

AValiação DE UM MÉTODo DE OTIMIZaÇÃO PROPOSTo PARA MODELOS DE SIMULAÇÃO A EVENTOS DISCRETOS

Alexandre Ferreira de Pinho
Universidade Federal de Itajubá (UNIFEI)
Caixa Postal 50, CEP: 37500-903, Itajubá, MG
pinho@unifei.edu.br

José Arnaldo Barra Montevechi
Universidade Federal de Itajubá (UNIFEI)
Caixa Postal 50, CEP: 37500-903, Itajubá, MG
montevechi@unifei.edu.br

Fernando Augusto Silva Marins
Universidade Estadual Paulista (UNESP)
Av. Dr. Ariberto Pereira da Cunha, 333 - CEP: 12.516-410, Guaratinguetá, SP
fmarins@feg.unesp.br

RESUMO

Métodos de otimização combinados com a simulação computacional a eventos discretos têm sido utilizados em diversas aplicações na manufatura. Entretanto, estes métodos possuem baixo desempenho, em relação ao tempo computacional, ao manipularem mais de uma variável de decisão. Desta forma, o objetivo deste artigo é avaliar a proposta de um método para otimização de modelos de simulação a eventos discretos com maior eficiência em relação ao tempo de processamento quando comparado a uma ferramenta comercial conhecida. Cabe ressaltar que a qualidade da variável de resposta não será alterada, ou seja, o método proposto manterá a eficácia das soluções encontradas. A comparação entre o método proposto com a ferramenta de otimização existente no mercado se dará através de uma metodologia já consolidada disponível na literatura. As conclusões serão apresentadas comprovando a eficácia do método proposto.

PALAVRAS CHAVE: Metaheurística, Otimização de Modelos de Simulação, Simulação a Eventos Discretos.

Área de classificação principal do trabalho: MH – Metaheurística

ABSTRACT

Optimization methods combined with discrete events simulation have been used in many manufacturing applications. However, these methods have poor performance considering the computational time, when manipulating more than one decision variable. In this way, the aim of this paper is to propose a method for optimizing discrete events simulation models with higher efficiency in relation to the processing time when compared to a known commercial tool. Besides, the optimization quality will not be altered, i. e., the proposed method will keep the effectiveness of the achieved solutions. The comparison between the developed method and the optimization tool will be accomplished by means of a consolidated methodology available in the simulation literature. The conclusions will be presented proving the effectiveness of the developed method.

Keywords: Metaheuristics, Optimization of Simulation Models, Discrete events simulation.
Paper topics: MH – Metaheurística

1. Introdução

A otimização de modelos de simulação computacional a eventos discretos tem se tornado cada vez mais comum. Fu (2002) afirma que durante a década de 90, a simulação e a otimização eram mantidas separadamente na prática. Atualmente, essa integração tem se mostrado bastante difundida, principalmente pelo fato de alguns pacotes de simulação incluírem rotinas de otimização. Adicionalmente, Hao e Shen (2008) afirmam que a otimização combinada à simulação tem sido utilizada em diversas aplicações de sistemas produtivos, uma vez que a otimização destes sistemas é bastante complexa para ser resolvida utilizando-se apenas de abordagens matemáticas.

Para Banks *et al.* (2005), a existência de uma variabilidade na amostragem das variáveis de entrada utilizadas, força a otimização via simulação a possuir uma heurística de busca bastante robusta. Muitas heurísticas têm sido desenvolvidas para problemas de otimização que, apesar de não garantirem encontrar a solução ótima, mostram-se muito eficientes em complexos problemas práticos.

Segundo Fu (2002), as rotinas de otimização implantadas nos programas de simulação são, em maioria, baseadas em metaheurísticas com predominância dos algoritmos evolutivos, tais como os Algoritmos Genéticos, os quais interagem numa família de soluções em vez de um único ponto. De fato, o uso de Algoritmos Genéticos para a otimização é encontrado em alguns pacotes comerciais existentes, tais como *ProModel*® e *AutoMod*® (LAW e KELTON, 2000).

Entretanto, uma crítica que se faz aos softwares existentes para a otimização de modelos de simulação é que estes, ao manipularem mais de uma variável de entrada, tornam-se muito lentos (HARREL, GHOSH e BOWDEN, 2000). De fato, a grande limitação para o uso da otimização em simulação é o número de variáveis, sendo seu desempenho reduzido enormemente diante de um modelo com alto número de variáveis a serem manipuladas pela otimização (BANKS, 2001; APRIL *et al.*, 2003; SILVA, 2005; TORGA, 2007). Adicionalmente, Tyni e Ylinen (2006) afirmam que o tempo de convergência é a restrição mais significativa para se atingir a eficiência computacional do algoritmo de otimização.

