

OTIMIZAÇÃO EM MODELOS DE SIMULAÇÃO: UM ESTUDO COMPARATIVO ENVOLVENDO MÉTODOS DE OTIMIZAÇÃO NÃO LINEARES BASEADOS EM ALGORITMOS GENÉTICOS

Rafael de Carvalho Miranda

Universidade Federal de Itajubá (UNIFEI)
Caixa Postal 50, CEP: 37500-903, Itajubá, MG
mirandaprod@yahoo.com.br

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

RESUMO

A utilização da otimização combinada a simulação tem se tornado cada vez mais comum, devido principalmente a pacotes comerciais que possuem rotinas de otimização integradas. No entanto estes *softwares* possuem baixa eficiência computacional na otimização de modelos de simulação com grande número de variáveis de decisão. Nesse sentido o presente trabalho realizou um estudo comparativo envolvendo dois métodos de otimização baseados em algoritmos genéticos: um desenvolvido pelos autores e outro comercial. Ambos os métodos foram utilizados na otimização não linear de um modelo de simulação a eventos discretos. A comparação entre os métodos se deu em função do tempo necessário para convergência e na qualidade da resposta obtida. Neste trabalho o método de otimização proposto foi modificado alcançando melhor resultado que o *software* comercial, entretanto com um tempo de convergência maior. Ao final desse artigo uma proposta é apresentada visando à melhoria do tempo de convergência do algoritmo proposto.

PALAVRAS CHAVE. Simulação a eventos discretos, Otimização, Algoritmos genéticos.

Área principal: SIM - Simulação

ABSTRACT

The combined use of simulation and optimization has become increasingly common, primarily due to commercial packages that have manufactured with optimization routines. However, these software packages have low computational efficiency in the optimization of simulation models with large number of decision variables. In this sense this paper conducted a comparative study involving two optimization methods based on genetic algorithms: one developed by the authors and the other by from a commercial software package. Both methods were used in the optimization of a nonlinear model of discrete event simulation. The comparison between the methods was given in function of the time required for convergence and response quality. In this work the optimization method was modified to achieve better results than the commercial software, but with a larger convergence time. At the end of this paper, a proposal aimed at improving the convergence time of the algorithm is presented.

KEYWORDS. Discrete event simulation, Optimization, Genetic algorithms.

Main area: SIM - Simulation

1. Introdução

A simulação computacional com o passar do tempo tem sido utilizada de forma crescente para auxílio à tomada de decisões (BANKS *et al.*, 2005; BRUZZONE *et al.*, 2007; SARGENT, 2009; LAW, 2007; LAW e KELTON, 2000). Esta já é apontada como uma das técnicas de pesquisa mais utilizadas em vários setores, devido principalmente à sua versatilidade, flexibilidade e poder de análise (JAHANGIRIAN *et al.*, 2010; RYAN e HEAVEY, 2006).

No entanto para Law e McComas (2002) uma das desvantagens da simulação é que esta por si só não é uma técnica de otimização. Fazendo com que um analista tenha que simular várias configurações do sistema real e escolher, dentre todos os resultados alcançados, aquele que apresente o maior desempenho. Esse cenário vem sendo alterado, devido principalmente a disponibilidade de computadores mais rápidos e com a melhoria nas técnicas de busca e nas heurísticas de otimização.

Corroborando com esta afirmação Fu (2002), Fu *et al.* (2000), Banks *et al.* (2005), Harrel *et al.* (2002) e Kelton, Sadowski e Sturrock (2007) afirmam que o uso da otimização em conjunto com a simulação vem crescendo de forma contínua, devido principalmente a pacotes de simulação que possuem rotinas de otimização integradas.

Segundo Hillier e Lieberman (2010), a metodologia para emprego de simulação na tentativa de identificar a melhor configuração para um sistema é conhecida como otimização via simulação. E ressaltam que este campo apresenta um interesse crescente no campo da Pesquisa Operacional.

Para Fu (2002) uma das interfaces mais bem-sucedida entre a pesquisa operacional e a computação tem sido o desenvolvimento de *softwares* de simulação a eventos discretos. Segundo o autor, várias técnicas de otimização tem sido integradas a simulação, principalmente por meio de *softwares* de simulação comerciais que já possuem módulos de otimização integrados. Hoje a inclusão de rotinas de otimização tornou-se quase onipresente na maioria dos pacotes comerciais de simulação.

