

MELHORANDO O DESEMPENHO DE METAHEURÍSTICAS COM O AUXÍLIO DE PLANEJAMENTO DE EXPERIMENTOS

Eduardo Batista de Moraes Barbosa

Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP)
Av. Dr. Ariberto Pereira da Cunha, 333 - Guaratinguetá, SP - 12516-410, FEG/UNESP
eduardo.bmbarbosa@gmail.com

Edson Luiz França Senne

Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP)
Av. Dr. Ariberto Pereira da Cunha, 333 - Guaratinguetá, SP - 12516-410, FEG/UNESP
edson.senne@unesp.br

Messias Borges Silva

Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP)
Av. Dr. Ariberto Pereira da Cunha, 333 - Guaratinguetá, SP - 12516-410, FEG/UNESP
messias.silva@feg.unesp.br

RESUMO

As metaheurísticas são algoritmos de propósito geral que orientam outros procedimentos (heurísticas e/ou métodos exatos) a encontrar soluções quase ótimas, ou algumas vezes ótima, de problemas de otimização. Geralmente aplicadas na solução de problemas para os quais não há algoritmos específicos e/ou eficientes, cada metaheurística possui um conjunto de parâmetros do qual é extremamente dependente. Entretanto, a sua configuração, ou sintonia-fina, nem sempre é trivial e, frequentemente, é realizada *ad hoc* de acordo com o problema em estudo. O presente artigo apresenta um estudo sobre a utilização de técnicas de planejamento de experimentos (DOE) para auxiliar a sintonia-fina das metaheurísticas algoritmo genético (GA) e recozimento simulado (SA), para solução de um problema de sequenciamento de tarefas. A qualidade dos resultados obtidos com as configurações propostas será comparada com resultados obtidos com uma configuração padrão dos algoritmos, submetidos à solução dos mesmos problemas. Resultados preliminares sugerem que o procedimento de sintonia-fina melhora a qualidade das soluções e permite tanto ao GA, quanto ao SA, ficarem mais próximos do ótimo para diferentes instâncias do problema de sequenciamento. Portanto, por meio deste estudo, pode-se concluir que a utilização de DOE pode ser uma ferramenta promissora para auxiliar na investigação, bem como na sintonia-fina de diferentes algoritmos.

PALAVRAS CHAVE. Metaheurísticas, Planejamento de Experimentos, Otimização.

Área principal: Metaheurísticas, Otimização Combinatória, Estatística

ABSTRACT

The metaheuristics are general purpose algorithms that guide other procedures (e.g.: heuristics and/or exact methods) to find nearly optimal solutions, or sometimes the optimal, of optimization problems. Generally applied to solve problems for which there are no specific efficient algorithms, each metaheuristic has a set of parameters, which is extremely dependent. However, its configuration, or fine-tuning, it is not always trivial and often it is *ad hoc* performed according to the problem studied. This paper presents a study on the use of design experiments (DOE) to assist the fine-tune of metaheuristics genetic algorithm (GA) and simulated annealing (SA), to solve a scheduling problem. The quality of results of the proposed settings will be

compared with results from the default settings of the algorithms, to solve the same problems. Preliminary results suggest the fine-tuning procedure improves the quality of solutions and allows for both GA and SA stay closer to the optimal for different instances of the scheduling problem. Therefore, by means of this study, it can be concluded that the use of DOE could be a promising tool to assist in research, as well as in the fine-tuning of different algorithms.

KEYWORDS. Metaheuristics, Design of Experiments, Optimization.

Main area: Metaheuristics, Combinatorial Optimization, Statistics.

1. Introdução

As metaheurísticas são algoritmos de propósito geral que orientam outros procedimentos (heurísticas e/ou métodos exatos) a encontrar soluções quase ótimas, ou algumas vezes ótima, de problemas de otimização. Em geral, esses problemas são intrinsecamente complexos e sua solução demanda o uso excessivo de recursos computacionais e tempo.

