

Combinação de Técnicas: Otimização-Simulação em uma Empresa do Setor Automotivo

Combination of Techniques: Optimization-Simulation in an Automotive Company

Luís Filipe Figueira de Faria¹, Universidade Federal de São Carlos
João Eduardo Azevedo Ramos da Silva², Universidade Federal de São Carlos
Deisemara Ferreira³, Universidade Federal de São Carlos

RESUMO

O presente artigo tem como objetivo avaliar o desempenho da combinação das técnicas de otimização e simulação de eventos discretos, que possuem abordagens distintas, mas podem ser complementares quanto ao alcance de objetivos. Por um lado, a otimização de sistemas busca, através de algoritmos, uma solução única e muitas vezes exata para um problema. Por outro lado, a simulação de eventos discretos analisa a interdependência e a interação entre os elementos do sistema em estudo e suas variáveis, ao longo do tempo. Espera-se então que, combinando as duas técnicas, seja possível extrair informações complementares das técnicas, de forma a potencializar os resultados do estudo. Dessa forma, o presente trabalho aplica essas técnicas, conjuntamente, para a solução de um problema real de seleção de *mix* produtivo gerado em função da expansão de uma empresa do setor automotivo, com designação de quais produtos serão produzidos em cada linha, por meio da otimização dos dados de entrada da simulação. Como principal resultado, observou-se um melhor aproveitamento das linhas e dos operadores, que apresentaram uma redução potencial de até 40% em sua utilização global.

Palavras-chave: otimização-simulação, combinação de técnicas, linha de produção, setor automotivo.

Editor Responsável: Prof.
Dr. Hermes Moretti Ribeiro da
Silva

ABSTRACT

This paper evaluates the performance of the combination of optimization techniques and discrete-event simulation, which, in general, are considered mutually exclusive in the Operations Research area. Optimization Techniques seeks a unique and often exact solution to a problem. On the other hand, discrete-event simulation analyzes the interdependence and interaction between the elements of the system under study, over time. It is expected that, by combining the two techniques, it will be possible to share complementary information of the techniques, in order to find a better solution for the study. Thus, the present study uses both techniques to solve a problem of selection of products to be manufactured in an automotive company, with designation of which products will be produced in each production line, by means of the optimization of the input data of the simulation. The combination of techniques enabled a better use of the lines and the operators, which presented a potential reduction of up to 40% in their utilization index.

Keywords: optimization-simulation, combination of techniques, production line, automotive industry.

1. Rodovia Washington Luis s/n, km 235 - Caixa Postal 676, CEP: 13565-905 - São Carlos – SP, luisfilipe.faria@yahoo.com.br; 2. jesilva@ufscar.br; 3. deisemaraferreira@gmail.com

FARIA, L. F. F.; SILVA, J. E. A. R.; FERREIRA, D. Combinação de Técnicas: Otimização-Simulação em uma Empresa do Setor Automotivo. **GEPROS. Gestão da Produção, Operações e Sistemas**, v. 14, n. 4, p. 93 - 113, 2019.

DOI: 10.15675/gepros.v14i4.2300

1. INTRODUÇÃO

A utilização de técnicas matemáticas, baseada em fundamentos quantitativos, vem contribuindo fortemente para uma tomada de decisão mais assertiva no tocante à economia de recursos e à produtividade nos sistemas de produção de bens e de prestação de serviços. Dentre as ferramentas, métodos e técnicas reportados, destacam-se a simulação de eventos discretos e a otimização de sistemas. Conforme mencionado por Pidd (2004), essas técnicas são oriundas da Pesquisa Operacional e utilizam modelos com parâmetros e restrições que representam sistemas produtivos reais e tornam possível a tomada de decisão com a mínima interferência nesses sistemas, poupando esforços, evitando custos desnecessários e aumentando a competitividade das organizações que as adotam.

Segundo Freitas Filho (2008), a simulação de eventos discretos se destaca por possibilitar a análise de sistemas ao longo do tempo, considerando a variabilidade dos processos representados, tornando possível a análise de sistemas que sequer existem ou que possuem difícil experimentação, gerando resultados representativos.

Por sua vez, a otimização se distancia da simulação quanto à forma de modelagem e o resultado final, representado por valores definidos de variáveis de decisão. Por meio dessas variáveis, agregadas a restrições que limitam o modelo matemático, é possível criar uma representação suficientemente fidedigna do sistema real, que geralmente fornece a melhor solução possível para a questão de pesquisa. (ARENALES *et al.*, 2007; HILLIER e LIEBERMAN, 2006)

Indaga-se, então, se a simulação e a otimização de sistemas poderiam ser utilizadas de forma conjunta na solução de problemas, uma vez que fornecem tipos de resultado e análise diferentes, e possivelmente complementares, para um mesmo sistema. Conforme destacado por Mokhtari e Dadgar (2015), uma das abordagens conjuntas pode ser chamada de simulação-otimização e é descrita pelo processo de obtenção dos valores ótimos de variáveis de decisão que são utilizadas como entrada em um modelo de simulação. Os autores, em seu estudo, utilizam um modelo de programação linear inteira mista para definir a disponibilidade das máquinas e para sequenciar a produção de forma a minimizar os atrasos nas entregas em um sistema *job-shop*. Em sequência, uma metaheurística que combina simulação e otimização é aplicada para testar e melhorar a solução do problema, incorporando variabilidade e interdependência nas análises.

Figueira e Almada-Lobo (2014) desenvolveram uma taxonomia específica para os métodos de combinação entre simulação e otimização de sistemas e descreveram esse tipo de integração como *Solution Completion by Simulation* (SCS), ou Complementação da Solução pela Simulação, onde o modelo de simulação discreta é utilizado para aprimorar ou testar os resultados fornecidos pelo modelo de otimização. Como exemplo dessa abordagem, pode-se citar o estudo de Lim *et al.* (2006), onde os autores aplicam a otimização para determinar capacidades de fábricas e centros de distribuição e complementam a solução através da simulação, quando os planos de produção e distribuição são definidos e testados.

