



ISSN 2175-6295

Rio de Janeiro- Brasil, 07 e 08 de novembro de 2007.

SPOLM2007

## ALGORITMOS GENÉTICOS NA ESTIMAÇÃO DE PARÂMETROS EM GESTÃO DE ESTOQUE

**Sidnei Alves de Araújo<sup>1,2</sup>**

<sup>1</sup>Centro Universitário Nove de Julho – Depto. Ciências Exatas  
Rua Diamantina 302, CEP 02117-010, São Paulo–SP, Brasil

<sup>2</sup>Universidade de São Paulo – Escola Politécnica – Depto. Eng. Sistemas Eletrônicos  
Av. Prof. Luciano Gualberto, tr. 3, 158, CEP 05508-900, São Paulo–SP, Brasil

saraujo@uninove.br

**André Felipe Henriques Librantz, Lin Chau Jen, Wonder Alexandre Luz Alves**

Centro Universitário Nove de Julho – Depto. Ciências Exatas  
Rua Diamantina 302, CEP 02117-010, São Paulo–SP, Brasil

{librantz, linchau, wonder}@uninove.br

### Resumo

A gestão de estoque é um dos instrumentos imprescindíveis para eficiência das organizações modernas. Em modelos de gestão de estoques é comum necessidade de estimação de variáveis que estão relacionadas com algumas incertezas. Para estimação de tais variáveis, normalmente utilizam-se algoritmos matemáticos de aproximação, visto que se trata de problemas, nos quais a exploração de todo o espaço de soluções torna-se inviável na maioria dos casos. Uma alternativa para solução de problemas de otimização tem sido o uso dos Algoritmos Genéticos (AG's) e das Redes Neurais Artificiais (RNA's). Neste trabalho, é apresentado um método baseado em Algoritmos Genéticos, que é uma técnica de otimização inspirada na genética e evolução natural, para estimação de parâmetros, a fim de maximizar a gestão de estoque. A técnica de AG foi implementada e testada com sucesso, e os resultados estão em boa concordância com aqueles obtidos a partir o emprego de busca exaustiva, o que justifica a aplicação dos AG's em problemas desta natureza.

**Palavras-Chaves:** Algoritmos Genéticos; Gestão de estoques; Estimação de parâmetros.

### Abstract

Inventory management is one important instrument regarding the efficiency of modern organizations. In such models, the necessity of parameters estimate is usual, which can be related to some uncertainties. For this purpose, algorithms of approximation are commonly used, once this kind of problem deals with a big solution domain that can make unfeasible the testing of all them. Thus, an interesting alternative to solve problems of this

nature, is the application of genetic algorithm (GA) and neural network techniques (ANN), as well. In this work, it was presented a method based on the Genetic Algorithms, which is an optimization technique inspired by genetics and natural evolution, in the parameters estimation, in order to maximize the inventory management. The GA technique was implemented and tested successfully, and the obtained results are in a good agreement with the results obtained by exhaustive searching algorithm that justifies the application of the GA method in problems of this nature.

**Keywords:** Genetic Algorithms; Inventory management; Parameters estimation.

## 1. INTRODUÇÃO

Sistemas de controle de estoque constituem um tema clássico na engenharia, particularmente, na modalidade industrial e de produção. Anos atrás, o estoque era visto como um ativo da empresa na medida em que minimizava as perdas decorrentes de eventuais problemas na sua linha de produção. Hoje, entretanto, com o advento das técnicas modernas de produção enxuta, o estoque é visto mais como um passivo, devido aos seus custos associados de matéria prima, de manuseio e de armazenamento [1]. O estudo de modelos de gestão de estoques não é simples dada a presença de incertezas, isto é, variáveis que não podem ser preditas antecipadamente e que precisam ser estimadas de alguma forma. Saber trabalhar com incertezas é uma importante habilidade para o sucesso de qualquer profissional e de qualquer empresa [2].

