

UTILIZAÇÃO DA SIMULAÇÃO COMPUTACIONAL POR EVENTOS DISCRETOS E OTIMIZAÇÃO PARA A PROGRAMAÇÃO DA PRODUÇÃO EM UMA EMPRESA DA INDÚSTRIA DE PLÁSTICOS

USE OF DISCRETE EVENTS COMPUTER SIMULATION AND OPTIMIZATION FOR PRODUCTION SCHEDULING IN A COMPANY OF THE PLASTICS INDUSTRY

Cristina Fabbris Piacentini* E-mail: cristinafabbrispiacentini@gmail.com

Leandro Gauss* E-mail: lgauss@unisinis.br

Maria Isabel Wolf Motta Morandi* E-mail: mmorandi@unisinis.br

Daniel Pacheco Lacerda* E-mail: dlacerda@unisinis.br

*Universidade do Vale do Rio dos Sinos (UNISINOS), São Leopoldo, Rio Grande do Sul, Brasil.

Resumo: Com a globalização e a crescente competitividade do mercado, as empresas precisam se manter em constante inovação e melhorando a eficiência dos processos. O problema que esse trabalho busca resolver é o elevado custo gerado pela ineficiência da programação. Dessa forma, o objetivo é propor a redução de custos por meio da diminuição dos estoques de materiais em processo, a fim de melhorar o planejamento da ocupação das máquinas, distribuir as manutenções preventivas e facilitar a tomada de decisões. Para isso, foi utilizada a simulação computacional por eventos discretos e otimização, por meio do software AnyLogic, para definir o cenário de melhor combinação das variáveis de decisão. Como resultado, foi possível verificar no cenário a possibilidade de se produzir além da demanda, e ainda reduzir 96% dos estoques em processo. Desta forma, a nível gerencial, foi possível analisar as alternativas, identificar possíveis falhas, corrigi-las e definir aquela que melhor atendeu às necessidades estratégicas da empresa. Isso considerando a possibilidade de ocorrência de eventos aleatórios e sem a necessidade de parar o funcionamento da fábrica para a realização de testes. A nível acadêmico, esse artigo agrega em estudos de simulação-otimização que consideram dados reais de uma produção MTS.

Palavras-chave: Otimização. Simulação computacional. Eventos discretos. Programação da produção.

Abstract: With globalization and increasing market competitiveness, companies need to keep constantly innovating and improving the process' efficiency. The problem that this work seeks to solve is the high cost generated by the programming inefficiency. Thus, the objective is to propose cost reduction by reducing the work in process, in order to improve the planning of the occupation of machines, distribute preventive maintenance and facilitate decision making. For this, discrete events computational simulation and optimization was used, through the AnyLogic software, to define the scenario of best combination of decision variables. As a result, it was possible to verify in the scenario the possibility of producing beyond demand, and also reduce 96% of the inventories in process. So, at the management level, it was possible to analyze the alternatives, identify possible flaws, correct them and define the one that best met the strategic needs of the company. This considering the possibility of random events and without the need to stop the operation of the factory for testing. At the academic level, this article aggregates into simulation-optimization studies that consider real data from a MTS production.

Keywords: Optimization. Computer simulation. Discrete events. Production scheduling.

1 INTRODUÇÃO

O mercado está evoluindo e se tornando competitivo com o passar dos anos e, conseqüentemente, as empresas demandam elevada eficiência, inovação e flexibilidade em seus processos (CRUZ JR., 2012). Há necessidade de se trabalhar com uma variedade de produtos que atendam as diferentes necessidades dos clientes e, com isso, o sistema produtivo tende a se tornar complexo (SOMAN; VAN DONK; GAALMAN, 2007). Nesse cenário a programação da produção se torna indispensável e tarefas como o planejamento da capacidade, definição de tamanho de lote, liberação de ordens de fabricação e sequenciamento são de suma importância para o bom desempenho da organização (GANSTERER; ALMEDER; HARTL, 2014).

Nesse contexto complexo, a programação da produção é realizada com base em inúmeros fatores, como a disponibilidade de matéria-prima, insumos, equipamentos e operadores. A ordenação desses recursos se torna um problema complicado quando há uma variedade de produtos que precisam ser processados por diversas etapas de fabricação (BERRETTA, 1997). Para isso, inúmeros estudos abordam a utilização de métodos heurísticos de pesquisa, como a simulação, a fim de buscar as melhores soluções para problemas complexos (LEE, 2018).

O problema que esse trabalho buscou resolver foram os elevados custos gerados pela ineficiência na programação da produção. O processo da empresa conta com uma produção *make-to-stock* (MTS) em lotes, ou bateladas, que consiste na produção de uma média a grande variedade de produtos em lotes grandes. O arranjo físico da produção da fábrica em questão é do tipo funcional, ou por processo, onde os equipamentos do mesmo tipo ou função estão localizados na mesma área (SLACK; CHAMBERS; JOHNSTON, 2002).

Uma das vantagens do arranjo tipo funcional é a mão de obra qualificada. Uma pessoa que é treinada para operar uma máquina pode facilmente operar as demais daquele tipo, que estão localizadas no mesmo espaço (PEINADO; GRAEML, 2007). Dentre as desvantagens estão o elevado tempo de atravessamento de produção, uma

vez que o processamento de uma etapa de determinado lote de produtos precisa ser realizado todo de uma vez para dar continuidade à próxima operação da sequência, e a dificuldade de balancear a produção, o que acarreta elevados WIP (*Work in Process*) e filas. Além disso, outra questão relevante é o elevado número de setups que precisam ser realizados, devido à alta flexibilidade das máquinas em produzir uma diversidade de produtos (PEINADO; GRAEML, 2007).

Pesquisas atuais, como de Diaz, Handl e Xu (2018) e Pergher e De Almeida (2017) são abordadas num contexto semelhante ao proposto, onde a simulação-otimização é explorada para realização de uma programação da produção eficiente e para avaliação de performance dos estoques em processo e de produto acabado, respectivamente, considerando um processo com ocorrência de eventos discretos e aleatórios que venham a interferir na programação da produção. Esses estudos, porém, pecam na consideração dos setups e envolvimento de outras partes/ setores do processo na simulação, que é uma abordagem que o presente trabalho irá desenvolver na sequência.

O objetivo deste artigo é, portanto, reduzir custos por meio da melhoria da programação da produção e redução dos estoques em processo de um pavilhão que injeta – também monta e embala, quando necessário – produtos de plástico de uma linha de irrigação, além de produzir itens para o abastecimento de outros seis pavilhões da empresa.

Buscando resolver o problema proposto, foi utilizada a simulação-otimização, por meio do *software* AnyLogic, onde alguns cenários foram modelados, testados e analisados. Foi possível verificar diferentes complicações e melhorias das alternativas observadas, visualizando o que ocorreria na prática com a implementação. A otimização foi utilizada na proposição de um cenário com a melhor combinação entre as variáveis de decisão do problema, buscando como função objetivo a redução do WIP. Para isso foi utilizado também o *software* RStudio para o tratamento dos dados e validação dos modelos.

Como resultado, identificou-se quais produtos devem ser injetados em sequência, a fim de minimizar os tempos de setup e aumentar a ocupação das máquinas. Além disso, o cenário de otimização mostrou que é possível reduzir 96%

dos estoques em processo, a fim de iniciar a produção apenas de itens que no final do mês pudessem ser acabados e estivessem disponíveis para venda.

Considerando as características do processo de produção em estudo, a proposta deste trabalho é importante para a organização, visto que buscou reduzir custos através da redução da quantidade de material parado em processo entre todas as etapas da produção e melhoria da organização dos lotes de produção e destinação deles. Isso acarreta diminuição do tempo de setups e melhoria da distribuição das manutenções preventivas das ferramentas, evitando assim muitas corretivas. A nível acadêmico, o trabalho agrega em estudos de simulação-otimização que consideram dados reais, produção MTS e a presença de eventos discretos no campo do sequenciamento da produção em lotes, que ainda é pouco explorado.

O artigo foi dividido da seguinte forma: Na seção 2 é apresentada a fundamentação teórica que foi dividida nas sub-seções 2.1, que aborda a programação da produção e 2.2, que trata dos problemas de simulação-otimização; na seção 3 é explanado o método do trabalho; na seção 4 os resultados da pesquisa; na seção 5 a discussão dos resultados e na seção 6 a conclusão do trabalho.

2 REFERENCIAL TEÓRICO

Nesta seção são apresentados os fundamentos teóricos dos dois principais assuntos desta pesquisa, estruturados em subseções. A primeira trata da contextualização do sequenciamento da produção na indústria. A segunda, por sua vez, aborda a utilização da simulação-otimização para solução de problemas, trazendo suas vantagens, desvantagens e analisando outros estudos sobre o tema.

2.1 Programação da Produção

O planejamento da produção pode ser dividido em três níveis hierárquicos: (i) estratégico; (ii) tático e (iii) operacional. No planejamento estratégico são definidos os recursos e políticas que serão aplicados a longo prazo com o intuito de atingir os objetivos e metas estipuladas pela empresa. O planejamento tático é responsável pelo

Plano Mestre de Produção, onde serão definidas as famílias dos produtos a serem produzidos, a alocação dos recursos e as compras de insumos. O nível operacional engloba as decisões do dia a dia, em que é definido o que será produzido, quando, onde, como, por quem, etc. (BERRETTA, 1997).