Dentre os vários *softwares* ou módulos de otimização integrados a *softwares* de simulação destacam-se: o *AutoStat*®, o *OptQuest*®, o *Optimiz*®, o *Optimizer*®, o *WizardGA*® e o *SimRunner*® (FU, 2002; LAW, 2007; LAW e KELTON, 2000; LAW e MCCOMAS, 2002). Estes *softwares* utilizam diferentes métodos de busca, tais como: Algoritmos Evolucionários (COELLO, LAMONT, VAN VELDHUIZEN, 2007), Algoritmos Genéticos (LINDEN, 2008), Busca Scatter (MARTÍ, LAGUNA e GLOVER, 2006), Busca Tabu (GLOVER, LAGUNA e MARTI, 2005), Redes Neurais (RIPLEY, 1996) e a *Simulated Annealing* (AARTS, KORST E MICHIELS, 2005).

Fu (2002) destaca a utilização de rotinas de otimização baseadas em metaheurísticas com predominância dos Algoritmos Evolutivos, como os Algoritmos Genéticos (AG). Este fato pode ser verificado em alguns pacotes de otimização comerciais como o *SimRunner*® da *ProModel*®, o *WizardGA*® do *Plant Simulation*® e o *AutoStat* do *AutoMod*® (LAW e KELTON, 2000).

Apesar dos avanços ocorridos nos *softwares* de otimização para modelos de simulação, uma crítica comum a estes pacotes comerciais é que ao manipularem mais de uma variável de entrada, estes *softwares* tornam-se muito lentos (HARREL, GHOSH e BOWDEN, 2000).

Para April *et al.* (2003), Banks (2001), Pinho (2008), Silva (2005) e Torga (2007) a grande limitação para o uso da otimização em simulação é o número de variáveis a serem manipuladas, sendo o desempenho desses *softwares* reduzidos de forma considerável em modelos com um alto número de variáveis. Nesse sentido Tyni e Ylinen (2006) afirmam que o tempo de convergência é a restrição mais significativa para se atingir a eficiência computacional de um algoritmo de otimização.

Desta forma, o objetivo principal desse artigo se concentra na comparação do método de otimização para modelos de simulação desenvolvido em Pinho (2008) com um *software* de otimização comercial, o *SimRunner*®, na otimização de modelos de simulação a eventos discretos considerando funções objetivas não lineares. Este trabalho buscará responder qual dos

métodos de otimização apresenta maior eficiência em termos de tempo de convergência computacional e na qualidade de resposta na otimização dos modelos de simulação.

A análise da literatura apresenta que vários estudos comparativos realizados focaram a otimização de modelos de simulação com funções objetivas lineares (DEBUSE, SMITH e SMITH, 1999; JAFFERALI, VENKATESHWARAN e SON, 2005; KLEIJNEN e WAN, 2007; LAW e MCCOMAS, 2002; LACKSONEN, 2001; PINHO, 2008; PINHO, MONTEVECHI e MARINS 2008; PINHO, MONTEVECHI e MARINS 2009). Este artigo abordará um campo ainda pouco explorado, a otimização via simulação de modelos não lineares.

Para cumprir com o objetivo deste trabalho, o artigo encontra-se estruturado da seguinte forma: a seção 2 apresenta a metodologia utilizada neste estudo comparativo. A seção 3 apresenta o levantamento bibliográfico sobre otimização via simulação a eventos discretos, tema central deste trabalho. A seção 4 detalha o método de otimização desenvolvido em Pinho (2008). A seção 5 apresenta o objeto de estudo a ser otimizado. A seção 6 apresenta a comparação entre o método de otimização proposto e o *SimRunner*®. A seção 7 apresenta uma proposta de trabalho futuro e por fim, a seção 8 traz as conclusões deste trabalho.

2. Metodologia para otimização via pacotes de simulação

A grande maioria das metodologias de otimização via simulação a eventos discretos partem de um modelo computacional já existente, verificado e validado. Geralmente, em uma primeira etapa são definidas as variáveis de decisão, seguida pela determinação da função objetivo, cujo resultado será avaliado pelos algoritmos de otimização na busca de um valor ótimo. O passo seguinte consiste na definição das restrições do problema, seguido pela configuração de parâmetros, tais como: número de replicações, precisão e critério de parada (PINHO, 2008; SILVA, 2005; TORGA, 2007).

