

Algoritmos genéticos na estimação de parâmetros em gestão de estoque

Sidnei Alves de Araújo

Doutorando em Engenharia Elétrica – Poli/USP;
Professor e pesquisador do Departamento
de Ciências Exatas – Uninove.
São Paulo – SP [Brasil]
saraujo@uninove.br

André Felipe Henriques Librantz

Pós-Doutorado pelo Ipen – USP;
Diretor do Programa de *Stricto Sensu* em Engenharia de
Produção e Professor pesquisador do Departamento de
Ciências Exatas – Uninove.
São Paulo – SP [Brasil]
librantz@uninove.br

Wonder Alexandre Luz Alves

Mestrando em Ciência da Computação – IME/USP;
Professor e pesquisador do Departamento
de Ciências Exatas – Uninove.
São Paulo – SP [Brasil]
wonder@uninove.br

A gestão de estoque é um dos instrumentos imprescindíveis para eficiência das organizações modernas. Em modelos de gestão de estoques, é comum a necessidade de estimação de variáveis relacionadas com algumas incertezas. Normalmente, utilizam-se para isso algoritmos matemáticos de aproximação, visto que se trata de problemas, nos quais a exploração de todo o espaço de soluções se torna inviável na maioria dos casos. Uma alternativa para solução de problemas de otimização tem sido o uso dos algoritmos genéticos (AGs) e das redes neurais artificiais (RNAs). Neste trabalho, é apresentado um método baseado em algoritmos genéticos, que é uma técnica de otimização inspirada na genética e na evolução natural, para estimação de parâmetros, a fim de maximizar a gestão de estoque. Essa técnica foi implementada e testada com sucesso, e os resultados são equivalentes àqueles obtidos a partir do emprego de busca exaustiva, o que justifica a aplicação dos AGs em problemas dessa natureza.

Palavras-chave: Algoritmos genéticos. Estimação de parâmetros. Gestão de estoques.



1 Introdução

Sistemas de controle de estoque constituem um tema clássico na engenharia, particularmente na modalidade industrial e de produção. Há anos, 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, em decorrência dos custos de matéria-prima, de manuseio e de armazenamento (DAVIS; AQUILANO; CHASE, 2001). O estudo de modelos de gestão de estoques não é simples, dada a presença de incertezas, isto é, variáveis que não podem ser preditas e que precisam ser estimadas de alguma forma. Saber trabalhar com incertezas é uma importante habilidade para o sucesso de quaisquer profissionais ou empresas (GAITHER; FRAZIER, 2001).

Problemas de otimização, como o de gestão de estoque, são encontrados em uma variedade de tarefas como escalonamento de processos, sequenciamento de processos operacionais e roteamento de veículos. Geralmente, a solução de um problema de otimização envolve a maximização ou minimização de uma função-objetivo definida sobre certo domínio. Para solução de tarefas dessa natureza, normalmente se utilizam algoritmos de aproximação, tais como *simulated annealing*, busca tabu e subida de encosta, dada a dificuldade de exploração de todo o domínio para a solução do problema. Observa-se que, na maioria dos casos, vale a pena obter uma aproximação de boa qualidade que possa ser rapidamente calculada em detrimento da otimalidade, que, em muitos casos, é computacionalmente inviável (ZNAMENKY; CUNHA, 2003). Nesse contexto, a inteligência artificial (IA) dispõe de algumas técnicas como os algoritmos genéticos (AGs) e as redes neurais artificiais (RNAs), que podem ser empregadas na so-

lução desses problemas (ZNAMENKY; CUNHA, 2003; MACEDO et al., 2006; WIDROW; RUMELHART; LEHR, 1994; PINTO et al., 2001; BIALOSKORSKI NETO et al., 2001). Ambas as técnicas, se bem utilizadas, são capazes de convergir para uma solução, de forma rápida e eficiente. Nota-se, no entanto, que, embora essas técnicas venham sendo largamente utilizadas em problemas de planejamento da produção, ainda são poucas as aplicações que envolvem diretamente a gestão de estoques (ZNAMENKY; CUNHA, 2003). Esse fato sinaliza a existência de um campo de pesquisa ainda pouco explorado e com grande potencial, já que os AGs, 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 AGs na estimação de dois parâmetros que maximizam a função de avaliação do modelo de gestão de estoque: ponto de reposição e tamanho do lote. Esses parâmetros, estimados a partir do uso dos AGs, foram comparados com os obtidos por meio da busca exaustiva, considerando um domínio, para comprovar a eficiência dos AGs na solução do problema.

