

GÊMEO DIGITAL BASEADO EM SIMULAÇÃO A EVENTOS DISCRETOS: UMA ABORDAGEM FOCADA EM DECISÕES ESTRATÉGICAS, TÁTICAS E OPERACIONAIS

Walther Azzolini Júnior

Universidade de São Paulo (USP), São Carlos, SP, Brasil
Av. Trab. São Carlense, 400 - Parque Arnold Schmidt, São Carlos - SP, 13566-590
wazzolini@sc.usp.br

Carlos Henrique dos Santos

Universidade Federal de Alfenas (Unifal), Poços de Caldas, MG, Brasil
Rodovia José Aurélio Vilela, BR 267, Km 533 11999 - Cidade Universitária, MG, 37715-400
carlos.henrique@unifal-mg.edu.br

André Luiz Romano

Universidade Federal de Alfenas (Unifal), Poços de Caldas, MG, Brasil
Rodovia José Aurélio Vilela, BR 267, Km 533 11999 - Cidade Universitária, MG, 37715-400
andre.romano@unifal-mg.edu.br

Adrieli da Silva Caires

Universidade de São Paulo (USP), São Carlos, SP, Brasil
Av. Trab. São Carlense, 400 - Parque Arnold Schmidt, São Carlos - SP, 13566-590
adrieli.scaires@usp.br

RESUMO

Com a chegada das tecnologias da Indústria 4.0, a simulação evoluiu para o conceito de Gêmeo Digital (GD), que integra dados em tempo real, interfaces gráficas e suporte contínuo à decisão. Este estudo propõe um GD baseado em simulação para suporte à decisão online e offline em uma fábrica de autopeças. O modelo permite decisões táticas, estratégicas e operacionais, com foco no planejamento da produção. Através da modelagem de células de produção de componentes de embreagem, foram avaliadas decisões como a implementação de buffers e um sistema de esteira semiautomático. O GD também auxilia na definição de parâmetros operacionais. A proposta se destaca por unificar decisões em diferentes níveis em um único modelo, promovendo maior eficiência nos sistemas produtivos da era da Indústria 4.0.

PALAVRAS CHAVE. Simulação a Eventos Discretos, Gêmeo Digital, Indústria 4.0.

Tópicos. SIM - Simulação

ABSTRACT

With the emergence of Industry 4.0 technologies, simulation has evolved into the concept of the Digital Twin (DT), which integrates real-time data, graphical interfaces, and continuous decision support. This study proposes a simulation-based DT for both online and offline decision-making in an automotive parts factory. The model enables tactical, strategic, and operational decisions, especially in production planning. By modeling clutch component production cells, the study assessed decisions such as buffer implementation and a semi-automatic conveyor system. The DT also supports the definition of operational parameters. This approach stands out by integrating decision-making at different levels within a single model, contributing to greater efficiency in production systems in the Industry 4.0 era.

KEYWORDS. Discrete Event Simulation. Digital Twin. Industry 4.0.

Paper topics. SIM - Simulation

1. Introdução

A Simulação de Eventos Discretos (SED) é uma das técnicas mais utilizadas para analisar e compreender a dinâmica de sistemas de manufatura. Devido à sua alta flexibilidade, permite a avaliação de diferentes configurações de sistemas e estratégias operacionais para apoiar a tomada de decisões em contextos de manufatura [Negahban e Smith 2014]. Além disso, a simulação pode ser adotada para lidar com incertezas e criar insights dinâmicos, levando em consideração os níveis de estoque, os tempos de espera e a utilização das máquinas envolvidas no processo de manufatura para diversos cenários, visando apoiar a tomada de decisões [do Amaral et al. 2022].

Além disso, o uso da simulação pode ser potencializado com o suporte da Tecnologia da Informação (TI) e das soluções trazidas pela chamada Indústria 4.0. Conforme mencionado por [Santos et al. 2021], a integração da SED com outras tecnologias e soluções permite uma ferramenta capaz de apoiar a gestão de operações por meio de tomadas de decisão mais assertivas, resultando em processos mais eficientes. Adicionalmente, vale destacar que a SED passou por mudanças significativas nas últimas décadas, evoluindo de uma ferramenta de uso pontual para se tornar um método indispensável e utilizado periodicamente no suporte à decisão, conhecido como Gêmeo Digital (GD) [Rodič 2017], [Santos et al. 2022].

