	0	0	0	0	2	1	4	0	0	0	0
I_{21}	5	5	5	5	4	4	4	4	5	5	3
I_{22}	0	0	0	0	1	1	4	0	0	0	0
I_{23}	0	0	0	0	5	0	0	1	0	0	1
I_{24}	0	0	0	0	0	0	3	0	0	0	1
I_{31}	5	5	5	5	2	2	4	4	5	5	5
I_{32}	0	0	0	0	4	0	1	0	0	0	0
I_{33}	0	0	0	0	4	0	2	2	0	0	3
I_{34}	0	0	0	0	4	0	1	0	0	0	0
J_{11}	5	5	5	5	3	5	4	5	5	5	3
J_{12}	0	0	0	0	1	0	2	2	0	0	1
J_{13}	0	0	0	0	3	0	0	1	0	0	0
J_{14}	0	0	0	0	4	0	3	0	0	0	0
J_{21}	5	5	5	5	1	5	0	5	5	5	5
J_{22}	0	0	0	0	0	0	3	0	0	0	1
J_{23}	0	0	0	0	4	0	5	0	0	0	0
J_{24}	0	0	0	0	1	0	2	0	0	0	4
K_{111}	5	5	5	5	3	5	2	5	5	5	5
K_{112}	4	5	2	3	1	4	2	3	4	0	0

K_{113}	2	3	3	3	2	0	3	0	0	0	3
K_{121}	5	5	5	5	5	5	1	5	5	5	5
K_{122}	0	0	0	0	5	0	0	0	0	0	4
K_{123}	0	0	0	0	3	1	2	0	0	0	3
K_{211}	5	5	5	5	5	5	5	5	5	5	5
K_{212}	3	0	2	3	1	1	1	0	5	1	1
K_{213}	4	1	0	5	1	3	5	0	3	0	0
K_{221}	5	5	5	5	2	5	5	5	5	5	5
K_{222}	21	17	18	16	8	0	20	6	3	6	0
K_{223}	1	5	1	0	1	0	5	1	0	0	0
K_{311}	5	4	5	5	4	5	2	5	4	5	5
K_{312}	2	5	2	0	1	0	0	2	3	2	1
K_{313}	0	1	0	2	0	0	2	0	0	0	0
K_{321}	5	5	5	5	4	5	2	5	5	5	5
K_{322}	0	5	1	1	1	3	2	0	0	0	0
K_{323}	5	0	3	2	1	0	2	0	0	0	3
Z_{111}	79	80	77	78	71	79	79	78	79	67	75
Z_{112}	58	58	61	60	55	56	55	56	45	45	63
Z_{113}	68	67	67	67	43	67	66	67	45	45	67
Z_{121}	9	7	13	15	10	35	48	35	27	33	47
Z_{122}	2	5	2	0	19	25	17	16	27	35	12
Z_{123}	0	0	0	0	2	4	13	10	11	29	16
Z_{211}	58	55	57	58	55	56	50	45	60	56	56
Z_{212}	76	76	73	77	67	77	79	73	73	67	73
Z_{213}	61	64	65	60	64	62	59	64	62	56	62
Z_{221}	61	57	58	56	50	40	39	43	42	45	33
Z_{222}	45	53	48	47	37	31	46	50	42	35	43
Z_{223}	78	72	79	77	79	84	76	64	82	83	76
Z_{311}	77	81	77	75	72	67	63	77	79	77	76
Z_{312}	68	66	68	72	62	67	63	67	67	67	67
Z_{313}	89	89	90	88	90	89	74	89	90	84	89
Z_{321}	45	50	46	46	45	47	36	45	44	45	39
Z_{322}	75	65	72	71	69	67	38	59	62	64	66
Z_{323}	35	40	32	38	35	25	32	38	31	19	21

Para a análise gráfica são utilizados os seguintes indicadores:

- *desempenho on-line*: Este índice está relacionado à média de todos os *fitness* de todos os indivíduos gerados até uma determinada geração. Este parâmetro é calculado em cada geração. A análise gráfica dos valores ao longo das gerações informa se ocorreu a convergência;
- *desempenho off-line*: Refere-se à média dos melhores indivíduos de cada geração gerados até determinada geração.

Os gráficos da melhor convergência de desempenho on-line e off-line do ED e AG, isto é, ED(1) e AG(2) (melhor *fitness*), ED(2) e AG(7) (melhor média), são apresentados a seguir.

Melhor *fitness* ED(1):

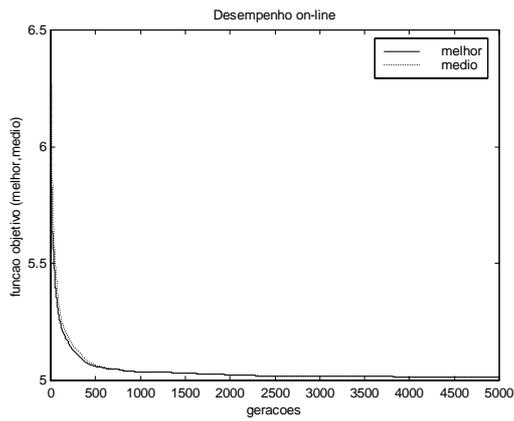


Figura 4.1 Desempenho *on-line* ED(1).

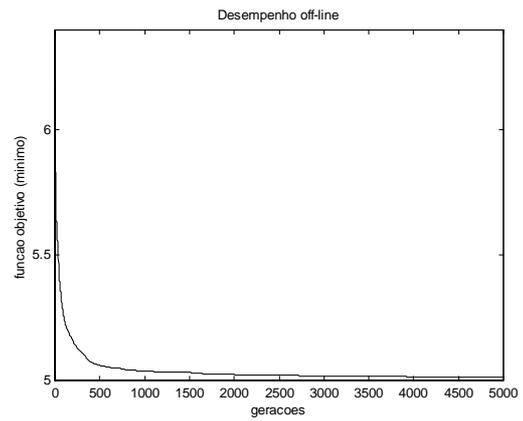


Figura 4.2 Desempenho *off-line* ED(1).