Geralmente aplicadas na solução de problemas para os quais não há algoritmos específicos e/ou eficientes, cada metaheurística possui um conjunto de parâmetros do qual é extremamente dependente. Entretanto, a sua configuração, ou sintonia-fina, nem sempre é trivial e, frequentemente, é realizada *ad hoc* de acordo com o problema em estudo, uma vez que a escolha de valores inadequados pode resultar no mau desempenho do algoritmo e/ou em soluções de baixa qualidade.

Pesquisas acerca de metaheurísticas estão em constante evolução e abrangem desenvolvimentos teóricos, novos algoritmos e o aprimoramento de técnicas para auxiliar os pesquisadores. Desde a última década, há um crescente interesse por metodologias para auxiliar a configuração desses algoritmos e reduzir o tempo dos trabalhos relacionados a essa atividade. Por isso, a sintonia-fina de metaheurísticas é um campo de pesquisa relevante no contexto de desenvolvimento desses algoritmos e de avaliação de problemas de áreas como Pesquisa Operacional e Engenharia.

A metodologia para planejamento de experimentos (em Inglês, *Design of Experiments* - DOE) permite o estudo simultâneo de múltiplos parâmetros combinados. Sua aplicação se destaca na solução de problemas que envolvem comparação, caracterização, modelagem e otimização. Por meio de uma abordagem estatística robusta, DOE têm sido empregado com sucesso em diferentes abordagens para auxiliar o processo de sintonia-fina e, também, a definição da configuração desses algoritmos (Coy *et al.*, 2000; Biratari *et al.*, 2002; Bartz-Beielstein *et al.*, 2003 e 2004; Adeson-Díaz e Laguna, 2006; Chan *et al.*, 2006; Nannen e Eiben, 2006 e 2007; Dobsław, 2010; Shahsavari *et al.*, 2011; Khoshjahan *et al.* 2013; e muitos outros).

O presente artigo tem como objetivo apresentar um estudo sobre a utilização de técnicas de DOE para auxiliar a sintonia-fina de metaheurísticas. A abordagem proposta será ilustrada a partir de um estudo de caso, no qual diferentes parâmetros dos algoritmos genético (em Inglês, *Genetic Algorithm* - GA) e de recozimento simulado (em Inglês, *Simulated Annealing* - SA) serão simultaneamente combinados e testados por meio de DOE, com a finalidade de encontrar a melhor configuração para cada algoritmo submetido à solução de um problema de otimização combinatória. A qualidade das configurações propostas será avaliada através da comparação dos resultados das metaheurísticas com a configuração padrão submetida à solução dos mesmos problemas.

O restante desse artigo está organizado da seguinte maneira: a Seção 2 apresenta um apanhado sobre o problema de sequenciamento de tarefas em máquinas, com o objetivo de minimizar o atraso total ponderado (em Inglês, *Total Weighted Tardiness Problem* - TWTP), bem como os algoritmos considerados no desenvolvimento desse estudo. Na Seção 3 é definido um procedimento de sintonia-fina de metaheurísticas com o auxílio de DOE. Os resultados da abordagem proposta para sintonia-fina são apresentados e analisados na Seção 4. As considerações finais do estudo estão na Seção 5.

2. Problema e Algoritmos Considerados

Problemas de sequenciamento envolvem tarefas que devem ser organizadas em máquinas, sujeitas a restrições, para otimizar uma função objetivo. A ideia-chave é encontrar uma ordem para as tarefas e determinar quando e em qual máquina cada tarefa deve ser executada.

Um problema de sequenciamento é definido como um conjunto J de tarefas ($j = 1, 2, \dots, n$). Cada tarefa $j \in J$ consome um tempo de processamento p_j (unidades de tempo) positivo e ininterrupto em m máquinas ($m \geq 1$), e pode possuir restrições em relação ao tempo para inicialização (r_j), data de finalização (d_j), prioridades (ω_j) de uma tarefa sobre outras tarefas, etc.