Segundo [Wright e Davidson 2020], enquanto modelos tradicionais podem fornecer uma análise pontual do comportamento físico de sistemas modelados, o uso de modelos como GD foca no uso recorrente, com ênfase em avaliar e apoiar decisões ao longo do tempo. [Santos et al. 2021] relatam que dentro do cenário de transformação impulsionado pela Indústria 4.0, a simulação combinada com interfaces gráficas e dados operacionais tornou-se a base dos modelos de GD. Por fim, [Alam e Saddik 2017] concluem que o GD pode ser usado para apoiar decisões operacionais por meio de três abordagens: (1) diagnóstica, visando analisar comportamentos passados; (2) monitoramento, para observar e controlar o processo; (3) prognóstica, visando antecipar e prever comportamentos e, consequentemente, orientar decisões.

Por um lado, GDs baseadas em simulação estão sendo cada vez mais adotadas para tomar melhores decisões em um ambiente de manufatura cada vez mais competitivo. Por outro lado, os sistemas de produção possuem uma complexidade crescente e precisam lidar com grandes quantidades de informações em um ambiente competitivo e desafiador. Nesse sentido, o setor automotivo se destaca como um bom exemplo, conforme destacado por [Guerrini e Pellegrinotti 2016], ilustrando tal complexidade com seu fluxo bidirecional de produtos (bens e serviços) e informações, exigindo integração, sincronização e transparência entre todos os participantes da cadeia produtiva para garantir decisões informadas.

Considerando a SED como a técnica de simulação mais utilizada como GDs em sistemas produtivos [Santos et al. 2022] e levando em consideração a necessidade de tomadas de decisão cada vez mais rápidas e eficientes em ambientes de manufatura, este estudo tem como objetivo propor um GD baseado em SED para apoiar decisões por meio de abordagens online e offline. Inicialmente, o modelo de GD fornece suporte para decisões específicas (táticas e/ou estratégicas), ou seja, analisando o comportamento de sistemas físicos offline sem necessariamente interferir no ambiente real. Por outro lado, a abordagem proposta também permite atualizações periódicas do modelo de acordo com mudanças no ambiente real, possibilitando análises online (decisões operacionais), ou seja, fornecendo suporte a cada intervalo de tomada de decisão e interferindo nos sistemas modelados. O modelo de GD proposto foi implementado em um estudo de caso real, que se refere a uma planta produtiva do setor de autopeças.

O artigo está estruturado da seguinte forma: a Seção 1 apresentou o contexto do problema e a Seção 2 apresenta o referencial teórico associado. A Seção 3 descreve a abordagem proposta, enquanto a Seção 4 apresenta os resultados e as discussões. Por fim, a Seção 5 apresenta as conclusões.

2. Referencial Teórico

Nos últimos anos, a simulação computacional tem se destacado como uma valiosa técnica de apoio à decisão em sistemas produtivos (bens e serviços) [Mourtzis 2020], [Scheidegger et al.

2018]. Isso se deve à sua capacidade de analisar sistemas complexos aliada à flexibilidade e ao baixo custo, uma vez que a simulação permite a análise de sistemas sem a necessidade de interferência direta em ambientes físicos [Greasley e Owen 2018]. Por meio de modelos virtuais, podemos representar o comportamento de sistemas físicos com suas principais características, possibilitando experimentação, comparação de cenários e otimização de decisões. Destacamos o uso da simulação em diversos setores, incluindo logística, saúde, militar e, principalmente, manufatura [Mourtzis 2020], [Negahban e Smith 2014]. Além disso, o principal tipo de simulação adotado em sistemas produtivos é a SED [Scheidegger et al. 2018].

Entretanto, apesar de sua ampla aplicabilidade, nota-se que o SED vem passando por diversas mudanças nos últimos anos. [Rodič 2017] destacam que avanços tecnológicos como sensores e dispositivos inteligentes, alta capacidade de processamento computacional e integração perfeita entre ambientes físicos e virtuais impactaram o uso da simulação. Nesse contexto, abordagens tradicionais de simulação, caracterizadas por modelos complexos e análises pontuais, estão dando lugar a modelos integrados e sincronizados com sistemas físicos, com interfaces amigáveis para uso contínuo no suporte a decisões [Goodall et al. 2019], [Montevecchi et al. 2020]. Dessa forma, os modelos de simulação vêm vivenciando a era do GD [Zhuang et al. 2018].

