

# OTIMIZAÇÃO VIA SIMULAÇÃO A EVENTOS DISCRETOS PARALELA UTILIZANDO DESIGN DE EXPERIMENTOS E METAMODELAGEM

**Wilson Trigueiro de Sousa Junior**

wilson.trigueiro@ufsj.edu.br

**Robson Bruno Dutra Pereira**

robsondutra@ufsj.edu.br

**Rafael de Carvalho Miranda**

mirandaprod@yahoo.com.br

**José Henrique de Freitas Gomes**

ze\_henriquefg@yahoo.com.br



*No setor industrial de produção de bens e serviços, existe a preocupação constante em se alocar recursos (na forma de pessoas e equipamentos) de maneira ótima para a redução de custos e aumentos do lucro. As técnicas de modelagem, simulação e otimização visam a determinação e análise das variáveis mais representativas para um objetivo em específico. Em sistemas complexos que envolvem variáveis de comportamento estocástico, é comum a utilização de técnicas de modelagem, simulação e otimização a eventos discretos. O presente trabalho utilizou de duas abordagens para o teste de um framework em ambiente Open Source, para reduzir em 75,4% o tempo de geração dos cenários e utilização de apenas 0,08% do espaço solução, para se encontrar o ponto de ótimo de alocação de recursos em um chão-de-fábrica em problema adaptado da literatura.*

*Palavras-chave: Simulação a Eventos Discretos, Paralelismo, Design de Experimentos, Metamodelo, otimização*

## 1. Introdução

Na busca em se manterem no mercado, as indústrias buscam a satisfação constante do consumidor cujas demandas recaem sobre a manutenção e aprimoramento da qualidade de produtos e serviços com possível redução do preço final (MAYNARD e HODSON, 2004; SALAM e KHAN, 2016). Com essa busca constante, técnicas de auxílio à tomada de decisão são utilizadas para a avaliação de possíveis alterações nos sistemas estudados (HILLIER e LIEBERMAN, 2015).

Com o advento da indústria 4.0, uma grande gama de dados vem sendo gerada e armazenada pelas empresas em *data centers* com a redução dos custos de: captura, transmissão e armazenamento de dados. Para que esse volume de dados gere benefício para as indústrias, são necessárias técnicas que auxiliem na sua análise, de forma tal que padrões sejam identificados e transformados em informação. Como exemplo de tais técnicas, pode-se identificar a simulação a eventos discretos, como metodologia suficientemente robusta para: tratamento de dados, captura de padrões e avaliação de cenários para auxílio no processo de tomada de decisão (BANKS *et al.*, 2010; WANG *et al.*, 2015; XU *et al.*, 2016).

Em se tratando de problemas complexos, é comum a presença de uma grande quantidade de soluções para serem avaliadas. Nesse sentido técnicas de otimização como: heurísticas, metaheurísticas e metamodelos são associadas a simulação a eventos discretos para se encontrar as melhores soluções que atendam às restrições dos diversos problemas da Engenharia de Produção podendo ser referente a: logística, layout de fábrica, alocação de recursos, planejamento da produção, etc. (NAWARA e HASSANEIN, 2013; PONSIGNON e MÖNCH, 2014; REIS DOS SANTOS e NOVA, 2006; SALAM e KHAN, 2016; VÉLEZ GALLEGO, VALENCIA RAMÍREZ e CASTRO ZULUAGA, 2012; WEBER, BOXNICK e DANGELMAIER, 2014).

O objetivo do trabalho é a integração de ferramentas computacionais de simulação a eventos discretos com técnicas de otimização e análise de resultados para testar a eficácia do framework em um problema da engenharia de produção, especificamente a alocação de recursos no chão-de-fábrica, unindo conceitos de otimização via hardware e via software, reduzindo o tempo necessário para a busca em todo o espaço solução.