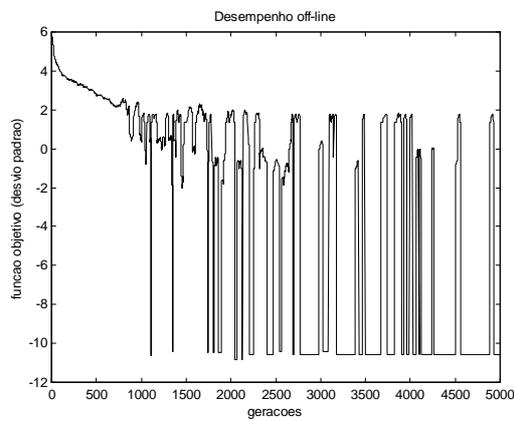


Figura 4.3 Desempenho *off-line* ED(1) considerando o desvio padrão.

Melhor *fitness* AG(2):

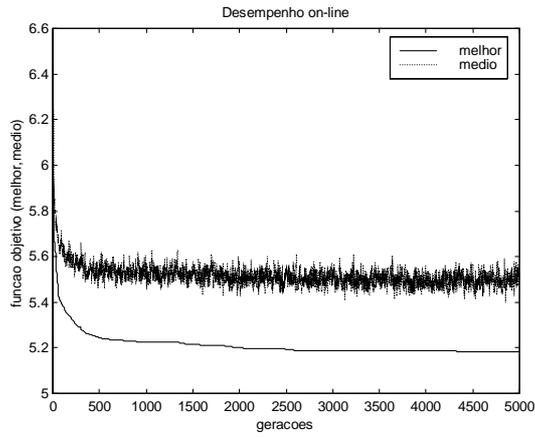


Figura 4.4 Desempenho *on-line* AG(2).

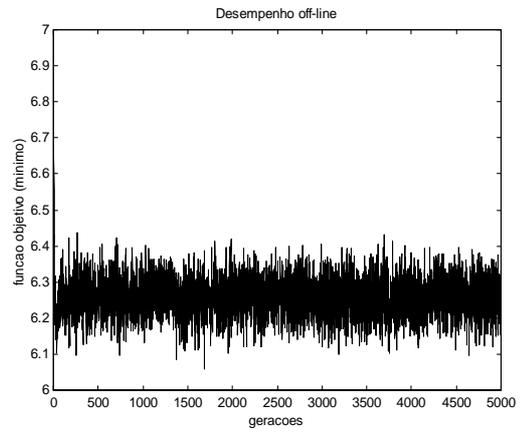


Figura 4.5 Desempenho *off-line* AG(2).

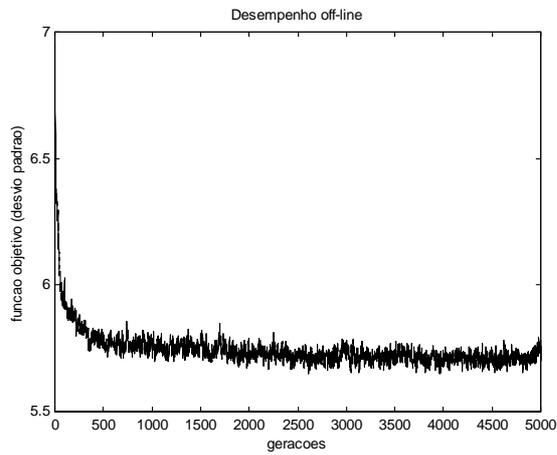


Figura 4.6 Desempenho *off-line* AG(2) considerando o desvio padrão.

Melhor média ED(2):

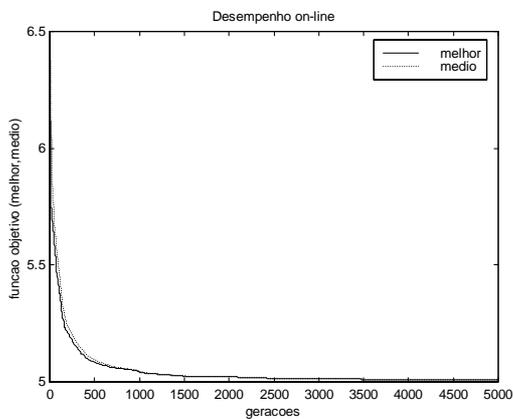


Figura 4.7 Desempenho *on-line* ED(2).

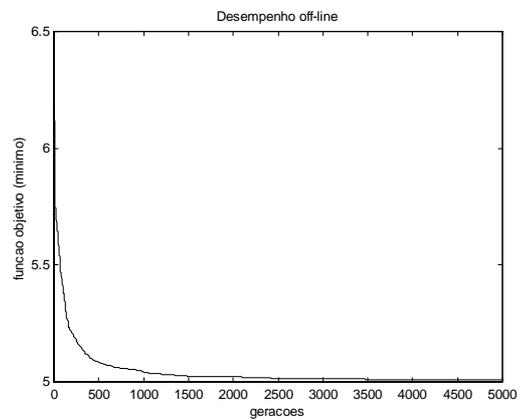


Figura 4.8 Desempenho *off-line* ED(2).