A nível operacional, a programação da produção é a atividade da ponta da cadeia, visto que trata do planejamento num horizonte de tempo de dias, no máximo poucas semanas (MOLINA; RESENDE, 2006). Essa tarefa é realizada por meio de um cronograma detalhado da produção do futuro próximo, visto que um planejamento minucioso a longo prazo seria irrelevante devido à inevitável ocorrência de eventos aleatórios que viriam por modificar a ordem ou até mesmo atrasar as atividades (MONOSTORI et al., 2010). Esse planejamento de nível operacional especifica todos os detalhes do produto, como cor, quantidade, embalagem, dentre outros (SOMAN; VAN DONK; GAALMAN, 2007), e para que isso seja definido, deve-se considerar todas as relações internas e externas da empresa (CAUCHICK-MIGUEL et al., 2018). Considerando as relações internas, o sequenciamento de máquinas é restringido tanto pela disponibilidade como, em uma produção com *layout* por processos, pelos *setups*, que variam significativamente em questão de tempo. Isso acontece principalmente quando há alteração de material e cor, interferindo diretamente nos tempos de atravessamento dos produtos (PEINADO; GRAEML, 2007). Quanto às relações externas, a programação está limitada a fatores como a disponibilidade de matérias-primas, demandas e tendências do mercado (CAUCHICK-MIGUEL et al., 2018). Portanto, uma programação da produção eficiente se faz necessária para otimizar os processos e integrar os elos da cadeia (ANLI; CARAMANIS; PASCHALIDIS, 2007).

A programação da produção não é trivial e embora exposto a contextos de alta variabilidade, pesquisas correntes o abordam por meio de cenários simplificados da realidade, que desprezam as incertezas nos problemas de otimização (STEVENSON; FUKASAWA; RICARDEZ-SANDOVAL, 2020). A abordagem determinística nesses casos é predominante, como nas pesquisas de Montalvao et al. (2011), que abordam o sequenciamento da produção com o objetivo de minimizar o tempo de execução das atividades por meio da programação linear inteira; Cardoso, Johner e Johner (2018), que propõem a utilização desse método para a maximização da ocupação dos

recursos de uma indústria; Moraes e Ferreira (2019), que realizam um modelo para maximizar o lucro da empresa por meio do sequenciamento da produção; e de Domingues et al. (2016), que utilizou da programação linear mista também para o sequenciamento de produção de uma empresa. A questão é que os problemas determinísticos não consideram as variabilidades dos processos e, se tratando de programação da produção, os dados de tais ocorrências são de extrema importância uma vez que alteram todo o planejamento e são decisivos para a tomada de decisões.

Dessa forma, atualmente a abordagem determinística vem perdendo espaço para os estudos estocásticos, que são aqueles que contemplam as aleatoriedades no processo e abordam análises de risco (EL RAOUI; OUDANI; EL HILALI ALAQUI, 2020). Essas incertezas presentes no dia a dia da organização, sejam elas quanto à disponibilidade de recursos e insumos, tempos de processamento, qualidade dos materiais, competências pessoais e afins, são consideradas e incluídas nos estudos para se obter soluções realistas (STEVENSON; FUKASAWA; RICARDEZ-SANDOVAL, 2020).

Sendo assim, as variações interferem diretamente na qualidade dos produtos, além da disponibilidade e performance dos recursos para a manufatura, e esses fatores refletem diretamente na programação e desempenho da produção (GNONI et al., 2003). Portanto, em pesquisas atuais e que buscam maior precisão, o sequenciamento da produção é abordado de modo estocástico e, seguindo tal orientação, o presente estudo irá abordar o assunto de maneira aprofundada na seção que segue.

2.2 Problemas de Simulação-Otimização

Em seu início, a Pesquisa Operacional buscava a solução de problemas por meio da divisão deles em partes isoladas. Com o tempo, os problemas foram ficando complexos, e essa perspectiva não era mais abrangente o suficiente (GAVIRA, 2003). A partir de então, foi-se desenvolvendo abordagens sistêmicas e, à medida que os recursos computacionais evoluíram, foram criados os programas de simulação para

modelagem de sistemas robustos (COELLI, 2008), que se tornaram uma ferramenta importante para auxiliar na tomada de decisões (CAUCHICK-MIGUEL et al., 2018).

Nesse sentido, segundo Teerasponpong e Sopadang (2021), com o intuito de gerar, avaliar e aprimorar soluções, a simulação computacional é uma imitação da realidade de um processo em meio virtual e, segundo Gavira (2003), possibilita ao administrador e ao engenheiro de produção identificar, formular e solucionar problemas ligados a projeto, operação, gerenciamento do trabalho e de sistemas de produção de bens e/ou serviços.

Dentre esses campos, Jahangirian *et al.* (2010) abordam que a simulação é reconhecida por ser a segunda técnica mais utilizada no gerenciamento de operações, uma vez que possibilita identificar a relação de uma decisão nas diferentes camadas do processo. Assim, possíveis problemas de aplicação podem ser identificados com antecedência e corrigidos, evitando elevados custos de operação e perda de tempo útil (MONOSTORI et al., 2010). Essa é justamente uma das principais vantagens da simulação, dado que não exige a parada do funcionamento normal da fábrica, como aconteceria se as hipóteses avaliadas fossem testadas na prática (JUAN et al., 2015).

Uma das desvantagens do método é mencionado por El Raoui, Oudani e El Hilali Alaoui (2020), que apontam que a técnica não é capaz de lidar com limitação de capacidade. Outra, segundo Amaran et al. (2016), é que as simulações detalhadas, ou de larga escala, por si só, costumam ser caras no que diz respeito ao tempo, recursos e dinheiro gastos. Por isso ambos os autores, assim como inúmeros outros, sugerem a utilização desse método em conjunto com a otimização, a fim de que se possa utilizar restrições no processo e definir parâmetros que serão testados pela simulação sem a necessidade de se elaborar muitos cenários por tentativa e erro para a definição da melhor solução (MOTEGI, 2008). Assim, é possível avaliar soluções e refinar problemas complexos com uma visão dinâmica e não linear (ILGIN; TUNALI, 2007) para se obter resultados realistas e de larga escala, sem a necessidade de elevados investimentos e num período muito curto (HATZIKONSTANTINO; ATHANASIOU; PANDELIS, 2012).

A otimização é realizada nos *softwares* de simulação através do OptQuest. Sabe-se que ele combina a utilização de meta-heurísticas com Pesquisa Tabu, Redes

Neurais, Scatter Search, programação linear e inteira (GANSTERER; ALMEDER; HARTL, 2014), porém, a heurística exata que é utilizada ainda é desconhecida (KLEIJNEN; WAN, 2007).

Diversos artigos abordam a simulação-otimização em diversas áreas. Na parte de programação da produção, Tian et al. (2010) avaliam a quantidade ideal de veículos de suporte para o abastecimento de aeronaves, utilizando a ferramenta OptQuest e o *software* Arena para a solução do problema. Assid, Gharbi e Hajji (2020) propõem um estudo para definição de setups e das taxas de produção de manufatura e remanufatura de bens. Para a solução do modelo foi utilizada a simulação-otimização, considerando a presença de eventos estocásticos também no *software* Arena. Yegul et al. (2017) abordam o problema de otimização da produção de uma linha e simulação baseada em quatro metodologias diferentes de programação através do SIMUL8. Teerasoponpong e Sopadang (2021) elaboraram um estudo para empresas de médio e pequeno porte que não têm o conhecimento nem grande disponibilidade de dados necessários para a utilização de ERP para o planejamento da capacidade de produção fabril. Nesse caso foram empregados alguns dados de produção e a inteligência artificial para criar um modelo para otimizar a configuração dos recursos da produção. Fakhrzard e Khademi Zare (2009) também propuseram a utilização da inteligência artificial para a definição do sequenciamento da produção bem como o tamanho dos lotes de cada produto, em um processo de diversos estágios, a fim de minimizar o custo de setups e inventário. Gansterer, Almeder e Hartl (2014) realizaram uma pesquisa para a definição do planejamento hierárquico da produção, utilizando a simulação por eventos discretos e um modelo de otimização matemática para definição dos parâmetros de tamanho de lote, *leadtime* e estoque de segurança. Stevenson, Fukasawa e Ricardez-Sandoval (2020) também utilizam da simulação-otimização considerando aleatoriedades do processo. Esses estudos têm uma abordagem muito semelhante a que será utilizada, demonstrando sucesso das técnicas na obtenção dos resultados almejados.

Diaz, Handl e Xu (2018) realizaram um estudo abordando o planejamento da produção por meio da otimização e da simulação computacional por eventos discretos. Eles, diferentemente dos outros estudos, trazem bem-sinalizada a questão

das incertezas que provém das falhas nas linhas de produção e o seu impacto no modelo proposto. Yoon e Kim (2013) propõem um estudo para minimizar as variações dos tempos de ciclo da fábrica em questão por meio da alteração do sequenciamento da produção e posteriormente experimentação com a ajuda da simulação. Dentre os objetivos estavam maximizar a produção, minimizar o trabalho em processo, as filas e os atrasos. Este trabalho tem muitos objetivos em comum, porém, não aborda a otimização em conjunto com a simulação, trazendo um enfoque matemático no artigo. Outro artigo que trata de sequenciamento da produção, em indústria química, foi realizado por Hatzikonstantinou, Athanasiou e Pandelis (2012). Nesse exemplo foi utilizada a simulação e uma abordagem por eventos discretos, todavia foi optado por um desenvolvimento analítico do problema, portanto não contempla a otimização. Singh e Mathirajan (2018) propuseram um trabalho que sugere que o estudo seria relevante para processos de manufatura MTS, porém, ele foi realizado com base em uma empresa e dados fictícios. Nele, foram contempladas análises de diferentes cenários de sequenciamento da produção, considerando eventuais falhas das máquinas, manutenções preventivas e eventos aleatórios, por meio do *software* Arena.

Carvalho, Oliveira e Scavarda (2016) realizaram um modelo robusto de otimização, que também considera as incertezas nos processos de produção *engineering-to-order* (ETO) para ajudar no planejamento de nível tático de uma empresa. Outra abordagem de produção ETO é trazida por Grabenstetter e Usher (2015), onde deseja-se definir um cronograma preciso de trabalhos utilizando a simulação por eventos discretos. Até então, todos os artigos citados que mencionavam o modelo de produção consideravam processos MTO ou ETO, o único que foi encontrado nessa abordagem de simulação-otimização que utilizou dados reais em um processo MTS foi elaborado por Pergher e De Almeida (2017). Os autores utilizam da DES para avaliar a performance do sistema, incluindo em relação ao estoque em processo e de produto acabado no planejamento da produção.