Desta forma, o objetivo deste artigo é avaliar o método para otimização proposto para modelos de simulação a eventos discretos aplicados a sistemas de manufatura, capaz de atingir os resultados de forma mais rápida, ou seja, mais eficiente, quando comparado a uma ferramenta de otimização comercial. Cabe ressaltar que a qualidade da variável de resposta não será alterada, ou seja, o método desenvolvido manterá a eficácia das soluções encontradas.

Este artigo está estruturado da seguinte forma: o item 2 trás uma revisão bibliográfica sobre simulação computacional combinada a otimização; o item 3 apresenta o método de otimização proposto para modelos de simulação computacional; o item 4 mostra a metodologia utilizada na otimização dos modelos de simulação; o item 5 mostra os quatro objetos de estudo utilizados neste artigo; o item 6 apresenta a comparação entre o método de otimização proposto e uma ferramenta comercial (*SimRunner*®) na otimização dos objetos de estudo; finalmente, o item 7 mostra as conclusões e contribuições deste trabalho.

2. Simulação Combinada a Técnica de Otimização

Segundo Harrel, Ghosh e Bowden (2000), simulação computacional é a imitação de um sistema real ou hipotético, modelado em computador, para avaliação e melhoria de seu desempenho. Ou seja, simulação é a importação da realidade para um ambiente controlado onde se pode estudar o comportamento do mesmo, sob diversas condições, sem riscos físicos e/ou grandes custos envolvidos. Já Banks (2000) afirma que a simulação computacional envolve a criação de uma abstração da realidade e, com base nesta história artificial, são realizadas observações e inferências nas características de operação do sistema real representado.

Dentre as vantagens de se utilizar a simulação está a possibilidade de se responder a questões do tipo “o que aconteceria se...?”, ou seja, avaliando os resultados do modelo para determinadas condições. Assim, para usar a simulação na avaliação e melhoria do desempenho

de um processo, é necessário construir cenários e logo em seguida executar a simulação para cada uma deles, analisando os resultados encontrados (OPTQUEST FOR ARENA USER'S GUIDE, 2002). Tal processo, apesar de ser capaz de gerar bons resultados, pode ser cansativo e consumir muito tempo, além disso, não garante na maioria das vezes que as melhores configurações sejam experimentadas.

O intuito de se associar as técnicas de otimização e simulação é justamente resolver tais problemas. Esta associação apresenta algumas terminologias diferentes como “otimização para simulação”, “otimização via simulação” e “otimização em simulação”, sendo estas duas últimas as mais utilizadas (Fu, 2002). Banks *et al.* (2005) utilizam a expressão “otimização via simulação” para designar uma situação onde o objetivo é minimizar ou maximizar algumas medidas de desempenho de um sistema, e este sistema só pode ser avaliado através da simulação computacional.

Segundo Fu (2002), até a última década, a simulação e a otimização eram mantidas separadamente na prática. Atualmente, essa integração tem se mostrado bastante difundida, principalmente pelo fato de alguns pacotes de simulação incluírem rotinas de otimização.

O processo de otimização testa várias combinações de valores para variáveis que podem ser controladas (variáveis independentes), na busca da solução ótima. Em muitos casos não é possível avaliar todas as combinações prováveis de variáveis devido ao grande número de combinações possíveis. Nestes casos, algoritmos heurísticos de otimização devem ser utilizados. Para Fu (2002), a otimização deve ocorrer de maneira complementar a simulação, fornecendo as variáveis de uma possível solução (inputs) à simulação, e esta, fornecendo respostas (outputs) para a situação proposta, que retornam à otimização, caso a solução não seja considerada satisfatória.

A otimização gera novas variáveis, utilizando técnicas de otimização específicas, que são novamente testadas pela simulação. Este ciclo é repetido até sua parada, definida de acordo com o método de otimização utilizado. Quando o método de otimização é baseado em algoritmos genéticos, para cada possível solução é efetuada uma tentativa, ou seja, um ciclo.

3. Método proposto de otimização de modelos de simulação

O fluxograma apresentado na Figura 1 mostra o processo de otimização proposto para modelos de simulação a eventos discretos, além das adaptações feitas no algoritmo genético. Tal método de otimização é fruto de uma tese de doutorado (PINHO, 2008) relativa ao primeiro autor deste artigo. Os desenvolvimentos parciais do método proposto foram apresentados nos SBPO de 2007 e 2008 (PINHO, MONTEVECHI e MARINS, 2007 e PINHO, MONTEVECHI e MARINS, 2008).