Na literatura contemporânea um dos objetivos mais amplamente estudados são aqueles relacionados a datas de finalização, especialmente significativos para a indústria devido à necessidade de cumprimento de prazos. Dentre os problemas com restrições de data, destaca-se o problema de minimização do atraso total ponderado (Vallada e Ruiz, 2009; Mazdeh *et al.*, 2011; Feili *et al.*, 2012). De maneira geral, o atraso de uma tarefa deve ser entendido como a diferença entre a data programada para finalização da tarefa e sua finalização efetiva. Por definição, o atraso (T_j) é computado como $\max(0, C_j - d_j)$, onde C_j é tempo de completude da tarefa j . O objetivo neste tipo de problema é organizar as tarefas de maneira a encontrar uma sequência ideal, tal que o atraso total ponderado seja minimizado.

Este problema pertence à classe de problemas denominada NP-difícil (van Leeuwen, 1994), cujas soluções ótimas podem ser obtidas a partir de algoritmos eficientes que demandam grande esforço computacional. Nesse contexto, as metaheurísticas despontam como abordagens promissoras para a solução desses problemas. Usualmente, inspiradas em metáforas de diferentes áreas, tais como biologia (algoritmos genéticos e redes neurais), etologia (colônia de formigas), ciências sociais (busca tabu), e física (otimização por enxame de partículas e recozimento simulado), estas técnicas se diferem em termos dos padrões de buscas, mas todas oferecem métodos precisos e balanceados para diversificação (exploração do espaço de buscas) e intensificação (exploração de uma região promissora) e compartilham características como o uso de componentes estocásticos (envolvendo aleatoriedade de variáveis) e uma variedade de parâmetros, que devem ser configurados de acordo com o problema em estudo.

O algoritmo genético (GA) é um método de base populacional proposto por (Holland, 1975). O método inspira-se no princípio de sobrevivência enunciado a partir da teoria da evolução das espécies de Darwin. Um típico GA é composto por operadores (seleção, cruzamento e mutação) análogos à natureza (Mitchel, 1996) para simular o processo de evolução, no qual a aptidão dos indivíduos (pais) é crucial para criar novas gerações.

O algoritmo de recozimento simulado (SA) é um método probabilístico proposto em (Kirkpatrick *et al.*, 1983) e (Cerny, 1985) com a finalidade de encontrar o extremo global de uma função objetivo com inúmeros extremos locais. Largamente aplicado na busca de uma solução para problemas de otimização combinatória, o método empregado no SA constitui uma analogia à termodinâmica, cuja essência é o resfriamento lento de um sólido, de modo que o produto final torne-se uma massa homogênea ao atingir uma configuração mínima de energia (Bertsimas e Tsitsiklis, 1993).

Uma das principais diferenças entre essas metaheurísticas é o método de busca empregado. O GA opera sob uma população de soluções, cujas novas gerações (prole) são geradas a partir dos indivíduos mais aptos das gerações anteriores (pais). Essa característica (princípio de sobrevivência) garante um incremento na qualidade das soluções à medida que novas gerações são criadas. Por outro lado, o SA realiza movimentos constantes entre uma solução (S) e outra (S') de acordo com alguma estrutura de vizinhança pré-definida. O SA utiliza um teste probabilístico para aceitar uma nova solução e, algumas vezes, essa característica permite que soluções de baixa qualidade sejam consideradas no processo de busca do algoritmo.

Tanto o GA, quanto o SA, possuem um conjunto de parâmetros (por exemplo, taxas de cruzamento e mutação, tamanho da população, para GA; e temperatura inicial e a sua taxa de decréscimo, número de interações, para o SA) que deve ser ajustado antes de iniciar a solução de um problema. Tendo em vista que as metaheurísticas são extremamente dependentes dos valores atribuídos aos diferentes parâmetros, eles devem ser cuidadosamente estudados durante o

processo de sintonia-fina, pois podem definir o sucesso dos algoritmos.