Muitos trabalhos similares foram encontrados na área da cadeia de suprimentos também, como é o caso do elaborado por Anli Caramanis e Paschalidis (2007), cujo objetivo era organizar a cadeia de suprimentos através da otimização do

planejamento da produção de curto prazo, considerando um modelo estocástico, a fim de agilizar os *lead times* mantendo a qualidade dos serviços. Esse modelo foi elaborado através da utilização de algoritmos de programação matemática, relaxamento Langragiano de algoritmos genéticos, modelos fluidos de aproximação e método de Monte Carlo, portanto, considerava um cenário estático. Pereira e Frazzon (2021) elaboraram um estudo utilizando o *machine learning* e planejamento operacional por meio da simulação-otimização em uma cadeia de suprimentos em que, de modo muito similar a este trabalho, as ferramentas utilizadas foram os *softwares* RStudio e AnyLogic. O objetivo era definir a melhor forma de entrega dos produtos e avaliar a alternativa com menor custo. Gnoni et al. (2003) elaboraram um estudo aplicado à cadeia de suprimentos de uma empresa de manufatura de equipamentos da indústria automotiva. Nele é utilizada a programação linear e a simulação computacional. Viera et al. (2019) também realizaram uma simulação semelhante aplicada à *supply chain* (SC), que considera um sistema dinâmico e incerto e utiliza-se de distribuições estatísticas para solução de problemas e análise de riscos nos cenários. El Raoui, Oudani e El Hilali Alaoui (2020) publicaram um artigo de revisão de bibliografias que abordam inúmeros outros problemas voltados para a SC e que utilizam a técnica híbrida de simulação-otimização.

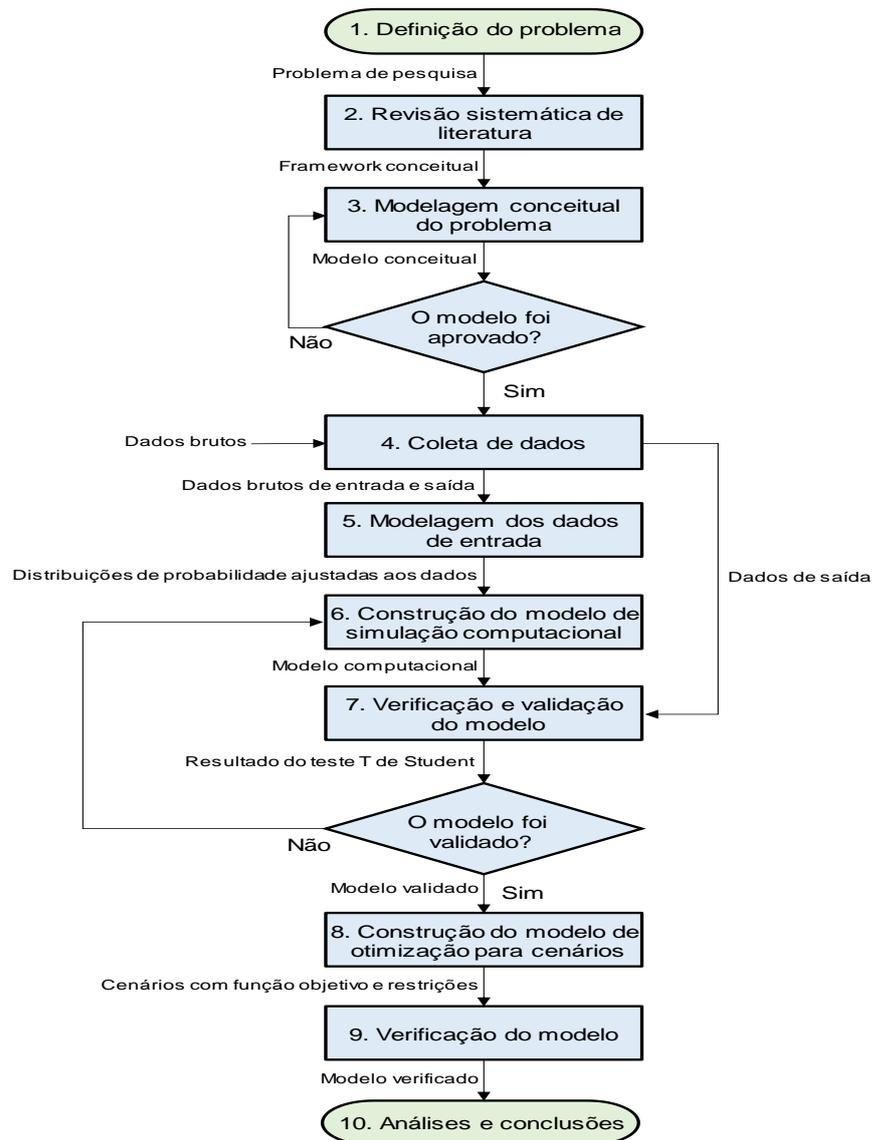
Com essa revisão foi possível verificar que a simulação-otimização é amplamente utilizada para análise de cenários e tomada de decisões de nível tático e principalmente operacional. Porém, considerando os artigos voltados para a produção, a maior parte dos analisados sequer informa o tipo de produção do processo analisado, pecando na parte da contextualização do problema. Dos que informaram, quase em sua totalidade eram estudos MTO e ETO, onde apenas dois se referiam a MTS sendo que, desses, apenas um abordava uma situação real com dados coletados em uma empresa. Inclusive, Teerasponpong e Sopadang (2021), Jahangirian et al. (2010) e Anli, Caramanis e Paschalidis (2007) mencionam em seus artigos que a maior dificuldade da simulação-otimização é a disponibilidade de dados, e por isso apenas a metade dos estudos que utilizam esse método consideram dados reais. Isso mostra que ainda há muito espaço para estudos de simulação-otimização envolvendo esse cenário na prática, uma vez que ele ainda é pouco explorado.

Percebe-se, também, que a maioria dos artigos trata sobre assuntos bem focados, como sequenciamento da produção, cadeia de suprimentos ou manutenção, mas nenhum deles aborda a relação entre as partes e como uma definição no sequenciamento pode influenciar na manutenção e na cadeia de suprimentos, por exemplo. Na seção seguinte será abordado o método da pesquisa, que busca justamente fazer essa ligação entre as partes mencionadas, diferentemente dos artigos citados, de modo a contextualizar e mostrar os impactos de diferentes decisões nessas áreas.

3 MÉTODO

Este estudo utiliza a pesquisa operacional, mais especificamente a Simulação Computacional por Eventos Discretos (SED), para auxiliar na programação da produção e redução dos estoques em processo de uma empresa da Serra Gaúcha que trabalha com plásticos e adota produção MTS. Por esse motivo, utiliza como método de pesquisa a modelagem e simulação, conforme proposto por Cauchick-Miguel et al. (2018), e apresentado na Figura 1.

Figura 1 – Método do trabalho



Fonte: Elaborado pela autora.

Na etapa 1 foi definido o problema de pesquisa, aqui caracterizado como a necessidade de redução de custos devido à ineficiência da programação da produção, que acarreta elevados estoques em processo, tempos de setup e desorganização das etapas de produção.

Na próxima etapa, a partir do problema de pesquisa, foi realizada uma revisão sistemática de literatura (RSL) para avaliar como as pesquisas atuais resolvem problemas de mesma natureza (MORANDI; CAMARGO, 2015, p.141). Como resultado, foram identificados 40 artigos associados a essa pesquisa e, destes, os 19

mais aderentes foram apresentados na seção 2 deste trabalho. Com base nesses estudos, verificou-se a SED como uma alternativa para a solução do problema desse trabalho, uma vez que artigos atuais sobre programação consideram a ocorrência de eventos aleatórios e, portanto, possibilita a realização de simulações precisas e realistas.

Na etapa 3, o modelo conceitual foi definido com o intuito de orientar, de maneira subsequente, a construção do modelo computacional (CHIWIF; MEDINA, 2007) e estabelecer os aspectos relevantes para serem agregados e aqueles menos importantes para serem desconsiderados (COELLI, 2008). Além da sua representação gráfica, foram definidas: (i) as medidas de desempenho, que serviram para avaliar os resultados dos cenários; (ii) o nível de detalhamento, simplificações e pressupostos adotados para suprimir algumas informações sem relevância (LAW; KELTON, 1991); (iii) as entidades, recursos, atividades realizadas; (iv) cenários a simular e (v) os dados de entrada e saída a serem coletados. Todos esses itens são detalhados na seção 4 deste trabalho. De maneira subsequente, o modelo conceitual foi validado por especialistas da empresa.

Na quarta etapa, a partir do modelo conceitual, foram coletadas observações para cada dado de entrada, conforme proposto por Chiwif e Medina (2007). Os dados foram coletados por meio de três fontes: (i) anotações realizadas diariamente pelos operadores; (ii) registros automáticos realizados por Manufacturing Execution Systems (MES) e (iii) informações referentes ao histórico de consumo do último ano, disponíveis no banco de dados da empresa.

Na etapa 5, os dados de produtos coletados nos últimos 12 meses foram primeiramente agrupados em famílias. A técnica utilizada para o agrupamento foi o algoritmo K-means Clustering, que define *clusters* por meio da homogeneidade dos dados analisados dos atributos (LIKAS; VLASSIS; J. VERBEEK, 2003). Como critério para a definição do número de clusters, adotou-se a métrica Silhouette (KODINARIYA; MAKWANA, 2013). Feito isso, as famílias foram analisadas com o auxílio da estatística descritiva, para explorar as medidas de posição e dispersão da amostra (FALCO, 2008). Tendo essas informações, foi avaliada a presença de *outliers* extremos, por meio da faixa interquartil do Box-Plot, os quais foram removidos da

amostra (MONTGOMERY; RUNGER; HUBELE, 2004). Em seguida, foi verificado se os dados eram independentes e identicamente distribuídos (IDD) por meio do coeficiente de correlação de Pearson (HOADLEY, 1971). Posteriormente, distribuições padrões de probabilidade e seus respectivos parâmetros foram ajustados aos dados através do método de máxima verossimilhança (HOADLEY, 1971), utilizando a linguagem de programação R. Por fim, a qualidade do ajuste foi verificada utilizando-se dos testes de aderência de Qui-Quadrado e Kolmogorov-Smirnov para identificar o melhor valor de “p”, a um nível de significância de 0,05, e a distribuição que melhor descreve os dados (ANLI; CARAMANIS; PASCHALIDIS, 2007).