Harrel, Ghosh e Bowden (2004) propuseram uma metodologia para o uso do *SimRunner*®. Um *software* de otimização que utiliza técnicas de otimização baseadas em AG. Partindo de um modelo computacional construído e validado algumas etapas são necessárias para que a otimização seja bem sucedida. Os autores definiram cinco passos:

- 1º. Passo: Definir as variáveis de decisão que irão afetar as saídas do modelo de simulação e que serão testadas pelo algoritmo de otimização. Estas variáveis terão seus valores alterados a cada rodada de simulação;
- 2º. Passo: Para cada variável de decisão definir o tipo de variável (real ou inteira) e os limites inferiores e superiores. O algoritmo de otimização buscará soluções compreendidas entre os limites impostos e respeitando o tipo de variável. Quanto maior o número de variáveis e os limites definidos, maior a dificuldade e o tempo consumido para identificar a solução ótima;
- 3º. Passo: Definir a função objetivo para avaliar as soluções testadas pelo algoritmo. Apesar de apresentada como uma terceira etapa do método, a função objetivo poderia ser estabelecida durante a fase de projeto do estudo de simulação. A função construída será minimizada, maximizada ou fazer uso de ambos em diferentes variáveis dependendo dos objetivos em estudo;
- 4º. Passo: Selecionar o tamanho da população (número de soluções) do algoritmo evolutivo. O tamanho da população afeta a confiabilidade e o tempo requerido para a condução de busca. Nesta fase são também definidos outros parâmetros, tais como: a precisão requerida, o nível de significância e o número de replicações;
- 5º. Passo: Após a conclusão da busca um analista deve estudar as soluções encontradas, uma vez que, além da melhor solução encontrada, o algoritmo encontra várias outras soluções competitivas. Uma boa prática é comparar todas as soluções tendo como base a função objetivo.

Apesar de definida para uso do *SimRunner*®, a metodologia proposta por Harrel, Ghosh e Bowden (2004) devido a seu caráter generalista, pode ser estendida e aplicada a outros *softwares* que utilizam como técnica de otimização os AG.

3. Otimização em modelos de simulação

Harrel, Ghosh e Bowden (2004) definem otimização como o processo de testar diferentes combinações de valores, para variáveis que podem ser controladas, objetivando encontrar a combinação de valores que fornecem o resultado mais desejável para os resultados de saída em um modelo.

Um modelo de simulação geralmente inclui n variáveis de entrada ($x_1, x_2, \dots, x_n$) e m variáveis de saída ($y_1, y_2, \dots, y_m$) (Figura 1). A otimização desse modelo de simulação implica em encontrar a configuração ótima das variáveis de entrada, ou seja, os valores de $x_1, x_2, \dots, x_n$ que otimizem a(s) variável(eis) de saída(s) (CARSON E MARIA, 1997).




Figura 1 – Modelo de simulação

Fonte: Adaptado de Carson e Maria (1997)

Para Harrel *et al.* (2002) o uso da otimização visa responder perguntas do tipo: Quais os ajustes ótimos das variáveis de entrada (x) que maximizam (ou minimizam) uma saída no modelo de simulação. Nesse sentido o objetivo é encontrar um valor ótimo, que maximize ou minimize um determinador indicador de desempenho.

Stuckman, Evans e Mollaghasemi (1991) classificam em três grupos os analistas que utilizam a simulação na tentativa de otimizar um sistema real. O primeiro grupo recorrerá a tentativa e erro, alterando desordenadamente as variáveis de entrada na esperança de encontrar uma solução que otimize o sistema. O segundo grupo promoverá uma alteração sistemática das variáveis de entrada, como em uma análise de sensibilidade (CHWIF e MEDINA, 2010) e observará os resultados alcançados. Já o terceiro grupo utilizará um procedimento de otimização via simulação, aplicando uma técnica de otimização para o problema.

Para Chwif e Medina (2010), inúmeras são as vantagens desta última abordagem. Para estes autores a principal vantagem se encontra em se ter um procedimento sistemático para a otimização das variáveis, evitando o método de tentativa e erro. Adicionalmente, com a utilização integrada da otimização, a simulação se torna um gerador de soluções e não só um avaliador de soluções.

Kleijnen, Van Beers e Van Nieuwenhuyse (2010) reconhecem os problemas de otimização via simulação como problemas de difícil solução. E apresentam como desvantagens de sua utilização o fato das saídas dos modelos de simulação serem provenientes de funções implícitas e expostas a ruídos. Os autores ainda afirmam que dependendo do número de entradas no modelo de simulação este pode se tornar um processo caro devido às exigências computacionais e ao tempo envolvido.

Para Wang e Schonfeld (2006) não existem garantias que os resultados encontrados na otimização de modelos de simulação sejam os ideais. Os resultados dependem do método de otimização utilizado e como as opções, parâmetros e tolerâncias foram especificadas. Um bom modelo de otimização pode atingir de forma eficiente uma configuração próxima a ideal. Na prática, segundo os autores, a diferença entre o ótimo global e a solução apresentada pela otimização é normalmente insignificante considerando as incertezas nas entradas e nas relações funcionais entre as várias variáveis.

Para Fu (2002) uma das interfaces mais bem-sucedida entre a pesquisa operacional e a computação tem sido o desenvolvimento de *softwares* de simulação a eventos discretos. Várias técnicas de otimização tem sido integradas a simulação, principalmente por meio de *softwares* de simulação comerciais. Hoje a inclusão de rotinas de otimização tornou-se quase onipresente na maioria dos pacotes de simulação a eventos discretos.

