

ALGORITMO GENÉTICO E SIMULAÇÃO DE EVENTOS DISCRETOS: UMA ABORDAGEM HÍBRIDA APLICADA NA OTIMIZAÇÃO DE LAYOUT E PROCESSOS INDUSTRIAIS

Jean Carlos Cendron, jeancendron@hotmail.com¹
Adelano Esposito, adelano.esposito@farroupilha.ifrs.edu.br²

^{1,2} Instituto Federal do Rio Grande do Sul, Campus Farroupilha, Av. São Vicente – Cinquentenário, Farroupilha – RS, 95180-000.

Resumo: Diante da atual conjuntura de mercado, vem sendo cada vez mais necessário que as empresas adotem estratégias e tecnologias de manufatura para produzir com mais agilidade, melhor qualidade e com menos recursos. Para tanto, a otimização de layout e processos mostra-se eficiente. No presente estudo, uma abordagem híbrida contemplando algoritmo genético e simulação de eventos discretos é apresentada como solução para a complexa problemática de otimização de layout e processos industriais, com foco em formação de células de manufatura, aplicada em uma fábrica moveleira do sul do Brasil. Tal abordagem dispensa o uso de pesos multiplicadores em sua função objetivo e considera parâmetros como demanda de peças (com base em um período do histórico de produção da empresa), suas diferentes rotas através do fluxo de processos, tempos de operação, adição e remoção de máquinas e suas dimensões e posições reais. A performance da solução proposta pelo algoritmo foi comparada à da configuração vigente na fábrica. Os resultados indicam uma redução de 15% no custo total de produção, sugerindo que a otimização dessas configurações pode melhorar significativamente as condições de manufatura.

Palavras-chave: otimização industrial, células de manufatura, algoritmo genético, simulação de eventos discretos.

1. INTRODUÇÃO

Seja devido ao desaquecimento da economia, ao avançar da concorrência ou até mesmo à possibilidade de obsolescência, é imprescindível que as empresas adotem estratégias e tecnologias de manufatura para produzir com mais agilidade, melhor qualidade e com menos recursos. Nesse cenário, a *group technology* (GT), conceito introduzido por Burbidge (Dimopoulos, 2007), tem aplicação nos sistemas de célula de manufatura (SCM), que se apresentam como uma metodologia eficiente para o desafio apresentado, uma vez que várias vantagens relacionadas à sua implementação têm sido relatadas na literatura, como o aumento da produtividade e do controle de produção, minimização dos estoques intermediários, redução no tempo de manuseio e transporte de materiais e melhoria na qualidade de produtos (Burbidge, 1992; Corrêa, 2004 e Esen *et al.*, 2017).

Para cumprir a complexa tarefa de otimização e busca pela melhor organização possível de *layout* e processos, com foco em SCM, a classe de abordagens heurísticas se mostra apropriada (Brown, 2001 e Heragu, 2008). Entre os modelos mais adequados, está o algoritmo genético (AG) (Heragu, 2008 e Mahdavi, 2009), um método heurístico desenvolvido por Holland (1975), baseado em princípios evolucionários da seleção natural para iterativamente otimizar uma população de soluções candidatas usando uma função de aptidão pré-definida.

No entanto, a alteração do *layout* de uma fábrica pode vir a ser uma tarefa custosa e, por isso, torna-se importante o desenvolvimento de um modelo de otimização de SCM que contemple múltiplos fatores, fiéis à realidade e que são relevantes para o sistema (Forghani, 2014). Nesse sentido, muitos trabalhos buscaram resolver a problemática com uma variedade de abordagens e modelos.

Jahanzaib *et al.* (2013) utilizou um AG e propôs um modelo matemático, como função objetivo, que permite minimizar o volume de movimentos de lotes de peças entre as células. Já Venugopal *et al.* (1992) apresenta uma função multiobjetivo, que possibilita minimizar, além do trânsito entre as células, a variação de carga total dentro de cada uma delas.

Outras abordagens foram apresentadas, agregando mais fatores a esse modelo matemático (Mungwattana, 2000; Tavakoli-Moghadam *et al.*, 2005 e Jayakumar *et al.*, 2011), como o custo de investimento em máquinas, de tempo de processamento de cada operação e de realocação de máquinas durante o período. Todos esses componentes de custo são somados, formando um modelo matemático multiobjetivo, e ponderados por pesos, os quais são determinados subjetivamente pelo tomador de decisão. Sequências de operações e rotas alternativas para as peças também foram consideradas nesses trabalhos, assim como a possibilidade de duplicação de máquinas.

Por sua vez, Wu *et al.* (2006), descreveu um modelo matemático que admite a minimização do custo total de movimento (intra e intercelular) e da quantidade de elementos excepcionais. Tais elementos excepcionais são definidos

como operações de uma peça que precisam ser realizadas em uma célula diferente daquela para a qual foi destinada pelo algoritmo. De modo semelhante, Hazarika (2021) utilizou um AG meta-heurístico para resolver a problemática, mas com foco na maximização da “eficácia de grupo”, reduzindo o número de movimentos intercelulares por forçar a organização de uma matriz de incidência peça-máquina em *clusters*, ou blocos diagonais, os quais representam as células.

Por fim, Forghani et al. (2014) também propôs uma função multiobjetivo que minimiza o custo total de manuseio de material, mas tendo em conta a posição precisa das máquinas em células com dimensões definidas, determinando assim um custo variável conforme a distância verdadeira, em vez da distância entre centros das células ou custo fixo de movimentação. Porém, o estudo considera que todas as máquinas são iguais em tamanho e que a duplicação de equipamentos não é permitida.

Apesar de alguns desses estudos apresentarem aplicações em casos reais e, aparentemente, obterem bons resultados, como Jayakumar *et al.* (2011) e Forghani *et al.* (2014), as abordagens mencionadas ainda possuem uma ou mais das seguintes limitações: (a) utilizar função multiobjetivo com pesos determinados de maneira subjetiva; (b) considerar poucos critérios, como, por exemplo, somente o número total de movimentos ou de elementos excepcionais, porém deixando de lado outros parâmetros essenciais que compõem o custo total de produção; (c) assumir que cada peça possui apenas uma rota de processos; (d) desconsiderar a possibilidade de duplicação ou remoção de máquinas; (e) considerar com pouca precisão as distâncias percorridas no manuseio e transporte dos materiais; e (f) utilizar exemplos hipotéticos com dados aleatórios em vez de dados oriundos de aplicações reais.