Ao iniciar-se uma nova geração, verifica-se se esta é a primeira geração. Se a resposta a esta questão for afirmativa, faz-se o cálculo do tamanho do indivíduo da população, ou seja, o número de bits necessários para cada indivíduo, que será utilizado no algoritmo genético (MITCHELL, 1996). Na seqüência, calcula-se o tamanho da população inicial conforme o equacionamento de Goldberg (1989), mostrado na equação (1). Nota-se que esta equação estabelece uma relação entre tamanho da população e tamanho do indivíduo.

$$\text{Tamanho da população} = 1,65 \cdot 2^{0,21 \cdot k} \quad (1)$$

Sendo:

k – número de bits necessários para cada indivíduo (tamanho do indivíduo);

Gera-se então a população inicial do algoritmo genético. Esta população representa as variáveis de entrada do modelo de simulação, tais como: quantidade de operadores, quantidade de máquinas, etc.

Se já existir uma população, ou seja, se não for a primeira geração, aumenta-se o parâmetro tamanho da população em 50%, ou seja, utiliza-se de uma técnica adaptativa para o tamanho de população (GONG *et al.*, 2007; KAVEH e SHAHROUZI, 2007; MA e ZHANG,

2008). Desta forma, a cada geração do algoritmo genético, um tamanho de população diferente é utilizado. A intenção é reduzir o tempo processamento em busca da solução ótima e ao mesmo tempo evitar a convergência prematura do algoritmo. Estes novos indivíduos serão gerados aleatoriamente e inseridos na população atual do problema.

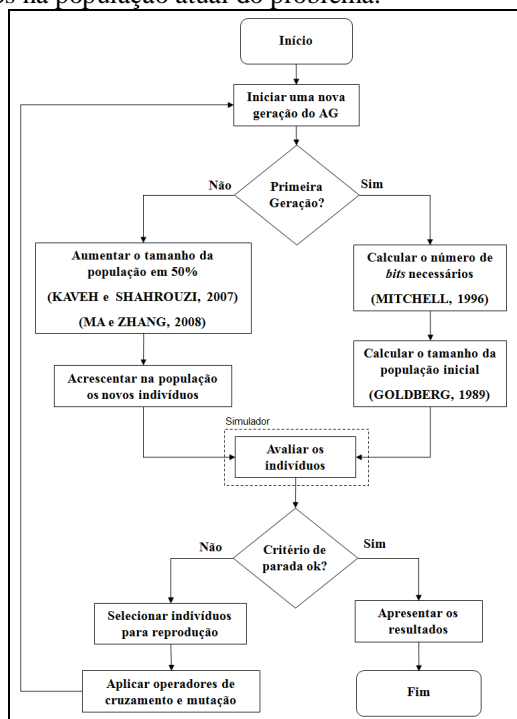


Figura 1: Fluxograma do método de otimização proposto

A avaliação de cada indivíduo é realizada através do simulador a eventos discretos. Para tal, o método envia, separadamente, cada indivíduo da população para o simulador, e este retorna a resposta do modelo de simulação para tais indivíduos com base na função objetivo definida. Após a avaliação de todos os indivíduos da população, verifica-se se há melhorias na resposta da geração atual em relação a geração anterior. Se não ocorrer melhorias significativas, considera-se que a condição de parada do método foi satisfeita. Apresenta-se, então os resultados da otimização do modelo de simulação e encerra-se o método.

Caso a condição de parada não seja satisfatória, selecionam-se os indivíduos para reprodução, através do método da roleta. Na sequência, aplicam-se os operadores de cruzamento e mutação nos indivíduos selecionados anteriormente. O operador de cruzamento utilizado foi o de Cruzamento de um Ponto e o operador de mutação utilizado foi o de Mutação Binária Simples. Utilizaram-se as taxas de 80% e 10% para as taxas de cruzamento e mutação respectivamente. Após a aplicação destes operadores nos indivíduos selecionados, uma nova geração pode ser formada, iniciando-se todo o processo novamente.

4. Metodologia para otimização via simulação

Geralmente as metodologias de otimização em simulação partem de um modelo já existente e validado. O primeiro passo é a definição das variáveis de decisão, ou seja, as variáveis que afetam a função objetivo do problema. Em seguida se define a função objetivo, que pode ser de maximização ou minimização, cujo resultado será avaliado pelos algoritmos de otimização na busca de um valor ótimo. O passo seguinte é a definição das restrições do problema seguido pela configuração de alguns parâmetros, como: número de replicações, precisão e critério de parada (SILVA, 2005). Harrel, Ghosh e Bowden (2000), propuseram uma metodologia específica para o

uso da otimização de modelos de simulação através do *SimRunner*®. Estes passos são listados a seguir.