Como contribuição desse trabalho pode-se ressaltar a utilização de *framework* em simulação com distribuição *Open Source* desenvolvido na linguagem Python 3.6.5, capaz de realizar simulações de cenários em paralelo, aproveitando os recursos presentes nos computadores que se possuem a tecnologia *multi-core*, permitindo uma maior rapidez na geração dos cenários. Contribui também para a comprovação da utilidade das técnicas de: *design* de experimentos, metamodelagem das respostas geradas e otimização da simulação por meio do metamodelo, comprovando que o ponto de ótimo do metamodelo é igual ao ponto de ótimo do espaço solução da simulação, para o exemplo estudado.

O trabalho foi dividido nas partes que se seguem: seção 2 referencial teórico; seção 3 metodologia; seção 4 resultados; seção 5 conclusões; seção 6 agradecimentos e por fim a seção 7 com as referências bibliográficas.

## 2. Referencial teórico

No intuito de dar embasamento à metodologia utilizada no presente trabalho, são apresentados nessa seção trabalhos referentes aos itens que compõem a parte experimental do trabalho constituída por: geração, tratamento e otimização dos dados.

### 2.1. Simulação a Eventos Discretos

O termo “simulação” refere a coleção de técnicas para imitar um comportamento específico de um sistema real ou ideal, empregando recursos (tempo e conhecimento) para responder

perguntas feitas para a estrutura estudada, do tipo “E se...?”, quando experimentos reais são muito caros ou impossíveis de serem realizados. A simulação pode ser utilizada em uma variedade de áreas de pesquisa, e em diversas aplicações, que basicamente consistem na aquisição de dados, análises e auxílio por intermédio do computador (BANKS *et al.*, 2010; KELTON, SADOWSKI e SWETS, 2010; LAW e MCCOMAS, 2000).

Como parte do processo de simulação, a escolha da plataforma computacional está relacionada às características dos pacotes atrelados ao programa principal, como: análise das distribuições estatísticas, interface gráfica por linha de programação, 2D ou 3D, integração com outros programas e de acordo com o conhecimento prévio do agente modelador em determinada plataforma de programação. Cada tipo de plataforma gera desafios e ganhos, pois em decorrência da necessidade técnica e/ou poder computacional para se gerar a complexidade do modelo desejada (CHWIF e MEDINA, 2015).

### 2.1.1. Paralelismo de simulação

Em um esforço para a utilização dos recursos computacionais modernos, foram desenvolvidos algoritmos capazes de aproveitar os recursos computacionais presentes nos computadores modernos (com popularização depois de 2005), com a presença de mais de uma unidade de processamento física por processador, denominada tecnologia *multicore*, capaz de realizar diferentes tarefas em paralelo (KIRK e HWU, 2010).

Nesse sentido, uma forma implementada para problemas que utilizam do paralelismo foi a adoção de controladores (programas), que consideram cenários conservativos ou otimistas para a ordenação dos eventos e comunicação entre os núcleos, de forma que cada evento possa ser gerado separadamente e ao mesmo tempo. Além da comunicação intra computador, é possível a comunicação entre processadores de diferentes estações, possibilitando uma simulação distribuída em um ou mais redes de máquinas (DAS, 2000; JAFER, LIU e WAINER, 2013).

No sentido de desenvolver algoritmos de simulação aproveitando do paralelismo, essa classe de programas foi denominada de *Parallel Discrete Event Simulation* (PDES) (SEIMEE e BRITS, 1996). Para problemas de áreas do conhecimento como biologia ou física (MONTAGNA, VIROLI e ROLI, 2015), é possível que os eventos sejam tratados de forma separada, ao contrário de problemas relacionados a área de Engenharia de Produção em que os eventos interagem com diferentes recursos que alteram seus estados de forma dinâmica com o ambiente e seus elementos de controle e necessidades de processamento. Assim foi denominada uma nova classe de algoritmos paralelos em que uma mesma instância completa é simulada em paralelo, com a finalidade de avaliação de múltiplos cenários ao mesmo tempo de processamento. Tais técnicas foram denominadas *Cloning Parallel Simulations* (HYBINETTE, 2004; HYBINETTE e FUJIMOTO, 1997, 2001).