Problemas de otimização como este de gestão de estoque são encontrados em uma variedade de tarefas nas organizações tais como escalonamento de processos, sequenciamento de processos operacionais, roteamento de veículos, entre outros. A solução de um problema de otimização geralmente envolve a maximização ou minimização de uma função objetivo definida sobre um certo domínio. Para solução de tarefas desta natureza normalmente utilizam-se algoritmos de aproximação tais como *simulated annealing*, busca tabu e subida de encosta, dada a dificuldade de exploração de todo o domínio para se obter a solução ótima para o problema. Observa-se que na maioria dos casos, vale a pena obter uma aproximação de boa qualidade e que possa ser rapidamente calculada em detrimento à otimalidade, que em muitos casos é computacionalmente inviável [3]. Neste contexto, a Inteligência Artificial (IA) dispõe de algumas técnicas como os Algoritmos Genéticos (AG's) e as Redes Neurais Artificiais (RNA's) que podem ser empregadas na solução de tais problemas [3,4,5,6,7]. Ambas as técnicas, se bem utilizadas, são capazes de convergirem para uma solução de forma rápida e eficiente. Nota-se, no entanto, que embora estas técnicas venham sendo largamente utilizadas em problemas de planejamento da produção, ainda são poucas as aplicações que envolvem diretamente a de gestão de estoques [3]. Esse fato sinaliza a existência de um campo de pesquisa ainda pouco explorado e com grande potencial já que os AG's, por exemplo, têm apresentado grande sucesso na resolução de problemas combinatórios similares ao de gestão de estoques aqui apresentado.

Neste trabalho, explora-se o uso dos AG's na estimação de dois parâmetros que maximizam a função de avaliação do modelo de gestão de estoque. São eles: ponto de reposição e tamanho do lote. Estes parâmetros estimados a partir do uso dos AG's foram comparados com os obtidos por meio da busca exaustiva, considerando um domínio, a fim de comprovar a eficiência dos AG's na solução do problema.

## 2. MODELO DE GESTÃO DE ESTOQUE COM BASE EM PONTO DE REPOSIÇÃO/TAMANHO DO LOTE

Este tipo de modelo é definido basicamente por duas incertezas: a demanda diária do produto e o prazo de entrega do produto pelo fornecedor (*lead time*). Essas incertezas

possuem suas distribuições de probabilidade apresentadas por meio de curvas normais (distribuição Gaussiana), de maneira que se conhece a média e o desvio padrão de cada distribuição. A figura 1 apresenta um exemplo das distribuições das incertezas do modelo.

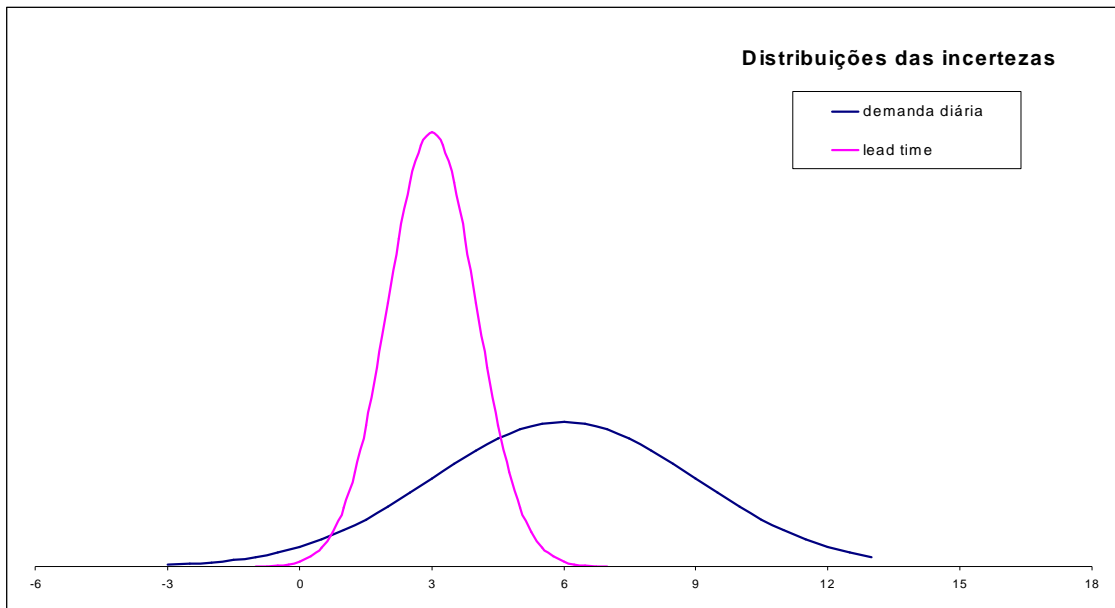


Figura 1 - As distribuições das duas incertezas envolvidas no problema.

