

Uso de simulação de eventos discretos e otimização combinatória para controle de linha: uma abordagem via algoritmos genéticos.

Leandro Henrique Gomes da Silva

Instituição: Universidade Federal de Pernambuco

Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901

e-mail: Leandro.hgsilva@ufpe.br

William da Silva Macedo Formágio

Instituição: Universidade de Pernambuco

Endereço: Av. Gov. Agamenon Magalhães - Santo Amaro, Recife - PE, 50100-010

e-mail: formagio.william@gmail.com

Lucas Matheus do Nascimento

Instituição: Universidade Federal de Pernambuco

Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901

e-mail: lucas.matheusn@ufpe.br

Rafael Gomes Paes de Lira

Instituição: Universidade Federal de Pernambuco

Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901

e-mail: Rafael.gplira@ufpe.br

Dênis Leite

Instituição: Universidade de Pernambuco

Endereço: Av. Gov. Agamenon Magalhães - Santo Amaro, Recife - PE, 50100-010

e-mail: denisleite@poli.br

Márcio José das Chagas Moura

Instituição: Universidade Federal de Pernambuco

Endereço: Av. Prof. Moraes Rego, 1235 - Cidade Universitária, Recife - PE, 50670-901

e-mail: marcio.cmoura@ufpe.br

RESUMO

Adotar as técnicas da Indústria 4.0 é crucial para que as empresas permaneçam relevantes e competitivas no exigente mercado global do século XXI. No âmbito de controle de linha, o fluxo de produtos pode ser impactado de acordo com a localização dos pontos de decisão, impactando diretamente a produção diária de uma fábrica. O estudo, analisa mudanças do posicionamento de sensores de forma simultânea em uma indústria de latas e propõe o algoritmo genético para aumentar a produção, levando em consideração as restrições físicas do posicionamento dos sensores. Foi-se utilizado a simulação, através de um modelo que representa a produção da fábrica e a lógica CLP de seus sensores. Diante dos resultados obtidos, foi percebido que a junção das técnicas mencionadas é capaz de trazer um aumento de produção em até 0,57% em um espaço de tempo viável.

Palavras-chave: Algoritmo genético, Plant simulation, Posicionamento de sensores.

Tópicos: Simulação e otimização

ABSTRACT

Adopting Industry 4.0 techniques is crucial for companies to remain relevant and competitive in the demanding global market of the 21st century. In the scope of line control, the flow of products can be impacted according to the location of decision points, directly impacting the daily production of a factory. The study analyzes changes in sensor positioning simultaneously in a can industry and proposes a genetic algorithm to increase production, considering the physical restrictions of sensor positioning. Simulation was used, using a model that represents the factory's production and the PLC logic of its sensors. Given the results obtained, it was realized that the combination of the mentioned techniques is capable of increasing production by up to 0.57% in a viable period

Keywords: Genetic algorithm, Plant simulation, Sensor positioning.

Paper topics: Simulation and optimization.

1. Introdução

Durante o século XXI, o setor industrial testemunhou uma necessidade significativa de adaptar e atualizar tecnologias para atender às demandas da Indústria 4.0 [Walczak e Mariusz Hetmanczyk 2023][Raman e Kumar 2022], porém, mesmo diante deste cenário, foi comum notar hesitação por partes de algumas indústrias para adotar técnicas oriundas da indústria 4.0 [Matits 2022]. Atualmente, os benefícios destas técnicas são mais palpáveis, [Maheswari Rajamanickam *et al.* 2023] atribui que a implementação da Indústria 4.0 leva a produtos inovadores, à satisfação do cliente, melhora a eficiência da produção e tem capacidade de reduzir despesas. A adoção de metodologias da Indústria 4.0 não apenas simplifica os processos, mas também revoluciona os modelos de negócios, permitindo que as empresas obtenham uma vantagem competitiva no cenário de mercado em evolução. Adotar esses avanços tecnológicos é crucial para que as empresas permaneçam relevantes e competitivas no ambiente industrial do século XXI.