Tendo os dados de entrada modelados e o modelo conceitual, na etapa 6, foi elaborado o modelo computacional no *software* AnyLogic, que posteriormente foi verificado e validado, na etapa 7. A verificação é a comparação do modelo computacional com o modelo conceitual, para avaliar se ele está conforme desejado, e foi realizado por meio de animação gráfica. A validação ocorreu em duas etapas. Primeiramente, uma amostra-piloto foi utilizada para comparar o erro dos dados de saída com o erro máximo de 1%, que foi definido como admissível. A partir dessa comparação, foi definida a quantidade de replicações necessárias para rodar o modelo atingindo um erro inferior ao estipulado. Ao rodar o modelo, os dados de saída da simulação foram comparados aos dados de saída reais por meio de um teste de comparação de médias, ou de Hipótese, o teste T de Student (MONTGOMERY; RUNGER; HUBELE, 2004). Ao não rejeitar a hipótese nula, com nível de significância de 0,05, de que a diferença entre as médias dos dados de saída do modelo e do processo real é igual a zero, o modelo foi validado (CLARK; DOWNING, 2010).

Após o modelo SED ser validado, na etapa 8, construiu-se um modelo de otimização para um dos cenários através da ferramenta OptQuest, incorporada ao AnyLogic. Essa ferramenta é eficiente para a determinação de alternativas para modelos complexos, a fim de que, neste caso, obtenha-se soluções ótimas sem a necessidade de realizar centenas de experimentos. Nesse contexto, primeiramente foram definidas as variáveis de decisão, que no presente estudo são: (i) a quantidade de produtos por família a produzir; (ii) a quantidade de produtos por família a ser destinada para cada tipo de embalagem e (iii) a quantidade de injetoras a serem

utilizadas. Em seguida, foi definida a função objetivo, com o propósito de reduzir a quantidade de estoque em processo, visto que o WIP é responsável por parte significativa dos custos da empresa. Por fim, foram estabelecidas as seguintes restrições para a delimitação do espaço de busca: (i) cada máquina irá processar um produto por vez; (ii) quando iniciada a produção de um produto, seu lote deverá ser concluído antes de iniciar outro; (iii) a ordem de processamento dos produtos será FIFO (First In First Out); (iv) será mantida 11% da produção de peças para embalagem A e o restante será encaminhada para embalagem B. Uma quantidade finita de simulações foi realizada até se encontrar uma solução ótima por meio dos indicadores de desempenho definidos. Na última etapa, os resultados foram analisados e o sequenciamento ótimo obtido foi prescrito para a empresa conforme será indicado na seção que segue.

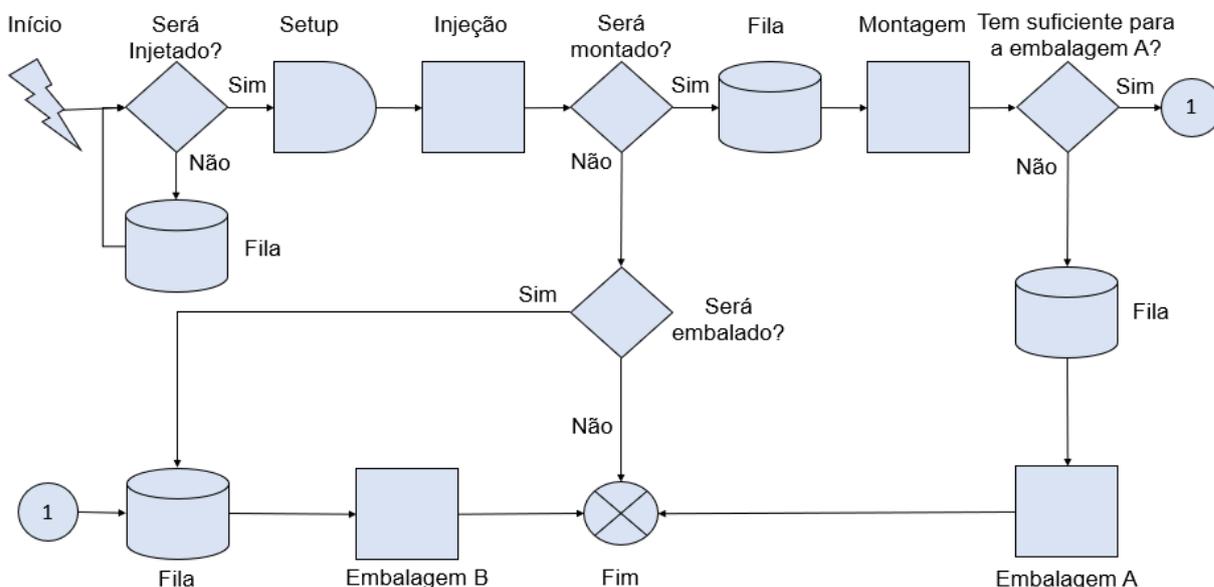
4 RESULTADOS

Nesta seção serão descritos os resultados do estudo, divididos em quatro subseções. Na subseção 4.1 é apresentado o modelo conceitual. Na 4.2 é abordada a coleta e modelagem dos dados de entrada. Na subseção 4.3 é apresentado o modelo de simulação computacional, sua verificação e validação. A subseção 4.4 trata dos cenários de otimização.

4.1 Modelo Conceitual

O modelo conceitual foi elaborado com o objetivo de auxiliar a visualização e construção do modelo computacional. Inicialmente foi desenvolvida uma representação gráfica, por meio da técnica Simple Process Network (SPN), apresentada na Figura 2.

Figura 2 – Modelo conceitual



Fonte: Elaborado pela autora.

A partir dessa figura, foi possível analisar e identificar:

- (i) Medidas de desempenho do modelo: lead-time, estoque em processo e número total de peças produzidas.
- (ii) Simplificações adotadas: tempo de setup médio, adoção de famílias de produtos e tempo de movimentação desprezível.
- (iii) Entidades: 127 produtos, que foram divididos em famílias.
- (iv) Recursos: 16 injetoras, 5 robôs de montagem, 3 embaladoras do tipo A e 3 embaladoras do tipo B.
- (v) Atividades realizadas: injeção, montagem e embalagem.
- (vi) Cenários a simular: cenário 1 (atual - MTS), cenário 2 (MTO) e cenário 3 (otimização - minimização dos estoques em processo).
- (vii) Dados de entrada e saída: coleta de dados reais referentes à demanda, tempos de processamento e produção mensal.

O modelo conceitual foi apresentado para três especialistas da empresa, conforme mencionado na seção 3, que validaram o modelo. Validado, serviu como base para o desenvolvimento das etapas das subseções seguintes.

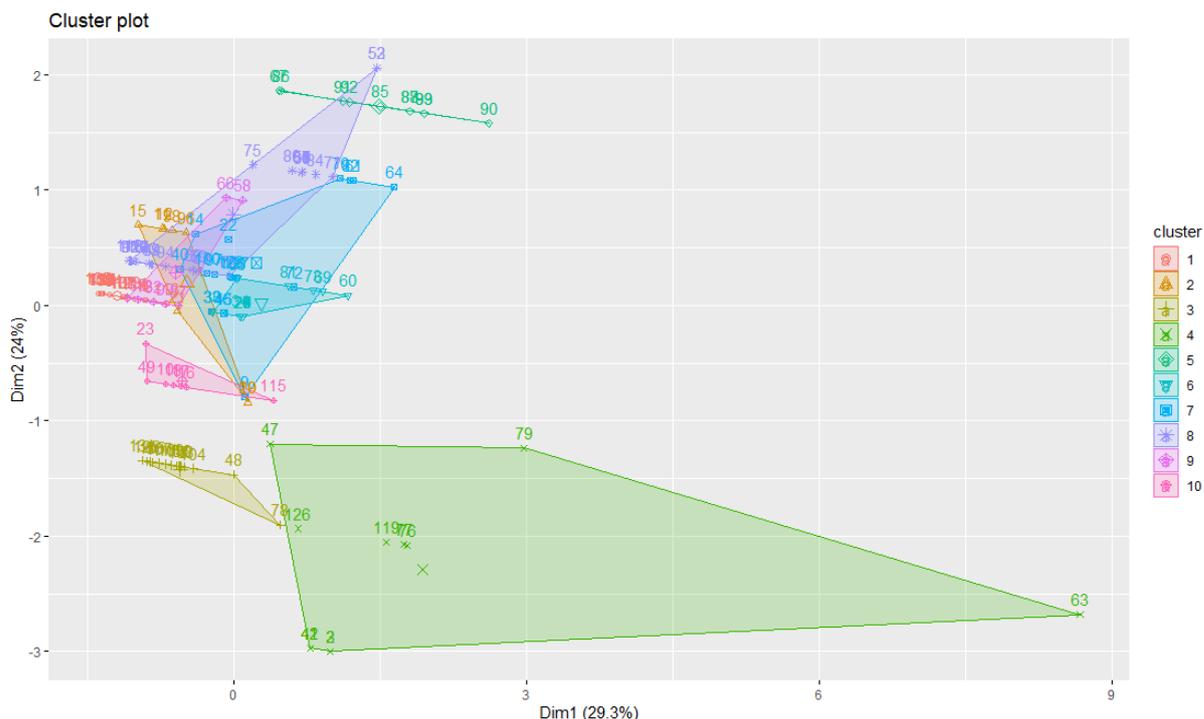
4.2 Dados de Entrada

Para a extração dos dados foram consideradas apenas anotações da base de dados da empresa referentes aos últimos doze meses, a fim de que estivessem o mais atualizados possível quanto ao processo. Foram coletados três tipos de dados:

- (i) Dados da demanda de cada produto *kanban* - média dos últimos 12 meses.
- (ii) Dados da demanda de cada produto vendável – média dos últimos 12 meses.
- (iii) Dados dos tempos de processamento de cada um dos recursos para cada produto – cerca de duas anotações cada dia, por recurso, nos últimos 12 meses.