No entanto para Barnett (2003) até o início do ano 2000 a comunidade de simulação foi relutante em utilizar ferramentas de otimização. April *et al.* (2006) aponta que esta resistência começou a diminuir com o início das pesquisas na área de metaheurísticas juntamente com a melhoria dos métodos de análise estatística.

Para Fu *et al.* (2000) a integração entre *softwares* de simulação e rotinas de otimização se deu recentemente, visto que a primeira vez que tal tema surgiu em dois dos mais renomados livros de simulação, Law e Kelton (2000) e Banks *et al.* (2000), foi no início do século XXI.

Para Silva, Galhardo e Montevechi (2004), a otimização via simulação vem sendo difundida devido em grande parte a pacotes de simulação integrados a rotinas de otimização.

O objetivo da inclusão destas rotinas em *softwares* de simulação é o de buscar definições melhoradas para os parâmetros do sistema em relação ao seu desempenho. No entanto ao contrário dos pacotes de programação matemáticos, o usuário não tem como saber se um ponto de ótimo foi realmente atingido (FU *et al.*, 2000).

Para Harrel *et al.* (2002) o progresso no desenvolvimento de ferramentas computacionais para análise de simulação tem sido especialmente lento na área de otimização da simulação. O uso de técnicas tradicionais para otimização faz com que apenas pessoas com alto grau de especialização compreendam os benefícios trazidos. Isso vem sendo resolvido com a inserção de novas técnicas de otimização como os Algoritmos Evolutivos (*Evolutionary Algorithms – EA*) e os Algoritmos Genéticos (*Genetics Algorithms – GA*).

A Tabela 1 agrupa os principais *softwares* de otimização existentes no mercado e citados em vários trabalhos presentes na literatura, assim como os pacotes de simulação aos quais estão incluídos. Apresentam-se, também, as técnicas de otimização utilizadas por esses pacotes.

Tabela 1 – *Softwares* de Otimização
Fonte: Adaptado de Fu (2002), Law (2007), Law e Kelton (2000), Law e McComas (2002)

Software de Otimização	Pacote de simulação	Técnica de otimização
<i>AutoStat</i> ®	<i>AutoMod</i> ®, <i>AutoSched</i> ®	Algoritmos Evolutivos e Algoritmos Genéticos
<i>OptQuest</i> ®	<i>Arena</i> ®, <i>Crystal Ball</i> ®, etc.	Busca Scatter , Tabu e Redes Neurais
<i>OPTIMIZ</i> ®	<i>SIMUL8</i> ®	Redes Neurais
<i>Optimizer</i> ®	<i>WITNESS</i> ®	<i>Simulated Annealing</i> e Busca Tabu
<i>WizardGA</i> ®	<i>Tecnomatix Plant Simulation</i> ®	Algoritmos Evolutivos e Algoritmos Genéticos
<i>SimRunner</i> ®	<i>ProModel</i> ®	Algoritmos Evolutivos e Algoritmos Genéticos

4. Método para otimização de modelos de simulação a eventos discretos proposto

O método para otimização de modelos de simulação a eventos discretos proposto por Pinho (2008) é composto por duas etapas. A primeira etapa consiste na verificação da possibilidade de aplicação do método para o problema de otimização proposto. Tal verificação é feita com base nas condições de contorno para sua utilização.

O método desenvolvido é aplicável para problemas de otimização de modelos de simulação a eventos discretos cujas variáveis de decisão são do tipo discretas, determinísticas e inteiras. Somente se estas condições forem atendidas, o método poderá iniciar a fase de otimização do modelo de simulação. Caso contrário, se uma das condições de contorno não for atendida não será possível iniciar a fase de otimização.

A segunda etapa do método consiste na otimização do modelo por meio do algoritmo genético adaptativo desenvolvido. A Figura 2 apresenta o fluxograma do algoritmo desenvolvido bem como suas adaptações.




Figura 2 – Fluxograma do método de otimização desenvolvido
Fonte: Pinho (2008)

Para a primeira geração o algoritmo calcula o número de *bits* necessários para cada indivíduo da população do AG (MITCHELL, 1996). Em seguida o tamanho da população inicial é calculado (GOLDBERG, 1989) gerando-se então a população inicial do AG. Estes passos só são executados na primeira rodada do algoritmo.

A partir da primeira geração, o algoritmo incrementa o parâmetro tamanho da população em 50%. Os indivíduos são gerados aleatoriamente e são inseridos na população atual do problema, constituindo uma nova geração.