## 2.2. Design de experimentos na simulação

A metodologia de *Design* de Experimentos (DOE) se refere a técnicas de estatísticas para criar um conjunto de experimentos de forma sistemática e controlada para geração e coleta de dados, com o objetivo de estimar a relação entre as variáveis dependentes e independentes (MONTGOMERY, 2017). Com um número finito de experimentos, é possível ter uma representatividade do espaço solução, de maneira que cada experimento avalia um conjunto de parâmetros possíveis para o problema estudado.

Dentre os problemas de simulação em Engenharia de Produção que utilizaram DOE pode-se citar como exemplo de arranjos fatorial completo e design robusto (Taguchi) (DEV, SHANKAR e DEBNATH, 2014; GALANKASHI *et al.*, 2016), com as finalidades de: alocação de recursos, definição de tempos de *setup*, cadeia de suprimentos e controle de processos produtivos contínuos (CAPACI *et al.*, 2017; DEV, SHANKAR e DEBNATH, 2014; GREWAL, ENNS e ROGERS, 2009; MONTEVECHI *et al.*, 2007).

### 2.3. Metamodelos e otimização

Após a determinação do arranjo experimental, podendo ser, por exemplo, gerado utilizando um Fatorial Completo ou um Arranjo Ortogonal de Taguchi, e da obtenção das suas respectivas respostas, é possível a criação de uma equação que melhor se ajusta aos dados coletados (KLEIJNEN, 2017a). A equação gerada tem o intuito de representar o espaço solução do problema. Dessa forma ao se encontrar os pontos de mínimo e máximo da equação que respeitam as restrições do problema, pode-se associar com a melhor resposta e ponto de ótimo, como exemplo dessas técnicas podemos citar: regressão linear, metamodelos de Kriging e redes neurais (ATTAR, RAISSI e KHALILI-DAMGHANI, 2016; KLEIJNEN, 2017B; YANG, 2010).

Ao contrário de técnicas de otimização como heurísticas e metaheurísticas, que podem ser aplicadas recursivamente em um modelo de simulação (JUAN *et al.*, 2015), o modelo gerado pelo ajuste dos arranjos de experimentos são comumente avaliados por métodos Bayesianos (TOLK, 2017) ou Gradientes (AQLAN, LAM e RAMAKRISHNAN, 2014; HILLIER e LIEBERMAN, 2015; SALVENDY, 2001).

## 3. Metodologia

Na metodologia são apresentadas as ferramentas e os motivos da escolha das mesmas para o desenvolvimento do presente trabalho, de forma a facilitar a reprodução dos resultados apresentados nas circunstâncias descritas, facilitando o desenvolvimento de novos trabalhos.

### 3.1. Objeto de estudo

Para o presente trabalho foi adotado um modelo de simulação adaptado de Gandhi *et al.* (2010). O objeto analisado foi o problema M/m/k, que consiste na simulação de um processo produtivo genérico onde máquinas produzem em paralelo, com fornecimento de matéria prima puxada, e probabilidade de quebra, demorando um tempo para ser reparado pelo

técnico de manutenção durante um determinado período de tempo, dados estes apresentados na Tabela 1.

Tabela 1: Distribuições de probabilidade associadas ao problema

Atividade	Distribuição de probabilidade (min)
Tempo de processamento por peça	Normal (média=10, desvio padrão=2)
Tempo entre as quebras	Exponencial ( $\lambda = 1/300$ )
Tempo de reparo da máquina	Constante (30)

A função objetivo desse problema visa a maximização dos lucros desse sistema, dados pela relação apresentada na Equação 1.

$$\begin{aligned} \text{Lucro} = & (\text{Total de peças} \times \$100) \\ & - (\text{Técnico de manutenção} \times \$800 \times \text{Tempo de operação}) \\ & - (\text{Tempo de operação} \times 2100) \end{aligned} \quad (1)$$

s.a.:

$$M_i = \{2, 3, \dots, 40\}: \forall i \in \text{Máquinas}$$

$$P_j = \{2, 3, \dots, 20\}: \forall j \in \text{Técnicos de manutenção}$$

$$T_k = \{30, 31, \dots, 150\}: \forall k \in \text{Tempo de operação}$$

Na Equação 1 estão relacionados o ganho de \$100 com a produção e venda de cada item e os custos de contratação de \$800 por semana do técnico de manutenção e \$2100 por semana de funcionamento da instalação industrial. Avaliando as restrições da Equação 1, o presente problema delimita um espaço solução constituído por 82080 possíveis combinações.