1. Definir as variáveis que afetarão as respostas do modelo e que serão testadas pelo algoritmo de otimização. São estas variáveis que terão o valor alterado a cada rodada de simulação.
2. Definir o tipo de variável (real ou inteira) e limites inferiores e superiores. Durante a busca, o algoritmo de otimização gerará soluções respeitando o tipo das variáveis e seus limites. O número de variáveis de decisão e a gama de valores possíveis afetam o tamanho do espaço de busca, alterando a dificuldade e o tempo consumido para identificar a solução ótima.
3. Definir a função objetivo para avaliar as soluções testadas pelo algoritmo. A função objetivo já poderia ter sido estabelecida durante a fase de projeto do estudo de simulação tendo por base peças (*entities*), equipamentos (*locations*), operários (*resources*) entre outros, buscando minimizar, maximizar ou fazer uso de ambos em diferentes variáveis, dando inclusive pesos diferentes para compor a função objetivo.
4. Selecionar o tamanho da população do Algoritmo Evolutivo. No caso do *SimRunner*® o algoritmo evolutivo utilizado é o Algoritmo Genético. O tamanho da população afeta a confiabilidade e o tempo requerido para a condução da busca, assim, é necessário que haja um equilíbrio entre o tempo requerido e o resultado esperado da otimização. Nesta fase também é importante definir outros parâmetros como: precisão requerida, nível de significância e número de replicações.
5. Após a conclusão da busca um analista deve estudar as soluções encontradas, uma vez que, além da solução ótima, o algoritmo encontra várias outras soluções competitivas. Uma boa prática é comparar todas as soluções tendo como base a função objetivo.

5. Objetos de estudo

Quatro objetos de estudo foram selecionados. O primeiro e o segundo objetos de estudo referem-se a empresas do setor automobilístico. Já o terceiro e o quarto objeto de estudo referem-se a uma empresa de alta tecnologia. Cabe ressaltar que os modelos conceituais e computacionais de cada um dos objetos de estudo, utilizados neste artigo, foram verificados e validados em trabalhos anteriores.

O primeiro objeto de estudo refere-se a uma linha de produção de uma empresa do setor automobilístico produtora de componentes eletrônicos. A verificação e a validação do modelo conceitual e computacional encontram-se em Montevechi *et al.* (2007). O segundo objeto de estudo refere-se a uma célula de manufatura de uma empresa do setor de autopeças. Em Montevechi *et al.* (2008a) encontra-se a verificação e a validação do modelo conceitual e computacional. Já o terceiro e o quarto objeto de estudo referem-se a uma empresa brasileira de alta tecnologia, focada na fabricação e desenvolvimento de equipamentos para a comunicação óptica. A verificação e a validação desses modelos conceituais e computacionais encontram-se em Montevechi *et al.* (2008b).

6. Otimização dos objetos de estudo

A seguir apresenta-se os 5 passos necessários para a execução da metodologia de otimização proposta por Harrel, Ghosh e Bowden (2000), mostrada anteriormente na seção 4, para modelos de simulação computacional.

6.1. Definição das variáveis de decisão (passo 1)

Para o primeiro objeto de estudo as variáveis de decisão do problema de otimização foram definidas como sendo as quantidades de *kanbans* necessários para as peças denominadas de P1 e P2. Já para o segundo objeto de estudo as variáveis de decisão são as quantidades de colaboradores para cada uma das operações existentes na célula: operação A, operação B e operação C. Para o terceiro objeto de estudo as variáveis de decisão são: quantidade de

operadores na célula, número de bancadas com *setup*, número de bancadas sem *setup* e se há ou não organização de material feita pela produção. Finalmente para o quarto objeto de estudo as variáveis de decisão são: número de bancadas com equipamentos, número de bancadas sem equipamentos, quantidade de operadores na célula, se há ou não organização de material feita pela produção e se há ou não a atividade atualizar projeto.

6.2. Definição do tipo de variável e limites superiores e inferiores (passo 2)

Para o primeiro objeto de estudo as variáveis representam as quantidades de *kanbans*. Desta forma, essas variáveis devem ser do tipo inteiras. Na definição dos limites das variáveis, foi tomada a quantidade atual de cartões como limite máximo (12 cartões), uma vez que não se deseja utilizar quantidades maiores que estas, e uma única unidade como limite mínimo.

Já para o segundo objeto de estudo as variáveis de decisão representam as quantidades de colaboradores, desta forma, estas variáveis devem ser do tipo inteiro, com limite inferior igual a 1 e limite superior igual a 10.