2 Modelo de gestão de estoque com base em ponto de reposição/tamanho do lote

Este modelo é definido basicamente por duas incertezas cujas distribuições de probabilidade são conhecidas: a demanda diária do produto e seu prazo de entrega pelo fornecedor (*lead time*). 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 vai entregar um lote de dimensão estabelecido pelo tamanho do lote. Modelos desse tipo formam a base de muitos sistemas comerciais de controle de estoque (NAHMIAS, 1997; CASTRO; PIZZOLATO, 2005).

O gestor do sistema de estoque se vê diante dos seguintes problemas: (a) se sua estratégia for trabalhar com pouco estoque, o número de vezes que poderá não atender a demandas será elevado, por estar com estoque insuficiente em razão das incertezas do tempo de entrega dos lotes e da grande quantidade de demandas; não será uma estratégia que busca a fidelização dos clientes; (b) por outro lado, se trabalhar com estoques elevados, poderá empatar capital financeiro significativo, o que pode implicar a 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 deverá manter-se 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 até o objetivo estratégico do momento da empresa. Neste trabalho, esse critério é estabelecido por meio da média ponderada de dois fatores. Um deles é o nível de atendimento (NA), e o outro, de ordem econômica, denominado critério econômico (CE), está associado ao nível diário médio do estoque. Os coeficientes da ponderação é 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 (SING; FOSTER, 1987).

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

$$FO = (NA \cdot \alpha) + (CE \cdot \beta), \alpha \text{ e } \beta \in [0,1] \quad (1)$$

Em que NA é o nível de atendimento (equação 2), e CE, o critério econômico (equação 3).

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

$$CE = e^{A \cdot \text{média do estoque diário}} \quad (3)$$

Em que o parâmetro A é definido por:

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

Os parâmetros α e β na equação 1 definem o peso de cada uma das parcelas, ou seja, estão relacionados à característica da gestão. Dessa forma, a função objetivo serve de balanço entre o 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).

A Figura 1 ilustra uma possibilidade de evolução do estoque de um determinado produto, considerando um intervalo de 29 dias.

No exemplo ilustrado na Figura 1, pode-se notar que há períodos nos quais não existe unidade do produto em estoque. Nesses momentos, não há como atender as possíveis demandas do produto, o



Figura 1: Exemplo da evolução do estoque de um produto durante 29 dias

Fonte: Os autores.



que poderia comprometer a gestão, caso a estratégia priorizasse a fidelização dos clientes.

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 (RUSSEL; NORVIG, 1995; GOLDBERG, 1989; HAUPT; HAUPT, 1998; MICHALEWICZ, 1996). Os AGs geram os indivíduos (cadeias de bits), também chamados de cromossomos, para evoluírem em busca da solução de um dado problema. Com a dinâmica do algoritmo, tais indivíduos competem entre si e os mais aptos são selecionados para, em seguida, serem cruzados e gerar 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, deverá convergir para uma solução do problema proposto. Ao contrário dos processos de busca e otimização tradicionais, os AGs 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 AGs constituem uma ferramenta poderosa para resolução de problemas complexos, cujos espaços de busca das soluções ótimas são muito grandes para poder determiná-las com precisão por meio de um método direto. Cabe ressaltar que essas soluções ótimas, em alguns casos, podem não existir. Além disso, muitas vezes, o que realmente precisamos é de uma aproximação que nos dê um resultado satisfatório no contexto do problema (CRUZ; DEMASI, 2002).

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, os quais são ilustrados no diagrama da Figura 2.

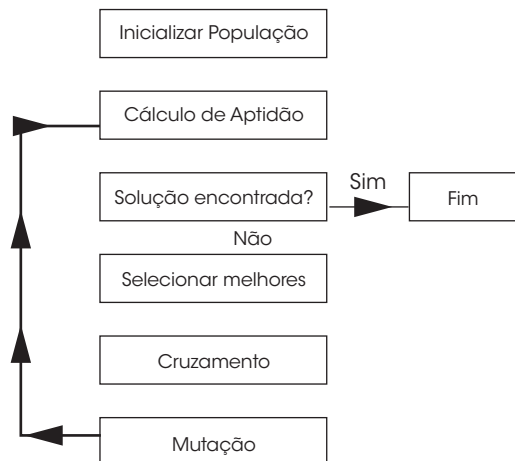


Figura 2: Estrutura básica do AG

Fonte: Os autores.