Por outro lado, Imran *et al.* (2016) utilizou AG e simulação de eventos discretos (SED) integradamente, de maneira que os indivíduos de cada geração são avaliados através da simulação. Trata-se de uma abordagem superior, pois, conforme argumentado pelo autor, a análise de um sistema de manufatura deve considerar o aspecto dinâmico e estocástico do sistema. Funções objetivo compostas apenas por termos matemáticos analíticos, como as mencionadas anteriormente, resultam em um custo total para avaliar uma configuração candidata a partir de componentes estimados médios. Porém, a estimação desses componentes não é trivial, já que, por exemplo, existe a possibilidade, em um caso real, de haver uma sequência de operações que precisa ser respeitada para a fabricação de uma peça, e, como consequência, filas de espera podem ser desenvolvidas nas máquinas durante o fluxo, gerando intervalos de tempo que também devem ser considerados para uma solução candidata. No entanto, embora essa metodologia corresponda melhor às condições reais ao fazer uso da simulação, ainda carrega algumas limitações, como não considerar o *layout* e posição real das máquinas e não permitir sua duplicação.

A fim de superar as deficiências dos métodos de otimização descritos e obter mais confiança na resolução de problemas reais de otimização de *layout* e processos com foco em SCM, uma abordagem baseada em AG e SED para a formação de células de manufatura será apresentada no presente estudo. Essa abordagem apresenta uma visão global e premissas mais realistas, considerando o custo de manuseio e transporte de materiais, além de outros aspectos como os custos de operação, energia, manutenção, consumíveis, área ocupada, investimento e venda das máquinas. Todos esses fatores são incorporados a uma simulação aplicada a uma base estatística de demanda, obtida a partir dos dados históricos da fábrica analisada.

2. FORMULAÇÃO DO PROBLEMA

De acordo com Venugopal *et al.* (1990), o número de permutações pelas quais m máquinas podem ser atribuídas a c células é dado pelo número de Stirling do segundo tipo, conforme a Equação (1), em que ‘ k ’ equivale ao número de células e ‘ m ’ ao número de máquinas.

$$S^{(k)} = \frac{\sum_{j=1}^k (-1)^{k-j} \cdot \frac{k!}{j!(k-j)!} \cdot j^m}{k!} \quad (1)$$

Para uma fábrica com dez máquinas e quatro células, existem 34.105 permutações possíveis. No entanto, Wemmerlöv *et al.* (1989), em um estudo com 32 empresas dos Estados Unidos, constatou que, em média, uma empresa apresenta a quantidade de 6 células de manufatura, contendo 6 máquinas cada, resultando em uma quantidade aproximada de 36 máquinas por fábrica. Logo, para problemas de médio a grande porte, modelos matemáticos triviais podem impor grandes dificuldades computacionais. No caso de vinte máquinas e quatro células, por exemplo, o número de permutações aumenta para $4,52 \times 10^{10}$, o que representa uma explosão combinatória. Isso torna evidente e comprova a importância do uso de métodos heurísticos eficientes para resolver o modelo proposto em problemas de maior escala (Mahdavi *et al.*, 2009) e, para tanto, o uso de um AG é uma solução adequada.

Além disso, conforme já mencionado, é comum, na literatura, a implementação de funções com diversos objetivos para a resolução da problemática. No entanto, é importante ressaltar que, em uma função multiobjetivo, há normalmente a unificação dos termos, pois o mecanismo evolucionário típico não possui a capacidade integrada de otimizar vários elementos simultaneamente, a menos que esses sejam agregados em um valor de aptidão único (Dimopoulos, 2007). Para tanto, comumente, cada termo é multiplicado por pesos, cujos valores podem ser definidos subjetivamente pelo tomador de decisão para determinar qual objetivo possui maior importância (Morad *et al.*, 1995). Essa conduta é apresentada, muitas vezes, como positiva, já que pode vir a ser essencial, para a gestão de determinadas empresas, em momento ou outro, priorizar algum elemento na otimização.

Porém, em casos em que os elementos a serem otimizados apresentem diferença de espécie (*i.e.*, tempo e dinheiro) ou escala (*i.e.*, 1 para 2), a tarefa, aparentemente simples, de determinar tais pesos pode se tornar inócua (Mansouri *et al.*, 2000). Isso porque o modelo matemático que representa tais elementos pode possuir um desequilíbrio inerente, de modo que alterar a relevância de um elemento através de um peso multiplicador pode significar o aumento de uma assimetria já existente, e não sua origem. Exemplificativamente, comparar um custo de investimento em equipamentos com um custo de manuseio intra e intercelular formado a partir do número total de movimentações, como é comum na literatura, pode vir a ser uma tarefa frustrada, haja vista que não há garantia de que tais critérios sejam equivalentes em escala. Portanto, como confiar que os pesos determinados expressarão a relevância desejada para cada um dos termos?

Para lidar com problemas complexos, faz-se necessário utilizar técnicas que: (i) agreguem os objetivos de maneira que cada componente seja compatível com o outro em espécie e escala, sem a necessária utilização de pesos multiplicadores e (ii) apresentem capacidade de considerar dados de entrada que incorporem aspectos reais do ambiente industrial, de testar vários cenários de produção e de modelar a natureza dinâmica e estocástica da demanda (Mansouri *et al.*, 2000 e Thomassey *et al.*, 2018). Nesse sentido, a SED se apresenta como uma ferramenta poderosa e eficaz (Azadeh *et al.*, 2014), pois não só permite a utilização de dados mais fiéis, como também a obtenção de valores de aptidão através da simulação da manufatura das peças em uma fábrica virtual que contém as características da verdadeira. Os atributos (i) e (ii) são importantes pois permitem comparar custos reais da fábrica e com mesma periodicidade (considerando dados estatísticos da empresa), garantindo que o modelo possua um nível de assimetria neutro, proporcionando uma otimização global.

Embora o tomador de decisão ainda possa, caso for de seu agrado, parcializar os critérios conforme sua necessidade, tal tarefa agora expressará a real parcialidade desejada. Nesse sentido, para a utilização de pesos multiplicadores, é recomendado determinar o conjunto de vetores, ou uma aproximação razoável, da fronteira eficiente de Pareto (Žilinskas *et al.*, 2014). Ela contém um grupo de pontos denominados dominantes, o que significa dizer que não há mais uma única solução ótima, mas sim um conjunto. Para um ponto ser considerado dominante, é necessário que, no domínio, não exista mais nenhum ponto que resulte em melhoria de pelo menos um objetivo enquanto os demais se mantêm inalterados (Arora, 2004). O processo de determinação da fronteira pode ser realizado ao definir, aleatoriamente, valores de pesos para cada objetivo na função de aptidão (Murata *et al.*, 2001).