O termo GD refere-se a duplicatas virtuais capazes de se vincular a sistemas físicos, replicando-os usando seus dados e informações e orientando a tomada de decisões [Wright e Davidson 2020]. Essa ideia foi inicialmente introduzida por [Shafto et al. 2010] e originalmente descreveu cópias virtuais inteligentes de equipamentos de propriedade da NASA, a Agência Aeroespacial dos Estados Unidos. Desde o seu início, tornou-se evidente que os GDs têm sido amplamente aplicados em vários campos, como manufatura, saúde e serviços, abrangendo réplicas virtuais de produtos e processos [Wright e Davidson 2020]. Além disso, muito do uso crescente de GDs pode ser atribuído à sua associação com a quarta revolução industrial, a Indústria 4.0 [Semeraro et al. 2021].

De acordo com [Tao e Zhang 2017], embora possa haver variações no grau de integração entre ambientes físicos e virtuais entre diferentes GDs, todos eles dependem de quatro componentes principais: (i) o Sistema Físico (SF), que compreende humanos, materiais e processos; (ii) o Sistema Virtual (SV), constituído por modelos que espelham o comportamento físico; (iii) o Sistema de Serviço (SS), que abrange a infraestrutura que facilita a comunicação entre ambientes físicos e virtuais; e (iv) o Sistema de Dados (SD), que compreende os dados e informações trocados entre o SF e o SV. A Figura 1 ilustra a arquitetura geral de um modelo GD.




Figura 1 – Estrutura geral do GD para apoio à decisão

Fonte: adaptado de [Tao e Zhang 2017]

[Tao e Zhang 2017] enfatizam que a adoção de GD é uma tendência inevitável. Nesse sentido, [Santos et al. 2022b] revelam que a simulação surge como uma alternativa mais barata e flexível para projetar GDs de processo em comparação com as soluções comerciais disponíveis. Ao conectar o modelo de simulação com sistemas físicos, uma réplica virtual altamente sincronizada é criada, responsiva a mudanças em tempo real, alinhando assim a tomada de decisão com o estado atual dos processos [Beregi et al. 2018]. Além disso, [Santos et al. 2022] argumentam que utilizar a simulação como GD aumenta a capacidade da ferramenta, permitindo que ela reconheça mudanças no sistema físico ao longo do tempo e, conseqüentemente, apoie a tomada de decisão de forma mais eficaz.

Neste caso, além da integração com sistemas físicos, destacam-se modelos com baixos níveis de abstração, alta capacidade gráfica, facilidade de manipulação e integração com outras ferramentas e técnicas de tomada de decisão [Mourtzis 2020]. Vários estudos na literatura abordaram o conceito de GD baseado em simulação, particularmente nos últimos anos [Santos et al. 2022]. Desta forma, diferentes possibilidades se destacam. Por um lado, é possível construir modelos autônomos que controlam sistemas físicos ou não autônomos, que apenas fornecem diretrizes para a tomada de decisão. Por outro lado, considerando a sincronização entre ambientes físicos e virtuais, podemos considerar modelos que atualizam em tempo real e quase real, dependendo da frequência de decisão [Santos et al. 2022b]

3. Abordagem proposta

O presente trabalho baseia-se na utilização da simulação sob duas perspectivas: (i) sua utilização para suporte à decisão seguindo uma abordagem tradicional, ou seja, análise pontual (abordagem offline); e (ii) a utilização da simulação como GD visando fornecer suporte periódico à tomada de decisão (abordagem online). Nesse contexto, [Santos et al. 2022b] destacaram diferenças importantes entre as abordagens de simulação tradicionais e GD: (a) a coleta de dados e a atualização do modelo devem ser automáticas e periódicas considerando as abordagens GD; (b) o modelo GD deve permitir análises em tempo real/quase tempo real, considerando uma interface amigável para decisão e um amplo escopo durante todo o ciclo de vida dos sistemas; e (c) o modelo pode ser autônomo (o modelo controla os sistemas) ou não autônomo (o modelo oferece diretrizes para a decisão). Além disso, diferente da literatura atual sobre GD baseado em simulação, focou-se em uma abordagem que é capaz de suportar abordagens offline e online, o que resulta em uma solução mais flexível considerando diferentes objetivos em relação às decisões. Consideramos duas fases para orientar a implementação da abordagem proposta: (i) Construção do modelo; e (ii) Operação do modelo. Ambas as fases são descritas abaixo:

3.1. Construção do modelo

Considerando a fase de construção do modelo, adotou-se o *framework* proposto por [Montevecchi et al. 2020] e [Santos et al. 2022], que se baseia em três fases: Modelagem Conceitual, Modelagem Computacional e Modelagem Operacional. Este *framework* foi desenvolvido com base em modelos importantes amplamente utilizados na área de simulação, mas adapta as atividades para se adequarem ao cenário atual de modelos de GD.

A fase de Modelagem Conceitual abrange as seguintes atividades: (a) Definição dos objetivos e do sistema; (b) Construção do modelo conceitual; (c) Validação do modelo conceitual; (d) Documentação do modelo conceitual; e finalmente; (e) Modelagem dos dados de entrada. Como resultado desta fase, obtém-se o Modelo Conceitual. A segunda fase, Modelagem Computacional, apresenta as seguintes etapas: (f) Construção do modelo computacional; (g) Verificação do modelo computacional; (h) Definição dos dados de atualização do modelo e das respostas desejadas; (i) Estruturação da interface com o processo real; e (j) Validação do modelo computacional. As etapas “h” e “i” são cruciais para a integração do modelo com sistemas físicos, uma característica chave da GD, enquanto as demais atividades são comuns às abordagens tradicionais de simulação.

Por fim, a última fase, Modelagem Operacional, consiste nas seguintes etapas: (k) Definição dos cenários a serem testados; (l) Execução periódica dos cenários; e (m) Análise e tomada de decisão. As duas etapas finais garantem o uso periódico do modelo para a tomada de decisão, uma característica essencial do GD baseado em simulação.

3.2. Operação do modelo

Considerando a fase de operação do modelo, o principal objetivo é obter um modelo que seja capaz de suportar decisões offline (pontuais) e online (periódicas). Nesse sentido, após a construção do modelo, o modelo operará em duas arquiteturas: (i) Offline: onde o modelo é utilizado em intervalos de tempo discretos para apoiar decisões táticas e/ou estratégicas e, neste caso, os objetivos podem estar relacionados à análise de mudanças de *layout* e fluxo, análise de aquisição de equipamentos, inclusão de um novo produto na linha de produção, entre outros; e (ii) Online: onde o modelo deve ser atualizado de acordo com as mudanças físicas (tempo quase real) para apoiar decisões operacionais e, neste caso, essas decisões podem estar relacionadas à alocação de materiais e recursos humanos, planejamento de produção, cronogramas de trabalho, entre outros. A Figura 2 ilustra a arquitetura proposta durante a fase de operação do modelo:




Figura 2 - Arquitetura da abordagem de simulação proposta

4. Aplicação e Resultados

4.1. Estudo de Caso e Modelagem Conceitual

Este estudo investigou a operação de uma unidade fabril de uma empresa multinacional do setor de autopeças, localizada no estado de São Paulo (Brasil), que desempenha um papel fundamental na cadeia de suprimentos automotiva brasileira há mais de cinquenta anos. A análise se concentrou nos componentes essenciais dos kits de embreagem fornecidos pela empresa: o platô e o disco de pressão. Além disso, vale ressaltar que o tempo de fabricação do platô é aproximadamente o dobro do necessário para o disco. Em resposta a essa disparidade, foi implementado um modelo de SED composto por duas células de fabricação para o platô e uma célula para o disco, operando simultaneamente. Com base no Diagrama de Pareto, as peças mais cruciais e comuns em diferentes modelos de veículos, que constituem as embreagens, foram identificadas e categorizadas como Classe A na curva ABC. Consequentemente, as peças mais representativas foram selecionadas para compor dois modelos principais de produtos, denominados “Modelo A” e “Modelo B”.