Tendo essas informações referentes a cada um dos 127 produtos, eles foram agrupados em famílias, para a redução da dimensionalidade e posterior modelagem. Foram definidas características quantitativas e qualitativas (que posteriormente foram convertidas em uma escala numérica) para que a separação dos grupos fosse feita por semelhança. Todos os itens foram classificados quanto aos atributos de tempo de ciclo de injeção, cor, material, embalagem e tamanho de máquina necessária para a produção. Para isso, foi utilizada a técnica de K-means Clustering, por meio do *software* RStudio e do método Silhouette, para que o algoritmo separasse os produtos com características parecidas em um mesmo *cluster*. Como resultado, os 127 produtos foram agrupados em 10 famílias, conforme mostra a Figura 3.

Figura 3 – Definição dos clusters



Fonte: Elaborado pela autora.

A partir das 10 famílias, as informações referentes às demandas de cada produto delas foram compiladas. Os dados de tempos de processamento também foram agrupados e posteriormente tratados, conforme mencionado na seção 3. Na Tabela 1 são apresentados os resultados, em minutos, identificados para cada família na operação de injeção, em que são abordados: (i) resultados de estatística descritiva antes do tratamento; (ii) limites para remoção dos outliers; (iii) resultados de estatística descritiva depois do tratamento; (iv) coeficiente de correlação de Pearson e (v) distribuição estatística e seus parâmetros. Isso foi feito para as operações de montagem e embalagens também.

Tabela 1 – Resultados do tratamento de dados de injeção

(continua)

		Família 1	Família 2	Família 3	Família 4	Família 5	Família 6	Família 7	Família 8	Família 9	Família 10		
Dados Brutos	Estatística Descritiva	Média	0,3059	0,5062	0,3704	0,0418	0,3414	0,1798	0,1020	0,1314	0,3141	0,1822	
		Mediana	0,1712	0,2121	0,3451	0,0295	0,3417	0,1438	0,0644	0,0655	0,3126	0,1135	
		Moda	0,1000	0,2000	0,3000	0,0000	0,3000	0,1000	0,1000	0,1000	0,1000	0,3000	0,1000
		Mínimo	0,0690	0,1008	0,1042	0,0058	0,0329	0,0426	0,0330	0,0369	0,0925	0,0325	
		Máximo	0,9670	1,7233	1,4250	0,2038	0,6930	0,8833	0,7150	0,5617	0,9983	0,5700	
		Amplitude	0,8980	1,6225	1,3208	0,1980	0,6601	0,8407	0,6820	0,5248	0,9058	0,5375	
		Variância	0,0661	0,3317	0,0413	0,0011	0,0265	0,0319	0,0136	0,0117	0,0397	0,0248	
	Box-Plot	Desvio-Padrão	0,2572	0,5760	0,2033	0,0330	0,1627	0,1786	0,1168	0,1083	0,1993	0,1573	
		Limite Inferior	0,0690	0,1008	0,1042	0,0058	0,0329	0,0480	0,0330	0,0369	0,0925	0,0325	
Dados Tratados	Estatística Descritiva	Limite Superior	0,9670	1,5250	0,6300	0,1274	0,6930	0,6508	0,1231	0,5617	0,9197	0,4152	
		Média	0,3002	0,2214	0,3328	0,0347	0,3394	0,1401	0,0573	0,1290	0,2789	0,1011	
		Mediana	0,1703	0,2058	0,3420	0,0287	0,3417	0,1438	0,0571	0,0653	0,3110	0,1109	
		Moda	0,1000	0,2000	0,3000	0,0000	0,3000	0,1000	0,1000	0,1000	0,3000	0,1000	
		Mínimo	0,0690	0,1008	0,1042	0,0058	0,0329	0,0480	0,0330	0,0369	0,0925	0,0325	
		Máximo	0,9350	0,6017	0,6208	0,0755	0,6554	0,2042	0,0718	0,5317	0,7933	0,1538	
		Amplitude	0,8660	0,5008	0,5166	0,0697	0,6226	0,1562	0,0388	0,4948	0,7008	0,1213	
		Variância	0,0629	0,0088	0,0099	0,0002	0,0259	0,0011	0,0001	0,0108	0,0179	0,0006	
	Desvio-Padrão	0,2508	0,0938	0,0995	0,0135	0,1610	0,0334	0,0097	0,1038	0,1339	0,0247		
	Coefficiente Pearson	0,4048	0,0627	0,3628	-0,1109	0,2470	0,5481	-0,1447	0,0333	0,5392	0,2993		

Tabela 1 – Resultados do tratamento de dados de injeção

(conclusão)

	Família 1	Família 2	Família 3	Família 4	Família 5	Família 6	Família 7	Família 8	Família 9	Família 10
Distribuição	lognormal	logistica	logistica	gamma	logistica	weibull	weibull	lognormal	gamma	weibull
Location	-	0,2032	0,3378	-	0,3465	-	-	-	-	-
Scale	-	0,0301	0,5167	-	0,0932	0,1520	0,0612	-	-	0,1103
Shape	-	-	-	5,3236	-	5,2781	7,6919	-	5,1552	4,9455
Rate	-	-	-	153,4269	-	-	-	-	18,4840	-
Meanlog	-1,5475	-	-	-	-	-	-	-2,3279	-	-
Sdlog	0,8252	-	-	-	-	-	-	0,7301	-	-

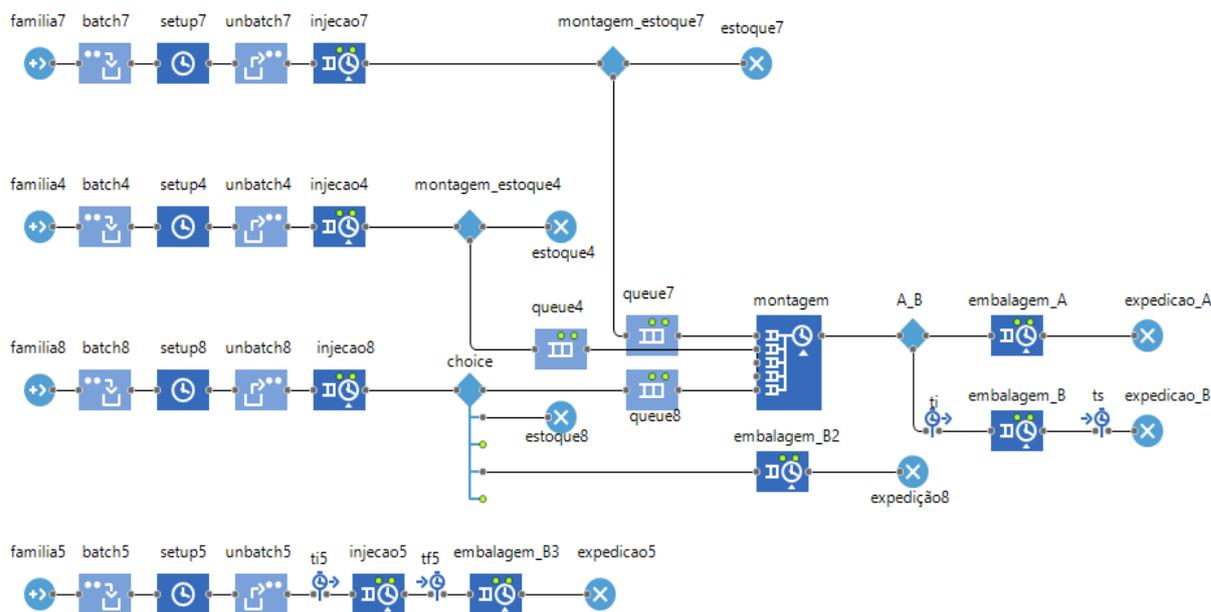
Fonte: Elaborado pela autora.

O tratamento foi realizado a partir da remoção dos dados que se encontravam fora dos limites da faixa interquartil. Nota-se que depois do tratamento dos dados, o desvio-padrão e a variância reduzem consideravelmente, o que demonstra um claro refinamento nos dados que serviram como base para a definição das distribuições estatísticas. Além disso, os coeficientes de Pearson maiores que $-0,7$ e menores que $+0,7$ indicam que há baixa correlação entre os dados da mesma família, mostrando que eles podem ser mais bem descritos por distribuições de probabilidade. Dessa forma, as informações extraídas referentes às distribuições e parâmetros foram utilizadas no modelo que será apresentado na próxima subseção. Essas distribuições, conforme mencionado na seção 3, foram validadas através dos testes de Kolmogorov-Smirnov e Qui-Quadrado.

4.3 Modelo de Simulação Computacional

Para a elaboração do modelo computacional, foi utilizado o *software* AnyLogic, considerando o período de simulação de 30 dias de uma produção MTS. A construção se baseou no modelo conceitual e, conforme explanado na seção 1, a fábrica em questão é responsável pela injeção, montagem e embalagem de alguns produtos. Além disso, a fábrica é responsável também por suprir a demanda de outros produtos *kanban* que são injetados no local, mas utilizados nas outras fábricas da empresa. Por esse motivo o modelo pode ser dividido em duas partes, conforme apresentado nas Figuras 4 e 5.

Figura 4 – Parte 1 do modelo



Fonte: Elaborado pela autora.

A primeira parte, mostrada na Figura 4, é o foco principal do estudo, e envolve as famílias 7, 4 e 8, as quais possuem componentes que, além de injetados, serão montados e embalados. A família 5 possui componentes que são apenas injetados e embalados, ou seja, não passam pela montagem. No início do processo foram representados os setups, cujos tempos foram definidos com *delay* médio de 20 minutos por troca de molde. Nesse caso foi considerado esse valor pois é o estabelecido pela empresa como tempo limite para a realização do setup. A definição das famílias serve justamente para minimizar esse tempo. Como forma de simplificação para representação do modelo, todos os componentes de cada família passam uma única vez pelo bloco *setup*. A Tabela 2 mostra para cada bloco de *setup* do modelo a quantidade de itens diferentes que passam pelo bloco e o tempo de *setup* total para realizar todas as trocas de produtos da família. Ou seja, o tempo de 20 minutos foi considerado para cada tipo de produto presente nas famílias, então para a família 8, que é composta por 23 produtos, foi considerado o tempo de 460 minutos, por exemplo.