No presente trabalho, uma função multiobjetivo é apresentada, em que todos os componentes de custo são agregados em mesma escala e caráter, ou seja, em valores monetários, proporcionais e referentes a um período específico de produção, visando uma otimização global, portanto, sem a utilização de pesos multiplicadores. A determinação do período mencionado permite a obtenção de uma base estatística de demanda para a simulação, a qual é formada a partir dos dados históricos da fábrica analisada e será abordada com mais profundidade na subseção 3.5.

Para fins de simplificação, será dispensada a distinção, apresentada por alguns autores, entre custo, despesa, investimento e perda. Todos os gastos serão tratados como equivalentes em espécie, e denominados “custos”, contemplando tanto diretos e indiretos, quanto fixos e variáveis. Informações como as filas de espera das peças em máquinas dentro das células, que são geradas devido às sequências de ordens e operações, que devem ser respeitadas, também são consideradas.

Quanto aos custos de transporte, intra e intercelular, esses são calculados com base nas posições exatas das máquinas, abordagem que é mais precisa do que aquela feita por métodos comuns, que usam distâncias de centro a centro das células (Forghani *et al.*, 2014). A diferença das duas abordagens nas distâncias resultantes é ilustrada pela Fig. 1.

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15
M1	-	1,0	2,0	2,7	4,5	4,5	4,5	4,5	5,5	5,5	5,5	5,5	7,5	7,5	7,5
M2	-	-	1,0	2,5	4,5	4,5	4,5	4,5	5,5	5,5	5,5	5,5	7,5	7,5	7,5
M3	-	-	-	2,7	4,5	4,5	4,5	4,5	5,5	5,5	5,5	5,5	7,5	7,5	7,5
M4	-	-	-	-	4,5	4,5	4,5	4,5	5,5	5,5	5,5	5,5	7,5	7,5	7,5
M5	-	-	-	-	-	2,1	3,0	4,0	6,7	6,7	6,7	6,7	5,5	5,5	5,5
M6	-	-	-	-	-	-	3,2	3,0	6,7	6,7	6,7	6,7	5,5	5,5	5,5
M7	-	-	-	-	-	-	-	2,1	6,7	6,7	6,7	6,7	5,5	5,5	5,5
M8	-	-	-	-	-	-	-	-	6,7	6,7	6,7	6,7	5,5	5,5	5,5
M9	-	-	-	-	-	-	-	-	-	1,1	2,1	2,9	4,5	4,5	4,5
M10	-	-	-	-	-	-	-	-	-	-	1,0	2,1	4,5	4,5	4,5
M11	-	-	-	-	-	-	-	-	-	-	-	2,1	4,5	4,5	4,5
M12	-	-	-	-	-	-	-	-	-	-	-	-	4,5	4,5	4,5
M13	-	-	-	-	-	-	-	-	-	-	-	-	-	2,2	1,5
M14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2,1
M15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15
M1	-	1,0	2,0	2,7	4,5	6,5	5,4	7,4	6,0	6,6	6,8	8,6	8,2	10,3	9,4
M2	-	-	1,0	2,5	3,5	5,5	4,6	6,5	6,1	6,5	6,6	8,5	7,6	9,6	8,9
M3	-	-	-	2,7	2,5	4,5	3,9	5,7	6,3	6,6	6,5	8,5	7,2	9,0	8,5
M4	-	-	-	-	4,3	5,9	3,5	5,6	3,6	4,0	4,1	6,0	5,7	7,8	6,8
M5	-	-	-	-	-	2,1	3,0	4,0	7,5	7,4	7,0	9,0	6,5	7,9	8,0
M6	-	-	-	-	-	-	3,2	3,0	8,5	8,1	7,5	9,4	6,2	7,0	7,6
M7	-	-	-	-	-	-	-	2,1	5,4	4,9	4,3	6,3	3,5	5,1	5,0
M8	-	-	-	-	-	-	-	-	7,0	6,3	5,4	7,1	3,4	4,0	4,7
M9	-	-	-	-	-	-	-	-	-	1,1	2,1	2,9	5,0	7,2	5,4
M10	-	-	-	-	-	-	-	-	-	-	1,0	2,1	4,0	6,1	4,3
M11	-	-	-	-	-	-	-	-	-	-	-	2,1	3,0	5,1	3,4
M12	-	-	-	-	-	-	-	-	-	-	-	-	-	4,0	5,6
M13	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2,2
M14	-	-	-	-	-	-	-	-	-	-	-	-	-	-	2,1
M15	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

Figura 1. À esquerda, distâncias calculadas entre as máquinas por meio das distâncias de centro a centro das células e, à direita, por meio de suas posições exatas.

Para um caso hipotético com 15 máquinas e 4 células, considerando velocidades médias de deslocamento intracelular e intercelular de 1 e 1,3 metros por minuto, respectivamente, enquanto uma sequência de operações específica deve ser respeitada, o tempo de transporte total, utilizando as distâncias de centro a centro das células, equivale a 26,7

minutos. Porém, se utilizada a abordagem mais realista, com as distâncias das posições verdadeiras, esse resultado passa para 32,5 minutos. Um erro de aproximadamente 18%. O *layout* de tal fábrica fictícia é representado pela Fig. 2, onde os espaços em branco representam os corredores principais e o espaço em amarelo representa uma posição vaga na célula.

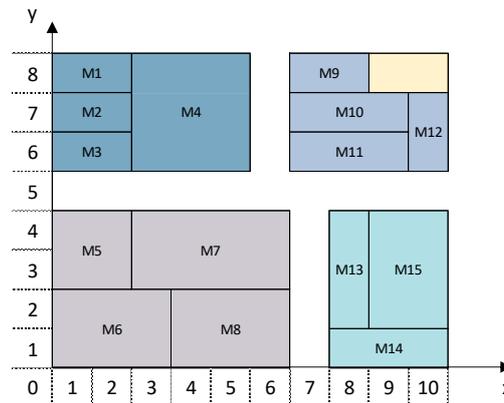


Figura 2. Layout de fábrica fictícia com suas respectivas máquinas e corredores.