As empresas atuais estão enfrentando uma intensa concorrência global onde mínimos detalhes podem resultar em grandes ganhos. Isso exige um maior rigor na busca por maior qualidade, maior variedade de produtos, custos mais baixos e prazos de entrega mais curtos [Espinoza-lara *et al.* 2021][Utku *et al.* 2022][Yue e Brychko 2019]. Para prosperar nesse cenário competitivo, os fabricantes devem se concentrar em otimizar seus processos de produção para atender às demandas dos clientes com eficiência. Isso inclui reduzir os tempos de produção, melhorar o gerenciamento de recursos e, principalmente, identificar gargalos. Estes objetivos, podem ser alcançados através de técnicas de simulação, um dos pilares da indústria 4.0.

A partir do uso das técnicas de simulação como uma ferramenta de apoio à decisão, as empresas podem testar efetividade sem correr riscos e, caso seja comprovado benefícios, implementar soluções enxutas no chão de fábrica para melhorar os processos de produção [Seyyedrezael e Alvandi 2023]. Nesse viés, diversas pesquisas mostraram que a adoção de soluções enxutas, oriundas de técnicas de simulação, pode aumentar a produtividade média em até 25%, além dos ganhos indiretos que esta melhoria traz à indústria [Seyyedrezael e Alvandi 2023]. Além de ganhos diretos na produtividade, a Indústria 4.0 enfatiza a importância das técnicas de modelagem e simulação para automação e flexibilidade do chão de fábrica, permitindo a comunicação perfeita entre humanos, máquinas e recursos [Fernandes *et al.* 2023][Dajana Antanasijevic *et al.* 2022]. De forma geral, o uso de simulação na indústria abre portas para a integração de tecnologias como IoT, CPS, *Big Data*, juntos podem melhorar a flexibilidade, eficiência e personalização da fabricação em fábricas inteligentes [Dajana Antanasijevic *et al.* 2022].

O foco desse estudo consiste na problemática de posicionamento de pontos de decisão em uma linha de produção contínua. A escolha da simulação como ferramenta para resolução dessa problemática é altamente recomendada devido à complexidade e dificuldade envolvidas em realizar mudanças na localização dos pontos de decisão empiricamente no ambiente fabril. A simulação permite experimentar um modelo computacional de um sistema de produção real, otimizando processos sem a necessidade de mudanças físicas [Alnajjar *et al.* 2023]. Em sistemas complexos, composto por diversos pontos de decisão seguindo regras multivariáveis e multiobjetivo, a quantidade de conjunto de soluções aumenta exponencialmente à medida que novos sensores são incorporados na linha de produção, sendo necessário o uso de métodos de otimização combinatória para casos como esse.

O método de otimização combinatória proposto como solução neste trabalho foi o algoritmo genético (*Genetic Algorithm - GA*). Segundo Vidrova *et al.*, o GA é particularmente eficiente para resolver problemas não lineares complexos. Estudos como o de [Kapoor *et al.* 2016] utilizam um GA para desenvolver um modelo de rede de sensores ideal dentre milhares de conjuntos de soluções possíveis, caso esse que é muito semelhante ao problema de otimização alvo deste trabalho.

A simulação de eventos discretos (*Discrete Event Simulation - DES*) aliada aos métodos de algoritmo genético torna-se uma ferramenta muito útil na etapa de avaliação e validação dos resultados. Além de ser computacionalmente eficiente para a solução do problema de otimização

combinatória, o modelo de SDE pode testar os resultados propostos pelo algoritmo genético e inferir os potenciais impactos e melhorias que essa solução terá no ambiente real [Kim *et al.* 2016]. Isto facilita a validação da técnica e dos resultados obtidos antes de implementar no cenário real, trazendo mais confiança ao tomador de decisão e um menor custo de implementação, dado que eventuais falhas e intercorrências podem ser visualizadas primeiro no sistema simulado.