3. Sintonia-fina de Metaheurísticas com Auxílio de Planejamento de Experimentos

A abordagem para sintonia-fina de metaheurísticas proposta nesse estudo pode ser expressa por meio de um procedimento que se inicia a partir da seleção arbitrária de n instâncias ($n > 1$) de um problema de otimização. As diferentes instâncias são estudadas por meio de planejamentos fatoriais completos 2^k , a partir da definição dos níveis (baixo e alto) que cada parâmetro pode assumir. Planejamentos fatoriais estabelecem uma relação de causa e efeito entre parâmetros e resposta, cuja representação usual é um modelo empírico (linear ou quadrático) representativo para o processo sob análise (Montgomery, 2001):

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_{12} X_1 X_2 + \varepsilon, \quad (1)$$

onde Y é a resposta, β_i são coeficientes, X_1 e X_2 correspondem aos parâmetros (fatores) e ε é o erro experimental. Planejamentos fatoriais são úteis para identificar os fatores que têm influência sobre a resposta, mas são insuficientes quando o interesse é determinar ajustes dos fatores que podem otimizar o processo e resultar na resposta ótima. Por isso, o próximo estágio da abordagem proposta consiste em empregar a metodologia da superfície de respostas (em Inglês, *Response Surface Methodology* - RSM) como uma ferramenta de sintonia-fina. A partir da RSM é possível explorar regiões promissoras perto do ótimo e determinar ajustes de boa qualidade para os fatores estudados.




Figura 1. Representações gráficas da superfície de respostas. (a) Região de máximo; (b) Região de Mínimo; (c) Região de ponto de sela.

A RSM pode ser definida como uma coleção de técnicas matemáticas e estatísticas empregadas na modelagem e análise de problemas em que a resposta é influenciada pelos fatores, e o objetivo é otimizar a resposta (Montgomery, 2001; Khuri e Mukhopadhyay, 2010). A relação entre resposta e fatores pode ser aproximada por modelos empíricos de baixo grau, em geral, sob a forma de:

$$Y = \beta_0 + \beta_1 X_1 + \beta_{11} X_1^2 + \beta_2 X_2 + \beta_{22} X_2^2 + \beta_{12} X_1 X_2 + \varepsilon, \quad (2)$$

e representada graficamente no espaço tridimensional como gráficos de contornos que ajudam a identificar o formato da superfície (Figura 1).

Nessa abordagem as instâncias previamente selecionadas são tratadas como um conjunto de treinamento, sobre o qual são realizados estudos experimentais para determinar a configuração dos parâmetros de um algoritmo estudado. Portanto, ao final dos estudos experimentais existirão diferentes configurações para cada parâmetro, sendo cada uma relacionada a uma instância. Na etapa final da abordagem, a configuração de um parâmetro é determinada por:

$$\overline{param_j} = \frac{1}{n} \sum_{i=1}^n param_j(i), j = 1, 2, \dots, m, \quad (3)$$

ou seja, a média aritmética das configurações sugeridas. Em (3), $param_j$ corresponde à configuração sugerida para um parâmetro em cada uma das instâncias previamente selecionadas, n é o número de total de instâncias selecionadas e m o número de parâmetros.

4. Estudo de Caso

Para ilustrar a abordagem proposta para sintonia-fina de metaheurísticas (Seção 3), foi escolhido um conjunto de parâmetros que, intuitivamente, parece influenciar o desempenho das metaheurísticas GA e SA, independente, do problema estudado. Para o GA, os seguintes parâmetros foram escolhidos: probabilidade de cruzamento (pCros), probabilidade de mutação (pMut), tamanho da população (sPop) e número de gerações (nGen). Para o SA, os parâmetros considerados foram: probabilidade de aceitar uma solução inicial (pIni), número de estágios da temperatura (iExt), número de iterações em um estágio de temperatura (iInt) e taxa de decaimento da temperatura (dTem).