Conforme indica o exemplo hipotético, utilizar as distâncias de centro a centro das células para o cálculo do custo de transporte de peças através da fábrica pode resultar em valores errôneos de tempo e, portanto, em um *layout* de máquinas inadequado. Portanto, a fim de aumentar o nível de precisão e de realismo do modelo, deve-se utilizar as posições precisas das máquinas para o cálculo dos tempos de transporte de peças.

Além disso, naturalmente, os custos de transporte intra e intercelular deveriam ser diferentes. Assim como Forghani *et al.* (2014) e Imran *et al.* (2016), muitos trabalhos sugerem que movimentações entre as células sejam pelo menos duas vezes mais custosas que as internas. No presente trabalho, no entanto, é defendido e recomendado que um estudo de processos seja realizado na fábrica em questão, haja vista que pode haver distinção a depender das características do negócio, e que esse múltiplo seja definido junto dos tomadores de decisão da organização.

Junto ao custo de transporte, o custo de operação também deve ser considerado, e, neste trabalho, é calculado através do tempo, relacionado especificamente às operações de máquinas, para a produção da demanda do período típico, multiplicado pelo custo médio de mão de obra de produção da fábrica. Para esse fim, segundo Desai *et al.* (2018), o tempo total de operação subdivide-se em: a) tempo de configuração (*setup time*), que é definido como o tempo necessário para preparar o equipamento para a operação e ocorre uma vez por lote; b) tempo de operação (*machining time*), o qual é definido como o tempo em que o processo é exercido; c) tempo de desmontagem (*teardown time*), o qual compreende o tempo para remover as ferramentas, gabaritos e acessórios utilizados no processo e d) tempo de parada (*downtime*), o qual se trata do tempo improdutivo resultante de vários fatores, como defeitos de máquina, falta de matéria-prima e falta do operador. Os principais e mais consideráveis são os dois primeiros, sendo que o tempo de configuração pode, inclusive, contemplar o tempo de desmontagem. Para o presente trabalho, apenas esses dois serão considerados, embora também seria possível considerar as outras subdivisões. O custo médio de mão de obra é então atribuído à soma dos tempos de operação e configuração para formar o custo total de operação.

Ambos os custos, tanto de transporte quanto de operação, são obtidos através dos tempos registrados para a produção da demanda de peças do período típico, decorrentes da SED. Além desses custos, são contemplados pelo método outros custos da planta fabril que podem ser relacionados aos equipamentos, e por isso recebem o nome, no presente trabalho, de “custos de equipamentos”.

São vários os métodos para distribuição dos custos em uma empresa de manufatura. Dentre eles, destaca-se a metodologia de alocação por máquina, que compreende a atribuição de custos específicos e realistas correspondentes a cada equipamento em particular. E, embora apresente algumas desvantagens, principalmente relacionadas à dificuldade no rateio de alguns gastos mais remotos à produção, concorda pontualmente com o objetivo deste trabalho, que é produzir uma composição e organização de máquinas para o *layout* que minimize a maior quantidade possível de custos relacionados, direta ou indiretamente, a esses itens. Além disso, mostra-se mais preciso do que outros mais triviais presentes na literatura (Domanski, 2020).

O procedimento metodológico para a distribuição de custos por equipamento deve considerar, ao menos, os custos de: a) energia elétrica; b) consumíveis, ou seja, insumos e suprimentos necessários para a operação do equipamento, como óleo, graxas e refrigerantes; c) manutenção; d) área ocupada; e) depreciação, ou seja, perda de valor de um ativo ao longo de sua vida útil, devido ao tempo de utilização, desgaste natural ou obsolescência; e f) custo de oportunidade, ou seja, a vantagem hipotética que fora sacrificada ao adotar uma alternativa (Desai *et al.*, 2018 e Potkány, 2019). Isso significa definir o custo da eletricidade, dos consumíveis, das manutenções e do aluguel para o espaço que a máquina está utilizando, além das taxas de depreciação e de custo de oportunidade condizentes.

Considerando que os custos de depreciação e de oportunidade são lançamentos contábeis, e, portanto, são custos não monetários, esses não serão considerados, neste trabalho, para equipamentos que a empresa já possui. No entanto,

serão contemplados para máquinas novas, no intuito de auxiliar no processo de decisão do modelo perante à relação custo-benefício do possível investimento.

Embora muitos trabalhos na literatura considerem os valores totais de compra e venda das máquinas no que compreende o custo de equipamentos, a totalidade de tais valores não será somada ou subtraída na função objetivo do modelo proposto neste trabalho. Isso porque, contabilmente, salvo possíveis rendimentos ou despesas como os mencionados anteriormente, o valor do ativo de uma empresa permanece o mesmo no momento em que um equipamento é comprado ou vendido, sendo tão somente alterada a natureza de tal ativo. Obviamente, caso a organização optasse por financiamentos bancários, novos custos periódicos poderiam ser envolvidos. Porém, são características particulares de cada caso, o que gera dificuldade e imprecisão para periodizar tais despesas. Portanto, apenas são consideradas as despesas e rendimentos intrínsecos a todos os cenários de compra ou venda de máquinas.

Por sua vez, quanto ao espaço, esse é um pré-requisito para a criação de uma nova planta fabril e, por isso, também deve ser considerado. Naturalmente, o custo do espaço que um equipamento irá usufruir dependerá da localização do imóvel, bem como de suas dimensões e possivelmente de outras características físicas.

Além disso, é importante apontar que o modelo permite identificar e eliminar máquinas excessivas, funcionalidade que se mostra valiosa, já que, sob certas circunstâncias, pode ser mais econômico ter movimentos entre células ao invés de máquinas extras (Mungwattana, 2000). Portanto, a relação de custo-benefício entre máquinas replicadas versus movimentos entre células deve ser analisada. Caso a eliminação de máquinas resulte em redução do custo total, assim será proposto pelo algoritmo.