Para o terceiro objeto de estudo as três primeiras variáveis de decisão selecionadas são do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 10. A quarta variável de decisão (se há ou não organização de material) é do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há).

De forma semelhante, para o quarto objeto de estudo as três primeiras variáveis de decisão selecionadas são do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 10. A quarta variável de decisão (se há ou não organização de material) é do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há). A quinta variável de decisão (se há ou não a atividade atualizar projeto) também é do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há).

6.3. Definição da função objetivo (passo 3)

Para o primeiro objeto de estudo o objetivo será encontrar a quantidade mínima de *kanbans*, para cada uma das peças analisadas, necessárias para garantir a demanda semanal da empresa e manter o mínimo de estoque intermediário entre os estágios produtivos. Para tal, elaborou-se uma função objetivo considerando-se a produção semanal, número de cartões utilizados e o estoque em processamento. Cabe ressaltar que a função objetivo utilizada neste objeto de estudo é linear.

Já para o segundo objeto de estudo o objetivo será encontrar a quantidade mínima de colaboradores para cada uma das operações A, B e C, que maximizam o total de peças produzidas em uma semana de produção. Para tal, elaborou-se uma função objetivo para a margem de contribuição considerando-se a receita gerada pela produção semanal e o custo de cada um dos colaboradores utilizados. Cabe ressaltar que a função objetivo utilizada neste objeto de estudo também é linear.

Para o terceiro objeto de estudo o objetivo será encontrar a quantidade mínima de operadores e de bancadas com e sem *setups*, além é claro de verificar se vale ou não a pena organizar os materiais na produção. Para tal, elaborou-se uma função para a margem de contribuição considerando-se a receita gerada pela produção semanal e o custo de cada um das decisões obtidas pelas variáveis de entrada. A função objetivo utilizada neste objeto de estudo também é linear.

Finalmente, para o quarto objeto de estudo o objetivo será encontrar a quantidade mínima de operadores e de bancadas com e sem equipamentos, além é claro de verificar se vale ou não a pena organizar os materiais na produção e efetuar a atualização de projetos. Para tal, elaborou-se uma função para a margem de contribuição considerando-se a receita gerada pela produção semanal e o custo de cada um das decisões obtidas pelas variáveis de entrada. A função objetivo utilizada neste objeto de estudo também é linear.

6.4. Definição dos parâmetros da simulação (passo 4)

O *SimRunner*® apresenta três perfis de otimização: cauteloso, moderado e agressivo. Desta forma, serão analisados os tempos de processamento para cada um destes perfis, juntamente com a qualidade da solução encontrada pelo simulador. Para cada um dos experimentos realizados serão adotadas três replicações.

Adicionalmente, o *SimRunner*® não permite, em suas configurações, definições sobre os parâmetros dos algoritmo genético utilizado por este. Em contra partida, o método de otimização proposto permite a configurações destes parâmetros. Selecionaram-se, então, as seguintes opções: taxa de cruzamento: 80%; taxa de mutação: 10%; número de replicações: 3. Nota-se que as definições para o número de replicações foram as mesmas que adotadas para o *SimRunner*®, uma vez que a intenção deste artigo é comparar os dois procedimentos de otimização.

Cabe ressaltar que estes parâmetros foram utilizados nos quatro objetos de estudo mostrados neste artigo.

6.5. Análise da solução (passo 5)

A Figura 2 mostra uma comparação entre os tempos de processamento necessários, considerando uma variável de decisão, para a otimização de cada um dos objetos de estudo analisados. Nota-se que, para uma variável de decisão, o método de otimização proposto foi sempre o mais lento, quando comparado aos perfis de otimização do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto não é adequado para a manipulação de apenas uma variável de decisão.



Figura 2: Gráfico com os tempos de processamento da otimização para uma variável de decisão

A Figura 3 mostra uma comparação entre os tempos de processamento necessários, considerando duas variáveis de decisão, para a otimização de cada um dos objetos de estudo analisados. Nota-se que, para duas variáveis de decisão, o método de otimização proposto foi mais rápido ou semelhante aos tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto já se mostra adequado para a manipulação de duas variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto Harrel, Ghosh e Bowden (2000) afirmam que o perfil agressivo apresenta uma qualidade de resposta inferior aos outros perfis.

De forma semelhante a Figura 4 mostra uma comparação entre os tempos de processamento necessários, considerando três variáveis de decisão, para a otimização do segundo, terceiro e quarto objetos de estudo analisados. Nota-se que, para três variáveis de decisão, o método de otimização proposto foi mais rápido ou semelhante aos tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto é adequado para a manipulação de três variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.