O presente estudo de caso foi realizado no ambiente de computação científica Scilab (<http://www.scilab.org>) em um computador de 64 bits com 1.8GHz Intel® Core i5™, 6GB de memória, 1 TB de disco rígido e Windows 8.

Para generalizar os resultados e compará-los, todas as respostas foram computadas por meio do desvio médio da solução ótima, dada por:

$$Desv = \frac{f(s) - f(s^*)}{f(s^*)}, \quad (4)$$

onde $f(s)$ representa a solução computada por um experimento e $f(s^*)$ é a solução ótima e conhecida do problema. Assim, quanto menor o valor de $Desv$, melhor o desempenho do algoritmo.

A sintonia-fina das metaheurísticas GA e SA foi realizada utilizando quatro instâncias arbitrariamente escolhidas do *benchmark* "wt40", um TWTP com 40 tarefas da biblioteca OR Library (URL: <http://people.brunel.ac.uk/~mastjjb/jeb/info.html>). Os parâmetros e os níveis (baixo e alto) requeridos por um planejamento fatorial completo 2^k ($k = 4$, com 16 rodadas experimentais), correspondentes à fase inicial da abordagem proposta são apresentados na Tabela 1.

Tabela 1. Configuração de parâmetros para GA e SA.

Params. (GA)	Baixo	Alto	Params. SA	Baixo	Alto
pCros	0,01	0,99	pIni	0,50	0,95
pMut	0,01	0,99	iExt	30	100
sPop	10	200	iInt	1000	2000
nGen	10	200	dTem	0,01	0,99

Nesse contexto, o planejamento fatorial foi utilizado com a finalidade de identificar os fatores que influenciam a resposta. Em linhas gerais, pode-se concluir tanto para o GA, quanto para o SA, que:

- todos os quatro fatores escolhidos são significativos para o processo, independente da instância considerada; e
- há diferenças nas interações entre fatores, de acordo com a instância estudada.

A próxima etapa consiste em aplicar a RSM para explorar as regiões promissoras próximas da região ótima, e obter configurações sugeridas para os parâmetros, de acordo com a instância estudada. A análise de variância (em Inglês, *Analysis of Variance* - ANOVA), que mede o grau de confiança dos dados, é empregada para confirmar a significância estatística e descrever um modelo empírico para explicar a relação entre parâmetros e resposta. Por exemplo, o modelo descrito pela ANOVA para os parâmetros do GA em uma instância é:

$$\begin{aligned}
 Y = & 0,139 + 0,003 * pCros - 0,039 * pCros^2 - 0,025 * pMut - 0,042 * pMut^2 \\
 & + 0,021 * sPop - 0,043 * sPop^2 - 0,001 * nGen - 0,038 * nGen^2 - 0,035 * pCros * pMut \\
 & - 0,010 * pCros * sPop + 0,022 * pCros * nGen - 0,031 * pMut * sPop + 0,001 * pMut * nGen \\
 & + 0,052 * sPop * nGen
 \end{aligned} \quad (5)$$

O modelo (4) foi otimizado por meio de um algoritmo de busca direta com base no método *simplex* de Nelder e Mead (1965). Na Tabela 2 são apresentados os resultados para o conjunto de parâmetros dos algoritmos estudados. Nessa tabela, a coluna Inst.3 corresponde aos

resultados dos parâmetros exemplificados no modelo (5).

Tabela 2. Configurações obtidas com a RSM para cada parâmetro.

Params. GA	Inst.1	Inst.2	Inst.3	Inst.4	Params. SA	Inst.1	Inst.2	Inst.3	Inst.4
pCros	0,54	0,51	0,55	0,53	pIni	0,74	0,76	0,74	0,71
pMut	0,56	0,58	0,54	0,57	iExt	62	61	64	64
sPop	110	121	140	116	iInt	1439	1429	1478	1401
nGen	123	133	137	120	dTem	0,58	0,56	0,58	0,53

Após obter as configurações sugeridas com a RSM, a fase final da abordagem consiste em determinar a configuração de cada parâmetro por meio (3) (Tabela 3). Por exemplo, $p_{Cross} = \frac{1}{4}(0,54 + 0,51 + 0,55 + 0,53) = 0,5325 \cong 0,53$ corresponde à configuração do parâmetro p_{Cros} do GA.