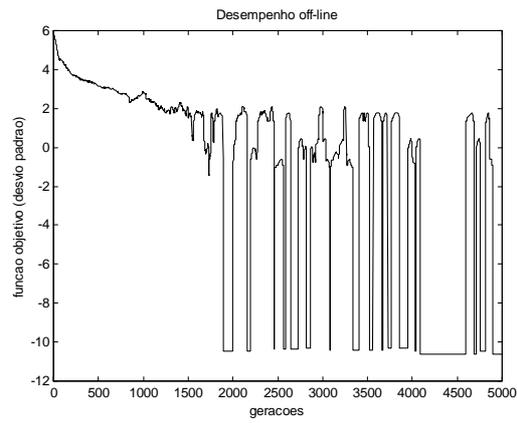


Figura 4.9 Desempenho *off-line* ED(2) considerando o desvio padrão.

Melhor média AG(7):

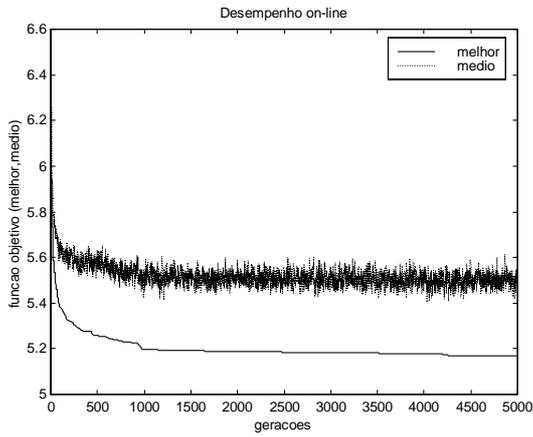


Figura 4.10 Desempenho *on-line* AG(7).

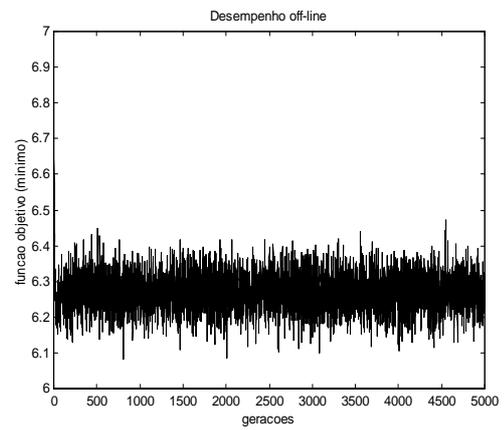


Figura 4.11 Desempenho *off-line* AG(7).

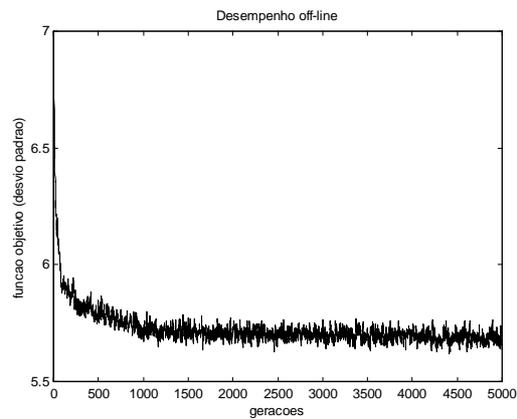


Figura 4.12 Desempenho *off-line* AG(7) considerando o desvio padrão.

Assim, pelos gráficos apresentados, o ED é um otimizador local e com convergência mais rápida do que o AG usado.

A Tabela 4.3 apresenta uma comparação entre os melhores representantes dos algoritmos propostos e os resultados obtidos por Mak e Wong (1995). É importante ressaltar que, preliminarmente, foi desenvolvido um algoritmo genético na mesma configuração do trabalho de Mak e Wong (1995) e o mesmo valor de 115.495 unidades financeiras para a função objetivo foi alcançado. No trabalho de referência, o algoritmo genético dos autores só aceita soluções factíveis na população inicial, enquanto que nos algoritmos desenvolvidos e testados nesta dissertação adotou-se um critério de penalização para as soluções não-factíveis. O artigo de referência também não especifica o espaço de busca, dificultando a análise comparativa em relação ao valor da função objetivo alcançado, à qualidade de convergência e ao tempo computacional consumido. O método de *Branch and Bound* presente no artigo de referência pode estar inconsistente, pois os autores consideraram o valor de 113.584 unidades financeiras como valor ótimo global e com a ED(1) analisada nesta dissertação obteve-se 98368,90.

Tabela 4.3 Comparação entre os melhores representantes dos algoritmos propostos e os resultados obtidos por Mak e Wong (1995).

$aval(x)$	ED	AG	AG Mak	B&B Mak
melhor	98368,90	130349,50	115495,00	113584,00

4.3 Conclusão do capítulo

Neste capítulo foram apresentados os resultados obtidos pelos 11 AEs desenvolvidos neste trabalho, na solução do problema de minimização dos custos de armazenagem, fabricação, transporte e falta de produto para o modelo de cadeia de suprimento simplificada com 3 materiais, 2 produtos, 3 distribuidores e 3 períodos de planejamento.

O melhor resultado em relação à convergência de resposta para o algoritmo de evolução diferencial tem os parâmetros de constante de cruzamento CR igual a 0,80 e fator de perturbação F gerado aleatoriamente com distribuição uniforme entre 0,05 e 1,50 a cada geração. Da mesma forma, o melhor resultado em relação à convergência de resposta para o

algoritmo genético desenvolvido tem os parâmetros de probabilidade de cruzamento e probabilidade de mutação de 0,70 e 0,10, respectivamente.

A análise dos resultados permite afirmar que a evolução diferencial se mostrou superior em relação aos algoritmos genéticos testados para o problema considerado nas configurações descritas em relação aos indicadores de qualidade da resposta, análise de convergência e tempo computacional consumido.