A consolidação de dados inclui a análise do tempo de fluxo, *takt time*, desvios-padrão e médios do fluxo de produção dos componentes ao longo do processo de simulação, bem como o giro diário do estoque. Essas métricas permitem que os tomadores de decisão avaliem o desempenho do sistema de produção e sua capacidade de atender à demanda definida no plano mestre de produção. O modelo de simulação de produção, desenvolvido utilizando o *software* Plant

Simulation da Siemens®, trata da sincronização do fluxo de produção de três células de manufatura da empresa estudada:

- Células PPUM5 e PPUM6 (Fabricação do componente platô);
- Célula DPM4 (Fabricação do componente do disco).

A Figura 3 mostra o *layout* das células PPUM5 e PPUM6 incluindo as operações da rota de fabricação das duas células. Já a configuração das PPUM5 e PPUM6 inclui duas máquinas para a operação 10, que operam em paralelo e permitem o balanceamento do fluxo de produção dentro da célula e, conseqüentemente, entre as células de fabricação de platô e disco. Além disso, a Figura 3 também ilustra o *layout* da célula DPM4 (disco). Ao longo da célula DPM4, seis operações consecutivas são executadas de acordo com a rota de fabricação, conforme apresentado.




Figura 3 – Planta baixa das operações envolvidas na produção de platô - Célula PPUM5 (o mesmo para PPUM6) (Real ~132 peças por hora; ~1122 peças por dia) e Célula DPM4 (Real ~ 368 peças por hora ~ 3.128 peças por dia)

Para este contexto específico, foram consideradas duas configurações de células para fabricação de platôs (PPUM5 e PPUM6) e uma configuração de célula de fabricação para o disco (DPM4), a fim de atender à demanda por platôs e discos em suas respectivas linhas de montagem dos modelos A e B, sincronizadas para montagem de kits. Os fluxos mencionados foram validados com gerentes e especialistas do processo, e a próxima etapa foi a modelagem dos dados. Neste caso, coletamos dados de todas as etapas do processo por meio do “GEMBA walking”. Vale ressaltar que consideramos o comportamento estocástico dos dados para entrada no modelo de SED.

4.2. Modelagem Computacional

O próximo passo foi construir o modelo computacional. [Rodič 2017] destaca, entre outras características, a alta resolução gráfica, o alto nível de detalhes e o baixo nível de abstração como características essenciais para a adequação da simulação como GD. As células de fabricação operam simultaneamente, com a montagem final do kit ocorrendo na célula de fabricação de discos. Além disso, o modelo de simulação lida com diferentes níveis de informação provenientes da planta, incluindo tempos de fluxo, *takt time*, comportamento do fluxo de produção e giro diário de estoque. Esses dados permitem que o tomador de decisão avalie a capacidade do sistema de produção de atender à demanda estabelecida no plano mestre de produção.

Para construir o modelo, foi necessário configurar a Lista de Materiais (*Bild of Materials* - BOM) e o processo de fornecimento, refletindo as especificidades do ambiente real da empresa. O modelo deve operar de forma sincronizada, garantindo o fornecimento de kits para os clientes. Essa configuração da BOM e do processo de fornecimento foi essencial para garantir que o modelo representasse fielmente o processo de produção real, uma vez que informações importantes que

alimentam o modelo vêm desses sistemas. Escolheu-se o *software* Plant Simulation da Siemens® (versão 14.1), que permite a modelagem, análise e visualização dos processos de produção, fluxo de materiais e operações logísticas.

Durante o processo de construção do modelo, a verificação do modelo computacional foi uma etapa crucial para garantir seu correto funcionamento, e foram incluídas: (i) Construção Modular: onde o modelo foi desenvolvido e testado em partes, permitindo a identificação e correção de erros em cada módulo individual antes de integrá-los ao modelo completo; e (ii) Animação Gráfica: onde a animação gráfica do modelo permitiu a identificação de discrepâncias entre o modelo simulado e o processo real (considerando fluxos, comportamentos, interações, etc.).

Considerando a interface com o processo real, etapa crucial na análise de aplicações de GD, pode-se dividir os sistemas em módulos. O primeiro é composto pelos sistemas de gestão da empresa, incluindo o Plano Diretor de Produção e tabelas auxiliares com a BOM, ordens de produção, projeção de data de entrega, estoque, etc. O segundo módulo contém as informações do processo de fornecimento, incluindo quantidade, frequência e programação de reposição de componentes, considerando as informações do módulo I. Por fim, o terceiro módulo refere-se a um modelo de simulação, que lê todos os dados e informações para simular cenários e apoiar a tomada de decisões. A Figura 4 ilustra a interface entre o modelo e o processo.