Projetos de expansão industrial envolvem diversas variáveis, como a demanda esperada e a capacidade produtiva, que devem ser analisadas para que os recursos necessários sejam alocados de forma eficiente. O presente estudo apresenta um caso de necessidade de expansão de uma fábrica que adquiriu quatro novas linhas de produção, onde a equipe de gestão deve decidir quais produtos produzir nas novas linhas e quais produtos manter nas linhas antigas. Nota-se, então, a demanda por técnicas que forneçam respostas confiáveis para apoio de decisões táticas e operacionais.

Neste trabalho, a otimização fornece parâmetros de produção que indicam o melhor *mix* de produção (qual tipo de produto produzir em quais linhas de produção disponíveis) para uma indústria do setor automotivo, com o objetivo de reduzir a quantidade de cenários a serem testados. A decisão do que produzir em qual linha é, então, inserida como entrada no modelo de simulação discreta, que testa e verifica se a fábrica possui capacidade produtiva em suas máquinas e recursos (mão de obra) para atender esse plano de produção, indicando possíveis gargalos e ociosidades nas linhas de produção.

O objetivo do estudo é aplicar e avaliar a combinação das técnicas de otimização e simulação de sistemas, por meio do caso descrito de expansão das linhas produtivas, e inferir seus benefícios, comparando-os aos resultados obtidos unicamente com a utilização da simulação de eventos discretos, que por sua vez utilizam dados de entrada baseados na experiência de especialistas da equipe de gestão.

2. REFERENCIAL TEÓRICO

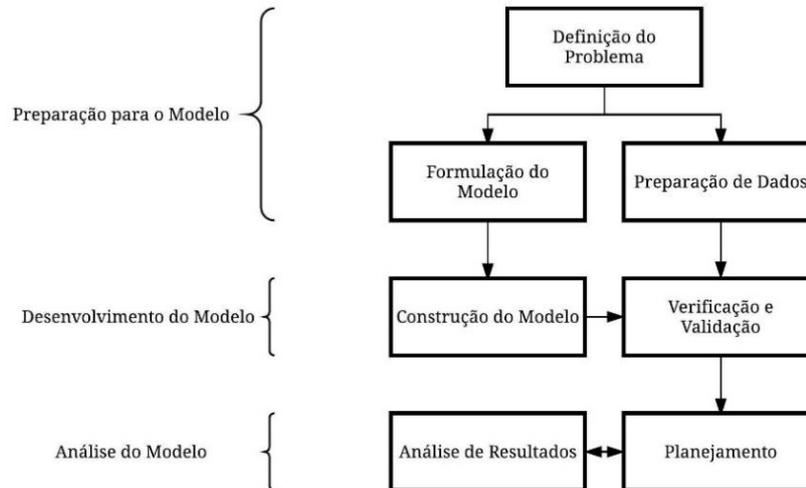
As técnicas de otimização e de simulação discreta possuem metodologias estruturadas para sua utilização de forma independente. A aplicação de técnicas de otimização via modelos matemáticos envolve um ciclo com 4 fases principais (ARENALES *et al.*, 2007). A primeira

GEPROS. Gestão da Produção, Operações e Sistemas, v. 14, n° 4, p. 93 - 113, 2019.

refere-se à delimitação do escopo do estudo (avaliação/julgamento do sistema ou problema real), definindo o caso estudado e suas características. Na sequência, é formulado um modelo matemático que, assumindo as necessárias simplificações, representa o escopo anteriormente determinado. Em seguida, métodos de solução são utilizados e resolvem o modelo proposto. Por fim, a solução fornecida pelo modelo é interpretada, inferindo-se sua aplicabilidade e, se viável a decisão por sua implementação, ou caso seja necessário, o modelo é ajustado para representar melhor o problema real, iniciando-se um novo ciclo de um estudo de otimização. Caso não haja mais ajustes, a solução é então implementada na prática. Como exemplos de trabalhos científicos onde a otimização foi aplicada com sucesso pode-se destacar o trabalho de Miranda, Morabito e Ferreira (2017), que desenvolveram um modelo de programação linear inteira-mista para o problema integrado de produção, estoque, distribuição e roteamento em uma empresa de móveis brasileira. De La Vega *et al.* (2018) por sua vez incorporaram um modelo matemático de otimização em uma estrutura de análise de decisão multicritério para o planejamento de transporte de cargas completas (FTL) ou fracionadas (LTL). Por fim, Além, Clark e Moreno (2016) desenvolveram um modelo de otimização de dois estágios para auxiliar a decisão eficiente no fornecimento de socorro às vítimas em casos de desastres naturais.

Por sua vez, Moraes e Santoro (2012) sintetizaram diversas metodologias encontradas na literatura visando elaborar uma metodologia genérica para estudos de simulação. Os autores constatarem que existem procedimentos em comum entre as metodologias disponíveis, como o início da pesquisa, onde Pritsker (1986), Shannon (1975), Law e Kelton (1991) e Pegden *et al.* (1995) determinam que um estudo de simulação parte da definição do problema e do sistema a ser avaliado. Os autores então propõem uma metodologia prática baseada nos fatores em comum das demais metodologias, de forma a representar todos os passos necessários de forma clara e objetiva. Essa metodologia é representada por 3 etapas, que por sua vez são subdivididas em atividades (Figura 1).

Figura 1: Metodologia para Modelagem em Simulação.



Fonte: Moraes e Santoro (2012).