O presente trabalho é um exemplo claro de como o uso de tecnologias da Indústria 4.0 pode oferecer às empresas um caminho claro para a otimização de processos, aumento da produtividade e redução de custos. A simulação, em particular, se destaca como uma ferramenta poderosa para testar cenários, otimizar layouts e validar soluções antes da implementação física, impulsionando a tomada de decisões mais assertivas e eficazes no ambiente industrial do século XXI. As empresas que abraçarem essa transformação digital estarão bem posicionadas para competir e prosperar em um mercado global cada vez mais dinâmico.

2. Metodologia


Essa é uma pesquisa exploratória de caráter explicativo e a finalidade dessa pesquisa tem por foco a aplicação de um modelo de simulação e otimização combinatória para identificar a posição ótima para todos os sensores responsáveis pela tomada de decisão no controle de linha, visando aumentar a produção. Isso será realizado utilizando uma abordagem conjunta de técnicas de simulação e GA. A simulação será responsável por representar o ambiente onde as possíveis soluções encontradas pelo GA serão avaliadas, além de realizar testes comparativos para obter dados que evidenciem ou não a melhoria na produção da indústria.

O Algoritmo Genético passará por cinco etapas: (1) identificar as restrições físicas do problema que devem ser inseridas na modelagem; (2) determinar os hiperparâmetros corretos para melhorar a performance e os resultados; (3) replicar soluções encontradas para obter resultados mais completos; e (4) com respaldo estatístico, definir comparativamente o melhor conjunto de posições dos pontos de decisão que maximizará o aumento da produção de latas.

2.1 Escopo do modelo

O sistema que está sendo simulado é uma fábrica de latas. Dentro da linha de produção, existem várias máquinas responsáveis pela execução de procedimentos essenciais para converter papel alumínio em latas de vários tamanhos e formatos. Normalmente, o alumínio passa por processos que incluem marcação, corte, limpeza, pintura, revestimento, formação de gargalo, avaliação do controle de qualidade e, finalmente, paletização das latas. A sequência de operações é representada visualmente na Figura 1.

Figura 1 – Fluxo de processos da linha de produção de latas




As máquinas operam de forma semiautomática, com poucas interferências humanas. As tomadas de decisões para o controle de linha são realizadas por sensores instalados nas esteiras que movimentam as latas em processamento de uma máquina a outra. No modelo de simulação, a lógica realizada pelos seus sensores é representada via linguagem de programação. O Plant Simulation, software de Simulação de Eventos Discretos da Siemens, possui sua própria linguagem, chamada *simtalk 2.0*, baseada na linguagem C++ e foi a ferramenta utilizada pelo presente trabalho como ambiente de simulação.

2.2 Estado atual

Antes da realização deste estudo, o uso do modelo de simulação da empresa era limitado à realização de testes exaustivos, ou seja, verificação par a par de cada futuro cenário a ser testado, seja por adicionar/retirar uma máquina, alterar os parâmetros das máquinas, mudar a posição de sensores etc. Para o problema de posicionamento de pontos de decisão, os testes eram limitados a alterar a posição de um ponto por vez, como ilustrado na Figura 2. Além disso, os resultados eram obtidos por meio de um único teste, o que, segundo Knapp *et al.*, por se tratar de análises de resultados provenientes de simulação, pode não representar com precisão o resultado real, destacando a necessidade do respaldo estatístico ao utilizar este tipo de ferramenta, principalmente em sistemas complexos onde pequenas variações podem levar a efeitos significativos [Freuli *et al.* 2022].


Figura 2 – Variação de um único sensor por tentativa



Fonte: Elaboração própria

Se aumentado a quantidade de esteiras, de sensores e das possíveis posições que cada um pode ocupar, a quantidade de soluções cresce exponencialmente, aumentando também o tempo necessário para montar, testar e analisar os resultados de cada combinação caso seja feito de forma exaustiva. Dito isto, torna-se evidente a necessidade de implicar um método de otimização combinatória para agilizar o processo de posicionamento de sensores, e avaliar a mudança de posição de todos sensores simultaneamente, como ilustrado na Figura 3. Nesse contexto, é notório que este problema se trata também de um problema combinatório multiobjetivo, dado que a mudança de posição pode ter objetivos conflitantes para as diversas métricas da produção e com o GA é possível avaliar grande parte do espaço de soluções e encontrar uma solução mais eficiente para a organização.