Figura 4 - Interface entre o modelo SED e o processo

A Figura 5 ilustra os modelos DES do PPUM5 e PPUM6 (Platô) e a Figura 6 ilustra o modelo DPM4 (Disco). São capturas de tela dos modelos de simulação de Planta durante a simulação do cenário.




Figura 5 - Captura de tela do modelo PPUM5 (o mesmo para PPUM6)




Figura 6 - Captura de tela do modelo DPM4

Por fim, a validação do modelo foi realizada para garantir que ele representasse com precisão o comportamento dos sistemas reais.

4.3. Modelagem Operacional

4.3.1. Abordagem Offline

No estado atual da planta de produção, as células de manufatura do platô utilizam um sistema de transporte convencional para transportar produtos entre a estação de montagem e as máquinas de balanceamento das células de fabricação de componentes. Nesse contexto, os gestores estão interessados em avaliar a adoção de transportadores semiautomáticos com velocidade variável como parte dos esforços de modernização da planta. Portanto, um dos objetivos táticos/estratégicos do modelo de simulação foi apoiar essa análise. Por outro lado, outra decisão específica de interesse dos gestores foi a implementação de *buffers* na entrada de cada célula de produção. O objetivo desses *buffers* é regular o fluxo quando houver algum descasamento entre as operações. Consequentemente, o uso de *buffers* pode absorver flutuações nos tempos de processo e no número de itens disponíveis, considerando o gargalo no tempo de operação da montagem do platô. Assim, tanto a decisão de implementar transportadores semiautomáticos quanto a adoção de *buffers* visam tornar o processo produtivo mais flexível e eficiente em resposta às variações na demanda e na disponibilidade de componentes.

Essas modificações (inclusão de uma esteira transportadora semiautomática e *buffers*) foram implementadas no modelo para testar sua viabilidade. A Figura 7 ilustra uma das células de

fabricação de platô e destaca alguns dos *buffers* entre as operações de montagem e balanceamento, bem como a esteira transportadora proposta. Neste caso, B9 é o *buffer* na entrada da montagem, B10 é o *buffer* na entrada da esteira transportadora, B11 e B12 são os *buffers* na entrada do processo de balanceamento de platô e C1 é a esteira transportadora semiautomática que facilita o transporte até a balanceadora.

No total, as células de fabricação de platô terão 12 *buffers*, enquanto a célula de fabricação de discos terá 23 *buffers*. Para analisar a viabilidade e os impactos dessa mudança, foram conduzidos experimentos iniciais considerando o saldo final de estoque de vários componentes, conforme ilustrado na Figura 8. Para essa análise inicial, os *buffers* foram dimensionados com base na demanda histórica e não representam necessariamente o dimensionamento mais eficiente (que será o foco da abordagem online). Como pode ser observado, o saldo de estoque com a adoção de *buffers* é menor em comparação ao cenário sem *buffers*. Portanto, fica claro que a adoção de *buffers* é benéfica para o ajuste do saldo de estoque no fluxo de produção.




Figura 7 - Captura de tela do modelo de uma das células de fabricação do platô com alguns dos *buffers* entre as operações de montagem e balanceamento




Figura 8 – Saldo de estoque dos componentes para cada cenário (com e sem *buffer*)

Adicionalmente, foi avaliada a implementação do transportador semiautomático, sendo que neste caso foram testados cinco cenários com diferentes configurações (comprimento e velocidade) do transportador, conforme ilustrado na Figura 9. Vale ressaltar que para este experimento também foram considerados comportamentos conforme demanda histórica, os quais não necessariamente representam os parâmetros ótimos (foco da abordagem online). Neste caso, pode-se observar que os cenários 3, 4 e 5 (velocidade da esteira variando entre 3 e 4 m/s e comprimento variando entre 3 e 3,5 m) apresentaram resultados semelhantes com diferentes *buffers* no início da esteira. Além disso, os cenários 1 e 2 não apresentaram bons resultados considerando

o conjunto de parâmetros (velocidade da esteira de 1 m/s e com e sem *buffer*, respectivamente). No entanto, considerando variações na demanda, velocidades menores poderiam contribuir para um processo enxuto, evitando desperdícios por superprodução. Assim, conclui-se que o comprimento da esteira não impactou os resultados avaliados, enquanto a velocidade e o dimensionamento do *buffer* devem ser definidos de acordo com a demanda (abordagem online) para obter decisões mais eficientes.