Tabela 3. Configurações padrão e sugerida para os parâmetros do GA e SA.

Params. (GA)	Padrão	Sugerida	Params. SA	Padrão	Sugerida
pCros	0,70	0,53	pIni	0,80	0,74
pMut	0,10	0,56	iExt	100	63
sPop	100	122	iInt	1000	1437
nGen	10	128	dTem	0,90	0,56

Para testar a qualidade das configurações sugeridas, ambos algoritmos GA e SA foram executados 10 vezes nas primeiras dez instâncias do *benchmark* "wt40" da OR Library, considerando-se as configurações padrão e sugerida para cada parâmetro dos algoritmos, conforme apresentado na Tabela 3.

4.1 Análise dos Resultados

Todos os resultados apresentados nesta seção foram computados por meio de (4) e para viabilizar comparações, foram obtidos antes e depois do procedimento de sintonia-fina usando as definições apresentadas na Tabela 3. Os resultados são apresentados nas Tabelas 4 (algoritmo GA) e 5 (algoritmo SA). Nessas tabelas, coluna DM apresenta a média aritmética de (4) em 10

execuções, isto é, $DM = \frac{1}{n} \sum_{i=1}^n Desv(i)$, onde $n = 10$; Min corresponde ao valor mínimo de (4)

alcançado após 10 execuções do algoritmo; e NÓtimo é o número de vezes que o algoritmo alcança o valor ótimo para cada instância. As linhas μ e σ são a média aritmética e o desvio padrão de todas as instâncias.

Tabela 4. Estatísticas do GA antes e após o procedimento de sintonia-fina.

Inst.	Antes da sintonia-fina			Após a sintonia-fina		
	DM	Min	NÓtimo	DM	Min	NÓtimo
1	1,63	1,01	0	0,19	0,02	0
2	0,59	0,40	0	0,13	0,05	0
3	2,42	0,69	0	0,28	0,07	0
4	0,53	0,46	0	0,12	0,01	0
5	0,87	0,19	0	0,09	0,00	2
6	0,70	0,48	0	0,01	0,00	5
7	0,74	0,47	0	0,03	0,00	3
8	0,54	0,26	0	0,05	0,01	0
9	0,32	0,21	0	0,01	0,00	2
10	0,48	0,31	0	0,05	0,01	0
μ	0,88	--	--	0,10	--	--
σ	0,61	--	--	0,08	--	--

A partir das estatísticas do algoritmo GA pode-se observar que há aumento na qualidade das soluções após o procedimento de sintonia-fina. O procedimento de sintonia-fina permite ao algoritmo alcançar o ótimo, destacando-se a instância 5, para a qual o valor ótimo é

obtido com maior frequência (50% das execuções). As estatísticas também revelam que 70% das instâncias (2 e de 4 a 10) chegam em valores muito próximos do ótimo após a configuração.

As estatísticas do SA (Tabela 5) demonstram que o algoritmo pode alcançar o ótimo com mais frequência após o procedimento de sintonia-fina. Com o SA, destacam-se as instâncias 4 e 5, em que o ótimo é alcançado em 50% e 60% das execuções, respectivamente. Semelhante ao observado com o GA, após o procedimento de sintonia-fina, o SA também pode obter valores muito próximos do ótimo para 80% das instâncias.

Tabela 5. Estatísticas do SA antes e após o procedimento de sintonia-fina.