Capítulo 5

Conclusões

Esta dissertação apresentou um estudo comparativo entre evolução diferencial e algoritmos genéticos para otimização de uma cadeia de suprimento. O equacionamento da cadeia de suprimento estudada foi concebido como um problema de otimização mista inteira e o modelo considerado é definido como sendo analítico e determinístico de otimização mono-objetivo.

A solução de problemas de cadeias de suprimento com muitos ótimos locais se depara com o conflito fundamental entre precisão, integridade e esforço computacional. O compromisso entre *exploitation* (convergência) e *exploration* (diversidade da população) é uma constante no AE e deve ser considerada na configuração de uma metodologia de otimização eficiente. Os parâmetros adotados para cada AE foram encontrados através de heurísticas de tentativa e erro e providenciaram resultados promissores para cada AE.

Os resultados encontrados permitem a validação da técnica de evolução diferencial no processo de otimização de cadeias de suprimento e assim, o objetivo de introdução da técnica na análise de problemas de planejamento e programação da produção no âmbito de cadeias de suprimento foi alcançado. Além disso, diferentes configurações para os parâmetros relacionados às operações de cruzamento e mutação foram testadas, permitindo mais uma exemplificação prática de valores ou intervalos a serem considerados em novos trabalhos.

O estudo comparativo entre a evolução diferencial e os algoritmos genéticos resultou em um desempenho superior da evolução diferencial em relação à qualidade da resposta, análise de convergência e tempo computacional consumido. Entretanto deve ser reforçado que este desempenho superior está limitado ao problema analisado, conforme o modelo e parâmetros adotados.

Uma observação relevante quanto aos AEs é apresentada no teorema *no free lunch* (NFL) (Wolpert & Macready, 1997): não existe algoritmo para a resolução de todos problemas de otimização que seja genericamente (em média) superior que outro algoritmo competidor. Segundo o NFL, a afirmação de que os AEs são inferiores ou superiores a algum

método alternativo é “insensata”. O que pode ser afirmado somente é que AEs comportam-se melhor que outros métodos com respeito à resolução de uma classe específica de problemas, e como consequência comportam-se inadequadamente para outras classes de problemas.

O teorema NFL pode ser confirmado pela análise dos AEs em relação a muitos métodos clássicos de otimização. Os métodos clássicos são mais eficientes para resolução de problemas lineares, quadráticos, fortemente convexos, unimodais, separáveis, e em muitos outros problemas em especial. Por outro lado, os AEs têm sido utilizados nos mais diversos problemas principalmente quando estes são descontínuos, não diferenciáveis, multimodais, ruidosos, e quando superfícies de resposta não convencionais são envolvidas.

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, onde os algoritmos genéticos se destacam. Além desta, a dificuldade de se encontrar pesquisas correlacionando modelo de cadeia de suprimento, otimização e metaheurística permitiu um levantamento bibliográfico que mapeia os desenvolvimentos realizados neste campo de pesquisa desde a aplicação de técnicas de otimização para dimensionamento de lotes de produção até recentemente os trabalhos voltados a cadeia de suprimento envolvendo simulação e otimização.

Além dos resultados e conclusões referentes às técnicas de algoritmos evolucionários empregadas, algumas informações diretamente relacionadas ao dia-a-dia logístico merecem destaque. Em primeiro lugar, a análise dos dados utilizados no problema possibilita a percepção de um peso maior da parcela referente ao custo de falta do produto. Trata-se de uma tentativa de aproximação de dois objetivos conflitantes: atendimento da demanda e baixo custo operacional. Os resultados encontrados confirmam a lógica do problema mono-objetivo com foco na minimização dos custos totais e assim, algumas demandas não foram atendidas em grande parte de sua totalidade, como por exemplo, os pedidos do produto 2 para o revendedor 1 nos três períodos considerados. Com os dados iniciais, os algoritmos evolucionários se concentram nas parcelas que impactam em menores custos e, em linhas gerais, priorizam o atendimento das demandas do produto 1 para os revendedores 1 e 2 e dos produtos 1 e 2 para o revendedor 3 (ver tabela 4.2). Ainda neste assunto vale ressaltar que o resultado confirma que nem sempre é vantajoso satisfazer todas as demandas do mercado. Isto é válido sempre que a taxa de custos adicionais for menor do que os benefícios atingidos. Apesar de óbvio, muitas empresas se deparam com resultados pífios após grandes demandas

satisfeitas. Outra informação interessante, mas com pouca relação direta com os resultados obtidos, é o custo do estoque de matéria-prima no fabricante ser maior do que o custo do estoque do produto acabado no mesmo fabricante. Para tal situação nos casos reais ocorre justamente o oposto. Por último, como resultado do conhecimento prévio das demandas, os algoritmos evolucionários anteciparam em algumas situações o embarque de produtos, ou seja, enviaram mais produtos do que a demanda do período. A sobra foi utilizada no período subsequente. Novamente, os custos de estoque são mínimos quando comparados aos custos de falta.

O modelo desenvolvido por Mak e Wong (1995) e utilizado como estudo de caso nesta dissertação apresenta importantes simplificações quando comparado a um sistema real. Este modelo consiste de três setores dispostos de forma serial e abrange os fornecedores, fabricante (e seus armazéns) e revendedores. 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. Para o modelo apresentado, busca-se através da otimização, minimizar o custo total do sistema que é composto por custos de: armazenagem, fabricação, transporte e de falta de produto (que equivale à perda de uma venda). As principais simplificações deste modelo quando comparado a um sistema real são:

- a não consideração da natureza dinâmica de um sistema real;
- nível de serviço reduzido a atendimento das demandas;
- foco em um único objetivo, ou seja, a minimização dos custos totais considerados pelo modelo;
- demandas previamente conhecidas;
- reduzido número de períodos de planejamento, materiais, produtos e participantes da cadeia de suprimentos;
- a não consideração de diferentes tempos de fabricação para cada fornecedor;
- a não consideração de diferentes modais de transporte (por exemplo: marítimo e aéreo);
- a não consideração de tamanhos de lote de compra padronizados;
- outros.