Figura 3 – Variação de vários sensores por tentativa



Fonte: Elaboração própria

2.3. Algoritmo genético

O Siemens Plant Simulation conta com uma ferramenta *low code* que facilita a aplicação do GA no ambiente de simulação, chamada “GAWIZARD”. Essa ferramenta é capaz de utilizar o ambiente de simulação e as lógicas contidas nele como uma forma de obter o resultado para sua função objetivo. As etapas do uso combinado do Plant simulation e o GA é ilustrado na Figura 4.



Fonte: <https://docs.sw.siemens.com/en-US/doc/297028302/PL20190919115137952.PlantSimulationENU/id17944#:~:text=Genetic%20Algorithm%20use%20an%20iterative,generating%20new%20solutions%20or%20not.>

A primeira etapa consiste em informar ao software de simulação valores de número de geração, tamanho de população e a direção de otimização (maximizar ou minimizar a função objetivo). Em seguida deve ser construída a função objetivo do modelo com base nos resultados da simulação, nesta pesquisa foi considerado uma variável que representa produção obtida no modelo como função objetivo. Além disso deve-se informar também restrições do problema e opcionalmente deve ser feita a alteração dos valores de seus hiperparâmetros, como será mostrado nos tópicos 2.4 e 2.5.

A segunda etapa é referente ao funcionamento do GA, um indivíduo é implementado no modelo logo após sua criação, a simulação ocorre pelo tempo determinado (3 dias) e é retornado para o usuário o resultado da função objetivo, sempre dando ênfase as 5 melhores indivíduos testados. Neste problema o conjunto de posições dos sensores é representado por um indivíduo do algoritmo genético, composto por 44 cromossomos através de um vetor de 44 pares (X_i, Y_j) onde X_i representa a posição do i -ésimo sensor em uma esteira e Y_j indica a esteira específica à qual o sensor pertence. Cada sensor ocupa uma posição única na esteira, assegurando que $X_i \neq X_j$ para $i \neq j$, mantendo a distinção das posições em cada esteira. O número de esteiras é sensível e não será explicitamente mencionado. Assim, o conjunto de soluções possíveis é determinado por todas as combinações válidas de posições e associações de esteiras para os 44 sensores. Logo uma solução teria o seguinte formato:


$$\text{Individuo} = [(X_1, Y), (X_2, Y), \dots, (X_{44}, Y)] \quad (1)$$

Este indivíduo tem como objetivo maximizar a produção total na saída da última máquina da linha de produção, considerando que a posição dos 44 sensores influencia o fluxo de produção. Podemos definir a função objetivo:

$$f(x) = \text{Out}(x) \quad (2)$$

Onde X representa a configuração dos sensores. Assim, a posição dos sensores influencia diretamente o fluxo de produção, e a solução ótima é aquela que maximiza $\text{Out}(x)$, garantindo o máximo de produção. Aqueles indivíduos com melhores valores são utilizados para continuar a próxima geração, até que uma condição de parada seja atendida. O processo detalhado realizado pela ferramenta é retratado na Figura 5.

Figura 5 – Fluxograma de funcionamento do algoritmo genético no modelo estudado



Fonte: Elaboração própria

2.4. Restrições do problema

Para que uma solução gerada pelo GA seja útil para a empresa é preciso garantir que o conjunto de posições resultante seja possível de ser instalado, ou seja, esteja dentro das restrições físicas da linha de produção. O local de instalação do ponto de decisão é compartilhado com motores e outros objetos específicos, logo, estes pontos não podem compartilhar o mesmo espaço destes objetos. Outra restrição importante é que os sensores devem estar a uma distância mínima de entrada/saída de sua esteira e por fim, existem esteiras específicas que não podem ter estes sensores instalados.