Tabela 2 – Setups

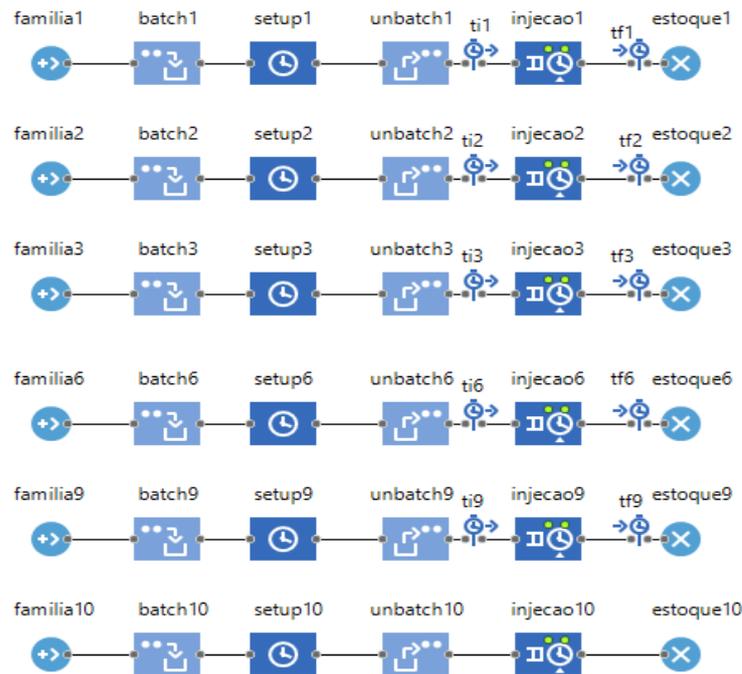
	Família	Quantidade de produtos	Tempo de setup total (minutos)
setup1	1	20	400
setup2	2	9	180
setup3	3	15	300
setup4	4	11	220
setup5	5	10	200
setup6	6	10	200
setup7	7	15	300
setup8	8	23	460
setup9	9	7	140
setup10	10	7	140

Fonte: Elaborado pela autora.

Depois da injeção, parte da produção é destinada para estoque - até o seu consumo ser realizado em outras operações da fábrica - e parte é encaminhada para montagem. Antes da montagem, encontram-se filas, uma vez que o processo de injeção de cada produto possui tempos de ciclo diferentes. Montados, esses produtos passarão pela embalagem tipo A ou B. As embalagens B2 e B3, representadas na Figura 4, são o mesmo tipo de embalagem de B, porém, com um recurso exclusivo para esses itens das famílias 8 e 5 que não são montados, posto que possuem dimensional diferente.

A segunda parte, representada na Figura 5, envolve as demais famílias, que são de componentes injetados, os quais serão armazenados e utilizados pelas outras fábricas.

Figura 5 – Parte 2 do modelo



Fonte: Elaborado pela autora.

Depois de construído o modelo, foi necessário fazer a sua verificação em relação ao modelo conceitual, por meio da animação gráfica do *software*. Após aprovação na verificação, foi realizada a validação, primeiro qualitativamente e depois quantitativamente. Na análise qualitativa foram avaliadas que as filas, capacidades e ocupações das máquinas estavam condizentes com o que é observado na realidade. Aprovado nesse quesito, o modelo passou pela validação quantitativa.

A validação quantitativa foi realizada analisando a quantidade total de peças produzidas no final de um mês de produção. Para isso foi realizada uma rodada com 10 replicações no AnyLogic, com o objetivo de capturar os dados do *output* escolhido para compor uma amostra-piloto. Essa amostra foi utilizada para calcular que eram necessárias 86 replicações do modelo para obter o erro estipulado de mais ou menos 1.600 peças no período de um mês. A seguir, rodou-se o modelo novamente com 86 replicações, e foram coletados os dados de saída para realizar a validação. Esses dados foram comparados com dados reais por meio do Teste T Student e, considerando um intervalo de confiança de 95%, identificou-se o p-valor como sendo 0,342. Como o valor de p é maior que 0,05, não é rejeitada a hipótese nula de que a

diferença entre as médias dos dados de saída do modelo simulado e do processo real é igual a zero, validando o modelo.

4.4 Cenários de Otimização

Com o modelo validado, foi iniciada a montagem dos três cenários propostos. Todos foram simulados com a mesma configuração entre as famílias e com a mesma quantidade de máquinas disponíveis. A diferença entre os cenários reside no tamanho do lote de produção de cada família e, por consequência, a quantidade de peças que passam em cada operação e os estoques em processo e finais. Na Tabela 3 são apresentados os resultados dos *outputs* do modelo, que são: (i) quantidade de produto acabado (PA) produzido na embalagem tipo B; (ii) quantidade de peças produzidas em todo o modelo (PA + *kanbans*); (iii) quantidade de peças que não são finalizadas (injetadas, mas não montadas e embaladas). Esses valores são proporcionais aos reais, mas não são exatos.

Tabela 3 – Resultados das simulações

Cenários	Outputs		
	Embalagem B	Produção Total	WIP
1 MTS	5.958	15.340	2.559
2 MTO	5.666	13.514	122
3 Otimização	5.775	13.637	100

Fonte: Elaborado pela autora.

Na Tabela 4 são expostas as ocupações das máquinas nos diferentes cenários. Os recursos de embalagem A, B2 e B3 foram desconsiderados nessa análise visto que possuem uma capacidade muito superior a essa demanda, uma vez que embalam outras formas de produtos que não foram contempladas no presente trabalho.

Tabela 4 – Ocupações das máquinas

Cenários	Ocupações		
	Injetoras	Robôs	Embaladora B
1 MTS	97%	50%	44%
2 MTO	84%	48%	42%
3 Otimização	89%	49%	43%

Fonte: Elaborado pela autora.

No primeiro cenário foi simulada a situação real da empresa, com produção MTS. A ideia vigente é que as injetoras não podem parar, portanto a produção trabalha 24 horas por dia, 7 dias por semana, e por esse motivo a ocupação fica em 97%. Nessa configuração acumula-se estoque de produtos inacabados, o qual representa cerca de 30% de tudo que é produzido. As operações de montagem e embalagem não trabalham todos os finais de semana do mês - o seu funcionamento costuma ser definido conforme disponibilidade de mão de obra, visto que a ocupação é baixa e tem-se espaço para isso. Por esse motivo que os estoques costumam ser elevados em processo, uma vez que a injeção em 70% dos itens possui um padrão de produção maior do que da montagem.

No segundo cenário foi simulada uma produção MTO, em que apenas a demanda mensal dos produtos é produzida. Nessa configuração, há redução de 32% da produção total, sendo que apenas 2,1% do que é produzido é acumulado em estoque em processo, ou seja, 97,9% do que é injetado é embalado e vendido no final do mês. Porém, nesse cenário, a ocupação das injetoras cai em média 13%, o que significa que num mês precisaria trabalhar apenas 26 dias para suprir a demanda, considerando o funcionamento de todas as máquinas. Como essa simulação considera dados discretos, perdas da eficiência das máquinas são consideradas individualmente para cada uma por meio das distribuições estatísticas consideradas.

Buscando construir outra versão do processo de maneira que se adaptasse melhor à realidade apresentada, o cenário 3 apresenta uma simulação-otimização que tem por função minimizar a quantidade de WIP. Foi deixada a quantidade de injetoras a serem utilizadas para cada família como uma variável de decisão, assim como a quantidade de peças a serem injetadas das famílias 4, 7 e 8, que são aquelas cujos componentes são montados e embalados. As demais famílias continuam com a quantidade de injeção igual à demanda. Dessa forma, busca-se aumentar a produção de produto acabado e a ocupação das máquinas ao passo que minimiza da melhor forma possível as peças inacabadas. Na Tabela 5 são mostradas as variáveis de decisão propostas pelo *software* para o cenário 3.

Tabela 5 – Variáveis de decisão propostas pelo software

Variáveis de decisão	Atual	Melhor solução
Quantidade F1	970	970
Quantidade F2	2420	2420
Quantidade F3	240	240
Quantidade F4	9697	8510
Quantidade F5	320	320
Quantidade F6	110	110
Quantidade F7	9718	6946
Quantidade F8	9829	9010
Quantidade F9	130	130
Quantidade F10	1170	1170
Nº de injetoras F4	2	2
Nº de injetoras F7	2	6
Nº de injetoras F8	2	5
Nº de injetoras F restantes	2	2
Interações realizadas	504	359

Fonte: Elaborado pela autora.

Como pode-se observar, foram simulados 504 cenários com interações diferentes entre os parâmetros a fim de minimizar a quantidade de peças inacabadas. Em negrito são mostrados os valores que estavam sendo testados na última interação e os valores que foram identificados como sendo os mais adequados na interação 359. Dessa forma, o cenário 3 adotou as variáveis da interação 359.

Assim, o cenário 3 foi o que apresentou o resultado mais positivo, visto que se consegue chegar em apenas 1,7% de produção em WIP, tem-se um aumento de 1,92% na produção de produto acabado, em relação ao cenário 2, e ainda define que uma injetora pode ser tirada do processo, elevando a ocupação das 15 operantes em 5% em relação ao cenário anterior. Estima-se, ainda, que com a adoção desse cenário proposto, o custo dos estoques em processo reduziria cerca de 96% em relação ao cenário 1.

5 DISCUSSÃO

O objetivo desta pesquisa é reduzir custos por meio de uma proposta de cenário de otimização que busca reduzir o WIP além de melhorar a programação da produção. Como consequência será elevada a ocupação das máquinas, reduzido o tempo de setups e a quantidade de manutenções corretivas, além de melhorar a distribuição das manutenções preventivas.