É perceptível a limitação dos algoritmos desenvolvidos devido às simplificações existentes no modelo. Entretanto, o sucesso no desenvolvimento de modelos mais complexos é dependente do nível de conhecimento alcançado para modelos mais simples e, constata-se na literatura espaço para o desenvolvimento deste conhecimento, como no caso, a aplicação de uma nova técnica de AE para o modelo anteriormente testado com algoritmos genéticos. Além disso, a inclusão de novas variáveis aumenta a complexidade do problema e, conseqüentemente, o grau de dificuldade de se encontrar uma boa solução em um tempo computacional adequado. Este é o dilema e o desafio de se aproximar a pesquisa científica aos problemas reais vivenciados no âmbito empresarial.

Como proposta de continuidade deste trabalho, a configuração de abordagens compostas por técnicas determinísticas (*branch-and-bound*), estas hibridizadas, com técnicas estocásticas, é uma alternativa. Para obter os benefícios da configuração híbrida, uma forma eficiente é executar, inicialmente, um AE para localizar a região de ótimo global e, em seguida aplicar outra metodologia de otimização para a busca local. A vantagem da utilização de um método de busca direto em relação à busca local está na melhoria da velocidade de convergência pela avaliação da função objetivo. O valor final obtido pelo método de busca direto provavelmente será mais preciso que o obtido pelo AE.

A pesquisa bibliográfica permitiu identificar trabalhos recentes relacionando otimização com simulação, sendo esta mais uma possibilidade de continuidade deste trabalho.

Aperfeiçoamentos gradativos no modelo de Mak e Wong (1995) eliminando as simplificações descritas e utilizando a técnica de evolução diferencial também pode ser uma nova continuidade desta dissertação.

Claramente, a composição das propostas anteriores, como por exemplo o desenvolvimento de um modelo de otimização híbrido envolvendo evolução diferencial e uma técnica de busca local para uma cadeia de suprimento com demandas estocásticas e múltiplos objetivos, deve permitir a elaboração de novas pesquisas.

Referências Bibliográficas

- AFENTAKIS, P.; GAVISH, B.; KARMARKAR, U. **Computationally Efficient Optimal Solutions to the Lot-Sizing Problem in Multistage Assembly Systems**, Management Science, 30(2): p. 222-238, 1984.
- ARROW, KENNETH J. **The Genesis of “Optimal Inventory Policy”**, Operations Research, 50 (1): 1-2, 2002.
- ATKINS, D.; SUN, D. **98%-Effective Lot Sizing for Series Inventory Systems with Backlogging**, Operations Research, v. 43, n. 2, p. 335-345, mar./apr. 1995.
- BÄCK, T., 1996, **Evolutionary algorithms in theory and practice**, Oxford: Oxford University Press.
- BÄCK, T.; HAMMEL, U.; SCHWEFEL, H. –P. **Evolutionary computation: comments on the history and current state**, IEEE Transactions on Evolutionary Computation, vol. 1, no. 1, p. 3-17, 1997.
- BANKS, J.; BUCKLEY, S.; JAIN, S.; LENDERMANN, P. Panel session: **opportunities for simulation in supply chain management**, Proceedings of the 2002 Winter Simulation Conference, Yücesan, E.; Chen, C. –H.; Snowdon, J. L.; Chanes, J. M. (eds.), p. 1652-1658, 2002.
- BAYDAR, C. **A hybrid parallel simulated annealing algorithm to optimize store performance**, Workshop on Evolutionary Computing for Optimisation in Industry at the Genetic and Evolutionary Computation Conference, GECCO-2002, New York, NY.

- BERKSTRESSER, G.; LITTLE, T. J.; FANG, S.-C.; KING, R. E.; NUTTLE, H. L. W.; WILSON, J. R. **Integrated supply chain analysis and decision support**, National Textile Center Research Briefs, June, p. 77-78, 2000.
- BERNING, G.; BRANDENBURG, M.; GÜRSOY, K., KUSSI, J. S.; MEHTA, V.; TÖLLE, F. -J. **Integrating collaborative planning and supply chain optimization for the chemical process industry (I)- methodology**, Computers and Chemical Engineering, vol. 28, p. 913-927, 2004.
- BLACKBURN, J.D.; MILLEN, R.A. **Improved Heuristics for Multi-Stage Requirements Planning Systems**, Management Science, v. 28, n.1, p. 44-56, 1982.
- BONADIO, P. V. G. **O Estudo da Logística na Cadeia de Suprimentos da VW – Motores**, In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 22. 2002, Curitiba. Anais do XXII ENEGEP, Curitiba: Abepro, 2002. p. 1-8.
- BRAMEL, J.; GOYAL, S.; ZIPKIN, P. **Coordination of Production/Distribution Networks with Unbalanced Leadtimes**, Operations Research, v. 48, n. 4, p. 570-577, jul./aug. 2000.
- BUOSI, THIAGO; CARPINETTI, LUIZ CÉSAR R. **Análise, Avaliação e Diagnóstico da Cadeia de Suprimentos: Uma análise crítica sobre modelos de referências**, p. 1-8, ENEGEP, Curitiba, 2002.
- CHENG, S.-L.; HWANG, C. **Optimal approximation of linear systems by a differential evolution algorithm**, IEEE Transactions on Systems, Man, and Cybernetics — Part A: Systems and Humans, vol. 31, no. 6, p. 698-707, 2001.
- CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operação**, Pearson Education do Brasil, São Paulo, SP, 2003.