O modelo de simulação é composto por 52 pontos de decisão, destes apenas 44 estão instalados em locais que podem sofrer alterações em sua posição. Para configurar suas possíveis localizações no GA devemos impor limite mínimo e máximo da posição do sensor relativo ao tamanho da esteira, estes valores deverão obedecer às restrições de posições impostas pelo problema, além disso, também podemos garantir que o conjunto de solução não aloque dois ou mais sensores em uma mesma posição.

Dado estas circunstâncias, o modelo do Plant Simulation categoriza o GA a um problema de alocação, onde cada sensor pode ocupar valores finitos dentro do limite impostos pela restrição, um indivíduo representa o conjunto de posições de n sensores e um cromossomo representa a posição do sensor n . Vale salientar que cada sensor pode variar entre sua posição máxima e mínima em incrementos de 0,01m, ou seja, gera-se 500 posições diferentes ao considerar um intervalo de 0 a 5m. Isso resulta em uma solução mais robusta e adequada às restrições físicas em cada segmento da fábrica.

Após a definição de restrições o algoritmo genético calcula quantas alocações diferentes podem ser feitas para cada cromossomo, a partir destes valores podemos estimar o tamanho do espaço de soluções do problema através do princípio fundamental da contagem, ou seja, multiplica-se o número de opções entre as escolhas que lhe são apresentadas, o cálculo é dado pela formula a seguir:

$$\text{Espaço de soluções } (S) = \prod_{i=1}^n X_i \quad (3)$$

Sendo X a quantidade de alocações possíveis para o sensor i , temos o seguinte espaço de soluções:

- $S = 91^2 * 101^1 * 141^1 * 150^2 * 201^5 * 251^2 * 301^8 * 331^1 * 350^3 * 401^6 * 450^1 * 501^8 * 601^1 * 700^2 * 900^1$
- $S \cong 1,032^{110}$

Obtemos um espaço de soluções aproximada de $1,032^{110}$. Lembre que atualmente, a organização realiza cálculos exaustivos para encontrar as localizações ótimas para cada sensor, ou seja, se cada solução testada na simulação dura em média 3 minutos para ser concluída, neste caso encontrar uma solução ótima para este tipo de problema sem a utilização de métodos de otimização combinatória é computacionalmente impossível.

2.5. Hiper parâmetros do algoritmo genético

O GA possui 2 principais hiper parâmetros: probabilidade de mutação e probabilidade de recombinação [El Beqal Asmae *et al.* 2023]. Qualquer valor utilizado nestes hiperparâmetros implica diretamente nos resultados obtidos pelo GA [Hassenat *et al.* 2019], principalmente em relação ao tempo necessário para concluir o processo do GA.

Um processo de busca perfeito exige alcançar um equilíbrio entre explorar de forma metódica e explorar de forma aleatória o espaço de soluções [Basu 2022]. A forma com que isso acontece no GA é ditada por seus operadores genéticos, que por sua vez sofre um *tradeoff* em seus

métodos de buscas por sua respectiva taxa de probabilidade. Um alto valor na probabilidade de mutação leva a uma exploração completa das soluções potenciais, embora cause uma dispersão contínua dos cromossomos no espaço de busca e, conseqüentemente, resulte em atraso na convergência [Basak 2020], ou seja, favorece a exploração aleatória. Por outro lado, um alto valor na probabilidade de recombinação resulta em um algoritmo de convergência genética rápido, embora com um escopo confinado e não necessariamente produzindo os melhores resultados [Rares Maniu e Laurentiu Alexandru Dumitru 2017], ou seja, favorece a exploração metódica.