### 3.2. Passos e recursos utilizados

Para a geração do arranjo de experimentos foi utilizado o planejamento fatorial completo utilizando-se o software *Minitab*® 17, assim como a análise de regressão para obtenção do metamodelo. O metamodelo foi otimizado via planilha eletrônica *Excel*® e seu pacote de otimização *Solver*® utilizando do algoritmo GRG (*Generalized Reduced Gradient*) para encontrar o ponto de máximo que otimiza o lucro da função objetivo presente na Equação 1. Os experimentos foram realizados em uma máquina munida de processador Intel i7 7700, com 16GB de RAM e sistema operacional Windows 10 x64 versão 1709. Os níveis para construção do DOE estão na Tabela 2.

Tabela 2: Níveis das variáveis consideradas na formação do DOE

Variável do Problema	Níveis utilizados
Técnico de manutenção (pessoa)	5, 10, 15, 20
Máquinas (unidade)	10, 15, 20, 30, 40
Tempo de operação (semanas)	30, 70, 110, 150

A partir dos dados da Tabela 2 foi gerado um arranjo de 68 experimentos utilizando de fatorial completo com quatro níveis para a variável Técnico de manutenção, cinco níveis para a variável Máquinas e quatro níveis para o Tempo de operação, considerando que todas as variáveis são discretas e seus limites estão expressos nos níveis de máximo e mínimo da Tabela 2.

Para a simulação computacional foi utilizado a linguagem de programação *Python* 3.0 com a distribuição fornecida pela *Python Software Foundation*, versão 3.6.5, juntamente com a biblioteca de simulação de eventos discretos *SimPy* 3.0.10. Essa biblioteca permite a modelagem via linha de código e a inserção direta de recursividade para a geração das instâncias desejadas. Além da biblioteca de simulação foi utilizada a biblioteca nativa de

mapeamento e distribuição das funções para aproveitar do recurso de paralelismo de geração de cenários.

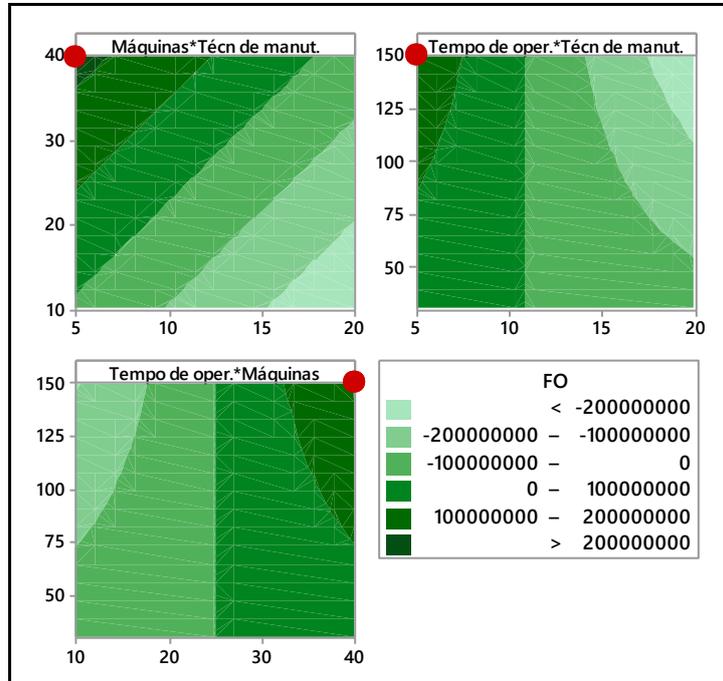
#### 4. Resultados

Em teste experimental, foram gerados 12 cenários e 10 replicações para cada cenário para a determinação da quantidade de replicações necessárias para o estudo. Como resultado, a variável dependente “total de peças” produzidas, em média gerava um erro inferior a 0,02%, e o resultado do lucro um erro inferior a 0,01%, considerando de 1 a 10 replicações. Avaliando a diferença entre o acréscimo ou decréscimo de uma unidade nas três variáveis independentes, o erro de uma replicação é em média 1,4%, o que não justificou a atualização de mais de uma replicação por cenário.