Inst.	Antes da sintonia-fina			Após a sintonia-fina		
	DM	Min	NÓtimo	DM	Min	NÓtimo
1	1,13	0,72	0	0,06	0,02	0
2	0,60	0,18	0	0,11	0,00	1
3	1,93	0,94	0	0,07	0,07	0
4	0,55	0,42	0	0,03	0,00	5
5	0,51	0,17	0	0,05	0,00	6
6	0,60	0,49	0	0,07	0,01	0
7	0,72	0,57	0	0,06	0,04	0
8	0,53	0,33	0	0,04	0,00	3
9	0,33	0,21	0	0,02	0,01	0
10	0,56	0,40	0	0,05	0,00	1
μ	0,75	--	--	0,06	--	--
σ	0,44	--	--	0,02	--	--

Através da análise das séries temporais dos algoritmos (Figura 2) em uma única instância, pode-se notar que, após o procedimento de sintonia-fina (linhas tracejadas no gráfico), há melhora de aproximadamente 90% no desempenho de ambos GA e SA. Na Figura 2 (e Figura 3), GA significa "Antes da sintonia-fina" e GA' significa "Após a sintonia-fina". O mesmo se aplica para SA e SA'.

As estatísticas (Tabelas 4 e 5) indicam que o procedimento de sintonia-fina melhora o desempenho dos algoritmos, diminui a sua variabilidade e ajuda a obter resultados mais próximos do ótimo (Figura 3). De acordo com as estatísticas, o procedimento de sintonia-fina proposto por meio de experimentos fatoriais e RSM parece ser muito eficaz. No entanto, estudos adicionais devem ser realizados, a fim de confirmar a eficácia do procedimento.




Figura 2. Séries temporais de uma única instância antes e após procedimento de sintonia-fina.




Figura 3. Variabilidade das metaheurísticas estudadas.

5. Considerações Finais

Este artigo apresentou um estudo sobre a sintonia-fina de diferentes metaheurísticas através de uma abordagem estatística por meio de técnicas de DOE. A partir de um estudo de caso, foi investigada a influência de diferentes parâmetros dos algoritmos GA e SA, aplicadas em diferentes instâncias de um problema clássico de otimização (TWTP). A qualidade das configurações propostas para o GA e SA foram avaliadas e comparadas considerando-se as configurações padrão e sugeridas pelo estudo de sintonia-fina.

A utilização de DOE permite identificar a influência de um conjunto de parâmetros no desempenho dos algoritmos GA e SA e, também, realizar estudos aprofundados por meio de RSM e determinar o melhor ajuste para cada parâmetro das metaheurísticas.

A partir dos resultados do estudo de caso pode-se concluir que independente da natureza da metaheurística, o procedimento de sintonia-fina melhora a qualidade das soluções e permite que tanto GA, quanto SA, alcancem resultados melhores para diferentes instâncias do problema TWTP. A partir das comparações dos resultados observa-se que o algoritmo SA é ligeiramente melhor do que o GA.

No âmbito deste estudo, os algoritmos (SA e GA) e problema (TWTP) foram utilizados apenas para demonstrar uma abordagem estatística por meio de DOE para auxiliar a sintonia-fina de metaheurísticas. Os resultados obtidos demonstram que o método proposto pode ser uma ferramenta promissora. No entanto, estudos adicionais devem ser realizados para verificar a eficácia da metodologia proposta, principalmente, quando aplicadas em algoritmos já bem configurados.

Referências

- Adeson-Diaz, B.; Laguna, M.** (2006) Fine-Tuning of Algorithms Using Fractional Experimental Designs and Local Search. *Operations Research*, v. 54, n. 1, p. 99-114.
- Bartz-Beielstein, T.; Parsopoulos, K. E.; Vrahatis, M. N.** (2003) Particle swarm optimizers for Pareto optimization with enhanced archiving techniques. In: *The 2003 Congress on Evolutionary Computation*, 3, p. 1780-1787.
- Bartz-Beielstein, T.; Parsopoulos, K. E.; Vrahatis, M. N.** (2004) Design and Analysis of Optimization Algorithms Using Computational Statistics. *Applied Numerical Analysis & Computational Mathematics*, v. 1, n. 3, p. 413-433.
- Bertsimas, D.; Tsitsiklis, J.** (1993) Simulated Annealing. *Statistical Science*, v. 8, n. 1, p. 10-15.
- Birattari, M., Stützle, T., Paquete, L., e Varrenttrapp, K.** (2002). A racing algorithm for