O método desenvolvido faz uso do simulador a eventos discretos para avaliar cada indivíduo, para tal este envia cada indivíduo da população para o simulador, que retorna a resposta do modelo de simulação para este indivíduo com base na função objetivo definida para o problema de otimização.

Esta comunicação entre o simulador e o método de otimização é feita por meio de um objeto chamado *ProActiveX* fornecido pelo fabricante do simulador. O relacionamento entre o método de otimização e o simulador via objeto é apresentado na Figura 3.

Durante a execução do método, a ferramenta desenvolvida envia para o objeto (*ProActiveX*), os indivíduos da população. Esses indivíduos representam as variáveis de entrada do modelo de simulação. O objeto insere as variáveis de entrada no simulador, aguarda a execução da simulação e armazena os resultados gerados pelo simulador. Esses resultados serão utilizados na avaliação de cada indivíduo.

Terminada a avaliação de todos os indivíduos componentes da população, o método faz uma verificação entre os resultados encontrados para a geração atual e o da geração anterior, caso não ocorra melhoria significativa considera-se que o critério de parada foi satisfeito. Neste caso os resultados da otimização são apresentados e o método é encerrado.




Figura 3 – Relacionamento entre método de otimização, simulador via objeto
Fonte: Pinho (2008)

Em caso contrário, ou seja, se a condição de parada não for satisfeita, indivíduos da população atual são selecionados pelo método da roleta para reprodução. Para os indivíduos selecionados são aplicados os operadores de cruzamento e mutação. Após a aplicação destes operadores, uma nova geração é formada, e todo o ciclo é novamente iniciado.

O método desenvolvido foi testado na otimização de vários modelos de simulação a eventos discretos com funções objetivos lineares (PINHO, 2008; PINHO, MONTEVECHI e MARINS, 2008; PINHO, MONTEVECHI e MARINS, 2009), obtendo excelentes resultados tanto em termos de qualidade de resposta, como na questão do tempo necessário para convergência.

5. Objeto de estudo

O modelo de simulação a ser otimizado nesse trabalho refere-se a uma célula de produção de uma empresa brasileira de alta tecnologia, produtora de produtos de comunicação óptica. A área de manufatura da empresa é composta por seis células de produção, sendo cada célula responsável por montar um grupo de equipamentos. A célula alvo deste estudo é responsável pela produção de *transponders* de 2,5 Gb.

Toda a implementação deste modelo desde suas etapas iniciais até a elaboração do modelo operacional pode ser verificada em Montevechi *et al.* (2008). A Figura 4 ilustra o modelo computacional desenvolvido e implementado no *software Promodel®*.




Figura 4 – Célula de produção implementada no *Promodel®*

6. Estudo comparativo

Nessa seção serão apresentados os 5 passos da metodologia proposta por Harrel, Ghosh e Bowden (2004) para otimização de modelos de simulação a eventos discretos, mostrados no item 2 deste artigo.

Passo 1: Definição das variáveis de decisão

Para o objeto de estudo em questão foram definidas como variáveis de decisão: quantidade de operadores na célula (X_1), número de bancadas com setup (X_2), número de bancadas sem setup (X_3) e se há ou não organização de material feita pela produção (X_4).

Passo 2: Definição do tipo de variável e limites superiores e inferiores

Definiu-se que as três primeiras variáveis de decisão (quantidade de operadores na célula, número de bancadas com setup, número de bancadas sem setup) seriam do tipo inteiras, com limite inferior igual a 1 e limite superior igual a 9. A quarta variável de decisão (se há ou não organização de material) foi determinada como sendo do tipo binária, com limite inferior igual a 0 (não há) e limite superior igual a 1 (há).

Passo 3: Definição da função objetivo

O objetivo do modelo de simulação será encontrar a quantidade de operadores e de bancadas com e sem setups, além de verificar se vale ou não a pena organizar os materiais na linha de produção a fim de maximizar o lucro obtido pela célula. Para tal, elaborou-se uma função para o lucro considerando-se a receita gerada pela produção semanal e o custo de cada uma das decisões obtidas pelas variáveis de entrada. A função objetivo utilizada neste objeto de estudo foi do tipo não linear.

Passo 4: Definição dos parâmetros da simulação

O *SimRunner*® apresenta três perfis de otimização: cauteloso, moderado e agressivo. O perfil de otimização é um reflexo do número de soluções possíveis que o *software* examinará. O perfil cauteloso considera um maior número de possíveis soluções e mais completa será a busca por melhores soluções. Contudo, o tempo necessário para seu processamento será elevado quando comparado aos outros perfis. O perfil agressivo trabalha com uma pequena população, a qual permite convergir para uma solução mais rapidamente, porém a confiabilidade de sua solução será menor comparada aos demais perfis. Por fim o perfil moderado apresenta o equilíbrio entre os perfis cauteloso e agressivo (TORGA, 2007; SIMRUNNER USER GUIDE, 2002). 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.