Nessa seção são apresentados os resultados com a aplicação da metodologia proposta. No que se refere à simulação do objeto de estudo, o modelo computacional foi construído de duas formas. A primeira, de maneira serial, e a segunda de maneira paralela, ambas com a mesma semente de números aleatórios. Na computação serial o programa demorou 472 segundos, sendo que na paralela a mesma instância com 68 cenários do planejamento fatorial completo gerado a partir dos níveis apresentados na Tabela 2 terminou com 116 segundos, representando um ganho de 75,4% em tempo de processamento, utilizando a mesma máquina.

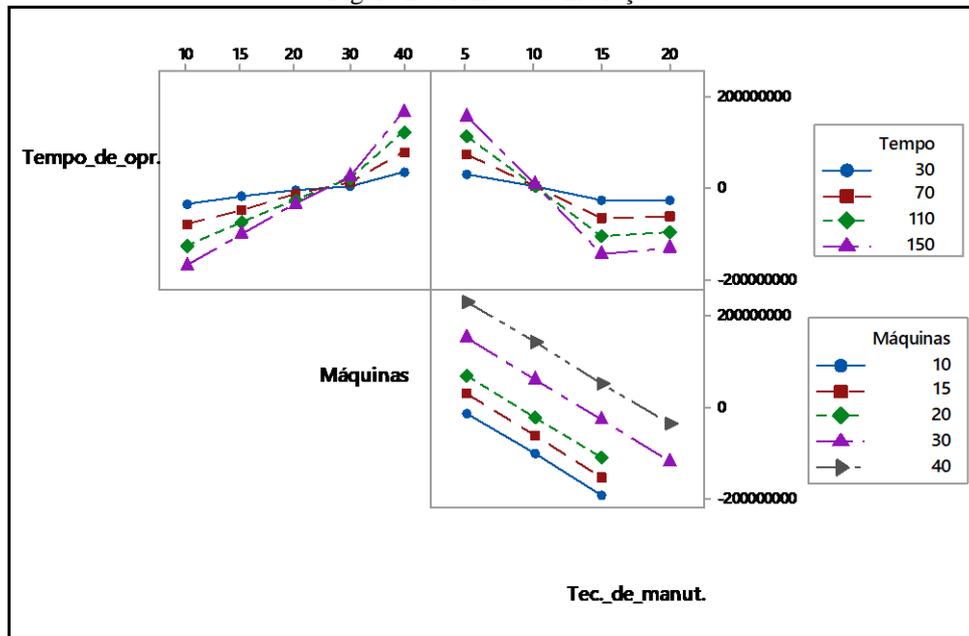
A Figura 1 ilustra os gráficos de contorno para o lucro em função das variáveis do problema. Pode-se observar graficamente que nível máximo de quantidade de máquina com mínimo tempo e mínimo número de técnicos de manutenção favorece a maximização do lucro, estando estes valores sinalizados por um ponto vermelho na Figura 1. Estes mesmos pontos sinalizados coincidem com os valores de ótimo encontrados para o problema após a otimização do metamodelo.

Figura 1 - Gráficos de contorno para o lucro em função das variáveis do problema



Fonte: Autores

Figura 2. Gráficos de interação



Fonte: Autores

A Figura 2 ilustra os gráficos de interação das variáveis do problema na função objetivo lucro. Pode-se observar que Técnico de manutenção = 5, Máquinas = 40 e Tempo de operação = 150

maximiza o lucro. Entretanto, considerando outros cenários viáveis, para níveis de Máquinas mais baixos e de Técnico de manutenção mais alto, o Tempo de operação = 30 apresenta resultados melhores.