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 em 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 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, e os outros, descartados. Cada indivíduo tem probabilidade de ser selecionado de acordo com sua aptidão. O *crossover* tem a função de recombinar o material genético dos indivíduos anteriores. Normalmente, os melhores indivíduos geram mais filhos que os demais. Na Figura 3, é ilustrado um esquema de *crossover* simples (com apenas um ponto de corte).

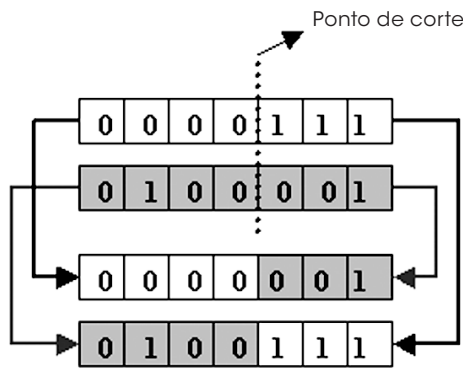


Figura 3: Crossover simples com um ponto de corte

Fonte: Os autores.

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 4.

É de fundamental importância para uma convergência rápida, a escolha adequada dos parâmetros do AG. Um fator importante é a taxa de




Figura 4: Exemplo de mutação

Fonte: Os autores.

alelos a serem mutados, que deve variar de 2% 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 às restrições do modelo abordado e maximizar a função objetivo (equação 1), o ponto de partida foi definir o tamanho do cromossomo. Para isso, primeiro definiu-se o intervalo de valores que os dois parâmetros a serem estimados poderiam assumir. Baseamo-nos 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 o tamanho do lote devem estar no intervalo de 2 a 10 vezes a demanda média diária; (b) se a prioridade da gestão for o nível de atendimento ao cliente ($NA > CE$), então o tamanho do lote não deverá ser inferior ao ponto de reposição; (c) se a prioridade da gestão for o critério econômico, ($CE > NA$), então o tamanho do lote deverá ser menor que o ponto de reposição.

Diante das premissas adotadas, definimos o cromossomo (Figura 5) com 22 alelos, divididos em dois genes de 10 alelos. O primeiro gene foi




Figura 5: Ilustração do cromossomo utilizado.
Gene 1: Parâmetro ponto de reposição Gene 2: Tamanho do lote

Fonte: Os autores.

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 às 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%. A configuração foi, assim, definida após vários experimentos, considerando diferentes valores para esses cinco parâmetros que regulam o funcionamento do AG.

A função de aptidão para avaliar os indivíduos, como mencionado, é a própria função-objetivo, que avalia a qualidade da gestão, definida na equação 1. É importante ressaltar que a avaliação de cada indivíduo da população depende da geração de novas observações, levando-se 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. Esse processo aumenta consideravelmente o tempo de busca que o AG consome para encontrar uma solução para o problema. Por esse motivo, optamos por sua implementação em linguagem C, na tentativa de “compensar” esse 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 encontrada se $FO \geq l$, sendo l um limiar determinado *a priori*, ou se a quantidade máxima de gerações for atingida.

5 Resultados experimentais

Com intuito de avaliar a qualidade das soluções encontradas pelo AG, realizamos uma série de experimentos que envolveram três diferentes cenários (Tabela 1), utilizando, em cada um, três diferentes estratégias de gestão. Para cada estratégia, executamos 10 vezes o AG e comparamos o valor médio da função-objetivo com o “ótimo” obtido pelo método da Busca Exaustiva (BE), no qual se calcula o valor dessa função para todas as combinações possíveis de valores para ponto de reposição e tamanho do lote, considerando os intervalos definidos para esses dois parâmetros. Cabe ressaltar que, embora custoso computacionalmente, só foi possível explorar todo o espaço de busca para selecionar a melhor solução, a fim de aferir o resultado do AG, 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, sendo, portanto, discretos. Os resultados dos experimentos citados podem ser vistos nas Tabelas 2 a 4.

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 <i>lead time</i>	5	5	7
Desvio padrão <i>lead time</i>	1	1	2
Estoque inicial	15	150	500

Fonte: Os autores.

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

Exp.	Cenário 1 - Estratégias da gestão											
	$\alpha = 0,5; \beta = 0,5$				$\alpha = 0,7; \beta = 0,3$				$\alpha = 0,3; \beta = 0,7$			
	TP	PR	TL	FO	TP	PR	TL	FO	TP	PR	TL	FO
1	9,0	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
Média	9,1s	-	-	0,6537	9,1s	-	-	0,7187	9,2s	-	-	0,7258
BE	107s	487	107	0,6586	106s	223	241	0,7290	109s	443	100	0,7285

Fonte: Os autores.