2.1. Considerações

As seguintes considerações são necessárias para o modelo apresentado no presente trabalho:

1. O tempo de movimentação de peças de uma máquina para a outra é composto pelo tempo de movimentação da máquina anterior para a atual (se for a primeira operação da sequência, o estágio anterior é o inventário), somado ao tempo de *setup* da máquina e ao de operação da peça.
2. A demanda de cada produto e, conseqüentemente, de cada peça, é dada por listas de ordens de produção fornecidas pela base estatística.
3. Os tempos de operação e de *setup* para cada peça em diferentes máquinas são conhecidos.
4. Cada peça possui uma sequência de operações predeterminada que deve ser respeitada.
5. O número e tamanho das células deve ser especificado, assim como sua geometria no *layout* da fábrica virtual (posições destinadas a cada célula).
6. Cada tipo de máquina pode performar uma ou mais operações, possivelmente com diferentes tempos de operação envolvidos.
7. O número de posições disponíveis na fábrica é conhecido.
8. A duplicação e remoção de máquinas é permitida.
9. A capacidade das máquinas é limitada.
10. As dimensões da fábrica e das máquinas são conhecidas.
11. As máquinas são arranjadas nas posições candidatas das células no plano cartesiano que representa a fábrica virtual.
12. A distância entre máquinas (norma Euclidiana) é calculada com base em suas posições exatas, desconsiderando os trajetos de corredores.

2.2. Notação utilizada

As seguintes notações são utilizadas para a formulação do problema:

Índices

- c = Índice para células de manufatura, $c = 1, \dots, C$ (onde C corresponde ao número total de células).
 m = Índice para tipos de máquina, $m = 1, \dots, M$ (onde M corresponde ao número total de máquinas).
 p = Índice para tipos de peça, $p = 1, \dots, P$ (onde P corresponde ao número total de peças).
 j = Índice para operações necessárias para a peça p , $j = 1, \dots, Op$ (onde Op corresponde ao número total de operações).
 v = Índice para versões de cada tipo de máquina utilizadas no *layout*, $v = 1, \dots, V$ (Onde V corresponde ao número total de versões possíveis para cada máquina).
 l = Índice para posições na fábrica, $l = 1, \dots, L$ (Onde L corresponde ao número total de posições possíveis na fábrica).

Parâmetros

- t_{jpm} = Tempo necessário para a operação j da peça p na máquina do tipo m , em segundos.
 tS_{jpm} = Tempo necessário para o *setup* da máquina m ao performar a operação j da peça p , em segundos.
 tO_m = Tempo operacional de cada máquina m durante a simulação, em segundos.

LB_c	=	Número mínimo de máquinas na célula c .
UB_c	=	Número máximo de máquinas na célula c .
X_{c_l}	=	Posição “x” do centroide para cada posição l .
Y_{c_l}	=	Posição “y” do centroide para cada posição l .
re	=	Valor médio de aluguel mensal, em R\$.
a_{jpm}	=	1, se a operação j da peça p pode ser realizada pela máquina m .
D_p	=	Demanda total do período típico para a peça p .
$Tsim$	=	Tempo total para a produção das ordens do período típico fornecido pelo procedimento de SED, em segundos.
Va_m	=	Valor de compra de cada tipo de máquina m no mercado, em R\$.
β	=	Custo médio de mão de obra da fábrica por hora, em R\$.
P_m	=	Potência para cada tipo de máquina m , em kW.
U	=	Custo de eletricidade por kWh, em R\$.
M_m	=	Custo de manutenção ao longo do período para cada máquina m , em R\$.
C_m	=	Custo de consumíveis ao longo do período para cada máquina m , em R\$.
A_m	=	Área ocupada pela máquina do tipo m , em m ² .
α	=	Custo do m ² ocupado na fábrica ao longo do período, em R\$.
P_{lvm}	=	1, se a posição l for ocupada pela máquina de versão v , do tipo m ; senão, 0.
DU_{mv-1}	=	1, se o tipo de máquina m apresenta $v-1$ versões extras; senão, 0.
r_m	=	Taxa de depreciação anual da máquina do tipo m .
n_m	=	Vida útil estimada da máquina de tipo m , em anos.
r	=	Taxa de juros básica.
S_m	=	Máquinas as quais o algoritmo sugeriu vender, pois se tornaram desnecessárias.
T_m	=	Capacidade de cada máquina do tipo m , em horas.
d	=	Distância entre os centroides das posições l e l' , em metros.
N_{mc}	=	Número de versões do tipo de máquina m por célula c .
Fic	=	Múltiplo que determina a diferença de custo entre movimentos intra e intercelulares. Também chamado de fator intercelular.
Or	=	Número de identificação da ordem de produção.
Vm	=	Velocidade média de deslocamento de materiais na fábrica, dada em m/s.

2.3. Modelo matemático

Minimizar:

$$Z = Tsim \beta + \sum_{m=1}^M \sum_{l=1}^L \sum_{v=1}^V \left\{ (P_m t_{o_m} U + M_m + C_m + A_m \alpha) P_{lvm} + DU_{mv-1} \left[\frac{Va_m - Va_m (1 - r_m)^{n_m}}{n_m} + Va_m r \right] - S_m Va_m r \right\} \quad (2)$$

Sujeito à:

$$\sum_{l=1}^L P_{lvm} = 1 \quad \forall v, m \quad (3)$$

$$\sum_{m=1}^M DU_{mv-1} \leq V - 1 \quad \forall v \quad (4)$$

$$\sum_{c=1}^C \sum_{l=UB_{c-1}}^{UB_{c-1}+UB_c} P_{lvm} \leq UB_c \quad \forall v, m \quad (5)$$

$$\sum_{c=1}^C \sum_{l=UB_{c-1}}^{UB_{c-1}+UB_c} P_{lvm} \geq LB_c \quad \forall v, m \quad (6)$$

A função objetivo dada pela Eq. (2) minimiza o custo total de produção do período típico. O primeiro termo se refere ao custo de operação, *setup* e transporte de materiais dentro da fábrica, cujos tempos são obtidos através da SED, haja vista que são necessários para a produção dos produtos contidos na base estatística referente ao período selecionado. O segundo representa o custo de equipamentos, em que são considerados como componentes os custos de energia elétrica,

manutenção, consumíveis, área ocupada, depreciação e custo de oportunidade, respectivamente. Além disso, é subtraído o rendimento com a eventual venda de máquinas desnecessárias sugerida pelo modelo, compreendendo a apreciação do valor obtido perante uma taxa média de juros. Caso não seja do interesse do gestor considerar a apreciação do valor das máquinas vendidas, assim como a depreciação e o custo de oportunidade relacionados às remanescentes, as taxas de juros devem ser zeradas. Conforme mencionado anteriormente, caso, devido à natureza do negócio, seja desejável criar assimetria proposital entre os custos, pesos multiplicadores podem ser adicionados aos termos.