A Equação 2 apresenta o metamodelo gerado para o problema proposto, a partir de uma regressão polinomial de primeira ordem com interação.

$$FO = 2061924 - 192105 \times \text{Técnico de manutenção} - 76442 \times \text{Máquinas} - 53597 \times \text{Tempo de operação} + 6833 \times \text{Técnico de manutenção} \times \text{Máquinas} - 200708 \times \text{Técnico de manutenção} \times \text{Tempo de operação} + 91247 \times \text{Máquinas} \times \text{Tempo de operação}$$

A Tabela 3 apresenta o modelo e o resultado para o teste t dos coeficientes de regressão com os respectivos p-valores. Como, para todos os termos estes apresentaram valor menor que  $\alpha = 0,05$ , houve significância estatística para os coeficientes de regressão.

Tabela 3. Regressão e teste t para os coeficientes

<b>Termo</b>	<b>Coef</b>	<b>SE Coef</b>	<b>T-Valor</b>	<b>P-Valor</b>
Constante	2061924.0	678498.0	3.0	0.003
Técnico de manutenção	-192105.0	54024.0	-3.6	0.001
Máquinas	-76442.0	23045.0	-3.3	0.002
Tempo de operação	-53597.0	5228.0	-10.3	0.000
Técnico de manutenção*Máquinas	6833.0	1477.0	4.6	0.000
Técnico de manutenção *Tempo de operação	-200708.0	355.0	-564.9	0.000
Máquinas*Tempo de operação	91247.0	162.0	562.2	0.000

Aplicando o algoritmo GRG presente no pacote *Solver*® no metamodelo da Equação 2 e inserindo as restrições presentes na Equação 1, o ponto de ótimo encontrado foi igual a utilização de 5 pessoas na manutenção, com 40 máquinas produzindo durante um tempo de 150 semanas, gerando uma solução ótima igual a \$388.321.769 unidades monetárias. Este ponto de ótimo está de acordo com o espaço solução representado na Figura 1.

## 5. Conclusão

O processo de modelagem, simulação e otimização para o presente estudo de caso proporcionou a avaliação de vários fatores que interferem na escolha dos métodos a serem utilizados em um projeto de otimização. Primeiramente, da escolha do método de otimização por metamodelagem de arranjo de experimentos com a utilização de um fatorial completo se deu pela quantidade de possibilidades de combinações do espaço solução (82080), fato este que possibilitou a utilização de método direto de otimização, através de complemento presente em planilha eletrônica, avaliando o metamodelo gerado e encontrando o ponto de ótimo global para o problema proposto com a avaliação de apenas 0,08% do espaço solução (68 cenários do *design* de experimento). Para a confirmação do ponto de ótimo, todo o espaço solução foi gerado, demandando 285 horas.

Em segundo ponto, foi identificado a dificuldade em encontrar uma plataforma de simulação a eventos discretos que permitisse a manipulação direta de dados de entrada para a formação de uma sequência desejada de experimentos e sua respectiva avaliação, com a adoção de funções específicas como o paralelismo das simulações e a constatação da sua eficiência. Nesse quesito a linguagem de programação *Python* juntamente com a biblioteca de simulação *SimPy* atenderam as demandas do presente trabalho, gerando as instâncias desejadas com um ganho de tempo de 75,4% em comparação do algoritmo paralelo e o serial, aproveitando assim, de todos os recursos computacionais que a máquina teste possuía.

Em trabalhos futuros será avaliado a utilização de métodos recursivos de otimização, como heurísticas e metaheurísticas, para a exploração de uma maior quantidade de níveis para as variáveis estudadas, além de outras técnicas de design de experimentos (como Krigagem e Tagushi), e também a possibilidade da aplicação de técnicas previsão por aprendizagem de máquina, que podem ser associadas com o processo de otimização.

## 6. Agradecimentos

Os autores agradecem o apoio da FAPEMIG, CAPES e CNPq.

## 7. Referências bibliográficas

AQLAN, F.; LAM, S. S.; RAMAKRISHNAN, S. An integrated simulation-optimization study for consolidating production lines in a configure-to-order production environment. **International Journal of Production Economics**, v. 148, p. 51–61, 2014.