Na etapa de Preparação para o Modelo, realizam-se as atividades necessárias para fornecer informações para o estudo, ou seja, um estudo prévio tanto quanto ao levantamento de dados como quanto à modelagem, o que resulta num modelo conceitual do sistema em estudo. Na etapa seguinte, Desenvolvimento do Modelo, com base nos dados e no modelo inicialmente planejado, elabora-se o modelo de simulação computacional, que será posteriormente utilizado para experimentação. Esse modelo é verificado quanto ao relacionamento entre as variáveis que o compõe e validado comparativamente ao sistema representado. Por fim, na etapa de Análise do Modelo, de posse do modelo validado é feito o planejamento experimental do estudo de simulação, definindo-se os cenários a serem experimentados com o modelo. Tais cenários são executados e os resultados são analisados, possibilitando uma recomendação para o sistema em estudo. Soluções baseadas em estudos de simulação discreta podem ser encontradas em diversas áreas. Faria e Silva (2015) avaliaram através da simulação a realocação de procedimentos de manutenção de equipamentos de colheita e transporte de cana-de-açúcar para períodos em que estivessem disponíveis. Por sua vez, Haass *et al* (2015) simularam opções de trocas de contêineres no transporte de bananas para o mercado europeu conforme o estágio de maturação das frutas. Ribeiro, Pinto e Peixoto (2017) avaliaram opções para o processo de entrada e saída de veículos em um aeroporto.

Com a análise das metodologias de ambas as técnicas individualmente, observa-se que a aplicabilidade de sua combinação é abrangente, uma vez que o método conjunto pode ser utilizado praticamente em todos os sistemas nos quais as ferramentas de otimização e simulação são aplicadas de forma individual.

Law e McComas (2000), definem a combinação entre simulação e otimização como a sequência de configurações de um sistema – cada configuração correspondente à um conjunto de valores para variáveis de decisão – que são simulados a fim de obter uma solução ótima ou próxima da ótima. Nos últimos anos, diversos autores vêm desenvolvendo técnicas combinadas de otimização e simulação para buscar potencializar o resultado dos estudos realizados.

Alguns estudos, por exemplo, utilizam a simulação de Monte Carlo para agregar variabilidade nos parâmetros ou resultados de um modelo de otimização (GRULER *et al.*, 2016; CORDEAU *et al.*, 2015; HERAZO-PADILLA *et al.*, 2015; MOKHTARI; DADGAR, 2015; NORLUND, GRIBKOVSKAIA; LAPORTE, 2015; KORYTKOWSKI, RYMASZEWSKI; WISNIEWSKI, 2013).

Há, ainda, estudos onde a otimização e a simulação são executadas simultaneamente ou alternadamente, até que um critério de parada seja alcançado. Dessa forma, os resultados dos modelos combinados evoluem até que uma solução robusta – e próxima da verdadeira solução ótima – seja encontrada (GUÇDEMIR E SELIM, 2017; BOYACI, ZOGRAFOS E GEROLIMINIS, 2017; FIKAR, GRONALT; HIRSCH, 2016; HAMZADAYI; YILDIZ, 2016; SHA; SRINIVASAN, 2016; LIN; CHEN, 2015; TAO; QIU, 2015; CHANG, CHANG; KUO, 2014; MORADY GOHAREH, KARIMI; KHADEMIAN, 2014; NOURINEJAD; ROORDA, 2014; BASSI, FERREIRA FILHO; BAHIENSE, 2012; MOUELHI-CHIBANI; PIERREVAL, 2010).

Dentre os estudos supracitados, destacam-se aqueles que utilizam a simulação como complemento para o resultado da otimização, como o estudo de Gruler *et al.* (2016), que combina metaheurísticas e simulação de Monte Carlo para a solução do problema de coleta de lixo com múltiplos depósitos e demanda estocástica; o estudo de Guçdemir e Selim (2017), que utiliza um modelo de simulação para agregar variabilidade no valor da função objetivo de um modelo de otimização aplicado à gestão de recursos de uma linha de manufatura; e o estudo de Sha e Srinivasan (2016), que utilizam a simulação baseada em agentes integrada

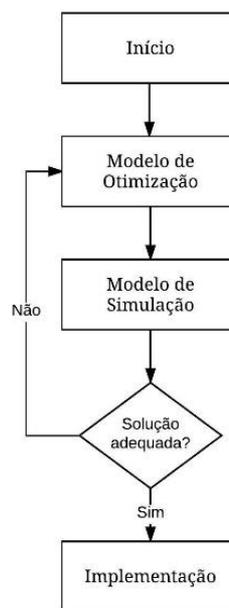
com um modelo de otimização para decidir políticas de roteamento e abastecimento de clientes de uma cadeia de suprimentos da indústria química.

3. PROCEDIMENTOS METODOLÓGICOS

3.1 Descrição da combinação de técnicas otimização-simulação

Para o presente estudo de caso, a combinação das técnicas de otimização e simulação foi utilizada da forma descrita por Boyaci, Zografos e Geroliminis (2017), encontrada na Figura 2.

Figura 2 - Etapas do estudo de Otimização-Simulação.



Fonte: Adaptado de Boyaci, Zografos e Geroliminis (2017).

Nessa metodologia conjunta, os resultados do modelo de otimização são fornecidos como entrada, ou seja, definem parâmetros, para o modelo de simulação. Em outras palavras, o modelo de simulação testa a capacidade do sistema em atender os parâmetros definidos pelo modelo de otimização. No presente estudo, o modelo de otimização fornece a melhor configuração do *mix* produtivo (que itens produzir em quais linhas) para o modelo de simulação, que por sua vez analisará através da consideração das interdependências e variabilidades temporais a factibilidade de atendimento desse *mix*.