Na figura 1, observa-se que a demanda diária de um produto fictício tem média de 6 unidades, mas pode assumir qualquer valor acima de zero (valores negativos não têm sentido e valores acima de 12 ou 13 unidades têm probabilidades extremamente reduzidas). O tempo de entrega do produto (*lead time*) tem média de 3 dias e também pode assumir qualquer valor acima de zero (fortemente concentrado no intervalo entre 0 e 6 dias). A figura 2 ilustra uma possibilidade de evolução do estoque do produto considerando o intervalo de 29 dias.




Figura 2 – Exemplo da evolução do estoque de um produto durante 29 dias.

No exemplo ilustrado na figura 2, pode-se notar que há períodos nos quais não existe unidade do produto no estoque. Nesses momentos, não há como atender as possíveis demandas do produto.

A gestão do estoque é realizada por meio do estabelecimento de dois parâmetros: o ponto de reposição e o tamanho do lote. O ponto de reposição é o nível do estoque que,

quando atingido, dispara uma solicitação de reposição ao fornecedor, que irá entregar um lote de dimensão estabelecido pelo tamanho do lote. Modelos desse tipo formam a base de muitos sistemas comerciais de controle de estoque [8,9].

O gestor do sistema de estoque se vê face aos seguintes problemas: (a) se sua estratégia for trabalhar com pouco estoque, o número de vezes que poderá não atender demandas será elevado, por estar com estoque insuficiente devido às incertezas do tempo de entrega dos lotes solicitados e das demandas de grande quantidade; não será uma estratégia que busca a fidelização dos clientes; (b) por outro lado, se trabalhar com estoques elevados, poderá estar empatando capital financeiro significativo, o que pode implicar na elevação do preço do produto. Assim, há que buscar um compromisso entre os diferentes valores institucionais e econômicos. Por exemplo, se o interesse for obter um elevado nível de atendimento, o estoque médio deve se manter em um nível relativamente alto, o que pode exigir um significativo capital empatado no estoque.

O critério de avaliação da gestão do estoque depende de vários fatores, desde o valor unitário do produto ao objetivo estratégico do momento da empresa. Neste trabalho, esse critério é estabelecido por meio da média ponderada de dois fatores. Um dos fatores é o nível de atendimento ( $NA$ ) e o outro, de ordem econômica e denominado critério econômico ( $CE$ ), está associado ao nível diário médio do estoque. São os coeficientes da ponderação que estabelecem a importância de cada fator. Dessa forma, o problema pode se traduzir em encontrar o conjunto de valores dos parâmetros de gestão (ponto de reposição e tamanho do lote) que resulte no valor máximo do critério de avaliação [10].

O critério de avaliação citado anteriormente será denominado, neste trabalho, como função objetivo ( $FO$ ) e é definido a partir da seguinte relação:

$$FO = (NA * \alpha) + (CE * \beta), \alpha e \beta \in [0,1] \quad (1)$$

Onde  $NA$  é o nível de atendimento (equação 2) e  $CE$  é o critério econômico (equação 3).

$$NA = \frac{\text{Soma da demanda atendida}}{\text{Demanda total}} \quad (2)$$

$$CE = e^{A * \text{media do estoque diario}} \quad (3)$$

Onde o parâmetro  $A$  é definido por:

$$A = \log \left( \frac{10^{-3}}{10 * \text{Media da demanda}} \right) \quad (4)$$

Os parâmetros  $\alpha$  e  $\beta$  na equação 1 definem o peso de cada uma das parcelas, ou seja, estão relacionados à característica da gestão. Desta forma, a função objetivo serve como balanço entre critério econômico e o nível de atendimento. O coeficiente  $A$  foi determinado empiricamente a partir da análise do comportamento da função que define o critério econômico (equação 3).