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: 20%; 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.

Passo 5: Análise da solução

Em testes preliminares de utilização do algoritmo proposto por Pinho (2008) na otimização de modelos de simulação com funções não lineares, verificou-se uma convergência prematura do mesmo para soluções pouco satisfatórias. Desta forma, optou-se por alterar a estrutura do algoritmo genético adaptativo para sua forma clássica. Assim, foram retirados da estrutura do AG o cálculo do número da população inicial (GOLDBERG, 1989) para a primeira geração e o acréscimo de 50% de novos indivíduos para cada nova geração (KAVEH e SHAHROUZI, 2007; MA e ZHANG, 2008), e adotou-se um número fixo para o tamanho da população como sendo igual a 80 (MICHEL, 1996). Ou seja, não se considerou o algoritmo

proposto como sendo um algoritmo adaptativo. A modificação na estrutura do algoritmo pode ser visualizada na Figura 5.




Figura 5 – Modificação realizada no método de otimização desenvolvido

Sendo assim, no estudo comparativo realizado entre os métodos de otimização foram utilizados tanto o método adaptativo proposto em Pinho (2008) como sua versão modificada, ou seja, o algoritmo em sua forma clássica.

A Figura 6 apresenta a comparação do tempo necessário para convergência dos algoritmos na otimização do modelo de simulação com quatro variáveis de decisão.




Figura 6 - Tempos de processamento na otimização do objeto de estudo

Como esperado na utilização do *software* comercial ocorreu um aumento no tempo para convergência em função do perfil de otimização utilizado, desde o perfil agressivo até o perfil cauteloso. Tanto o método de otimização proposto original como o alterado, necessitaram de mais tempo para convergência que o perfil cauteloso do *SimRunner*®.

Para que se possa realizar uma análise mais aprofundada dos resultados provenientes da otimização do modelo de simulação, as respostas apresentadas pelo *SimRunner*® e pelo método

proposto (adaptativo e clássico), bem como a solução para o problema de maximização foram agrupados na Tabela 2.

Tabela 2 - Resultados da Otimização do Modelo de Simulação

Otimizador / Perfil	Solução	Valor Função Objetivo	Tempo de Processamento
<i>SimRunner</i> ®/Agressivo	$X_1=9/X_2=7/X_3=5/X_4=1$	R\$ 130.366,70	144 s
<i>SimRunner</i> ®/Moderado	$X_1=9/X_2=8/X_3=5/X_4=1$	R\$ 139.866,70	216 s
<i>SimRunner</i> ®/Cauteloso	$X_1=9/X_2=8/X_3=5/X_4=1$	R\$ 139.866,70	295 s
Método Proposto Adaptativo	$X_1=9/X_2=9/X_3=5/X_4=1$	R\$ 136.500,00	415 s
Método Proposto Clássico	$X_1=9/X_2=4/X_3=4/X_4=1$	R\$ 139.900,00	480 s

No perfil agressivo o *software* comercial encontrou uma solução com pouco mais de dois minutos, o menor tempo computacional entre os métodos, porém o resultado encontrado divergiu em mais de R\$ 9.000,00 em relação à melhor resposta encontrada. Por sua vez, os perfis moderado e cauteloso do *SimRunner*® convergiram para uma mesma resposta, a diferença entre ambos foi o tempo necessário para encontrar a solução. O perfil cauteloso precisou de 30% a mais de tempo em relação ao perfil moderado para convergir para a mesma solução.

O método proposto adaptativo convergiu para uma solução intermediária entre o perfil agressivo e os perfis cauteloso e moderado, no entanto necessitou de 40% a mais de tempo que o perfil cauteloso para tal. A melhor solução foi encontrada pelo método proposto clássico, para 9 operadores, 4 bancadas com setup, 4 bancadas sem setup e com a organização de materiais na célula, resultando num lucro máximo de R\$ 139.900,00. Porém, o método demandou mais tempo que o perfil cauteloso (62% a mais) e o moderado (122% a mais) do *SimRunner*®.

8. Conclusões

O estudo comparativo permitiu verificar que a estrutura do algoritmo adaptativo proposto por Pinho (2008), apesar de apresentar excelentes resultados na otimização de modelos de simulação lineares, tanto em termos de qualidade de resposta como em eficiência para convergência, não apresenta bons resultados na otimização de modelos não lineares.

No estudo conduzido, verificou-se que em sua estrutura original, o algoritmo converge prematuramente a uma solução não satisfatória quando comparado a um *software* comercial de otimização (*SimRunner*®).