Figura 9 – Total produzido e tempo de fluxo, considerando diferentes configurações para os parâmetros do transportador e diferentes *buffers* no início do transportador

4.3.2. Abordagem Online (GD)

Como mencionado anteriormente, a abordagem online é baseada em um modelo de GD e o objetivo é dar suporte a decisões operacionais relacionadas aos parâmetros ótimos das células de produção. Neste trabalho, as decisões operacionais estão relacionadas ao dimensionamento ótimo do *buffer* e à velocidade da esteira e, neste caso, o modelo deve testar cenários com base no estado atual das células de produção para avaliar as decisões mais eficientes. Conforme ilustrado na Figura 10, o modelo é atualizado periodicamente de acordo com as informações de demanda, em uma abordagem em tempo quase real, e dá suporte à escolha ótima em relação ao dimensionamento do *buffer* e à velocidade da esteira para alinhar a capacidade das células à demanda. Além disso, é importante destacar que escolhemos uma abordagem em tempo quase real, uma vez que as decisões são tomadas em intervalos de tempo discretos (semanais ou diários) e uma atualização contínua do modelo não é necessária. Além disso, o GD oferece diretrizes sobre as decisões ótimas, uma vez que as células não possuem sistemas autônomos. De acordo com [Santos et al. 2022], esta é uma abordagem de GD válida.




Figura 10 – Arquitetura do GD baseado em simulação

Considerando os resultados do modelo GD, é importante destacar que eles estão disponíveis em uma interface amigável. Nesse caso, diversos gráficos estão disponíveis para o

decisor, a fim de subsidiar as decisões. Primeiramente, pode-se observar o comportamento do alinhamento entre a demanda e a capacidade das células (conforme ilustrado na Figura 11). Este gráfico é atualizado de acordo com as decisões sugeridas pelo modelo. Além disso, o usuário também pode visualizar o tempo de fluxo por unidade produzida e o total produzido no período (Figura 11), o que pode ajudar a identificar as melhores decisões de forma fácil e intuitiva.




Figura 11 – Gráficos da interface do GD

5. Conclusões

A Simulação de Eventos Discretos (SED) tornou-se uma ferramenta indispensável para o suporte à decisão em sistemas de manufatura. Sua integração com tecnologias da Indústria 4.0, levando ao desenvolvimento de Gêmeos Digitais (GDs), representa um avanço significativo na área. Este estudo exemplifica a aplicação prática de um GD baseada na SED no setor de peças automotivas, demonstrando seu potencial para aprimorar parâmetros de produção, alinhar a capacidade com a demanda variável e apoiar a tomada de decisões informadas tanto offline quanto online.

Especificamente, a análise concentrou-se em uma linha de fabricação de kits de embreagem composta por três células de produção (duas para Platô e uma para Disco). A integração da SED com dados de sistemas físicos garante que os sistemas de manufatura possam se adaptar às mudanças, mantendo assim a competitividade e a eficiência. Foi proposta uma abordagem de arquitetura dupla para a operação do modelo, que inclui suporte à decisão tanto online quanto offline, fornecendo uma estrutura versátil e eficaz para melhorar a eficiência da manufatura.

O modelo offline permitiu que os tomadores de decisão conduzissem análises em intervalos específicos para embasar decisões táticas e estratégicas. Neste caso, o modelo foi utilizado para subsidiar análises referentes à implementação de *buffers* e de uma esteira transportadora semiautomática nas células. Por outro lado, a abordagem online envolve a atualização do modelo em tempo quase real, auxiliando na tomada de decisões operacionais. Neste caso, o modelo é capaz de se adaptar de acordo com a demanda das células, oferecendo diretrizes quanto ao dimensionamento ideal do *buffer* e à velocidade da esteira transportadora para alinhar a capacidade das células à sua demanda. Dessa forma, garante-se um processo enxuto, mitigando cenários de superprodução e demanda não atendida.