- CHRISTOPHER, M. **Logistics and Supply Chain Management: Strategies for Reducing Cost and Improving Service**. 2.ed. Pearson Education Limited, 1998. 294p.
- CHWIF, L.; BARRETTO, M. R. P. **Supply chain analysis:spreadsheet or simulation?** Proceedings of the 2002 Winter Simulation Conference, Yücesan, E.; Chen, C. –H.; Snowdon, J. L.; Chanes, J. M. (eds.), p. 59-66.
- CLARK, A.J.; SCARF, H. **Optimal Policies for a Multi-Echelon Inventory Problem**, Management Science, n. 6, p. 475-490, 1960.
- CLARK, A. R.; ARMENTANO V.A. **Echelon Stock Formulation for Multi-Stage Lot-Sizing with Component Lead Times**, International Journal of Systems Science, v. 24, n. 9, p. 1759-1775, 1993.
- CLARK, A. R.; ARMENTANO, V.A. **A Heuristic for a Resource-Capacitated Multi-Stage Lot-Sizing Problem with Lead Times**, Journal of the Operational Research Society, n. 46, p. 1208-1222, 1995.
- COELHO, L. S. **Identificação e Controle de Processos Multivariáveis via Metodologias Avançadas e Inteligência Computacional**, Florianópolis, 2000. 307p. Tese (Doutorado em Engenharia Elétrica) – Universidade Federal de Santa Catarina, UFSC.
- COUNCIL OF LOGISTICS MANAGEMENT. Disponível em: <<http://www.clm1.org>>
Acesso em: 11 abr. 2002.
- CRUZ, I.L.L.; WILLIGENBURG, L.G.V.; STRATEN, G. V. **Efficient Differential Evolution algorithms for multimodal optimal control problems**, Applied Soft Computing Journal, v. 3, i. 2, p. 97-122, 2003.
- DAKIN, R. **A tree-search algorithm for mixed integer programming problems**, Computer Journal, vol. 8, p. 250-255, 1965.

- DAVIS, MARK M., AQUILANO, NICHOLAS J., CHASE, RICHARD B. **Fundamentos da Administração da Produção**. 3ª ed. Porto Alegre: Bookmann Editora, 2001.
- DIMOPOULOS, C.; ZALZALA, A. M. S. **Recent Developments in Evolutionary Computation for Manufacturing Optimization: Problems, Solutions, and Comparisons**, IEEE Transactions on Evolutionary Computation, Vol. 4, n. 2, p. 93 – 113, 2000.
- DING, H.; BENYOUCEF, L; XIE, X. **A simulation-optimization approach using genetic search for supplier selection**, Proceedings of the 2003 Winter Simulation Conference, Chick, S.; Sánchez, P. J.; Ferrin, D.; Morrice, D. J. (eds.), p. 1260-1267, 2003.
- DISNEY, S. M.; NAIM, M. M.; TOWILL, D. R. **Genetic algorithm optimisation of a class inventory control systems**, International Journal of Production Economics, vol. 68, p. 259-278, 2000.
- DONG, M. **Process modeling, performance analysis and configuration simulation in integrated supply chain network design**, Doctoral dissertation, Department of Industrial and Systems Engineering, Virginia Polytechnic Institute and State University, Blacksburg, Virginia, USA, 2001.
- ENNS, S.; SUWANRUJI, P. **A simulation test bed for production and supply chain modeling**, Proceedings of the 2003 Winter Simulation Conference, Chick, S.; Sánchez, P. J.; Ferrin, D.; Morrice, D. J. (eds.), p. 1174-1182, 2003.
- FILHO, E. R., **A Logística e as questões estocásticas**. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 22. 2002, Curitiba. Anais do XXII ENEGEP, Curitiba: Abepro, 2002. p. 1-8.
- FILHO, J. L. R.; TRELEAVEN, P. C.; ALIPPI, C. **Genetic-Algorithm Programming Environments**, IEEE Computer, v. 27, n. 6, p. 28 – 43, jun. 1994.

FU, M. C., **Simulation optimization**, Proceedings of the 2001 Winter Simulation Conference, Peters, B. A.; Smith, J. S.; Medeiros, D. J.; Roher, M. W. (eds.), p. 53-61, 2001.

FU, M. C. **Optimization for simulation: theory and practice**, INFORMS Journal on Computing, vol. 14, no. 3, p. 192-215, 2002.

GANAPATHY, S.; NARAYANAN, S.; SRINIVASAN, K. **Simulation based decision support for supply chain logistics**, Proceedings of the 2003 Winter Simulation Conference, Chick, S.; Sánchez, P. J.; Ferrin, D.; Morrice, D. J. (eds.), p. 1013-1020.

GEOFFRION, A. M.; POWERS, R. F. **Twenty Years of Strategic Distribution System Design: An Evolutionary Perspective**. Interfaces, 25, p. 105 – 127, set-out. 1995. Disponível em: <<http://www.ucla.edu/faculty/art.geof...v25n5a6.pdf>> Acesso em: 23 set. 2002.

GOLDBARG, M. C.; LUNA, H. P. L. **Otimização combinatória e programação linear: modelos e algoritmos**, Editora Campus, Rio de Janeiro, RJ, 2000.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Massachusetts: Addison-Wesley Longman, 1989. 411p.

GUPTA, P. Y.; KEUNG, Y. **A Review of Multi-stage Lot-sizing Models**, International Journal of Operations and Production Management, 10 (9):p. 57-73, 1990.