ATTAR, A.; RAISSI, S.; KHALILI-DAMGHANI, K. Simulation-optimization approach for a continuous-review, base-stock inventory model with general compound demands, random lead times, and lost sales. **Simulation**, v. 92, n. 6, p. 547–564, 2016.

BANKS, J.; NELSON, B. L.; CARSON, J. S.; NICOL, D. M. **Discrete-Event System Simulation**. 5th. ed. [s.l.] Pearson, 2010.

CAPACI, F.; BERGQUIST, B.; KULAHCI, M.; VANHATALO, E. Exploring the Use of Design of Experiments in Industrial Processes Operating Under Closed-Loop Control. **Quality and Reliability Engineering International**, v. 33, n. 7, p. 1601–1614, 2017.

CHWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos**. 4. ed. [s.l.] Elsevier, 2015.

DAS, S. R. Adaptive protocols for parallel discrete event simulation. **Journal of the Operational Research Society**, v. 51, n. 4, p. 385–394, 2000.

DEV, N. K.; SHANKAR, R.; DEBNATH, R. M. Supply chain efficiency: A simulation cum DEA approach. **International Journal of Advanced Manufacturing Technology**, v. 72, n. 9–12, p. 1537–1549, 2014.

GALANKASHI, M. R.; FALLAHIAREZODAR, E.; MOAZZAMI, A.; YUSOF, N. M.; HELMI, S. A. Performance evaluation of a petrol station queuing system: A simulation-based design of experiments study. **Advances in Engineering Software**, v. 92, p. 15–26, 2016.

GANDHI, A.; DOROUDI, S.; HARCHOL-BALTER, M.; SCHELLER-WOLF, A. Exact Analysis of the M / M / k / setup Class of Markov Chains via Recursive Renewal Reward. **Proceedings of the ACM SIGMETRICS/international conference on Measurement and modeling of computer systems**, p. 153–166, 2010.

GREWAL, C. S.; ENNS, S. T.; ROGERS, P. Performance effects of setup time reduction with and without decision variable re-optimization: A simulation-optimization study. **Proceedings - Winter Simulation Conference**, n. 2003, p. 2135–2144, 2009.

HILLIER, F. S.; LIEBERMAN, G. J. **Introduction to Operational Research**. 10th. ed. [s.l.] McGraw-Hill, 2015.

HYBINETTE, M. Just-in-time cloning. Proceedings of the eighteenth workshop on Parallel and distributed simulation - PADS '04. **Anais...**New York, New York, USA: ACM Press, 1 out. 2004Disponível em: <<http://portal.acm.org/citation.cfm?doid=508366.508370>>

HYBINETTE, M.; FUJIMOTO, R. Cloning: A Novel Method for Interactive Parallel Simulation. **Winter Simulation Conference**, n. Fujimoto, p. 444–451, 1997.

HYBINETTE, M.; FUJIMOTO, R. M. Cloning parallel simulations. **ACM Transactions on Modeling and Computer Simulation**, v. 11, n. 4, p. 378–407, 2001.

JAFER, S.; LIU, Q.; WAINER, G. Synchronization methods in parallel and distributed discrete-event simulation. **Simulation Modelling Practice and Theory**, v. 30, p. 54–73, jan. 2013.

JUAN, A. A.; FAULIN, J.; GRASMAN, S. E.; RABE, M.; FIGUEIRA, G. A review of simheuristics: Extending metaheuristics to deal with stochastic combinatorial optimization problems. **Operations Research Perspectives**, v. 2, p. 62–72, 2015.

KELTON, W. D.; SADOWSKI, R. P.; SWETS, N. B. **Simulation with Arena**. 5th. ed. [s.l.] McGraw-Hill, 2010.

KIRK, D.; HWU, W.-M. W. **Programming Massively Parallel Processors: A Hands-on Approach**. Second ed. [s.l.] Elsevier, 2010.

KLEIJNEN, J. P. C. Design and Analysis of Simulation Experiments: Tutorial. *In*: [s.l.: s.n.]. p. 135–158.  
\_\_\_\_\_. Regression and Kriging metamodels with their experimental designs in simulation: A review. **European Journal of Operational Research**, v. 256, n. 1, p. 1–16, 2017b.