Com a definição de famílias de produtos por similaridade de material, cor e tamanho de máquina necessária para a injeção, foi possível definir quais deles devem ser injetados em sequência, para evitar setups frequentes de máquina. Dessa forma, os produtos da mesma família têm material e cor iguais ou muito similares, o que reduz consideravelmente a mão de obra para a troca de produto da injetora. Como consequência, o tempo de máquina parada diminui e a ocupação delas aumenta. Atualmente existe a tentativa de minimização dos setups por meio da melhoria no sequenciamento, mas é tudo feito de maneira empírica, e com essa predefinição a tarefa de sequenciar se tornará eficaz.

Tratando sobre os estoques intermediários de produtos inacabados, percebe-se que no cenário 1 o volume aumenta gradativamente para todas as famílias, visto que o objetivo é manter todas as injetoras funcionando o mês inteiro. O cenário se agrava pelo fato de que a montagem e embalagem não são mantidas em operação pelo mesmo período que a injeção e por isso a tendência é acumular WIP. Além disso, conforme mencionado na Seção 4, na maior parte dos produtos, a operação de injeção possui tempo de ciclo menor que a montagem, o que é outra predisposição ao acúmulo de produto em processo. Tendo essas informações, foi simulado no cenário 2, o outro extremo do cenário 1, onde seria produzida apenas a demanda média mensal de cada família. Nesse cenário é reduzido o WIP, conforme mencionado na seção anterior. Porém, do ponto de vista da gestão é inviável já que reduz 13% a ocupação das máquinas e a empresa preza por trabalhar com estoques de produtos acabados. Dessa forma, a partir da simulação do cenário de otimização 3, é possível reduzir o WIP, além de aumentar a produção de PA e a ocupação das máquinas. Isso

foi possível depois de considerar outras 504 possíveis interações entre as variáveis do modelo.

Falando sobre a ocupação das máquinas, no cenário 1 é de 97%, isso quer dizer que os outros 3% são perdas em setup, visto que é trabalhado o mês inteiro e as perdas de eficiência estão contempladas nos dados inseridos no modelo. No cenário de otimização a ocupação é 89%, sendo que da mesma forma, aproximadamente 3% são perdas pelo tempo de trocas de molde, uma vez que o número de setups e a duração deles são iguais para todos os cenários. Neste caso a ocupação é elevada em 5% em relação ao cenário 2 devido ao aumento no número de peças produzidas e à exclusão de uma injetora no processo. Porém, num período de 30 dias, ainda assim em dois deles seria necessário produzir para estoque ou realocar as pessoas para outras tarefas.

Nota-se, também, que a ocupação dos robôs é aproximadamente 6% maior que a da embaladora B, ou seja, a operação de montagem tem capacidade menor que a embalagem. Esse desnivelamento da capacidade sob o ponto de vista dos estoques é positivo, posto que tudo que é montado pode ser embalado na sequência, sem acumular peças inacabadas em processo. Dessa forma, se fosse decidido iniciar a produção conforme previsto no cenário 3, as pessoas que sobriam na operação de injeção por dois dias poderiam ser realocadas para as operações de montagem e embalagem em um final de semana - que são dias em que essas operações normalmente não seriam realizadas - a fim de consumir o estoque que é acumulado em processo.

Além disso, no cenário 3, diferentemente do 1, torna-se possível realizar um cronograma de manutenções preventivas nas máquinas e moldes. Quando a operação é 24 horas por dia, acaba-se desconsiderando as manutenções preventivas e, com isso, eleva-se o número de problemas mecânicos e conseqüentemente de corretivas a serem realizadas. Com a disponibilidade de 1 injetora que fica fora de operação, é viável revezar as manutenções das 16 durante o ano e garantir que seja realizado o menor número de corretivas possível, aumentando a confiabilidade do processo, reduzindo o tempo de paradas e evitando problemas de qualidade nas peças também.

Tendo em vista as informações levantadas, percebe-se que a organização da produção poderia ser realizada de forma diferente, a fim de minimizar os custos tanto com a redução do WIP como das manutenções corretivas que são realizadas frequentemente. Dessa forma, avaliando o conjunto de informações trazidas, identifica-se que no *trade-off* entre aumento da produção e redução dos custos, a situação mais vantajosa para a empresa seria o cenário 3, que concilia requisitos básicos para o benefício da mesma.

Em relação à empresa, com esse estudo foi possível observar que, como se tem uma capacidade maior que a demanda, a infraestrutura da mesma suportaria ainda um crescimento de aproximadamente 15% na demanda das injetoras, 50% dos robôs e 57% das embaladoras tipo B. Nota-se que o crescimento das vendas dos produtos dessa linha, no último ano, foi de 18,7%, então, se esse crescimento se mantiver, em menos de um ano será necessário avaliar a necessidade de se investir na ampliação da capacidade produtiva das injetoras. Para esse tipo de análise o modelo será de fundamental importância para simulação de novos cenários com mais máquinas, por exemplo.

Academicamente, esse estudo agrega em trabalhos realizados com dados reais e que combinam a heurística com a otimização para solução de problemas complexos. A heurística é importante na inclusão de dados reais, considerando a presença de eventos aleatórios e, portanto, as incertezas que estão presentes em todos os processos. A otimização, por sua vez, é fundamental para reduzir o período necessário para simulação de cenários e a capacidade computacional requerida para tais experimentos, por meio da otimização.

Considerando os demais estudos mencionados na seção 2, referentes a pesquisas nessa área, é possível perceber que o diferencial desse trabalho é justamente o fato de analisar um sistema de produção real MTS e a sua relação com os estoques em processo, ocupação das máquinas e disponibilidade para o planejamento de manutenções. Estudos como o de Pergher e De Almeida (2017), que também foi de uma produção MTS, abordou a DES somente para avaliar estoques, Diaz, Handl e Xu (2018) discorrem somente a questão do sequenciamento da produção com DES, Yoon e Kim (2013) apresentam a questão do sequenciamento,

mas sem contemplar otimização. Dessa forma, pode-se notar que os estudos abordam essas perspectivas separadamente, porém, dentro de um processo fabril existem inúmeras variáveis que afetam os resultados da empresa e, por isso, quanto mais fatores forem considerados, mais robusto se torna o estudo.

6 CONCLUSÃO

No cenário competitivo em que as empresas se encontram, é inevitável manter os processos em constante atualização. Para acompanhar tal necessidade de evolução, é de suma importância utilizar de tecnologias que auxiliem na tomada de decisões, a fim de garantir maior segurança e a menor taxa de erro possível na previsão de cenários. Considerando tais necessidades, a simulação-otimização vem sendo cada vez mais utilizada, uma vez que possibilita testar inúmeras alternativas e cenários produtivos sem a necessidade de parar a fábrica.

Com base na revisão sistemática de literatura sobre simulação computacional por eventos discretos, otimização e sequenciamento da produção, foi possível notar que diversos estudos abordam os temas separadamente, e quase a totalidade daqueles que abordam esses assuntos possuem enfoques diferentes de produção.

Buscando a redução de custos por meio do planejamento do sequenciamento da produção e do WIP, foi realizado um estudo de simulação-otimização. A partir da simulação computacional por eventos discretos e otimização, o presente trabalho passou pelas etapas de: (i) modelagem conceitual e validação; (ii) coleta e modelagem dos dados de entrada; (iii) construção, verificação e validação do modelo computacional; (iv) experimentação por meio do OptQuest para otimização no *software*.

A primeira parte da solução do problema foi realizada por meio da definição das famílias de produtos. Entende-se que os componentes da mesma família devem ser injetados em sequência para a minimização dos setups e aumento da ocupação das máquinas. Considerando a segunda parte do problema, foi possível identificar com o auxílio da simulação-otimização um cenário que representasse a melhor combinação entre as variáveis de decisão, considerando a função objetivo que é minimizar os

estoques em processo. O cenário de simulação 3, portanto, foi o mais viável para atender a finalidade da fábrica de reduzir o WIP, enquanto aumenta a ocupação das máquinas e a quantidade de produtos acabados. Estima-se que esse cenário reduz cerca de 78.688,00 reais no período de um mês. Dessa forma, constata-se que o propósito da pesquisa de atender a tais necessidades reduzindo o custo foi atingido, dentro das limitações presentes.

As limitações identificadas na pesquisa estão relacionadas à grande quantidade de dados que tiveram que ser inseridos no modelo. Como foi utilizada a versão educacional do AnyLogic, o número de interações é limitado, e por isso os cenários tiveram que ser simplificados para que o *software* suportasse toda a simulação. Além disso, na otimização foram realizadas apenas o número máximo de interações disponíveis na versão.

Esse trabalho também se limitou a analisar apenas as relações internas da empresa, portanto, sugere-se para um estudo futuro avaliar as relações externas do processo produtivo com fornecedores e terceiros. Seria importante avaliar o sequenciamento da produção com a entrega de insumos, a fim de minimizar os custos em relação aos materiais excedentes em estoque e melhorar a previsão de consumo. Dessa forma seria possível analisar maior parte da cadeia para alinhar a produção da melhor forma possível.

REFERÊNCIAS

AMARAN, S. *et al.* Simulation optimization: a review of algorithms and applications. **Annals of Operations Research**, v. 240, n. 1, p. 351–380, 2016.

ANLI, O. M.; CARAMANIS, M. C.; PASCHALIDIS, I. C. Tractable supply chain production planning, modeling nonlinear lead time and quality of service constraints. **Journal of Manufacturing Systems**, v. 26, n. 2, p. 116–134, 2007.

ASSID, M.; GHARBI, A.; HAJJI, A. Production control of failure-prone manufacturing-remanufacturing systems using mixed dedicated and shared facilities. **International Journal of Production Economics**, v. 224, n. 2019, p. 107549, 2020.

BERRETTA, R. E. **Heurísticas para otimização do planejamento da produção em sistemas MRP**. 1997. 152f. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, Campinas, SP.

1997.

CARDOSO, J.; JOHNER, C. R.; JOHNER, D. M. F. DA S. Aplicação da programação linear para maximização da capacidade produtiva em uma célula de produção de longarinas. *In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENESEP)*, 38., 2018, Maceió. **A Engenharia de Produção e suas contribuições para o desenvolvimento do Brasil**. Rio de Janeiro: Associação Brasileira de Engenharia de Produção, 2018.