Com o objetivo de otimizar os resultados provenientes do GA ao sugerir um valor ideal para estes parâmetros, Hassenat *et al.* 2019 afirma que existem dois melhores métodos de definir estas taxas, a primeira é a *Dynamic ILM/DHC*, e seu uso é recomendável em populações com menos de 100 indivíduos. Este método consiste em iniciar o procedimento com a probabilidade de recombinação em 100% e a probabilidade de mutação em 0% e com o passar das gerações inverter estes valores, isto é possível através do delta por geração. Sendo assim atribuímos os seguintes valores para o delta por geração:

$$\Delta(\text{Recombinação}) = - \frac{100\%}{\text{Tamanho de geração}} \quad (4)$$

$$\Delta(\text{Mutação}) = + \frac{100\%}{\text{Tamanho de geração}} \quad (5)$$


O segundo método, chamado *Dynamic DHM/ILC* tem uso recomendável para população com mais de 200 indivíduos, e possui metodologia contrária ao método anterior. Inicia o procedimento com probabilidade de recombinação em 0% e probabilidade de mutação em 100%, e inverte estes valores com o passar das gerações, logo podemos definir os valores de delta por geração da seguinte forma:

$$\Delta(\text{Recombinação}) = + \frac{100\%}{\text{Tamanho de geração}} \quad (6)$$

$$\Delta(\text{Mutação}) = - \frac{100\%}{\text{Tamanho de geração}} \quad (7)$$

A utilização de parâmetros diferentes no GA pode influenciar significativamente os resultados obtidos, fazendo com que a função objetivo varie dinamicamente conforme ilustrado na Figura 6, em relação ao indivíduo gerado. Um problema de otimização combinatória encontra uma solução “boa o suficiente”, mas que não garante o valor ótimo, a priori. Testar diferentes métodos nos permite garantir que a solução proposta se aproxime mais do ótimo global, evitando soluções que convergem prematuramente e acabam “presas” em um ótimo local, como pode ser observado também na Figura 6.

Figura 6 – Exemplo de resultados da função objetivo



Fonte: <https://alexandremundim.medium.com/algoritmos-geneticos-o-que-sao-o-que-comem-e-como-se-reproduzem-31a65d5b9709>

3. Análise de resultados

Para a execução do GA no Plant Simulation, a simulação foi feita em um computador com as seguintes especificações: *Intel Core i7-9700k 3.6GHz, 32gb de RAM, Nvidia GeForce RTX 2060 4gb, 240gb de SSD e 4tb de HD*. Para identificar a melhor configuração de hiper parâmetros, a avaliação dos resultados será conduzida tanto para o GA com populações pequenas quanto para populações grandes, com o intuito de verificar as diferenças na performance e resultado obtidos ao utilizar diferentes os hiper parâmetros do GA.


Em seguida, ao replicar várias vezes a simulação da solução obtida pelo GA, pode-se aproveitar o Teorema do Limite Central para aumentar a significância estatística e a representatividade dos resultados [Cao 2021]. Essa abordagem permite um cálculo mais preciso das médias e garante a robustez da solução obtida por meio do GA [Roy e Ma 2023]. Em seguida, serão comparadas as médias de produção do modelo antes e após o processo de otimização. Os parâmetros e desempenhos obtidos de cada método sugerido está disposto na Tabela 1.

Tabela 1 – Resultados de performance do algoritmo genético

Variáveis	<i>Dynamic ILM/DHC</i>	<i>Dynamic DHM/ILC</i>
Tamanho de população	50	200
Tamanho de geração	10	10
Conjunto de possíveis soluções	950	3800
Conjunto de soluções analisadas	729	3800
Tempo de conclusão	02:13:18	12:39:58

Os dois métodos testados obtiveram resultados parecidos quanto ao aumento de produção do modelo de simulação, porém, com performances muito diferentes. O método *Dynamic ILM/DHC* foi capaz de entregar um melhor resultado em pelo menos 5x mais rápido, graças a sua capacidade em diminuir o espaço de busca de soluções para chegar em seu melhor conjunto de posições de sensores. Isso acontece pois os hiperparâmetros do método *Dynamic ILM/DHC* fazem com que com o avançar das gerações os indivíduos gerados coincidam com indivíduos antigos, logo uma menor quantidade de indivíduos unicos são criados. Este fato é ilustrado na Figura 7, onde os valores em vermelho mostrar que o indivíduo já foi analisado anteriormente.