Figura 3: Gráfico com os tempos de processamento da otimização para duas variáveis de decisão




Figura 4: Gráfico com os tempos de processamento da otimização para três variáveis de decisão

A Figura 5 mostra uma comparação entre os tempos de processamento necessários, considerando quatro variáveis de decisão, para a otimização do terceiro e quarto objetos de estudo analisados. Nota-se que, para quatro variáveis de decisão, o método de otimização proposto foi mais rápido que os tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma, pode-se afirmar que o método de otimização proposto é adequado para a manipulação de quatro variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.

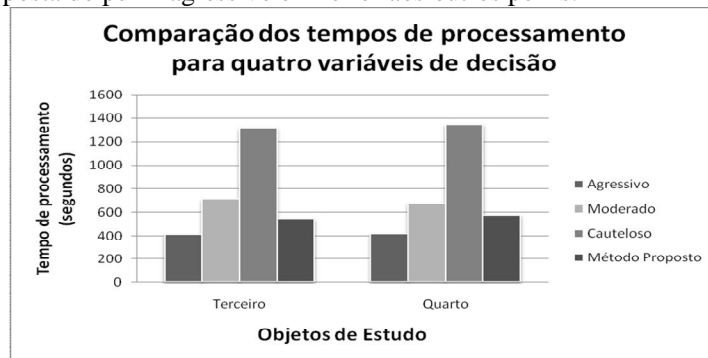


Figura 5: Gráfico com os tempos de processamento da otimização para quatro variáveis de decisão

A Figura 6 mostra uma comparação entre os tempos de processamento necessários, considerando cinco variáveis de decisão, para a otimização do quarto objeto de estudo analisado. Nota-se que, para cinco variáveis de decisão, o método de otimização proposto foi mais rápido que os tempos de processamento dos perfis moderado e cauteloso do *SimRunner*®. Desta forma,

pode-se afirmar que o método de otimização proposto é adequado para a manipulação de cinco variáveis de decisão simultaneamente. O método proposto foi mais lento que o perfil agressivo do *SimRunner*®, entretanto conforme discutido anteriormente, a qualidade da resposta do perfil agressivo é inferior aos outros perfis.




Figura 6: Gráfico com os tempos de processamento da otimização para cinco variáveis de decisão

Para a avaliação da qualidade das respostas obtidas em cada um dos objetos de estudo foi utilizado um teste de hipótese sobre uma média populacional com desvio padrão desconhecido (TRIOLA, 2005). Utilizou-se este método uma vez que o *SimRunner*® não apresenta os valores das amostras e também não apresenta o desvio padrão para a solução encontrada. Em contra partida, é possível obter estes resultados pelo método de otimização proposto.

As tabela 1 apresenta, respectivamente, para o primeiro, segundo, terceiro e quarto objeto de estudo, o valor médio da função objetivo e seu respectivo desvio padrão obtidos pelo método de otimização proposto, além da média da função objetivo obtido pelo *SimRunner*®. Estes valores são apresentados para a quantidade de variáveis de decisão de cada objeto de estudo.

Tabela 1: Média e desvio padrão da função objetivo do método de otimização proposto e do *SimRunner*® para cada objeto de estudo

Quantidade de variáveis de decisão	Método proposto		<i>SimRunner</i> ®
	Média	Desvio padrão	Média
Primeiro objeto de estudo			
1	9514,67	5,03	9514
2	9517,67	3,05	9517
Segundo objeto de estudo			
1	419,67	3,51	421
2	432,67	7,50	433
3	452,67	2,52	453
Terceiro objeto de estudo			
1	50,33	2,51	50,5
2	82,33	4,04	82,5
3	289,67	4,50	290,1
4	290,67	3,05	290,1
Quarto objeto de estudo			
1	169,33	7,02	169
2	172,66	6,51	172
3	740,33	4,04	740
4	740,67	2,51	740
5	740,33	7,50	740

A hipótese H0 será que as médias encontrada pelo método de otimização proposto para as variáveis de decisão são iguais as médias encontradas pelo *SimRunner*® para o perfil

cauteloso. Cabe ressaltar que se optou em testar a qualidade da resposta apenas para o perfil cauteloso do *SimRunner*® uma vez que, segundo Harrel, Ghosh e Bowden (2000), este é o perfil que apresenta a melhor qualidade de resposta.

Já a hipótese alternativa H1 será que a média da qualidade encontrada pelo método de otimização proposto seja inferior a média da qualidade encontrada pelo perfil cauteloso do *SimRunner*®.