LAW, A. M.; MCCOMAS, M. G. Simulation-based optimization. **2000 Winter Simulation Conference Proceedings (Cat. No.00CH37165)**, v. 1, p. 46–49, 2000.

MAYNARD, H. B.; HODSON, W. K. (EDS.). **Maynard's Industrial Engineering Handbook**. [s.l.] McGraw-Hill, 2004.

MONTAGNA, S.; VIROLI, M.; ROLI, A. A framework supporting multi-compartment stochastic simulation and parameter optimisation for investigating biological system development. **Simulation**, v. 91, n. 7, p. 666–685, 2015.

MONTEVECHI, J. A. B.; PINHO, A. F. DE; LEAL, F.; MARINS, F. A. S. **Application of design of experiments on the simulation of a process in automotive industry**2007 Winter Simulation Conference. **Anais...IEEE**, dez. 2007Disponível em: <<http://ieeexplore.ieee.org/document/4419779/>>

MONTGOMERY, D. C. **Design and Analysis of Experiments**. 9th. ed. [s.l.] John Wiley & Sons, Inc., 2017.

NAWARA, G.; HASSANEIN, E. Solving the Job-Shop Scheduling Problem by Arena Simulation Software. **International Journal of Engineering Innovation & Research**, v. 2, n. 2, p. 161–166, 2013.

PONSIGNON, T.; MÖNCH, L. Simulation-based performance assessment of master planning approaches in semiconductor manufacturing. **Omega**, v. 46, p. 21–35, jul. 2014.

REIS DOS SANTOS, M. I.; NOVA, A. M. O. P. Statistical fitting and validation of non-linear simulation metamodels: A case study. **European Journal of Operational Research**, v. 171, n. 1, p. 53–63, 2006.

SALAM, M. A.; KHAN, S. A. Simulation based decision support system for optimization A case of Thai logistics service provider. **Industrial Management & Data Systems**, v. 116, n. 2, p. 236–254, 2016.

SALVENDY, G. **Handbook of Industrial Engineering**. 3th. ed. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2001.

SEIMEE, E.; BRITS, G. Pergamon Parallel Discrete Event Simulation of Manufacturing Systems: A Technology Survey Chong Peng and F. Frank Chert Dept. of Industrial & Systems Engineering Florida International University Miami, FL 33199 **Abstract Parallel discrete event simulat.** v. 31, n. 1, p. 327–330, 1996.

TOLK, A. **Advances in Modeling and Simulation**. Cham: Springer International Publishing, 2017.

VÉLEZ GALLEGO, M. C.; VALENCIA RAMÍREZ, D. A.; CASTRO ZULUAGA, C. A. A simulation-optimization heuristic for configuring a selective pallet rack system. **Ingeniare. Revista chilena de ingeniería**, v. 20, n. 1, p. 17–24, abr. 2012.

WANG, S.; WAN, J.; ZHANG, D.; LI, D.; ZHANG, C. Towards smart factory for Industry 4.0: A self-organized multi-agent system with big data based feedback and coordination. **Computer Networks**, v. 101, p. 158–168, 2015.

WEBER, J.; BOXNICK, S.; DANGELMAIER, W. **Experiments using meta-heuristics to shape experimental design for a simulation-based optimization system: Intelligent configuration and setup of virtual tooling** Asia-Pacific World Congress on Computer Science and Engineering. **Anais...IEEE**, nov. 2014 Disponível em: <<http://ieeexplore.ieee.org/document/7053839/>>

XU, J.; HUANG, E.; HSIEH, L.; LEE, L. H.; JIA, Q.-S.; CHEN, C.-H. Simulation optimization in the era of Industrial 4.0 and the Industrial Internet. **Journal of Simulation**, v. 10, n. 4, p. 310–320, 2016.

YANG, F. Neural network metamodeling for cycle time-throughput profiles in manufacturing. **European Journal of Operational Research**, v. 205, n. 1, p. 172–185, 2010.