A restrição dada pela Eq. (3) garante que apenas uma máquina ocupe cada uma das posições da fábrica. A Eq. (4) garante que não sejam geradas mais versões das máquinas de tipo m do que o permitido, ou seja, V . As Eqs. (5) e (6) são condições de contorno que asseguram que os limites superior e inferior do número de máquinas por célula sejam respeitados.

3. DESENVOLVENDO UM ALGORITMO GENÉTICO PARA O PROBLEMA PROPOSTO

Conforme abordado anteriormente, devido à complexidade do problema em questão, o uso de métodos meta-heurísticos, como o AG, torna-se necessário. Nesta seção, o conceito, a estrutura e outras características do AG desenvolvido para resolver o modelo proposto são abordadas.

3.1. Algoritmo genético

O algoritmo genético foi desenvolvido inicialmente por Holland (1975), consistindo em uma técnica adaptativa e estocástica para otimização e busca de soluções em um domínio específico. Esse método emprega princípios dos mecanismos evolucionários da seleção natural e genética apresentados na teoria de Charles Darwin, e tem aplicação em diferentes áreas, como biologia, economia, matemática e engenharia (Goldberg, D., 1989).

O método funciona por meio da disputa gerada entre um grupo de soluções, chamado de população. Os mecanismos de seleção e elitismo permitem que as melhores soluções da população original sejam selecionadas, e os operadores genéticos de reprodução, como o cruzamento e mutação, permitem a produção de novas e melhores populações, ou seja, conjuntos de soluções com valores de aptidão maiores que os anteriores, avaliados por critérios compreendidos pela chamada função objetivo, função custo, ou função de aptidão. Apenas as soluções de melhor qualidade tenderão a permanecer na população, enquanto as demais poderão ser penalizadas ou eliminadas, retratando o conceito “*survival of the fittest*”, conforme apresentado por Herbert Spencer (1864). Essa evolução prossegue até o critério de parada ser atendido e, embora não garanta soluções ótimas propriamente ditas, permite a descoberta de soluções de qualidade elevada de maneira inteligente e em um período de tempo relativamente curto, se comparado com outras heurísticas. O passo a passo do procedimento utilizado neste trabalho é ilustrado pelo diagrama da Fig. 3.

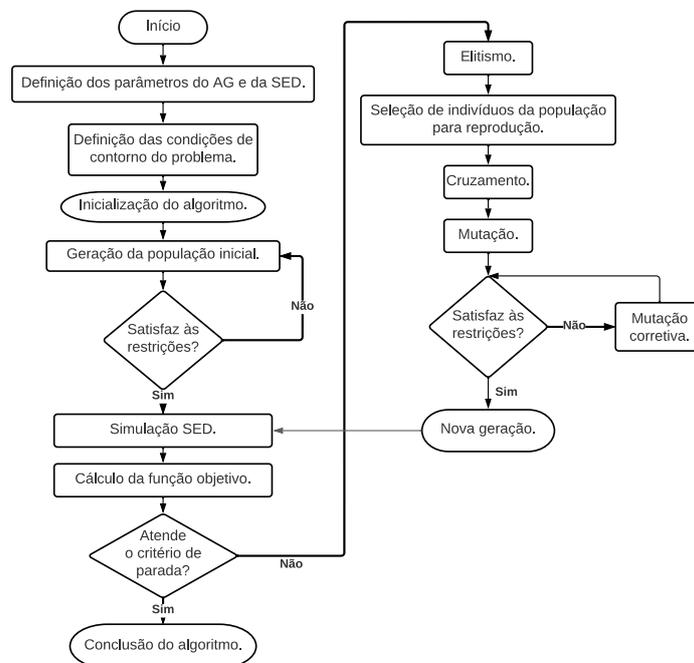


Figura 3. Diagrama ilustrando o passo a passo do AG proposto.

Nesse contexto, tendo em vista que o AG busca reproduzir os mecanismos da seleção natural, cada solução contida na população é tomada como um cromossomo, também chamado de indivíduo. Os compartimentos que contêm as informações de cada cromossomo são denominados genes, e o valor de cada um desses genes recebe o nome de alelo.

3.2. Estrutura cromossômica multisseção

Para a resolução da problemática apresentada na seção anterior, faz-se necessário estabelecer uma sistemática para representar numérica e matematicamente cada possível solução. Tavakoli *et al.* (2007) propôs um sistema composto por duas matrizes, $[X]_{jp}$ e $[Y]_m$, as quais representam a alocação de operações para as máquinas e para as células, respectivamente. No presente trabalho, três matrizes, $[X]_{jp}$, $[Y]_m$ e $[Z]_l$, são utilizadas para representar uma solução, conforme mostra a Fig. 4. A matriz $[X]$ representa a alocação de operações para as máquinas; $[Y]$, a quantidade de máquinas de cada tipo; e $[Z]$, a alocação de máquinas para cada posição.

$$\left[\begin{array}{cccc} X_{1,1} & X_{1,2} & \dots & X_{1,p} \\ \dots & \dots & \dots & \dots \\ X_{j,1} & X_{j,2} & \dots & X_{j,p} \end{array} \right] \left\| \begin{array}{cccc} Y_1 & Y_2 & \dots & Y_m \end{array} \right\| \left[\begin{array}{cccc} Z_1 & Z_2 & \dots & Z_l \end{array} \right] = [X]_{jp} [Y]_m [Z]_l$$

Figura 4. Estrutura cromossômica.

Isto é, $[X]_{jp}$ é a máquina em que a operação j da peça p deve ser realizada, $[Y]_m$ é a quantidade de máquinas de cada tipo m , onde $0 \leq y_m \leq V$, e, finalmente, $[Z]_l$ é a máquina destinada para cada posição l na fábrica. É importante mencionar que, para a seção $[X]_{jp}$, é possível que duas ou mais máquinas sejam selecionadas para uma mesma operação, desde que essas sejam do mesmo tipo m . Em tal circunstância, a quantidade de peças a ser produzida será dividida proporcionalmente entre essas máquinas durante a simulação.

Outro aspecto notável desta estrutura cromossômica, dividida em seções, é o fato dela permitir, ao modelador, customizar o mecanismo de otimização. Ou seja, caso a organização em questão possua cenários de demanda extremamente dinâmicos ou não possua padrão definido de sazonalidade, um procedimento recomendado seria otimizar a totalidade da estrutura cromossômica utilizando uma base estatística, e, periodicamente, otimizar o roteamento das peças (seção $[X]$) enquanto as partições $[Y]$ e $[Z]$ são mantidas fixas. Desta forma, a fábrica poderia gradativamente se adaptar à dinamicidade de demanda sem ter de reorganizar seu *layout* com frequência, realizando as próximas otimizações totais da estrutura somente no decorrer de períodos mais longos.