Para a realização deste teste de hipótese selecionou-se a distribuição *t*, uma vez que não se conhece o desvio padrão da amostra que se quer avaliar e os dados amostrais provêm de uma população que é normalmente distribuída. A estatística de teste utilizada para avaliar H0 é apresentada na Equação 2 (TRIOLA, 2005).

$$t = \frac{\bar{x} - \mu_x}{\frac{s}{\sqrt{n}}} \quad (2)$$

Sendo:

- \bar{x} : média da qualidade da resposta obtida pelo método de otimização proposto;
- μ_x : média da qualidade da resposta obtida pelo *SimRunner*®;
- *s*: desvio padrão da qualidade da resposta obtida pelo método de otimização proposto;
- *n*: tamanho da amostra (número de replicações).

Utilizando-se a tabela estatística para distribuição *t* (TRIOLA, 2005), considerando-se um nível de significância igual a 0,05 e um grau de liberdade igual a *n*-1=2, tem-se o valor crítico de *t* igual a 2,920 ($t_{\text{crítico}} = 2,920$) para um teste unilateral à direita. Semelhantemente, o valor crítico de *t* será igual a -2,920 ($t_{\text{crítico}} = -2,920$) para um teste unilateral à esquerda.

A tabela 2, a seguir, apresenta o valor da estatística de teste *t* para cada uma das situações apresentadas anteriormente na tabela 1.

Tabela 2: Estatística de teste *t*

Quantidade de variáveis de decisão	Teste t
Primeiro objeto de estudo	
1	0,23
2	0,38
Segundo objeto de estudo	
1	-0,66
2	-0,076
3	-0,227
Terceiro objeto de estudo	
1	-0,117
2	-0,073
3	-0,165
4	0,324
Quarto objeto de estudo	
1	0,081
2	0,176
3	0,142
4	0,426
5	0,076

Como a estatística de teste *t* não se encontra na região crítica, em nenhum dos casos analisados, não é possível rejeitar H0. Desta forma, pode-se afirmar que o método de otimização proposto possui a mesma qualidade de resposta que o *SimRunner*® no perfil cauteloso em todos os objetos de estudo.

7. Conclusão e contribuições do trabalho

A contribuição deste artigo foi avaliar o método de otimização proposto para modelos de simulação a eventos discretos aplicados a sistemas de manufatura, capaz de atingir os resultados de forma mais rápida e com a mesma qualidade, quando comparado a um software de otimização comercial.

Quatro objetos de estudo foram utilizados na aplicação do método de otimização proposto. Os resultados encontrados foram comparados com uma ferramenta de otimização disponível comercialmente, conhecida como *SimRunner*®, através da metodologia de otimização para modelos de simulação a eventos discretos proposta por Harrel, Ghosh e Bowden (2000). Em relação a qualidade dos resultados, o método de otimização proposto mostrou-se tão eficaz quanto o *SimRunner*®.

Para uma variável de decisão, o método de otimização proposto mostrou-se menos eficiente. Já para duas variáveis de decisão analisadas simultaneamente, o método apresentou melhor ou igual eficiência. Entretanto, para três ou mais variáveis de decisão analisadas simultaneamente, o método de otimização proposto é sempre mais eficiente.

Quando comparado ao perfil cauteloso do *SimRunner*®, o método de otimização proposto para o primeiro objeto de estudo, considerando-se duas variáveis de decisão, foi cerca de 46% mais rápido. Em relação ao segundo objeto de estudo, considerando-se três variáveis de decisão, o método foi cerca de 51% mais rápido. Já para o terceiro objeto de estudo, considerando-se quatro variáveis de decisão, o método foi cerca de 59% mais rápido. Finalmente, para o quarto objeto de estudo, considerando-se cinco variáveis de decisão, o método foi cerca de 80% mais rápido.

De mesma forma que anteriormente, quando comparado ao perfil moderado do *SimRunner*®, o método de otimização proposto para o primeiro objeto de estudo, considerando-se duas variáveis de decisão, foi cerca de 38% mais rápido. Em relação ao segundo objeto de estudo, considerando-se três variáveis de decisão, o método foi cerca de 24% mais rápido. Já para o terceiro objeto de estudo, considerando-se quatro variáveis de decisão, o método foi cerca de 23% mais rápido. Finalmente, para o quarto objeto de estudo, considerando-se cinco variáveis de decisão, o método foi cerca de 50% mais rápido.

Ressalta-se que o método proposto é válido para as condições de contorno estabelecidas por este trabalho, que consiste na manipulação de variáveis de decisão do tipo discretas, determinísticas e inteiras.

Agradecimentos

Os autores gostariam de agradecer a CAPES (PE 024/2008) e a FAPEMIG pelo suporte dados a esta pesquisa.