Figura 7 – Indivíduos não unicos gerados com o passar da gerações



Fonte: O autor (2024)

Quanto ao aumento de produção obtido no modelo, realizamos 100 replicações de cada solução e comparamos com o valor do modelo original, visando validar as respostas obtidas e verificar sua robustez quanto a aleatoriedade do modelo. Devido a sensibilidade destas informações para a organização onde foi aplicado esse estudo, os valores de produção serão normalizados para serem inseridas no grafico. A Figura 8 representa a comparação dos valores de produção normalizados antes e depois do uso do GA.

Figura 8 – Comparativo entre *boxplot* de produção



Fonte: O autor (2024)

A solução obtida utilizando o método *Dynamic ILM/DHC* após 100 replicações provou ser melhor também em questão de aumento de produção do modelo, nestas replicações obteve-se um valor médio de produção 0,57% maior que a produção no modelo original, já o método *Dynamic DHM/ILC* resultou num aumento de 0,51% na média de produção do modelo de simulação. Uma boa proximidade de resultados, levando em consideração a grande diferença de performance dos dois métodos.

4. Conclusões

Este estudo mostrou que a combinação de técnicas de otimização combinatória com softwares de simulação de eventos discretos é positiva na busca por melhoria no chão de fábrica. Isso porque o GA é capaz de reduzir o tempo para se obter uma solução de um problema complexo que poderia ser resolvido exaustivamente em anos por apenas algumas horas e à disponibilidade de uma ferramenta para testar propostas de solução, evitando possíveis riscos associados aos testes diretos no local de trabalho.

Sendo assim, o trabalho cumpriu com seu objetivo de encontrar um conjunto de posições de sensores tomadores de decisão cuja sua disposição ideal refletissem no aumento de produção do modelo de simulação, que por sua vez sugere também o aumento de produção na linha de produção real. O aumento de 0,57% de produção é visto de forma muito positiva, tendo em vista a complexidade da produção, a meta anual da empresa e facilidade de replicação do trabalho para outras linhas de produção desta mesma empresa.

Em relação a comparação dos métodos utilizados, ficou evidente que o método *Dynamic ILM/DHC* retornou melhor performance e resultados e por isso será considerado melhor para problemas como este, porém, isso não garante o domínio sobre o método *Dynamic DHM/ILC* em situações com diferentes configurações.

A partir deste trabalho, identificamos uma melhoria na produção ao realizar o reposicionamento dos sensores ao longo da linha. No entanto, a configuração ideal dos sensores pode variar conforme o desempenho atual da fábrica, o que sugere que o posicionamento ideal dos sensores deve ser ajustado diariamente. Diante disso, é recomendável que, no futuro, se implemente um sistema que utilize sensores contínuos, em vez de distribuí-los de forma discreta ao longo das esteiras. Esses sensores contínuos poderiam tomar decisões com base no status atual da linha de produção, considerando não apenas a capacidade momentânea, mas também outros fatores operacionais relevante.

Agradecimentos e financiamento

Os autores agradecem ao Fundo INOVAR-PE e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001. Os modelos de simulação deste trabalho foram feitos com a Siemens Tecnomatrix Plant Simulation Research License.