GUPTA, S. M.; POCHAMPALLY, K. K. **Crucial Issues in Closed-loop Supply Chain Design**. mai, 2004. Disponível em: <http://www.poms.org/POMSWebsite/Meeting2004/POMS_CD/Browse%20This%20CD/PAPERS/002-274.pdf> Acesso em: 25 jun. 2004.

- HARRISON, T.P.; LEWIS, H.S. **Lot-Sizing in Serial Assembly Systems with Multiple Constrained Resources**, Management Science, 42 (1): p. 19-36, 1996.
- HARTMANN, S.; KOLISCH, R. **Experimental Evaluation of State-of-the-Art Heuristics for the Resource – Constrained Project Scheduling Problem**, INFORMS spring conference, 1998.
- HICKS, D. A. **A four step methodology for using simulation and optimization technologies in strategic supply chain planning**, Proceedings of the 1999 Winter Simulation Conference, Farrington, P. A.; Nembhard, H. B.; Sturrock, D.T.; Evans, G. W. (eds.), p. 1215-1220.
- HWANG, H. -S. **Design of supply-chain logistics systems considering service level**, Computers & Industrial Engineering, vol. 43, p. 283-297, 2002.
- JEONG, B.; JUNG, H. -S.; PARK, N. -K. **A computerized causal forecasting system using genetic algorithms in supply chain management**, The Journal of Systems and Software, vol. 60, p. 223-237, 2002.
- JOHNSON, M. E.; PYKE, D. F. **Supply Chain Management**. jul, 1997. Disponível em: <http://www.mba.tuck.dartmouth.edu/pages/faculty/dave.pyke/case_studies/supply_chain_or_ms.pdf> Acesso em: 20 mar. 2003.
- JOINES, J. A.; GUPTA, D.; GOKCE, M. A.; KING, R. E.; KAY, M. G. **Supply chain multi-objective simulation optimization**, Proceedings of the 2002 Winter Simulation Conference, Yücesan, E.; Chen, C. -H.; Snowdon, J. L.; Chanes, J. M. (eds.), p. 1306-1314, 2002.
- JONES, R. D.; KEMP, M. D. **An Overview of Optimization Technology: Delivering The Competitive Advantage**. out, 2001. Disponível em: <<http://www.nafems.org/publications/downloads/Optimization.pdf>> Acesso em: 07 abr. 2003.

- KARMAKAR, U. S. **The Multilocation Multiperiod Inventory Problem: Bounds and Approximations**, Management Science, 33(1): p. 86-94, 1987.
- KLEYWEGT, A. J.; SHAPIRO, A. **Stochastic optimization**, Handbook of Industrial Engineering, 3rd edition, Gavriel Salvendy, Ed., Jon Wiley, p. 2625-2650, 2001.
- LEE, Y. H.; JEONG, C. S.; MOON, C. **Advanced planning and scheduling with outsourcing in manufacturing supply chain**, Computers & Industrial Engineering, vol. 43, p. 351-374, 2002.
- LEE, Y. H.; KIM, S. H. **Optimal Production-Distribution Planning in Supply Chain Management Using a Hybrid Simulation-Analytic Approach**. 2002. Disponível em: < www.informs-cs.org/wsc00papers/169.PDF> Acesso em: 17 mai. 2003.
- LI, H. L. **An approximate method for local optima for nonlinear mixed integer programming problems**, Computers & Operational Research, vol. 19, no. 5, p. 435-444, 1992.
- LOURENÇO, H. R. Supply Chain Management: **An opportunity for Metaheuristics**. Economic Working Papers Series, n. 538, 2001. Disponível em: <<http://www.ideas.repec.org/p/upf/upfgen/538.html>>. Acesso em: 22 mar. 2003.
- MAN, K. F.; TANG, K. S.; KWONG, S. **Genetic Algorithms: Concepts and Applications**, IEEE Transactions on Industrial Electronics, v. 43, n. 50, p. 519 – 534, 1996.
- MAK, K. L.; WONG, Y. S. **Design of integrated production-inventory-distribution systems using genetic algorithm**, Proceedings of Genetic Algorithms in Engineering Systems: Innovations and Applications, p. 454-460, 1995.
- MARDLE, S.; PASCOE, S. **An overview of genetic algorithms for the solution of optimisation problems**. CHEER Papers, v. 13, issue 1, 1999. Disponível em: <<http://ideas.repec.org/a/che/chepap/v13y1999i1p16-20.html>> Acesso em: 15 abr. 2003.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs**. 3.ed. Springer, 1996. 387p.

MILLER, A. J. **Polyhedral approaches to capacitated lot-sizing problems**, Ph.D. thesis, School of Industrial and Systems Engineering, Georgia Institute of Technology, December, 1999.

NORONHA, T. F. **Uma Abordagem sobre Estratégias Metaheurísticas**, 2001. Disponível em: <<http://www.sbc.org.br/reic/edicoes/2001e1/cientificos/UmaAbordagemSobreEstrategiasMetaheurísticas.pdf>> Acesso em 11 set. 2003.

OCHI, L. S. **Conhecimento Heurístico: Aplicações em Problemas de Otimização**. In: XIV CONGRESSO DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO/XIII JORNADA DE ATUALIZAÇÃO EM INFORMÁTICA, 1994, Caxambú. Apostila. Minas Gerais, 1994, 43p.

PRESS, W. H.; TEUKOLSKY, S. A.; VETTERLING, W. T.; FLANNERY, B. P. **Numerical recipes in c: the art of scientific computing**, 2nd ed. Cambridge Press, 1994.