Para ilustrar cada seção da estrutura cromossômica, um exemplo hipotético foi empregado, conforme indica a Fig. 5. Dado que a replicação de máquinas é permitida através da metodologia apresentada, torna-se necessária também a identificação de cada máquina por sua respectiva versão nas partições $[X]$ e $[Z]$.

Na seção $[Z]$ também é possível observar três cores distinguindo as posições entre três células de manufatura diferentes, haja vista que, conforme apresentado na consideração nº 7 da seção anterior, a quantidade, tamanho e geometria das células deve ser definida *a priori*.

	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11
OP1	1a	10a	10a	9a	3a	0	3a	5a	1a	1a	9a
OP2	8a	8a	4a	2a	4a	0	3a	4a	2b	5a	8a
OP3	0	2b	1a	10a	1a	0	0	0	2a	6a	2a
OP4	0	7a	0	0	6a	0	0	0	3a	0	0

M1	M2	M3	M4	M5	M6	M7	M8	M9	M10
1	2	1	1	1	1	1	1	1	1

6a	2b	10a	7a
2a	4a	9a	1a
5a	8a	3a	0

Figura 5. Representação gráfica das seções $[X]_{jp}$, $[Y]_m$ e $[Z]_l$.

Evidentemente, considerando a diferença de dimensões entre as matrizes, é necessário que as três sejam convertidas em um vetor linear, formando um cromossomo linear formado por g genes, em que $g = J \cdot P + M + L$, o qual contempla as informações das três seções.

Ademais, embora em algoritmos genéticos tradicionais as dimensões dos cromossomos sejam definidas *a priori* e mantidas posteriormente e, como consequência, o tamanho do cromossomo não seja alterado durante a evolução das gerações do algoritmo (Kim, I. *et al.*, 2004), no presente trabalho, no entanto, uma abordagem para permitir a flexibilidade nas dimensões dos cromossomos é utilizada para suas seções. Trata-se da técnica de “bits fictícios” (Gan *et al.*, 2016), ou seja, genes do cromossomo que recebem o numeral “0” para indicar a ausência de máquinas nos respectivos postos fabris, por exemplo. Neste caso, no entanto, dado que L é o limite superior da quantidade de posições definida pelo modelador, haverá, no momento de partida, um número limitado de posições vagas na fábrica.

3.3. Gerando a população inicial

Conforme apresentado pelo diagrama da Fig. 3, a geração de uma população inicial é o ponto de partida do processo evolucionário. Tal tarefa é executada ao formar as matrizes $[X]_{jp}$ e $[Z]_l$ de maneira aleatória, porém respeitando as restrições do problema. Ou seja, para a seção $[X]$, as operações de cada peça são atribuídas às máquinas escolhendo-

as aleatoriamente dentre as opções disponíveis e indicadas pela matriz a_{jpm} . Para a seção [Z], as máquinas são atribuídas de maneira aleatória às posições disponíveis. E, finalmente, para fins de simplificação, a seção [Y] começa com a quantidade de cada tipo de máquina disponível da fábrica real atual.

Para a realização do estudo de caso do presente trabalho, uma população de 10 indivíduos/cromossomos é utilizada. Tal escolha foi realizada com base em outros trabalhos da literatura, embora o modelo permita a definição de maiores ou menores populações, a depender das exigências do problema abordado e da capacidade computacional disponível.

3.4. Avaliação da aptidão

No presente trabalho, o cálculo da aptidão é realizado através de uma função objetivo, conforme apresentado na subseção 2.3. No entanto, a avaliação de cada solução candidata de uma geração é realizada conjuntamente com o auxílio da SED, a qual reproduz o funcionamento de um sistema como uma sequência de eventos discretos no tempo. Em outras palavras, uma fábrica virtual é criada, e o tempo é consumido pelas operações e distâncias percorridas necessárias para a manufatura dos produtos demandados pelas ordens da base estatística do período selecionado, dada uma velocidade média de deslocamento (V_m). Um diagrama indicando o funcionamento do método é apresentado pela Fig. 6.

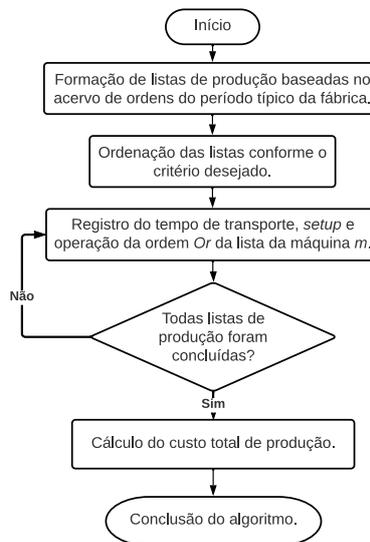


Figura 6. Fluxograma do procedimento da SED.

Para que a simulação seja realizada, é preciso, primeiramente, formar a matriz tridimensional que atuará como base de teste e comandará a ordem em que os eventos discretos ocorrerão no tempo. Tal matriz contém as listas de ordens de produção do período para cada máquina, e é formada a partir dos dados históricos da fábrica em questão. Uma representação visual desta matriz tridimensional é apresentada pela Fig. 7.

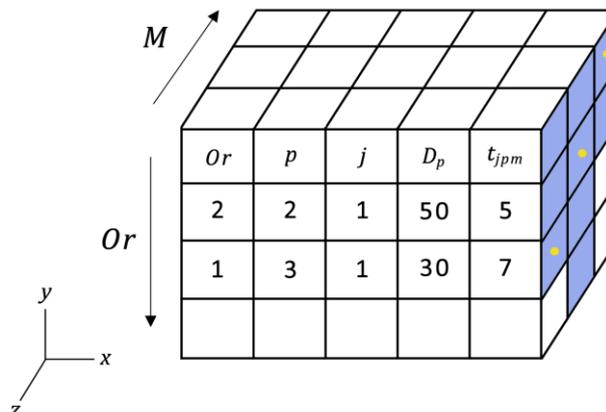


Figura 7. Matriz tridimensional de listas de produção.