A metodologia utilizada como referência para o desenvolvimento dos modelos de simulação discreta e otimização seguem as propostas de Moraes e Santoro (2012) e Arenales *et al.* (2007), respectivamente. Inicialmente, discutiu-se com a equipe responsável pelo projeto a delimitação do escopo do estudo, bem como seu objetivo – definir através da modelagem computacional o melhor *mix* de produção com relação ao número de linhas utilizadas para produzir um mesmo produto, utilizando cenários pré-definidos para a comparação das soluções. Em seguida, os dados e especificações do sistema necessários para a construção dos modelos computacionais foram coletados. Esses dados foram extraídos de registros históricos das linhas existentes e especificações técnicas fornecidas pela equipe responsável pelo projeto. Por fim, os modelos computacionais foram construídos e os cenários definidos foram executados.

Para a comparação dos resultados da combinação de técnicas com o modelo de simulação puro, foram configurados três cenários: C1 – Sistema inicial; C2 – Alocação dos produtos maiores nas linhas novas e C3 – Otimização-Simulação. O primeiro representa o cenário de *mix* inicial apresentado pela empresa estudada, onde todas as linhas produzem todos os tipos de produtos. Por sua vez, o segundo cenário representa uma estratégia de interesse da equipe gestora da empresa que representa um possível *mix* após a introdução das novas linhas – a transferência dos produtos maiores e com maior tempo de produção para as quatro linhas novas e a manutenção dos itens mais rápidos e simples nas quatro linhas já existentes.

Para a composição do cenário C3, seguindo a metodologia de combinação adotada, o resultado ótimo de *mix* de produção foi inserido no modelo de simulação que, ao longo de um mês, verificou a disponibilidade do sistema e a existência de gargalos produtivos – testando a possibilidade de cada uma das linhas de produzir a demanda estipulada pelo modelo de otimização.

3.2 Objeto de estudo

O processo produtivo em estudo consiste na produção empurrada de lotes de 5 tipos de produto, nomeados no texto por Tipo 1 a Tipo 5, por razões de sigilo, que variam em suas dimensões e tempos produtivos. Para produzir esses itens, a fábrica dispõe de 8 linhas de produção, denominadas aqui de linhas S5, S6, S7, S8, que são quatro linhas já existentes na fábrica; e as linhas SN1, SN2, SN3 E SN4, que são quatro linhas novas a serem implantadas.

Os dados utilizados para as linhas não existentes foram baseados em estimativas fornecidas pela empresa estudada.

Em relação à disponibilidade de produção, as linhas operam com 11 operadores cada (com exceção das linhas S5 e S6, que compartilham os 11 operadores entre si), em 3 turnos de 8 horas cada, com paradas de 1 hora para almoço, durante 25 dias por mês. Nas Tabelas 1, 2 e 3 podem ser observados os valores de tempo de produção, disponibilidade de tempo das linhas e demanda por tipo de produto, respectivamente. Observa-se na Tabela 3 a demanda de 1.200.000 unidades de produto conforme os tipos apresentados, tomada como meta para o horizonte de simulação de um mês.

Tabela 1 - Tempos de produção unitários por tipo de produto e por linha.

Linha	Tempo (minutos)				
	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5
S5	9,38	11,92	10,25	26,25	6,35
S6	9,38	11,92	10,25	24,75	4,90
S7	3,05	8,25	9,25	15,00	3,75
S8	3,05	8,25	9,25	15,00	3,75
SN1	3,05	8,25	9,25	15,00	3,75
SN2	3,05	8,25	9,25	15,00	3,75
SN3	3,05	8,25	9,25	15,00	3,75
SN4	3,05	8,25	9,25	15,00	3,75

Fonte: Elaboração dos autores.

Tabela 2 - Disponibilidade de tempo das linhas de produção por mês.

Linha	Disponibilidade (minutos)
S5	792.000
S6	792.000
S7	1.044.000
S8	792.000
SN1	720.000
SN2	720.000
SN3	720.000
SN4	720.000

Fonte: Elaboração dos autores.

Tabela 3 - Demanda por tipo de produto

Tipo de Produto	Quantidade	Percentual (%)
Tipo 1	937.729	78%
Tipo 2	79.284	7%
Tipo 3	37.595	3%
Tipo 4	98.011	8%
Tipo 5	47.378	4%
Total	1.200.000	100%

Fonte: Elaboração dos autores.

O objetivo do modelo de otimização é definir o *mix* de produção, restrito à disponibilidade mensal, em minutos, das linhas produtivas. Cada linha de produção, embora possua processos internos distintos tais como montagens, movimentações e inspeções, pode ser considerada como uma única operação, com tempo determinístico, por produto e que independe da sequência de produção. Por sua vez, o objetivo do modelo de simulação é testar o *mix* definido pelo modelo de otimização, representando os processos de forma mais detalhada, com a consideração dos operadores responsáveis pela produção das linhas e suas restrições (como trocas de turno e paradas para refeições), tempos de *setup* e formação de lotes. Nessas operações unificadas – que podemos chamar de “*black box*”, os 11 operadores são utilizados simultaneamente por toda a linha, independentemente da quantidade de operações existentes.

3.3 Modelos computacionais

Foi utilizado o software ProModel® (versão 9.2) para construção do modelo de simulação e o *software* GAMS (versão 24.1.3 demonstrativa) para implementação do modelo de otimização. Como critério de parada, para o modelo de simulação, foi considerada uma execução de um mês produtivo (25 dias). Por sua vez, para o modelo de otimização, o critério de parada foi a obtenção de um *gap* relativo ao melhor limitante inferior menor que 0.0001.