### 3. ALGORITMOS GENÉTICOS

O Algoritmo Genético consiste de um método de busca e otimização baseado no processo de seleção natural que simula a evolução das espécies [11,12,13,14]. Os AG's geram os indivíduos (cadeias de bits) também chamados de cromossomo, para evoluírem em busca da solução de um dado problema. Cada indivíduo representa uma possível solução para o problema. Com a dinâmica do algoritmo, os indivíduos competem entre si e os mais aptos são selecionados para em seguida serem cruzados e gerarem novos indivíduos mais aptos e,

portanto, melhores que os anteriores. Dessa forma, a cada nova geração deve haver um indivíduo mais próximo de uma solução para o problema. Se um AG for desenvolvido corretamente, deve convergir para uma solução do problema proposto. Ao contrário dos processos de busca e otimização tradicionais, os AG's trabalham num processo de busca sobre a população de indivíduos em paralelo, fazendo a avaliação das soluções em diferentes regiões do espaço de buscas.

Os AG's constituem uma ferramenta poderosa para resolução de problemas complexos cujos espaços de busca das soluções ótimas sejam muito grandes para que se possa determiná-las com precisão através de um método direto. Cabe ressaltar que essas soluções ótimas, em alguns casos, podem nem existir. Além disso, muitas vezes, o que realmente precisamos é de uma aproximação que nos dê um resultado satisfatório dentro do contexto do problema [15].

Os elementos básicos de um AG são: (a) cromossomo: conjunto de bits (também chamado de indivíduo da população); (b) gene: subconjunto de bits do cromossomo e (c) alelo: cada bit de um gene.

A estrutura básica de um AG contempla quatro principais operações: o cálculo de aptidão (*fitness*), a seleção, o cruzamento (*crossover*) e a mutação, as quais são ilustradas no diagrama da Figura 3.

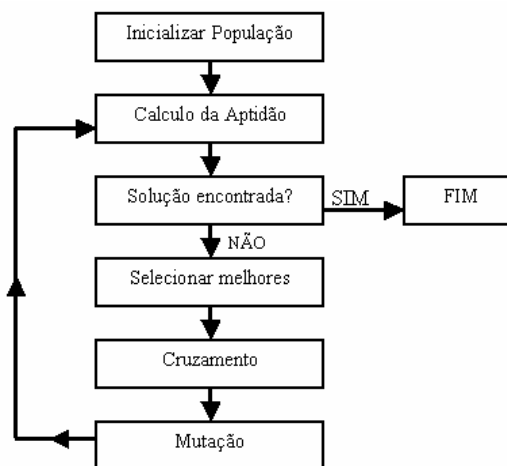


Figura 3 - Estrutura básica do AG.

O processo de funcionamento de um AG começa com uma população de indivíduos (estados de busca) gerados aleatoriamente chamados de população inicial. Um indivíduo normalmente é formado por uma string binária que é convertida para um valor decimal a ser avaliado de acordo com seu *fitness*. O tamanho da população é definido com base no problema a ser solucionado. Essas estruturas são então avaliadas para gerar oportunidades reprodutivas de forma que os cromossomos que representam as “melhores soluções” tenham maiores chances de se reproduzir. A definição de uma solução melhor ou pior está relacionada ao problema e é quantificada de acordo com uma função de aptidão.

O cálculo da aptidão serve para analisar os indivíduos que serão selecionados, a partir da população. Normalmente, por se tratar de otimização, a aptidão serve para minimizar ou maximizar uma função objetivo. Ela fornece uma medida da proximidade da solução em relação a um conjunto de parâmetros, visando encontrar o ponto ótimo. Neste trabalho, a função de aptidão é a própria função objetivo definida na equação 1.

O processo de seleção consiste na escolha dos melhores indivíduos que serão os reprodutores. Dessa forma, aqueles com maior aptidão são selecionados para a reprodução enquanto os outros são descartados. Cada indivíduo tem uma probabilidade de ser selecionado proporcional à sua aptidão. O *crossover* tem a função de recombinar o material genético dos

indivíduos anteriores. A escolha de quem vai cruzar com quem, pode ser feita aleatoriamente ou seguir alguma regra definida pelo desenvolvedor do algoritmo. Normalmente os melhores indivíduos geram mais filhos que os demais. Na Figura 4, é ilustrado um esquema de *crossover* simples (com apenas um ponto de corte).