CARVALHO, A. N.; OLIVEIRA, F.; SCAVARDA, L. F. Tactical capacity planning in a real-world ETO industry case: a robust optimization approach. **International Journal of Production Economics**, v. 180, p. 158–171, 2016.

CAUCHICK-MIGUEL, P. A. et al. **Metodologia de Pesquisa para Engenharia de Produção e Gestão de Operações**. 3. ed. Rio de Janeiro: Elsevier, 2018.

CHIWIF, L.; MEDINA, A. C. **Modelagem e Simulação de Eventos Discretos: teoria & aplicações**. 2. ed. São Paulo: [s.n.].

CLARK, J.; DOWNING, D. **Estatística Aplicada - Série Essencial**. 3. ed. São Paulo: Editora Saraiva, 2010.

COELLI, F. C. **Simulação computacional por eventos discretos na otimização do fluxo de pacientes e na caracterização de custos em clínica de mamografia**. 2008. Tese (Doutorado em Engenharia Biomédica) – Programa de Pós-Graduação em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.

CRUZ JR., A. S. DA. Globalização, Inovação e Sistema Internacional: O Brasil e as transformações da economia mundial. **Revista FAAC**, p. 165–178, 2012.

DIAZ, J. E.; HANDL, J.; XU, D.-L. Integrating meta-heuristics, simulation and exact techniques for production planning of a failure-prone manufacturing system. **European Journal of Operational Research**, v. 266, n. 3, p. 976–989, 2018a.

DIAZ, J. E.; HANDL, J.; XU, D. L. Integrating meta-heuristics, simulation and exact techniques for production planning of a failure-prone manufacturing system. **European Journal of Operational Research**, v. 266, n. 3, p. 976–989, 2018b.

DOMINGUES, M. A. S. *et al.* Otimização do sequenciamento de produção com abordagem just-in-time e tempos de setup dependentes da sequência em uma usina siderúrgica. *In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENESEP)*, 36., 2016, João Pessoa. **Contribuições da Engenharia de Produção para melhores práticas de gestão e modernização do Brasil**. Rio de Janeiro: Associação Brasileira de Engenharia de Produção, 2016.

EL RAOUI, H.; OUDANI, M.; EL HILALI ALAOUI, A. Coupling Soft Computing, Simulation and Optimization in Supply Chain Applications: Review and Taxonomy.

IEEE Access, v. 8, p. 31710–31732, 2020.

FAKHRZAD, M. B.; KHADEMI ZARE, H. Combination of genetic algorithm with Lagrange multipliers for lot-size determination in multi-stage production scheduling problems. **Expert Systems with Applications**, v. 36, n. 6, p. 10180–10187, 2009.

FALCO, J. G. **Estatística Aplicada**. Cuiabá: EdUFMT, 2008.

GANSTERER, M.; ALMEDER, C.; HARTL, R. F. Simulation-based optimization methods for setting production planning parameters. **International Journal of Production Economics**, v. 151, p. 206–213, 2014.

GAVIRA, M. O. **Computacional como uma ferramenta de aquisição de conhecimento**. 2003. Dissertação (Mestrado em Engenharia de Produção) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 2003.

GNONI, M. G. *et al.* Production planning of a multi-site manufacturing system by hybrid modelling: A case study from the automotive industry. **International Journal of Production Economics**, v. 85, n. 2, p. 251–262, Feb. 2003.

GRABENSTETTER, D. H.; USHER, J. M. Sequencing jobs in an engineer-to-order engineering environment. **Production and Manufacturing Research**, v. 3, n. 1, p. 201–217, Apr. 2015.

HATZIKONSTANTINOOU, O.; ATHANASIOU, E.; PANDELIS, D. G. Real-time production scheduling in a multi-grade PET resin plant under demand uncertainty. **Computers and Chemical Engineering**, v. 40, p. 191–201, May 2012.

HOADLEY, B. Asymptotic properties of maximum likelihood estimators for the independent not identically distributed case. **The Annals of Mathematical Statistics**, v. 42, n. 6, p. 1977-1991, 1971.

ILGIN, M. A.; TUNALI, S. Joint optimization of spare parts inventory and maintenance policies using genetic algorithms. **International Journal of Advanced Manufacturing Technology**, v. 34, n. 5-6, p. 594-604, 2007.

JAHANGIRIAN, M. *et al.* Simulation in manufacturing and business: A review. **European Journal of Operational Research**, v. 203, n. 1, p. 1–13, 2010.

JUAN, A. A. *et al.* A review of simheuristics: Extending metaheuristics to deal with stochastic combinatorial optimization problems. **Operations Research Perspectives**, v. 2, p. 62-72, Dec. 2015.

KLEIJNEN, J. P. C.; WAN, J. Optimization of simulated systems: OptQuest and alternatives. **Simulation Modelling Practice and Theory**, v. 15, n. 3, p. 354-362, Mar. 2007.

KODINARIYA, T. M.; MAKWANA, D. P. R. Review on determining of cluster in K-

means clustering review on determining number of cluster in K-means clustering. **International Journal of Advanced Research in Computer Science and Management Studies**, v. 1, n. 6, p. 90–95, 2013.

LAW, A. M.; KELTON, W. D. **Simulation Modeling & Analysis**. 2 ed. Singapore: McGraw-Hill, 1991.

LEE, C. K. H. A review of applications of genetic algorithms in operations management. **Engineering Applications of Artificial Intelligence**, v. 76, n. August, p. 1–12, 2018.

LIKAS, A.; VLASSIS, N.; J. VERBEEK, J. The global k-means clustering algorithm. **Pattern Recognition**, v. 36, n. 2, p. 451–461, 2003.

MOLINA, C.; RESENDE, J. Atividades do planejamento e controle da produção (PCP). **Revista Científica Eletrônica de Administração**, v. 6, n. 11, p. 1-5, 2006.

MONOSTORI, L. *et al.* Digital enterprise solution for integrated production planning and control. **Computers in Industry**, v. 61, n. 2, p. 112-126, 2010.

MONTALVAO, E. H. R. *et al.* Um modelo de programação inteira para o problema de. *In*: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENEGEP), 31., 2011, Belo Horizonte. **Inovação tecnológica e propriedade intelectual: desafios da engenharia de produção na consolidação do brasil no cenário econômico mundial**. Rio de Janeiro: Associação Brasileira de Engenharia de Produção, 2011.

MONTGOMERY, D. C.; RUNGER, G. C.; HUBELE, N. F. **Estatística aplicada à engenharia**. 2 ed. Barueri: LTC, 2004.

MORAES, D. G. DE; FERREIRA, C. V. Linear : Estudo De Caso Em Uma Indústria De Esquadrias De Alumínio. **Revista Fatec Zona Sul**, v. 5, n. 4, p. 26–37, 2019.

MORANDI, Maria Isabel Wolf Motta; CAMARGO, Luis Felipe Riehs. Revisão sistemática da literatura. *In*: DRESH, A.; LACERDA, D. P.; JÚNIOR, J. A. V. A. **Design Science Research**. Porto Alegre: Bookman, 2015.

MOTEGI, S. IT in risk management. **Journal of the Society of Mechanical Engineers**, v. 111, n. 1081, p. 984-985, 2008.

PEINADO, J.; GRAEML, A. R. **Administração da Produção: operações industriais e de serviços**. Curitiba: UnicenP, 2007.

PEREIRA, M. M.; FRAZZON, E. M. A data-driven approach to adaptive synchronization of demand and supply in omni-channel retail supply chains. **International Journal of Information Management**, v. 57, p. 102-165, Apr. 2021.

PERGHER, I.; ALMEIDA, A. T. A multi-attribute decision model for setting production planning parameters. **Journal of Manufacturing Systems**, v. 42, p. 224-232, Jan. 2017.

SINGH, R.; MATHIRAJAN, M. Experimental investigation for performance assessment of scheduling policies in semiconductor wafer fabrication: a simulation approach. **International Journal of Advanced Manufacturing Technology**, v. 99, n. 5-8, p. 1503-1520, 2018.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da Produção**. 2. ed. São Paulo: Atlas S.A., 2002.

SOMAN, C. A.; VAN DONK, D. P.; GAALMAN, G. J. C. Capacitated planning and scheduling for combined make-to-order and make-to-stock production in the food industry: An illustrative case study. **International Journal of Production Economics**, v. 108, n. 1–2, p. 191–199, July 2007.

STEVENSON, Z.; FUKASAWA, R.; RICARDEZ-SANDOVAL, L. Evaluating periodic rescheduling policies using a rolling horizon framework in an industrial-scale multipurpose plant. **Journal of Scheduling**, v. 23, n. 3, p. 397-410, June 2020.

TEERASOPONPONG, S.; SOPADANG, A. A simulation-optimization approach for adaptive manufacturing capacity planning in small and medium-sized enterprises. **Expert Systems with Applications**, v. 168, 2021.

TIAN, F. *et al.* Simulation and optimization of vehicle scheduling in flight logistic support process based on Arena. *In*: INTERNATIONAL CONFERENCE ON COMPUTER APPLICATION AND SYSTEM MODELING (ICCAISM), 2010, Taiyuan. **Anais [...]**. Nova Jersey: IEEE, p. 446-449, 2010.

VIEIRA, A. A. C. *et al.* Simulation of an automotive supply chain using big data. **Computers and Industrial Engineering**, v. 137, n. August, p. 106033, 2019.

YEGUL, M. F. *et al.* Improving configuration of complex production lines via simulation-based optimization. **Computers and Industrial Engineering**, v. 109, p. 295–312, 2017.

YOON, H. J.; KIM, J. G. Heuristic scheduling policies for a semiconductor wafer fabrication facility: Minimizing variation of cycle times. **International Journal of Advanced Manufacturing Technology**, v. 67, n. 1–4, p. 171–180, 2013.

Artigo recebido em: 20/03/2022 e aceito para publicação em: 30/08/2022

DOI: <https://doi.org/10.14488/1676-1901.v22i1.4597>