Referências

- ALNAJJAR, A. B. et al. Wireless Sensor Network Optimization Using Genetic Algorithm. **Journal of Robotics and Control/Journal of Robotics and Control (JRC)**, v. 3, n. 6, p. 827–835, 1 jan. 2023.
- BASAK, A. A Rank based Adaptive Mutation in Genetic Algorithm. **International Journal of Computer Applications**, v. 175, n. 10, p. 49–55, 17 ago. 2020.
- BASU, P. Perfect i.i.d Processes. **Asian Journal of Probability and Statistics**, p. 41–45, 11 jul. 2022.
- CAO, S. Central limit theorems for combinatorial optimization problems on sparse Erdős–Rényi graphs. **The Annals of Applied Probability**, v. 31, n. 4, 1 ago. 2021.
- DAJANA ANTANASIJEVIĆ et al. Towards a Formal Specification of Human Worker for Industry 4.0. 23 nov. 2022.
- EL BEQAL ASMAE; HAFIDI SANAE; BENHALA BACHIR. A Study of Genetic Algorithm Parameterization via a Benchmark of Test Functions. 18 maio 2023.
- ESPINOZA-LARA, B.; LOGROÑO-JIMENEZ, J.; ROMERO-BLACK, W. Determinación de los costos comprimidos en la producción y envasado de água: caso empresa água Purissima. **593 Digital Publisher CEIT**, v. 6, n. 6, p. 251–264, 3 nov. 2021.
- FERNANDES, N.; BARROS, J.-P.; CAMPOS-REBELO, R. Graphic Model for Shop Floor Simulation and Control in the Context of Industry 5.0. **Applied Sciences**, v. 13, n. 2, p. 930, 10 jan. 2023.
- FREULI, F.; HELD, L.; HEYARD, R. Replication success under questionable research practices – a simulation study. **Econstor**, 3 ago. 2022.
- HASSANAT, A. et al. Choosing mutation and crossover ratios for genetic algorithms-a review with a new dynamic approach. **Information (Switzerland)**, v. 10, n. 12, 1 dez. 2019.
- KAPOOR, R.; SHAH, B. J.; SHAH, N. H. A simulation- and genetic algorithm-based optimisation of closed-loop multi-echelon inventory system. **International Journal of Mathematics in Operational Research**, v. 8, n. 1, p. 28, 2016.
- KIM, N. et al. A Genetic Algorithm to Solve the Optimum Location Problem for Surveillance Sensors. **Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography**, v. 34, n. 6, p. 547–557, 31 dez. 2016.
- KNAPP, B.; OSPINA, L.; DEANE, C. M. Avoiding False Positive Conclusions in Molecular Simulation: The Importance of Replicas. **Journal of Chemical Theory and Computation**, v. 14, n. 12, p. 6127–6138, 24 out. 2018.
- MAHESWARI RAJAMANICKAM et al. Fourth Industrial Revolution. p. 41–84, 23 jan. 2023.

MATITS, P. Industry 4.0 to your industrial campus. **SYNCHROINFO JOURNAL**, v. 8, n. 5, p. 26–33, 2022.

RAMAN, R.; KUMAR, A. Potential, Scope, and Challenges of Industry 4.0. p. 201–213, 30 nov. 2022.

RARES MANIU; LAURENTIU ALEXANDRU DUMITRU. Genetic algorithm - adaptive crossover based on solution distribution in search space. 1 maio 2017.

ROY, A.; MA, Y. A Central Limit Theorem for Algorithmic Estimator of Saddle Point. **Cornell University**, 1 jan. 2023.

SEYYEDREZAEI, M. A.; ALVANDI, M. Improving the manufacturing process using Industry 4.0 tool: a simulation-based approach. **International Journal of Process Management and Benchmarking**, v. 14, n. 1, p. 52, 2023.

VIDROVA, Z.; BOHUS, Z.; ADAMKO, P. Simulation as a Tool for Process Optimization in a Manufacturing Company. **SHS Web of Conferences**, v. 92, p. 08023, 2021.

UTKU, D. H.; SUBAŞI, G.; KASIMOĞLU, F. Improving Bottlenecks: An Automotive Company Application. **European Journal of Science and Technology**, 16 abr. 2022.

YUE, D.; BRYCHKO, A. Competitiveness of production as a determining factor of effective management of the enterprise in market conditions. **Ekonomika ta upravlinnâ APK**, n. 2(151), p. 67–75, 16 dez. 2019.

WALCZAK, M.; MARIUSZ HETMAŃCZYK. The performance of IIoT communication standards. **Diagnostyka**, v. 24, n. 3, p. 1–8, 19