Figura 4 - Crossover simples com um ponto de corte.

Para evitar que o AG convirja muito cedo para mínimos locais, é feita a operação de mutação, o que promove a alteração de um ou mais alelos de um cromossomo sorteado aleatoriamente com uma determinada probabilidade. Quando o cromossomo é representado por uma string binária os valores 1 são trocados por 0 e vice versa como ilustrado na Figura 5.




Figura 5 – Exemplo de mutação.

É de fundamental importância para uma convergência rápida, a escolha adequada dos parâmetros do AG. Um fator importante é a taxa de alelos a serem mutados, que deve variar de 5% a 10% de acordo com o tamanho da população.

#### 4. METODOLOGIA PARA ESTIMAÇÃO DOS PARÂMETROS DA GESTÃO DE ESTOQUE POR MEIO DO AG

Para que o AG pudesse ser modelado com intuito de encontrar o par de valores ponto de reposição e tamanho do lote para atender as restrições do modelo abordado e maximizar a função objetivo (equação 1), o ponto de partida foi definir o tamanho do cromossomo. Para isso, primeiramente definiu-se o intervalo de valores que os dois parâmetros a serem estimados poderiam assumir. Nos baseamos num produto fictício com demanda média diária de 50 a 200 unidades e *lead time* variando de 5 a 7 dias. Além disso, definimos algumas restrições: (a) tanto o ponto de reposição quanto tamanho do lote deve estar no intervalo de 2 a 10 vezes a demanda média diária; (b) se prioridade da gestão for o nível de atendimento ao cliente ( $NA > CE$ ), então o tamanho do lote não deve ser inferior ao ponto de reposição; (c) se a prioridade da gestão for o critério econômico, ( $CE > NA$ ), então o tamanho do lote deve ser menor que o ponto de reposição.

Diante das premissas adotadas, definimos o cromossomo (Figura 6) com 22 alelos divididos em dois genes de 10 alelos. O primeiro gene foi associado ao parâmetro ponto de reposição e o segundo ao tamanho do lote. Como cada gene tem 11 bits, é possível representar, para cada parâmetro um valor no intervalo  $[0,2^{11}-1]$ , o que atende as restrições impostas. O AG foi configurado da seguinte maneira: (a) Quantidade de indivíduos por população: 100; (b) Quantidade de indivíduos selecionados para crossover em cada geração:

30; (c) Quantidade máxima de gerações para obter a solução do problema: 100; (d) Pontos de corte: 2 (aleatórios); (e) Taxa de mutação: 10%.




Figura 6 - Ilustração do cromossomo utilizado. O primeiro gene representa o parâmetro ponto de reposição e o segundo, tamanho do lote.

A função de aptidão para avaliação dos indivíduos, como mencionado anteriormente, é a própria função objetivo que avalia a qualidade da gestão e que foi definida na equação 1. É importante ressaltar que a avaliação de cada indivíduo da população depende da geração de novas observações levando em conta o par de parâmetros estimados e as distribuições de probabilidade da demanda e do *lead time*. Para isso, utilizamos o método de Monte Carlo considerando um período de 5000 dias. Este processo aumenta consideravelmente o tempo de busca que o AG consome para encontrar uma solução para o problema. Por este motivo, optamos pela sua implementação em linguagem C, na tentativa de “compensar” este custo adicional. Para realização dos experimentos utilizou-se um microcomputador P4-2.8 GHz.

Com relação ao critério de parada do AG, a solução é considerada encontrada se  $FO \geq l$  onde  $l$  é um limiar determinado a priori ou se a quantidade máxima de gerações é atingida.