A modificação na estrutura do algoritmo genético adaptativo para sua versão clássica, fixando o número inicial da população, fez com que o método proposto chegasse a uma solução melhor que o perfil cauteloso do *SimRunner*®, porém o algoritmo teve sua eficiência em termos de tempo para convergência comprometida.

Cabe aqui ressaltar que se encontra em andamento uma pesquisa que busca adaptar o algoritmo desenvolvido para otimização de modelos de simulação não lineares, para que ao mesmo tempo em que este seja capaz de apresentar uma solução com elevada qualidade de resposta, não se descuide do tempo necessário para convergência na otimização. O trabalho buscará apresentar uma alternativa adaptativa para o método original e definir qual o melhor conjunto de parâmetros para a nova estrutura do algoritmo.

A princípio se buscará por meio de revisão da literatura uma estratégia adaptativa para otimização de modelos não lineares, mais eficaz que a utilizada no algoritmo original, e a utilização do delineamento de experimentos (DOE) para o estabelecimento do melhor conjunto de parâmetros para o AG.

Agradecimentos

Os autores agradecem a CAPES, CNPq, FAPEMIG e Padtec pelo suporte dado a esta pesquisa.

Referências bibliográficas

- Aarts, E. H. L.; Korst, J.; Michiels, W.** *Simulated Annealing*. In: *Burke, E.K.; Kendall, G. (eds.). Introductory tutorials in optimisation, decision support and search methodologies*. Springer, p. 187-211, 2005.
- April, J.; Better, M. Glover, F.; Kelly, J. P.; Laguna, M.** (2006) Enhancing Business Process Management With Simulation Optimization. In: *Proceedings of the Winter simulation conference*, Monterey, CA, USA.
- 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.** (2001) Panel Session: The Future of Simulation. In: *Proceedings of the Winter Simulation Conference*, Atlanta, GA, USA.
- Banks, J.** (2000) Introduction to Simulation, In: *Proceedings of the Winter Simulation Conference*, Orlando, FL, USA.
- Banks, J.; Carson, J. S.; Nelson, B. L.; Nicol, D. M.** *Discrete event system simulation*. 4.ed. Upper Saddle River, NJ: Prentice-Hall, 2005.
- Barnett, M.** (2003) Modeling & Simulation in Business Process Management, *BP Trends Newsletter*, White Paper & Technical Briefs, pp. 1-10.
- Bruzzone, A. G., Bocca, E., Longo, F., Massei, M.** (2007) Training and recruitment in logistics node design byusing web-based simulation. *International Journal of internet Manufacturing and Services*, Vol. 1, No. 1, pages 32-50.
- Carson, Y.; Maria, A.** (1997) Simulation optimization: methods and applications. In: *Proceedings of the Winter Simulation Conference*, 118-126.
- Chwif, L.; Medina, A.C.** *Modelagem e Simulação de Eventos Discretos: Teoria e Aplicações*. São Paulo: Ed. dos Autores, 309p., 2010.
- Coello, C. A. C.; Lamont, G. B.; Van Veldhuizen, D. A.** *Evolutionary Algorithms for Solving Multi-Objective Problems* (Genetic and Evolutionary Computation) Springer, 2nd ed., 2007.
- Debusse, J. C. W.; Smith V. J. R.; Smith, G. D.** (1999) Parameter optimization for a discrete event simulator. *Computers & Industrial Engineering*, v.37, p.181-184.
- Fu, M. C.** (2002) Optimization for Simulation: Theory vs. Practice. *Journal on Computing*, v.14, n.3.
- Fu, M. C.; Andradóttir, S.; Carson, J. S.; Glover, F.; Harrell, C. R.; Ho, Y. C.; Kelly, J. P.; Robinson, S. M.** (2000) Integrating optimization and simulation: research and practice. In *Proceedings of the Winter Simulation Conference*, 610-616. Piscataway, NJ, USA.
- Glover, F.; Laguna, M.; Marti, R.** *Principles of Tabu Search*, In: *Approximation Algorithms and Metaheuristics*. Chapman & Hall/CRC, 2005.
- Goldberg, D. E.** *Genetic Algorithm in Search, Optimization and Machine Learning*. Redwood City: Addison-Wesley Publishing Company, Inc., 1989.
- Harrel, C. R.; Mott, J. R. A.; Bateman, R. E.; Bowden, R. G.; Gogg, T. J.** *Simulação: otimizando os sistemas*. 2ed. São Paulo: IMAM. 136 p., 2002.
- Harrel, C. R.; Ghosh, B. K.; Bowden, R.** (2004) *Simulation Using Promodel*. 2ed. New York: McGraw-Hill.
- Hillier, F. S.; Lieberman, G. J.** *Introduction to Operations Research*; 9th Ed.; McGraw-Hill, 2010.
- 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.
- Jafferli, M.; Venkateshwaran, J.; Son, Y. J.** (2005) Performance comparison of search-based simulation optimization algorithms for operations scheduling, *International Journal of Simulation & Process Modelling*. 1. 58-71.
- Jahangirian, M.; Eldabi, T.; Naseer, A.; Stergioulas, L. K.; Young, T.** (2010) Simulation in manufacturing and business: A review. *European Journal of Operational Research*. 203. pp 1-13.
- Kelton, W. D.; Sadowski, R. P. E.; Sturrock, D. T.** *Simulation with Arena*, Forth Edition, New York: McGraw- Hill, 2007.