Referências bibliográficas

- April, J.; Glover, F.; Kelly, J. P.; Laguna, M.** (2003). Practical Introduction to Simulation Optimization. In: Proceedings of the Winter Simulation Conference, Boulder, CO, USA.
- Banks, J.** (2000). Introduction to Simulation. Proceedings of the Winter Simulation Conference, Atlanta, USA.
- Banks, J.** (2001). Panel Session: The Future of Simulation. Proceedings of the Winter Simulation Conference, Atlanta, GA, USA.
- Banks, J.; Carson, J. S.; Nelson, B. L.; Nicol, D. M.** Discrete-event Simulation. 4.ed. Upper Saddle River, NJ: Prentice-Hall, 2005.
- Fu, M. C.** (2002). Optimization for Simulation: Theory vs. Practice. Journal on Computing, vol. 14, n 3.

- Goldberg, D. E.** Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley Publishing Company, INC. United States of America, 1989.
- Gong, D.W.; Hao, G.S.; Zhou, Y; Sun, X.Y.** (2007). Interactive genetic algorithms with multi-population adaptive hierarchy and their application in fashion design. *Applied Mathematics and Computation*, v.185, p.1098–1108.
- Hao, Q.; Shen, W.** (2008). Implementing a hybrid simulation model for a Kanban-based material handling system. *Robotics and Computer-Integrated Manufacturing*, v.24, p.635–646.
- Harrel, C. R.; Ghosh, B. K.; Bowden, R.** Simulation Using Promodel. McGraw-Hill, 2000.
- Kaveh, A.; Shahrouzi, M.** (2007). A hybrid ant strategy and genetic algorithm to tune the population size for efficient structural optimization. *International Journal for Computer-Aided Engineering and Software*, v.24, n.3, p.237-254.
- Law, A. M.; Kelton, W. D.** Simulation modeling and analysis. 3.ed. New York: McGraw-Hill, 2000.
- Ma, Y.; Zhang, C.** (2008). Quick convergence of genetic algorithm for QoS-driven web service selection. *Computer Networks*, v.52, p.1093–1104.
- Mitchell, M.** An Introduction a Genetic Algorithm. MIT Press, Massachusetts, London, England, 1996.
- Montevecchi, J.A.B.; Pinho, A.F. De; Leal, F.; Marins, F.A.S.** (2007). Application of design of experiments on the simulation of a process in an automotive industry. In: Proceedings of the Winter Simulation Conference, Washington, DC, USA.
- Montevecchi, J.A.B.; Pinho, A.F. De; Leal, F.; Marins, F.A.S.; Costa, R. F. Da S.** (2008). Improving a process in a brazilian automotive plant applying process mapping, design of experiments and discrete events simulation. In: Proceedings of the 20 Symposium Europeo de Modelado y Simulacion, Briatico, Itália.
- Montevecchi, J.A.B.; Leal, F.; Pinho, A.F. de; Costa, R.F. Da S.; Marins, F.A.S.; Marins, F.F.; Jesus, J.T.** (2008). Combined use of modeling techniques for the development of the conceptual model in simulation projects. In: Proceedings of the 2008 Winter Simulation Conference, Miami, USA.
- Optquest for Arena User's Guide.** Rockwell Software Inc, 2002.
- Pinho, A.F.de.** Metodologia para utilização de algoritmos genéticos em modelos de simulação computacional em ambientes de manufatura. 189 f. Tese (Doutorado em Engenharia Mecânica) – Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, 2008.
- Pinho, A.F.de; Montevecchi, J.A.B.; Marins, F.A.S.** (2007). Análise da aplicação de projeto de experimentos nos parâmetros dos algoritmos genéticos. In: XIL Simpósio Brasileiro de Pesquisa Operacional, Fortaleza.
- Pinho, A.F.de; Montevecchi, J.A.B.; Marins, F.A.S.** (2008). Desenvolvimento de uma ferramenta computacional para a otimização de modelos de simulação a eventos discretos. In: XL Simpósio Brasileiro de Pesquisa Operacional, João Pessoa.
- Silva, W. A.** Otimização de parâmetros da gestão baseada em atividades aplicada em uma célula de manufatura. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2005.
- Torga, B. L. M.** Modelagem, Simulação e Otimização em Sistemas Puxados de Manufatura. 126 f. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2007.
- Triola, M.F.** Introdução à Estatística. 9a.ed. Rio de Janeiro: Editora LTC, 2005.
- Tyni, T.; Ylisen, J.** (2006). Evolutionary bi-objective optimization in the elevator car routing problem. *European Journal of Operational Research*, v.169, p.960–977.