## 5. RESULTADOS EXPERIMENTAIS

Com intuito de avaliar a qualidade das soluções encontradas pelo AG, realizamos uma série de experimentos envolvendo 3 diferentes cenários (Tabela 1) e utilizando, em cada cenário, 3 diferentes estratégias de gestão. Para cada estratégia de gestão, executamos 10 vezes o AG e comparamos o valor médio da função objetivo com o valor “ótimo” obtido pelo método da Busca exaustiva (BE) no qual se calcula o valor da função objetivo para todas as combinações possíveis considerando os intervalos de valores definidos para os parâmetros ponto de reposição e tamanho do lote. Cabe ressaltar que, embora custoso computacionalmente, explorar todo o espaço de busca para selecionar a melhor solução a fim de aferir o resultado do AG só foi possível porque: (a) limitamos o intervalo de valores para os parâmetros a serem estimados (2 a 10 vezes a média da demanda média diária) e (b) os valores a serem estimados exprimem quantidades de produtos e, portanto, são discretos. Os resultados dos experimentos supra citados podem ser vistos nas tabelas 2 a 4 a seguir.

Tabela 1. Cenários utilizados nos experimentos.

Parâmetros de controle	Cenários		
	Cenário 1	Cenário 2	Cenário 3
Media demanda	50	100	200
Desvio padrão demanda	10	20	50
Media lead time	5	5	7
Desvio padrão lead time	1	1	2
Estoque inicial	15	150	500

Na tabela 1 é possível verificar o conjunto de valores dos parâmetros de controle utilizados para os 3 cenários. Em cada uma das tabelas, de 2 a 4 a seguir, considera-se um cenário e para cada um deles, 3 estratégias de gestão diferentes. Cada estratégia é caracterizada pelo par de fatores  $\alpha$  (nível atendimento) e  $\beta$  (critério econômico) que estão

diretamente relacionados com a função objetivo (FO), definida na equação 1. Outros dados associados aos experimentos são: tempo de processamento em segundos (TP), ponto de reposição (PR) e tamanho do lote (TL). Estes dois últimos são os parâmetros estimados pelo AG.

Tabela 2. Resultados obtidos para o conjunto de parâmetros de controle do cenário 1.

Cenário 1 - Estratégias da gestão												
	$\alpha = 0,5; \beta = 0,5$				$\alpha = 0,7; \beta = 0,3$				$\alpha = 0,3; \beta = 0,7$			
Exp.	TP	PR	TL	FO	TP	PR	TL	FO	TP	PR	TL	FO
1	9,0	212	115	0,6550	9,1	245	255	0,7186	9,1	400	101	0,7280
2	9,1	396	107	0,6551	9,1	230	237	0,7175	9,1	376	103	0,7275
3	9,1	209	113	0,6590	9,1	269	271	0,7174	9,1	324	104	0,7255
4	9,2	390	107	0,6527	9,2	223	238	0,7212	9,2	296	106	0,7187
5	9,0	322	123	0,6536	9,0	222	243	0,7166	9,2	417	104	0,7247
6	9,1	375	128	0,6516	9,1	195	223	0,7175	9,1	494	105	0,7256
7	9,1	324	100	0,6523	9,1	228	258	0,7206	9,1	123	100	0,7277
8	9,1	200	104	0,6517	9,0	242	272	0,7195	9,4	270	103	0,7261
9	9,1	376	103	0,6527	9,1	249	279	0,7175	9,1	141	101	0,7261
10	9,2	468	139	0,6533	9,1	238	243	0,7212	9,1	139	100	0,7280
<b>Média</b>	<b>9,1s</b>	<b>-</b>	<b>-</b>	<b>0,6537</b>	<b>9,1s</b>	<b>-</b>	<b>-</b>	<b>0,7187</b>	<b>9,2s</b>	<b>-</b>	<b>-</b>	<b>0,7258</b>
<b>BE</b>	<b>107s</b>	<b>487</b>	<b>107</b>	<b>0,6586</b>	<b>106s</b>	<b>223</b>	<b>241</b>	<b>0,7290</b>	<b>109s</b>	<b>443</b>	<b>100</b>	<b>0,7285</b>

Tabela 3. Resultados obtidos para o conjunto de parâmetros de controle do cenário 2.