O modelo de simulação foi validado através da comparação dos resultados da execução do modelo (com os parâmetros de entrada iguais aos utilizados pela empresa), com os resultados históricos da produção. No caso, foram realizadas reuniões com equipes de especialistas da empresa de forma a verificar inconsistências do modelo em relação ao sistema

real. Por sua vez, para a validação do modelo de otimização basta verificar se cada linha respeita os limites de disponibilidade e possibilidade de produção.

O modelo matemático completo utiliza a notação seguinte:

Índices e conjuntos:

i = Índice do produto a ser produzido;

j = Índice da linha a ser utilizada;

I = Conjunto de produtos a serem produzidos (Tipos 1, 2, 3, 4 e 5);

J = Conjunto de linhas disponíveis (S5, S6, S7, S8, SN1, SN2, SN3 e SN4).

Parâmetros de entrada:

C_j = Capacidade mensal de produção da linha j (em minutos);

D_i = Demanda mensal do produto i ;

M = Valor suficientemente grande que não limita a produção nas linhas;

$t_{i,j}$ = Tempo para produzir um produto i na linha j (em minutos).

Variáveis de decisão:

$y_{i,j}$ = Se a linha j produz o produto do tipo i ;

$x_{i,j}$ = Quantidade de produtos do tipo i produzidos na linha j .

Por fim, a formulação do modelo:

$$\min F(x) = \sum_{i \in I} \sum_{j \in J} y_{i,j} \quad (1)$$

$$\sum_i x_{i,j} * t_{i,j} \leq C_j, \quad \forall j \in J \quad (2)$$

$$\sum_i x_{i,j} \geq D_i, \quad \forall i \in I \quad (3)$$

$$x_{i,j} \leq M * y_{i,j}, \quad \forall i \in I, \forall j \in J \quad (4)$$

$$x_{i,j} \in Z^+, y_{i,j} \in B^{mn} \quad (5)$$

A função objetivo (1) do modelo busca minimizar a quantidade de linhas utilizadas para produzir um mesmo tipo de produto. As restrições (2) e (3) determinam, respectivamente, que a soma das quantidades de produtos produzidos em cada linha deve ser menor ou igual à disponibilidade de tempo total da linha e maior ou igual a demanda daquele

tipo de produto. A restrição (4) é de setup e determina que se haverá a produção de um tipo de produto i na linha j ela deve estar disponível. Por fim, a restrição (5) define o domínio das variáveis x e y , no conjunto dos inteiros positivos e binários, respectivamente.

Paralelamente, o modelo de simulação representa fidedignamente o sistema produtivo estudado, com resultados validados e semelhantes aos resultados produzidos pelo sistema real. Ressalta-se que os processos possuem, basicamente, restrições de utilização de funcionários e disponibilidade dos equipamentos, além do *setup* mencionado anteriormente.

Para representar os parâmetros de possibilidade de produção de cada linha, foram criadas tabelas que são importadas pelo modelo de simulação através de uma interface automática com o Excel® e determinam os seus valores dentro do modelo. As Tabelas 4, 5 e 6 representam o cenário C1 – Sistema inicial, onde todas as linhas produzem todos os tipos de produtos; o cenário C2 – onde os produtos maiores e com maior tempo de produção (Tipo 2, 3 e 4) são alocados intencionalmente nas linhas novas, e o cenário C3 – onde as possibilidades de produção são resultados do modelo de otimização.

Tabela 4 - *Mix* do Cenário C1 - Inicial

Linha	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5
S5	SIM	SIM	SIM	SIM	SIM
S6	SIM	SIM	SIM	SIM	SIM
S7	SIM	SIM	SIM	SIM	SIM
S8	SIM	SIM	SIM	SIM	SIM
SN1	SIM	SIM	SIM	SIM	SIM
SN2	SIM	SIM	SIM	SIM	SIM
SN3	SIM	SIM	SIM	SIM	SIM
SN4	SIM	SIM	SIM	SIM	SIM

Fonte: Elaboração dos autores.

Tabela 5 - *Mix* do Cenário C2 – Produtos maiores nas linhas novas

Linha	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5
S5	SIM				SIM
S6	SIM				SIM
S7	SIM				SIM
S8	SIM				SIM
SN1		SIM	SIM	SIM	

SN2	SIM	SIM	SIM
SN3	SIM	SIM	SIM
SN4	SIM	SIM	SIM

Fonte: Elaboração dos autores.

Tabela 6 - Mix do Cenário C3 – Otimização-Simulação

Linha	Tipo 1	Tipo 2	Tipo 3	Tipo 4	Tipo 5
S5				SIM	
S6			SIM		SIM
S7				SIM	
S8		SIM			
SN1	SIM				
SN2	SIM				
SN3	SIM				
SN4	SIM				

Fonte: Elaboração dos autores.

Observa-se que o cenário otimização-simulação apresenta a produção de produtos Tipo 1 somente nas linhas novas. Isso ocorre devido à alta demanda e à eficiência da linha na produção para esse tipo de produto, que representa 78% da demanda mensal total, ocasionando uma exclusividade das linhas novas para tais produtos. Os outros tipos, por sua vez, foram distribuídos entre as linhas antigas, conforme a disponibilidade de tempo das linhas e tempos de produção dos produtos. Destaca-se que, diferentemente do que esperava a equipe técnica da empresa, as linhas não demandam flexibilidade para mais de um tipo de produto, uma vez que todas as linhas, com exceção da linha 6, produzem apenas um tipo. Por fim, vale ressaltar a necessidade de produção do produto Tipo 4 em duas linhas diferentes, por se tratar do produto com maior tempo de produção e o segundo produto com mais unidades produzidas – o que impossibilita a produção em somente uma linha, por indisponibilidade de tempo.