Este estudo traz diversas contribuições importantes para a área. Na prática, fornece uma estrutura robusta para a integração da SED com dados em tempo real, permitindo que os sistemas de manufatura sejam mais responsivos e eficientes. A abordagem de arquitetura dupla garante que as decisões estratégicas e operacionais sejam bem fundamentadas, oferecendo melhorias tangíveis na gestão da linha de produção. Quanto à teoria, esta pesquisa avança a literatura ao demonstrar a aplicação prática da SED e GDs em um contexto real, destacando a importância dos modelos offline e online na era da Indústria 4.0.

6. Agradecimentos

Agradecemos ao CNPq, CAPES, FAPESP e FAPEMIG, bem como à empresa objeto deste estudo, pelo apoio a esta pesquisa.

Referências

- Alam, K. M., e Saddik, A. El. (2017). C2PS: A Digital Twin Architecture Reference Model for the Cloud-Based Cyber-Physical Systems. *IEEE Access*, 5, 2050–2062.
- Beregi, R., Szaller, Á., e Kádár, B. (2018). Synergy of of multi-modelling of process control. *IFAC-PapersOnLine*, 51(11), 1023–1028.
- do Amaral, J. V. S. et al. (2022). Metamodeling-based simulation optimization in manufacturing problems: a comparative study. *International Journal of Advanced Manufacturing Technology*, 120(7–8), 5205–5224.
- Greasley, A., Owen, C. (2018). Modelling people's behaviour using discrete-event simulation: a review. *International Journal of Operations & Production Management*, 38(5), 1228–1244.
- Guerrini, F. M., e Pellegrinotti, C. C. (2016). Reference model for collaborative management in the automotive industry. *Production Planning and Control*, 27(3), 183–197.
- Montevechi, J. A. B. et al. (2020). A Method Proposal for Conducting Simulation Projects in Industry 4.0: a Cyber-Physical System in an Aeronautical Industry. *Anais do Winter Simulation Conference*, 2731–2742.
- Mourtzis, D. (2020). Simulation in the design and operation of manufacturing systems : state of the art and new trends. *International Journal of Production Research*, 58(7), 1927–1949.
- Negahban, A., & Smith, J. S. (2014). Simulation for manufacturing system design and operation: Literature review and analysis. *Journal of Manufacturing Systems*, 33, 241–261.
- Rodič, B. (2017). Industry 4.0 and the New Simulation Modelling Paradigm. *Organizacija*, 50(3), 193–207.
- Santos, C. H. et al. (2021). Decision-making in a fast fashion company in the Industry 4.0 era : a Digital Twin proposal to support operational planning. *The International Journal of Advanced Manufacturing Technology*, 116(5), 1653–1666.
- Santos, C. H. et al. (2022b). Use of Simulation in the Industry 4.0 context: creation of a Digital Twin to optimize decision making on non-automated process. *Journal of Simulation*, 16(3), 284–297.
- Santos, C. H. dos et al. (2022). Decision support in productive processes through DES and ABS in the Digital Twin era : a systematic literature review. *International Journal of Production Research*, 60(8), 2662–2681.
- Scheidegger, A. P. G. et al. (2018). An introductory guide for hybrid simulation modelers on the primary simulation methods in industrial engineering identified through a systematic review of the literature. *Computers & Industrial Engineering*, 124, 474–492.
- Semeraro, C. et al. (2021). Digital twin paradigm: A systematic literature review. *Computers in Industry*, 130.
- Shafto, M. et al. (2010). DRAFT Modeling, Simulation, Information Technology & Processing Roadmap. Technology Area 11 - National Aeronautics and Space Administration (NASA), 11, 1–27.
- Tao, F., & Zhang, M. (2017). Digital Twin Shop-Floor: A New Shop-Floor Paradigm Towards Smart Manufacturing. *IEEE Access*, 5, 20418–20427.
- Wright, L., & Davidson, S. (2020). How to tell the difference between a model and a digital twin. *Advanced Modeling and Simulation in Engineering Sciences*, 7(13), 1–13.
- Zhuang, C., Liu, J., & Xiong, H. (2018). Digital twin-based smart production management and control framework for the complex product assembly shop-floor. *The International Journal of Advanced Manufacturing Technology*, 96, 1149–1163.