Cenário 2 - Estratégias da gestão												
	$\alpha = 0,5; \beta = 0,5$				$\alpha = 0,7; \beta = 0,3$				$\alpha = 0,3; \beta = 0,7$			
Exp.	TP	PR	TL	FO	TP	PR	TL	FO	TP	PR	TL	FO
1	9,4	603	213	0,6549	9,4	472	493	0,7232	9,4	742	203	0,7249
2	9,3	738	249	0,6541	9,2	495	544	0,7202	9,3	975	205	0,7293
3	9,4	660	201	0,6531	9,3	442	459	0,7211	9,4	317	208	0,7229
4	9,4	782	230	0,6534	9,3	501	536	0,7186	9,3	355	206	0,7279
5	9,4	750	211	0,6523	9,3	415	461	0,7220	9,3	224	203	0,7253
6	9,4	527	223	0,6528	9,3	418	477	0,7232	9,2	414	200	0,7280
7	9,3	390	203	0,6546	9,2	491	510	0,7220	9,3	973	201	0,7277
8	9,2	387	213	0,6545	9,3	362	426	0,7194	9,3	446	201	0,7251
9	9,4	548	208	0,6524	9,4	434	455	0,7230	9,3	729	202	0,7292
10	9,3	423	254	0,6545	9,4	424	431	0,7205	9,3	804	204	0,7274
<b>Média</b>	<b>9,4s</b>	<b>-</b>	<b>-</b>	<b>0,6537</b>	<b>9,3s</b>	<b>-</b>	<b>-</b>	<b>0,7213</b>	<b>9,3s</b>	<b>-</b>	<b>-</b>	<b>0,7268</b>
<b>BE</b>	<b>428s</b>	<b>576</b>	<b>222</b>	<b>0,6563</b>	<b>424s</b>	<b>449</b>	<b>461</b>	<b>0,7288</b>	<b>424s</b>	<b>553</b>	<b>200</b>	<b>0,7290</b>



Tabela 4. Resultados obtidos para o conjunto de parâmetros de controle do cenário 3.

Cenário 3 - Estratégias da gestão												
Exp.	$\alpha = 0,5; \beta = 0,5$				$\alpha = 0,7; \beta = 0,3$				$\alpha = 0,3; \beta = 0,7$			
	TP	PR	TL	FO	TP	PR	TL	FO	TP	PR	TL	FO
1	9,6	1374	469	0,6126	9,4	1806	1988	0,7006	9,5	987	405	0,7147
2	9,6	1703	401	0,6068	9,7	1522	1944	0,6997	9,6	1483	400	0,7177
3	9,5	1890	441	0,6099	9,6	1624	1776	0,7005	9,6	1487	411	0,7154
4	9,6	729	451	0,6081	9,5	1845	1971	0,7006	9,4	1754	414	0,7179
5	9,5	1164	532	0,6059	9,5	1860	1926	0,7014	9,5	809	405	0,7144
6	9,5	895	451	0,6076	9,5	1736	1740	0,7010	9,5	761	404	0,7178
7	9,5	948	493	0,6080	9,6	1937	1937	0,7050	9,6	1627	400	0,7185
8	9,5	1601	431	0,6072	9,6	1889	1949	0,7012	9,5	1898	407	0,7178
9	9,4	1155	433	0,6073	9,5	1781	1946	0,7001	9,5	654	404	0,7119
10	9,5	1839	451	0,6091	9,5	1909	1939	0,6998	9,5	1478	400	0,7170
<b>Média</b>	<b>9,5</b>	-	-	<b>0,6083</b>	<b>9,5</b>	-	-	<b>0,7010</b>	<b>9,5</b>	-	-	<b>0,7163</b>
<b>BE</b>	<b>1686s</b>	<b>1882</b>	<b>426</b>	<b>0,6089</b>	<b>1654s</b>	<b>1919</b>	<b>1942</b>	<b>0,7108</b>	<b>1652s</b>	<b>847</b>	<b>403</b>	<b>0,7181</b>

Os resultados reportados nas tabelas de 2 a 4 mostram que na gestão de estoque de produtos em pequena quantidade, o método de busca exaustiva pode ser viável. À medida que aumenta a quantidade de um produto, explorar todo o espaço de buscas vai se tornando bastante dispendioso no que concerne o tempo de processamento. Os valores obtidos pelos 2 métodos mostraram diferenças pouco significativas sendo as soluções encontradas pelo AG adequadas a todos os cenários propostos no trabalho.