Percebe-se a diferença entre a metodologia utilizada nesse estudo e as metodologias utilizadas por Boyaci, Zografos e Geroliminis (2017) e Kim e Lee (2016). Os cenários a serem avaliados pela simulação são, nestes dois estudos, fornecidos pelo modelo de otimização até que um critério de parada seja alcançado (utilização de recursos entre 70% e 80%, por exemplo). No presente estudo, além do cenário fornecido pelo modelo de

otimização, a equipe responsável pela programação das linhas também propôs dois cenários para avaliação (C1 e C2), fruto de seu conhecimento tácito, possibilitando a comparação dessa alternativa com a indicação do modelo de otimização.

4. RESULTADOS E DISCUSSÕES

Com as tabelas de entrada configuradas, foi executado o modelo de simulação para um mês contínuo, sem interrupções. Abaixo, são observadas as quantidades de produção de cada tipo de produto em cada linha, para os 3 cenários analisados (Tabelas 7, 8 e 9, respectivamente).

Tabela 7 - Produção do Cenário 1 - Inicial

Tipo - Linha de Produção	Quantidade Produzida (unidades/mês)	Tipo - Linha de Produção	Quantidade Produzida (unidades/mês)
Tipo 1 - S5	53.040	Tipo 1 - SN1	108.032
Tipo 2 - S5	2.304	Tipo 2 - SN1	9.568
Tipo 3 - S5	1.584	Tipo 3 - SN1	3.648
Tipo 4 - S5	5.280	Tipo 4 - SN1	11.648
Tipo 5 - S5	1.872	Tipo 5 - SN1	6.336
Tipo 1 - S6	48.672	Tipo 1 - SN2	150.016
Tipo 2 - S6	5.760	Tipo 2 - SN2	13.312
Tipo 3 - S6	1.296	Tipo 3 - SN2	6.912
Tipo 4 - S6	4.080	Tipo 4 - SN2	16.800
Tipo 5 - S6	3.120	Tipo 5 - SN2	5.984
Tipo 1 - S7	162.048	Tipo 1 - SN3	154.880
Tipo 2 - S7	14.560	Tipo 2 - SN3	12.272
Tipo 3 - S7	5.760	Tipo 3 - SN3	7.104
Tipo 4 - S7	15.792	Tipo 4 - SN3	16.912
Tipo 5 - S7	7.040	Tipo 5 - SN3	7.392
Tipo 1 - S8	163.584	Tipo 1 - SN4	95.744
Tipo 2 - S8	14.352	Tipo 2 - SN4	7.072
Tipo 3 - S8	7.104	Tipo 3 - SN4	4.224
Tipo 4 - S8	18.256	Tipo 4 - SN4	10.976
Tipo 5 - S8	9.856	Tipo 5 - SN4	6.336
		Total	1.200.528

Fonte: Elaboração dos autores.

Tabela 8 - Produção do Cenário 2 – Produtos com demandas maiores nas linhas novas

Tipo - Linha de Produção	Quantidade Produzida (unidades/mês)	Tipo - Linha de Produção	Quantidade Produzida (unidades/mês)
Tipo 1 - S5	85.280	Tipo 4 - SN1	19.824
Tipo 5 - S5	6.656	Tipo 2 - SN2	22.256
Tipo 1 - S6	90.047	Tipo 3 - SN2	12.672
Tipo 5 - S6	1.872	Tipo 4 - SN2	31.136
Tipo 1 - S7	258.560	Tipo 2 - SN3	23.296
Tipo 5 - S7	17.952	Tipo 3 - SN3	12.480
Tipo 1 - S8	274.430	Tipo 4 - SN3	30.240
Tipo 5 - S8	18.304	Tipo 2 - SN4	15.392
Tipo 2 - SN1	18.096	Tipo 3 - SN4	5.952
Tipo 3 - SN1	6.528	Tipo 4 - SN4	18.480
		Total	969.453

Fonte: Elaboração dos autores.

Tabela 9 - Produção do Cenário 3 – Otimização-Simulação

Tipo e Linha de Produção	Quantidade Produzida (unidades/mês)
Tipo 4 - S5	16.160
Tipo 3 - S6	13.824
Tipo 5 - S6	32.032
Tipo 4 - S7	83.104
Tipo 2 - S8	79.040
Tipo 1 - SN1	194.560
Tipo 1 - SN2	282.624
Tipo 1 - SN3	283.392
Tipo 1 - SN4	215.616
Total	1.200.352

Fonte: Elaboração dos autores.

Através dos resultados de produção fornecidos pelo modelo de simulação, optou-se por descartar o Cenário 2, uma vez que a demanda estipulada para o mês simulado não foi

atendida. A alocação intuitiva dos produtos maiores nas linhas novas ocasionou a sobrecarga de algumas linhas e a ociosidade de outras. Observa-se, com relação aos cenários C1 e C3, que ambos foram capazes de atender a demanda – tornando-se necessário a análise de outros indicadores quantitativos para comparar os cenários analisados. É possível notar ainda, através dos resultados de alocação de produtos em linhas, que o cenário C3 oferece uma especialização maior das linhas, facilitando a programação da produção e diminuindo a necessidade de *setup* – uma vez que um produto é alocado sempre para um mesmo conjunto de linhas. No trabalho de Guçdemir e Selim (2017), o objetivo do modelo de otimização-simulação era determinar regras de sequenciamento que forneçam o melhor nível de satisfação do cliente. Entretanto, uma especialização das linhas semelhante à fornecida pelo modelo de otimização do presente estudo minimiza ou até descarta a necessidade de um sequenciamento da produção, uma vez que cada linha é dedicada a apenas um ou no máximo a dois produtos, no caso da linha S6.

Na Tabela 10 abaixo, pode-se observar as taxas de ocupação das linhas de produção, pareados para os dois cenários.