- configuring metaheuristics. In: *Genetic and evolutionary computation conference*.
- Cerny, V.** (1985) Thermodynamical approach to the traveling salesman problem: an efficient simulation algorithm. *Journal of Optimization Theory and Applications*, v. 45, p. 41-51.
- Chan, K. Y.; Aydin, M. E.; Forgy, T. C.** (2006) Main effect fine-tuning of the mutation operator and the neighbourhood function for uncapacitated facility location problems. *Soft Computing*, v. 10, n. 11, p. 1075-1090.
- Coy, S.; Golden, B. L.; Runger, G. C.; Wasil, E. A.** (2000) Using Experimental Design to Find Effective Parameter Settings for Heuristics. *Journal of Heuristics*, v. 7, n. 1, p. 77-97.
- Dobslaw, F.** (2010) A Parameter Tuning Framework for Metaheuristics Based on Design of Experiments and Artificial Neural Networks. In: *Proceeding of the International Conference on Computer Mathematics and Natural Computing 2010*. p. 1-4.
- Feili, H.; Haddad, H.; Ghanbari, P.** (2012) Two Hybrid Algorithms for Single-Machine Total Weighted Tardiness Scheduling Problem with Sequence-Dependent Setup. *American Journal of Scientific Research*, Issue 64, p. 22-29.
- Holland, J. H.** (1975) *Adaptation in Natural and Artificial Systems*. University of Michigan Press, Boston, Mass, USA.
- Mazdeha, M. M.; Hamidinia, A.; Karamouziana, A.** (2011) A mathematical model for weighted tardy jobs scheduling problem with a batched delivery system. *International Journal of Industrial Engineering Computations 2*, p. 491-498.
- Mitchell, M.** (1996) *An Introduction to Genetic Algorithms*. Massachusetts Institute of Technology.
- Montgomery, D. C.** (2001) *Design and Analysis of Experiments*. (5th Edition), John Wiley & Sons Inc.
- Nannen, V.; Eiben, A. E.** (2006) A Method for Parameter Calibration and Relevance Estimation in Evolutionary Algorithms. In: *Genetic and Evolutionary Computation Conference (GECCO-2006)*, p. 183-190.
- Nelder, J. A.; Mead, R.** (1965) *Computer J.*, 7, 308.
- Kirkpatrick, S.; Gelatt, C. D.; Vecchi, M. P.** (1983) Optimization by simulated annealing. *Science*, v. 220, n. 4598, p. 671- 680.
- Khoshjahan, Y.; Najafi, A. A.; Afshar-Nadjafi, B.** (2013) Resource constrained project scheduling problem with discounted earliness-tardiness penalties: Mathematical modeling and solving procedure. *Computers & Industrial Engineering*, v. 66, n. 2, p. 293-300.
- Khuri, A. I.; Mukhopadhyay, S.** (2010) Response surface methodology. *WIREs Computational Statistics*, v. 2, p. 128-149.
- Nannen, V.; Eiben, A. E.** (2007) Relevance Estimation and Value Calibration of Evolutionary Algorithm Parameters. In Manuela M. Veloso, editor, *IJCAI*, p. 1034-1039.
- Shahsavari, M.; Najafi, A. A.; Niaki, S. T. A.** (2011) Statistical design of genetic algorithms for combinatorial optimization problems. *Mathematical Problems in Engineering*, v. 2011, p. 1-17.
- Vallada, E.; Ruiz, R.** (2009) Cooperative metaheuristics for the permutation flowshop scheduling problem. *European Journal of Operational Research*, Volume 193, Issue 2, p. 365-376.
- van Leeuwen, J.** (1994) *Handbook of Theoretical Computer Science*. The MIT Press.