RIBEIRO, R.; LOURENÇO, H. R. **Strategies for na Integrated Distribution Problem**, 2003. Disponível em: <<http://www.econ.upf.edu/docs/papers/downloads/723.pdf>> Acesso em 11 dez. 2003.

RODRIGUES, L. F. **Meta-Heurísticas Evolutivas para Dimensionamento de Lotes com Restrições de Capacidade em Sistemas Multiestágios**. São Carlos, 2000. 107p. Monografia (Especialização em Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, USP.

ROLL Y.; KARNI R. **Multi-item, Multi-level Lot-Sizing with an Aggregate Capacity Constraint**, European Journal of Operational Research, 51: p. 73-87, 1991.

SAMBASIVAN, M.; SCHMIDT, C. P. **A Heuristic Procedure for Solving Multi-Plant, Multi-Item, Multi-Period Capacitated Lot-Sizing Problems.** Asia-Pacific Journal of operational Research, v. 19, p. 87-105, 2002.

SCARF, H. E. **Inventory Theory**, Operations Research, 50(1): p. 186-191, 2002.

SCHAEFER, A. et al. **Integrated Planning and Operations for Supply Chain Management**, 2001 Disponível em: http://custom.ce.cmu.edu/archives/12162001/miniconference/cdrom/POSTERFILES/HAKAN_YILDIZ.pdf > Acesso em: 20 mar. 2003.

SILVER, E. A.; PYKE, D. F.; PETERSON, R. **Inventory management and production planning and scheduling**, John Wiley & Sons, New York, NY, 1998.

SLACK, N. et. al. **Administração da Produção**. 1.ed. São Paulo: Atlas, 1997. 726p.

SLACK, N. et. al. **Administração da Produção**. Edição compacta. 1 ed. São Paulo: Atlas, 1999. 526p.

SMIRNOV, A. V.; SHEREMETOV, L. B.; CHILOV, N.; CORTES, J. R. **Soft-computing technologies for configuration of cooperative supply chain**, Applied Soft Computing, vol. 4, p. 87-107, 2004.

SOARES, G. L. **Algoritmos Genéticos: Estudo, Novas Técnicas e Aplicações**. Belo Horizonte, 1997. 137p. Monografia (Especialização em Engenharia Elétrica) – Escola de Engenharia, UFMG.

SRINIVAS, M.; PATNAIK, L. M. **Genetic Algorithms: A Survey**, IEEE Computer, v. 27, n. 6, p. 17 – 26, jun. 1994.

STAGGEMEIER, A. T.; CLARK, A. R. **A Survey of Lot-Sizing and Scheduling Models**, Simpósio Brasileiro de Pesquisa Operacional, p. 938-947, 2001

STORN, R.; PRICE, K. **Differential evolution: a simple and efficient adaptive scheme for global optimization over continuous spaces**, Technical Report TR-95-012, International Computer Science Institute, Berkeley, 1995.

STORN, R. **On the Usage of Differential Evolution for Function Optimazation**, 1996. 1996 Biennial Conference of the North American Fuzzy Information Processing Society (NAFIPS1996), Berkeley, p. 519 – 523. IEEE. Disponível em:<<http://www.icsi.berkeley.edu/~storn/litera.html>> Acesso em 07 mai. 2003.

STORN, R.; PRICE, K. **Differential Evolution – A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces**, Journal of Global Optimization, n. 11, p. 341-359, 1997.

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

TOKLU, B.; WILSON, J. M. **A Heuristic for Multi-Level Lot-Sizing Problems with a Bottleneck**, International Journal of Production Research, 30 (4): p. 787-798, 1992.

TOKLU, B.; WILSON, J. M. **An Analysis of Multi-Level Lot-Sizing Problems with a Bottleneck under a Rolling Schedule Environment**, International Journal of Production Research, 33 (7):p. 1835-1847, 1995.

TOMASSINI, M. **A Survey of Genetic Algorithms**. 1995. Disponível em: <<http://www.citeseer.nj.nec.com/tomassini95survey.html>> Acesso em 24 jul. 2003.

- TOMASSINI, M. **Evolutionary Algorithms**. 1996. Disponível em: <<http://www.citeseer.nj.nec.com/tomassini96evolutionary.html>> Acesso em 24 jul. 2003.
- TUBINO, D. F. **Manual de planejamento e controle da produção**. 1 ed. São Paulo: Atlas, 1997, 220p.
- VENKATESWARAN, J.; KULVATUNYOU, B. **Investigation of influence of modeling fidelities on supply chain dynamics**, Proceedings of the 2002 Winter Simulation Conference, Yücesan, E.; Chen, C. -H.; Snowdon, J. L.; Chanes, J. M. (eds.), p. 1183-1191, 2002.
- VERGARA, F. E.; KHOUJA, M.; MICHALEWICZ, Z. **An evolutionary algorithm for optimizing material flow in supply chains**, Computers & Industrial Engineering, n.43, p. 407-421, 2002.
- VIANA, J. J. **Administração de Materiais: um enfoque prático**. São Paulo: Atlas, 2000.
- VICKERY, S. K.; MARKLAND, R. E. **Multi-stage lot sizing in a serial production system**, International Journal of Production Research, 24(3), p. 517-534, 1986.
- WAGNER, H. M.; WHITIN, T. M. **Dynamic Version of the Economic Lot Size Model**, Management Science, 5, p. 89-96, 1959.
- WEI, J.; KRAJEWSKI, L. A model for comparing supply chain schedule integration approaches, International Journal of Production Research, 58(9), p. 2099-2123, 2000.
- WOLPERT, D. H.; MACREADY, W. G. **No free lunch theorems for optimization**, IEEE Transactions on Evolutionary Computation, vol. 1, no. 1, p. 67-82, 1997.

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