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

Exp.	Cenário 2 - Estratégias da gestão											
	$\alpha = 0,5; \beta = 0,5$				$\alpha = 0,7; \beta = 0,3$				$\alpha = 0,3; \beta = 0,7$			
	TP	PR	TL	FO	TP	PR	TL	FO	TP	PR	TL	FO
1	9,4	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
Média	9,4s	-	-	0,6537	9,3s	-	-	0,7213	9,3s	-	-	0,7268
BE	428s	576	222	0,6563	424s	449	461	0,7288	424s	553	200	0,7290

Fonte: Os autores.

Na Tabela 1, é possível verificar o conjunto de valores dos parâmetros de controle utilizados para os três cenários. Em cada uma das Tabelas, de 2 a 4, considera-se um cenário, e para cada um deles, três estratégias de gestão diferentes. Cada estratégia é caracterizada pelo par de fatores α (nível atendimento) e β (critério econômico), que estão diretamente relacionados com a função-objetivo (FO), definida na equação 1. Outros dados associados aos experimentos são: tempo de pro-

cessamento em segundos (TP), ponto de reposição (PR) e tamanho do lote (TL). Estes dois últimos são os parâmetros estimados pelo AG.

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, torna-se bastante dispendioso explorar todo o espaço de buscas no que se refere ao tempo de processamento. Os va-



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

Exp.	Cenário 3 – Estratégias da gestão											
	$\alpha = 0,5; \beta = 0,5$				$\alpha = 0,7; \beta = 0,3$				$\alpha = 0,3; \beta = 0,7$			
	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
Média	9,5	-	-	0,6083	9,5	-	-	0,7010	9,5	-	-	0,7163
BE	1686s	1882	426	0,6089	1654s	1919	1942	0,7108	1652s	847	403	0,7181

Fonte: Os autores.

lores obtidos pelos dois 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 estão muito próximos dos valores “ótimos”, os quais foram obtidos da exploração de todo o espaço de buscas dos casos abordados. Além disso, 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 de outros de natureza semelhante.

Genetic algorithms for parameters estimation applied in inventory management problem

Inventory management is one important instrument for 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 in most of the cases. Thus, an interesting alternative to solve problems of this nature is the application of Genetic Algorithm (GA) and Neural Network Techniques (ANN). In this work, it is 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 results obtained 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.

Key words: Genetic Algorithms. Inventory management. Parameters estimation.

Referências

- BIALOSKORSKI NETO, S. et al. Monitoramento de cooperativas agropecuárias: um ensaio utilizando-se de modelo de redes neurais. In: Congresso Internacional de Economia e Gestão de Negócios Agroalimentares, 3., 2001, Ribeirão Preto, *Anais...* Ribeirão Preto: FEARP/USP, 2001, 1-15.
- 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.
- 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.
- DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. *Fundamentos da administração da produção*. 3. ed. Porto Alegre: Bookman, 2001.
- GAITHER, N.; FRAZIER, G. *Administração da produção e operações*. 8. ed. São Paulo: Pioneira Thomson Learning, 2001.
- GOLDBERG, D. E. *Genetic algorithms in search, optimization, and machine learning*. Massachusetts: Addison-Wesley Pub., 1989.
- 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.
- 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.
- MICHALEWICZ, Z. *Genetic algorithms + data structures = evolution programs*. New York: Springer-Verlag; Berlin: Heidelberg, 1996.
- NAHMIAS, S. *Production and operations analysis*. 3. ed. Chicago: McGraw-Hill, 1997.
- 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: Salão de Iniciação Científica, 13., 2001, Porto Alegre-RS, *Anais...* Porto Alegre, UFRGS, p. 154-154.
- RUSSEL, S.; NORVIG, P. *Artificial intelligence: a modern approach*. New Jersey: Prentice Hall, 1995.
- SING, H., FOSTER, J. B. Production scheduling with sequence dependent setup costs. *IIE transactions*, London, v. 19, n.1, p. 43-49, 1987.
- WIDROW, B.; RUMELHART, D. E.; LEHR, M. A. Neural networks: applications in industry, business and science. *Communications of the ACM*, New York, v.37, n.3, p. 93-105, 1994.
- 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.

Recebido em 16 dez. 2008 / aprovado em 19 jan. 2009

Para referenciar este texto

ARAÚJO, S. A. de; LIBRANTZ, A. F. H; ALVES, W. A. L. Algoritmos genéticos na estimação de parâmetros em gestão de estoque. *Exacta*, São Paulo, v. 7, n. 1, p. 21-29, 2009.