- Kleijnen, J. P. C.; Wan, J.** (2007) Optimization of simulated systems: OptQuest and alternatives. *Simulation Modelling Practice and Theory*. v.15, p.354–362.
- Kleijnen, J. P. C.; Van Beers, W.; Van Nieuwenhuysse, I.** (2010) Constrained optimization in simulation: A novel approach. *European Journal of Operational Research*, v.202, p.164–174.
- Lacksonen, T.** (2001) Empirical comparison of search algorithms for discrete event simulation. *Computers & industrial Engineering*, v.40, p.133-148.
- Law, A. M.** (2007) *Simulation modeling and analysis*, 4th edition. McGraw-Hill, 768p.
- Law, A. M.; Kelton, W. D.** *Simulation modeling and analysis*. 3.ed. New York: McGraw-Hill, 760 p., 2000.
- Law, A. M.; McComas, M. G.** (2002) Simulation-Based Optimization, In: *Proceedings of the Winter Simulation Conference*, San Diego, CA, USA.
- Linden, R.** *Algoritmos Genéticos: Uma Importante Ferramenta da Inteligência Computacional*. Rio de Janeiro: Editora Brasport, 2008.
- Ma, Y.; Zhang, C.** Quick convergence of genetic algorithm for QoS-driven web service selection. *Computer Networks*, v.52, p.1093–1104, 2008.
- Marti, R.; Laguna, M.; Glover, F.** (2006) Principles of scatter search. *European Journal of Operational Research*, v.169, p.359–372.
- Mitchell, M.** *An Introduction a Genetic Algorithm*. Cambridge: MIT Press, 1996.
- Montevecchi, J. A. B.; Leal, F.; Pinho, A. F.; Costa, R. F. 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 Winter Simulation Conference*, Miami, FL, USA.
- Pinho, A. F.** *Proposta de um método de otimização de modelos de simulação a eventos discretos*. 2008. Tese (Doutorado). Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, Guaratinguetá, SP, 2008.
- Pinho, A. F.; 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.
- Pinho, A. F.; Montevecchi, J. A. B. ; Marins, F. A. S.** (2009) Avaliação de um método de otimização proposto para modelos de simulação a eventos discretos. In: *XLI Simpósio Brasileiro de Pesquisa Operacional*, Porto Seguro.
- Ripley, B.** *Pattern Recognition and Neural Networks*. Cambridge University Press, 1996.
- Ryan, J.; Heavey, C.** (2006) Process modeling for simulation. *Computers in Industry*, v.57, n.5, p.437–450.
- Sargent, R. G.** (2009) Verification and validation of simulation models. In: *Proceedings of the Winter Simulation Conference*, Austin, TX, USA.
- Silva, W. A.** *Otimização de parâmetros da gestão baseada em atividades aplicada em uma célula de manufatura*. 2005. Dissertação (Mestrado em Engenharia de Produção) – UNIFEI – Universidade Federal de Itajubá, Itajubá, MG, 2005.
- Silva, W. A.; Galhardo, M. R.; Montevecchi, J. A. B.** (2004) Otimização de uma célula de manufatura usando simulação computacional. In: *XXIV Encontro Nacional de Engenharia de Produção (XXIV ENEGEP)*, Anais... Florianópolis, SC, Brasil, p.3062-3069.
- SimRunner User Guide**. ProModel Corporation: Orem, UT. USA. 2002.
- Stuckman, B.; Evans, G.; Mollaghasemi, M.** (1991) Comparison of global search methods for design optimization using simulation, In: *Proceedings of the Winter Simulation Conference*, SCS, San Diego, CA, USA.
- 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.
- Tyni, T.; Ylinen, J.** (2006) Evolutionary bi-objective optimization in the elevator car routing problem. *European Journal of Operational Research*, v.169, p.960–977.
- Wang, S.; Schonfeld, P.** (2006) Genetic Algorithm for Selecting and Scheduling Waterway Projects. NETS Report.