Tabela 10 - Taxa de ocupação das linhas nos cenários C1 e C3

Linha	Taxa de ocupação (%)		Diferença C3-C1 (%)
	Cenário 1	Cenário 3	
S5	74,7	44,8	-29,9
S6	73,5	39,8	-33,7
S7	88,9	93,5	4,6
S8	70,8	40,6	-30,2
SN1	89,0	91,4	2,4
SN2	85,4	90,5	5,1
SN3	84,0	93,5	9,5
SN4	86,1	93,4	7,3
Média	82,5	73,4	-9,1

Fonte: Elaboração dos autores.

É possível notar que os produtos foram produzidos com uma eficiência maior no cenário 3, uma vez que tiveram uma taxa média de ocupação menor. Nas linhas S5, S6 e S8 pode-se observar taxa de ocupação de aproximadamente 40%, que aponta o atendimento da

demanda com baixa utilização, e possibilita uma maior utilização dessas linhas em casos de aumento de demanda, por exemplo. As demais linhas (S7, SN1, SN2, SN3 e SN4), atenderam à demanda com variação máxima de 9,5% (SN3) entre os cenários, indicando que não houve sobrecarga dessas linhas para conferir ociosidade às três linhas anteriormente mencionadas.

Por sua vez, para a análise dos operadores, cuja quantidade foi mantida constante em todos os cenários, observa-se uma taxa média de ocupação menor dos operadores no cenário 3 (49,1%) em comparação ao cenário 1 (54,8%), o que possibilita a realocação de parte desses trabalhadores em outros setores (Tabela 11). Lembra-se que os operadores das linhas 5 e 6 são compartilhados.

Tabela 11 - Utilização dos operadores nos cenários C1 e C3

Linha	Taxa de ocupação (%)		Diferença C3-C1 (%)
	Cenário 1	Cenário 3	
S5-6	58,3	58,8	0,5
S7	60,9	48,1	-12,8
S8	64,2	26,9	-37,3
SN1	43,2	43,8	0,6
SN2	58,4	63,6	5,2
SN3	59,6	63,6	4,0
SN4	39,2	39,5	0,3
Média	54,8	49,1	-5,7

Fonte: Elaboração dos autores.

É possível observar na Tabela 11 que, na maioria das linhas, a demanda foi atendida com uma utilização menor ou praticamente igual dos mesmos no cenário C3, com exceção das linhas SN2 e SN3, que tiveram um aumento de até 5,2% na carga de trabalho. Entretanto, de forma geral, nota-se uma diminuição de 5,7%, em média, na taxa de ocupação dos operadores do cenário C1 para o cenário C3. O destaque, em termos de redução da taxa de ocupação dos operadores, ocorreu nas linhas S7 e S8, que resultaram nos valores de 48,1% e 26,9%, respectivamente, uma redução de 12,8 e 37,3 pontos percentuais em relação ao cenário C1.

6. CONCLUSÕES

Por meio do caso avaliado, o qual visava decidir a alocação de produtos a linhas de produção, os cenários estudados permitiram concluir que a combinação de técnicas forneceu o melhor aproveitamento dos recursos, simultaneamente ao atendimento da demanda estipulada. Sem a combinação de técnicas, a tarefa de decidir o *mix* produtivo seria árdua, uma vez que a combinação possível entre linhas e produtos é vasta. Observa-se que embora a solução obtida através dos modelos combinados pudesse ser encontrada utilizando-se somente do modelo de simulação, a quantidade de cenários possíveis a serem testados seria alta, demandando um esforço maior para análise.

Pode-se inferir que a combinação de técnicas de simulação e otimização é uma ferramenta com alto potencial de aplicabilidade na indústria e na área de pesquisa. No caso da indústria, a combinação pode ser utilizada para maximizar os resultados de um estudo de melhoria, como ocorrido no presente trabalho. Por sua vez, para pesquisas, a simulação pode ser utilizada de diversas formas, como para avaliar resultados de modelos de otimização teóricos, criando ambientes fictícios onde os resultados podem ser testados, ou agregar variabilidade em um modelo de otimização.

Como principal limitação do estudo, aponta-se a desconsideração das restrições de mão de obra e tempos de *setup* na otimização. Se consideradas, essas restrições e tempos poderiam alterar substancialmente o resultado da otimização. Entretanto, observa-se que o objetivo da combinação das técnicas ainda seria alcançado – fornecer o melhor cenário para teste em simulação.

Como sugestão de trabalhos futuros, propõe-se, um detalhamento maior do sistema no modelo de otimização no tocante a questões que afetam o processo, como os tempos de *setup* para produção de diferentes produtos em uma mesma linha e as restrições de mão de obra, como paradas para refeição, trocas de turno e curvas de aprendizagem que apontam a produtividade de cada operador de forma mais precisa.

Referências

ALEM, D.; CLARK, A.; MORENO, A. Stochastic network models for logistics planning in disaster relief. **European Journal of Operational Research**, v. 255, n. 1, p. 187–206, 2016.

ARENALES, M. **Pesquisa operacional**. Rio de Janeiro: Elsevier, 2007.