## 6. CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho explorou-se o uso de algoritmos genéticos na estimação dos parâmetros ponto de reposição e tamanho de lote em um modelo de gestão de estoques. Os resultados obtidos demonstraram que os valores estimados pelo algoritmo genético são muito próximos dos valores “ótimos”, os quais foram obtidos a partir da exploração de todo o espaço de buscas dos casos abordados. Em adição, pode-se inferir que em espaços amostrais nos quais o domínio das soluções é pequeno, os métodos tradicionais ou mesmo a busca exaustiva são viáveis, dispensando aplicação de técnicas “inteligentes” para estimação dos parâmetros. No entanto, à medida que o espaço de soluções torna-se maior, o uso de algoritmos genéticos pode ser uma alternativa interessante na solução do problema abordado e outros de natureza semelhante.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. Fundamentos da Administração da Produção. 3. ed. Porto Alegre: Bookman Editora, 2001.
- [2] GAITHER, N.; FRAZIER, G. Administração da Produção e Operações. 8. ed. São Paulo: Pioneira Thomson Learning, 2001.

- [3] ZNAMENKY, A.; CUNHA, C. B. O problema de estoque-roteirização com demanda determinística. *Revista Transportes*, São Paulo, v. 11, n. 2, p. 31-40, dez. 2003.
- [4] MACEDO, R. A. et al. Estimação de parâmetros de um sistema elétrico de potência utilizando algoritmos genéticos. *Revista IEE América Latina*, v. 4, n. 1, p. 47-54, 2006.
- [5] Widrow, B.; Rumelhart, D. E.; Lehr, M. A. Neural networks: Applications in industry, business and science. *Communications of the ACM*, v.37, n.3, p. 93-105, 1994.
- [6] PINTO, P. R. et al. Utilização de inteligência artificial (redes neurais artificiais) no gerenciamento de reprodutoras pesadas de uma empresa avícola do sul do Brasil. In: *Anais do XIII Salão de Iniciação Científica*, 2001, Porto Alegre-RS, p. 154-154.
- [7] BIALOSKORSKI NETO, S. et al. Monitoramento de Cooperativas Agropecuárias: Um ensaio Utilizando-se de Modelo de Redes Neurais. In: *Anais do III Congresso Internacional de Economia e Gestão de Negócios Agroalimentares*, 2001, Ribeirão Preto-SP.
- [8] NAHMIAS, S. *Production and Operations Analysis*. 3. ed. Chicago: McGraw-Hill, 1997.
- [9] CASTRO, J. G.; PIZZOLATO, N. D. A Programação de lotes econômicos de produção (ELSP) com tempos e custos de setup dependentes da seqüência: um estudo de caso. *Revista Gestão Industrial*, CEFET-PR Paraná, v. 1, n. 3, p. 357-367, 2005.
- [10] SING, H., FOSTER, J. B. Production scheduling with sequence dependent setup costs, *IIE transactions*, v. 19, n.1, p. 43-49, 1987.
- [11] Russel, S.; Norvig, P. *Artificial intelligence: a modern approach*. New Jersey: Prentice Hall, 1995.
- [12] GOLDBERG, D. E. *Genetic algorithms in search, optimization, and machine learning*. Massachusetts: Addison-Wesley Pub. Inc., 1989.
- [13] HAUPT, R. L.; HAUPT, S. E. The Binary Genetic Algorithm. In: HAUPT, R. L.; HAUPT, S. E. *Practical Genetic Algorithms*. 1. ed., New York: Wiley-Interscience, 1998. Cap. 2, p. 25-48.
- [14] MICHALEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. New York: Springer-Verlag Berlin Heidelberg, 1996
- [15] CRUZ, A. J. O.; DEMASI, P. Algoritmos Coevolucionários Cooperativos em Jogos. In: *Proceedings of the 1st Brazilian Workshop in Games and Digital Entertainment*, 2002. v. 1, p. 1-6.