- BASSI, H. V.; FERREIRA FILHO, V. J. M.; BAHIENSE, L. Planning and scheduling a fleet of rigs using simulation-optimization. **Computers and Industrial Engineering**, v. 63, n. 4, p. 1074–1088, 2012.
- BOYACI, B.; ZOGRAFOS, K. G.; GEROLIMINIS, N. An integrated optimization-simulation framework for vehicle and personnel relocations of electric carsharing systems with reservations. **Transportation Research Part B: Methodological**, v. 95, p. 214–237, 2017.
- CHANG, K. H.; CHANG, A. L.; KUO, C. Y. A simulation-based framework for multi-objective vehicle fleet sizing of automated material handling systems: an empirical study. **Journal of Simulation**, v. 8, n. 4, p. 271–280, 2014.
- CORDEAU, J. F.; LEGATO, P.; MAZZA, R. M.; TRUNFIO, R. Simulation-based optimization for housekeeping in a container transshipment terminal. **Computers and Operations Research**, v. 53, p. 81–95, 2015.
- DE LA VEGA, D. S. et al. A decision on the truckload and less-than-truckload problem: An approach based on MCDA. **International Journal of Production Economics**, v. 195, n. August 2017, p. 132–145, 2018.
- FARIA, L. F. F.; SILVA, J. E. A. R. Effects of Maintenance Management Procedures in Sugarcane Mechanic Harvesting System Equipment. **Journal of the Brazilian Association of Agricultural Engineering** v. 3535, n. 66, p. 1187–1197, 2015.
- FIGUEIRA, G.; ALMADA-LOBO, B. Hybrid simulation–optimization methods: A taxonomy and discussion. **Simulation Modelling Practice and Theory**, v. 46, p. 118-134, 2014.
- FIKAR, C.; GRONALT, M.; HIRSCH, P. A decision support system for coordinated disaster relief distribution. **Expert Systems with Applications**, v. 57, p. 104–116, 2016.
- FREITAS FILHO, P. J. **Introdução à modelagem e simulação de sistemas: com aplicações em Arena**. 2 ed. Florianópolis: Visual Books, 2008.
- GRULER, A.; FIKAR, C.; JUAN, A. A.; HIRSCH, P. CONTRERAS-BOLTON, C. Supporting multi-depot and stochastic waste collection management in clustered urban areas via simulation–optimization. **Journal of Simulation**, v. 11, n. 1, p. 11–19, 2017.
- GUÇDEMIR, H.; SELIM, H. Customer centric production planning and control in job shops: A simulation optimization approach. **Journal of Manufacturing Systems**, v. 43, p. 100–116, 2017.
- HAASS, R. et al. Reducing food losses and carbon emission by using autonomous control - A simulation study of the intelligent container. **International Journal of Production Economics**, v. 164, p. 400–408, 2015.

HAMZADAYI, A.; YILDIZ, G. Hybrid strategy based complete rescheduling approaches for dynamic m identical parallel machines scheduling problem with a common server. **Simulation Modelling Practice and Theory**, v. 63, p. 104–132, 2016.

HERAZO-PADILLA, N. et al. Simulation-optimization approach for the stochastic location-routing problem. **Journal of Simulation**, v. 9, n. 4, p. 296–311, 2015.

HILLIER, F. LIEBERMAN, G. **Introduction to operations research**. Tradução. Boston: McGraw-Hill, 2006.

KORYTKOWSKI, P.; RYMASZEWSKI, S.; WIŚNIEWSKI, T. Ant colony optimization for job shop scheduling using multi-attribute dispatching rules. **The International Journal of Advanced Manufacturing Technology**, v. 67, n. 1–4, p. 231–241, 2013.

LAW, A. M.; MCCOMAS, M. G. Simulation-based optimization. In: **Proceedings of the Winter Simulation Conference**, p. 46-49, 2000.

LIM, S. J.; JEONG, S. J.; KIM, K. S.; PARK, M. W. A simulation approach for production-distribution planning with consideration given to replenishment policies. **International Journal of Advanced Manufacturing Technology**, v. 27, n. 5–6, p. 593–603, 2006.

LIN, J. T.; CHEN, C.-M. Simulation optimization approach for hybrid flow shop scheduling problem in semiconductor back-end manufacturing. **Simulation Modelling Practice and Theory**, v. 51, p. 100–114, 2015.

MIRANDA, P. L.; MORABITO, R.; FERREIRA, D. Optimization model for a production, inventory, distribution and routing problem in small furniture companies. **Top**, p. 1–38, 2017.

MOKHTARI, H.; DADGAR, M. Scheduling optimization of a stochastic flexible job-shop system with time-varying machine failure rate. **Computers and Operations Research**, v. 61, p. 31–45, 2015.

MORADY GOHAREH, M.; KARIMI, B.; KHADEMIAN, M. A simulation-optimization approach for open-shop scheduling problem with random process times. **International Journal of Advanced Manufacturing Technology**, v. 70, n. 5–8, p. 821–831, 2014.

MORAES, L. H.; SANTORO, M. C. Proposta de um processo genérico e prático para simulação de sistemas. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. 32. 2012. **Anais...ENEGEP**, 2012.

MOUELHI-CHIBANI, W.; PIERREVAL, H. Training a neural network to select dispatching rules in real time. **Computers and Industrial Engineering**, v. 58, n. 2, p. 249–256, 2010.

NORLUND, E. K.; GRIBKOVSKAIA, I.; LAPORTE, G. Supply vessel planning under cost, environment and robustness considerations. **Omega**, v. 57, p. 271–281, 2015.

NOURINEJAD, M.; ROORDA, M. J. A dynamic carsharing decision support system. **Transportation Research Part E: Logistics and Transportation Review**, v. 66, p. 36–50, 2014.

PIDD, M. **Computer simulation in management science**. 5° ed. 2004.

RIBEIRO, H. A. S.; PINTO, K. C. R.; PEIXOTO, N. E. S. Análise do Processo de Entrada e Saída de Veículos no Aeroporto Regional de Uberlândia: Um Modelo de Simulação. **GEPROS. Gestão da Produção, Operações e Sistemas**, v.12, n. 4, p. 320-343, 2017.

SHA, M.; SRINIVASAN, R. Fleet sizing in chemical supply chains using agent-based simulation. **Computers and Chemical Engineering**, v. 84, p. 180–198, 2016.

TAO, J.; QIU, Y. A simulation optimization method for vehicles dispatching among multiple container terminals. **Expert Systems with Applications**, v. 42, n. 7, p. 3742–3750, 2015.