Conforme é possível observar na Fig. 7, as colunas (eixo 'x') contêm as seguintes informações: número de identificação da ordem Or , peça p , operação j , demanda D_p e tempo para a operação em segundos t_{jpm} . Ao longo do

eixo 'y', cada linha contém uma ordem e suas informações, as quais compõem a lista de produção de cada máquina, além de representar a posição atual na fila, haja vista que, para cada máquina, representadas ao longo do eixo 'z', é possível ter listas de comprimentos diferentes, conforme indicado pelos espaços preenchidos em azul e, além disso, suas posições atuais no tempo também podem ser diferentes, conforme indicado pelos marcadores amarelos.

Ademais, uma posição somente pode ser assumida caso a operação anterior da peça já tenha sido realizada e a máquina a ser utilizada esteja livre para iniciar uma nova operação. Caso uma dessas condições não for satisfeita, a linha seguinte será analisada, e assim sucessivamente, até encontrar uma ordem que possa ser executada ou até atingir o fim da lista. Além dessa análise, é preciso verificar se os movimentos realizados são intra ou intercelulares. Para tal fim, uma verificação das células a que as máquinas pertencem é realizada, e, no caso de movimentos intercelulares, o tempo registrado recebe o produto do fator intercelular, *Fic*.

Na ilustração acima, o ordenamento das linhas ao longo do eixo 'y' foi feito a partir da demanda, abordagem em que as ordens com maior quantidade de peças deverão ser executadas por primeiro, e por isso ocupam o topo da lista. A escolha do critério para ordenar as listas deve ser feita pelo tomador de decisão, dadas as características de negócio e prioridades da organização em questão. Pode ser escolhido, como tal critério, uma das seguintes opções: a) demanda; b) número da ordem de produção e c) data da ordem de produção (a qual pode ser atribuída à mesma coluna *Or*).

Desta forma, a simulação somente acaba quando todas listas de produção forem finalizadas e seus marcadores já tenham passado por suas respectivas últimas posições. Neste momento, todas máquinas encontram-se desocupadas, e, portanto, a produção da base de teste de demanda do período fora finalizada. O tempo é registrado e é tido como tempo total de produção, T_{sim} .

Tal integração das técnicas de AG com SED é tida como adequada para otimizar a *performance* de sistemas cujo estado sofre alterações em função do tempo, além de oferecer melhores resultados quando comparada a outros métodos de integração (Imran, M. *et al.*, 2016).

3.5. Formação da base estatística

Conforme mencionado anteriormente, indústrias de manufatura enfrentam ambientes de produção dinâmicos e estocásticos. No entanto, é possível, por meio da estatística, obter um cenário de requisitos de produção, a fim de tornar o ambiente de testes determinístico (Jayakumar, V. *et al.* 2011).

Naturalmente, a organização do *layout* e do roteamento de processos é função da demanda de peças, e, portanto, esta deve ser a mais realista possível, afinal, diferentes cenários de demanda implicarão na descoberta de diferentes configurações de *layout* e roteamento tidos como ótimos pelo algoritmo de otimização. Nesse sentido, uma estratégia de projeto robusta consiste em buscar um sistema de fabricação que seja bom em relação a todo horizonte de planejamento, mesmo que não seja ótimo para os períodos isolados (Mungwattana, A., 2000).

A partir dos dados históricos de demanda, valores médios podem ser obtidos para a formação de uma base estatística para a realização de testes de simulação (Lam, J. *et al.*, 1996). Já a partir da chamada suposição de continuidade, premissa de que o futuro será ao menos semelhante ao passado próximo, é possível também realizar uma previsão quantitativa, tomando em conta não apenas valores médios dos dados, mas também as tendências existentes nas séries temporais, através de métodos que são apropriados justamente para prever valores futuros e fornecer uma base para a otimização de processos industriais (Box, G. *et al.* 1994; Makridakis, S. *et al.*, 1997 e Godwin, G. *et al.*, 2021).

São vários os métodos preditivos que podem ser empregados para prever a demanda, desde abordagens mais simples, como médias móveis aritméticas, às mais complexas, como redes neurais artificiais (Makridakis, S. *et al.*, 1997; Godwin, G. *et al.*, 2021). No entanto, esse não é o foco do presente estudo, e, embora formulações sofisticadas e elaboradas possam elevar o grau de realismo, muitas vezes não melhoram a precisão, e, além disso, a simplicidade é especialmente importante quando existem poucos dados históricos disponíveis para o treinamento (Armstrong, J., 2001). Dito isso, a técnica empregada no estudo de caso é a regressão linear simples, um algoritmo amplamente utilizado na área de *Machine Learning* e que permite obter resultados satisfatórios (Gopalakrishnan, T. *et al.*, 2018; Godwin, G. *et al.*, 2021). Gopalakrishnan (2018) aplicou a técnica de regressão linear para prever vendas de um ano, a partir de três anos de dados históricos, e constatou uma taxa de precisão de mais de 80%, um nível considerado elevado.

3.6. Seleção

Uma vez obtidos os valores de aptidão de cada cromossomo de uma população, a seleção deve ser aplicada. Seu objetivo é direcionar os melhores indivíduos para as operações genéticas subsequentes, as quais formarão novas gerações.

Enquanto uma porção dos indivíduos mais aptos sempre é diretamente indicada para as próximas gerações, devido ao elitismo, o restante pode ou não ser selecionado. Essa abordagem busca, primeiramente, garantir que a melhor solução de cada geração não seja perdida, e que as particularidades desse indivíduo sejam transmitidas à próxima geração (Ahn, C. *et al.*, 2003 e Reed, P. *et al.*, 2004). E, para os indivíduos remanescentes, a técnica de *roulette wheel* é utilizada (Arora, 2004), a qual permite que os mais aptos tenham maior chance de serem considerados para a reprodução e formação da nova geração. No entanto, embora tais indivíduos tenham maior chance, trata-se de um processo estocástico e, portanto, qualquer dos indivíduos da população pode ser selecionado.

No presente trabalho, uma taxa de elitismo de 20% é aplicada para todas gerações, valor comumente encontrado na literatura, conforme Imran, M. *et al.* (2016). Isso significa dizer que, para cada geração, uma elite é formada nessa

proporção e é direcionada à próxima, sem sofrer interferência de operadores genéticos, como o cruzamento e a mutação. Em seguida, a seleção é realizada para toda população, conforme descrito anteriormente.

3.7. Operadores de cruzamento

O cruzamento é definido como um mecanismo evolucionário que busca combinar diferentes indivíduos, mesclando seus genes, no intuito de formar novas soluções descendentes para as próximas gerações do algoritmo. No presente trabalho, a técnica de *one point crossover* é aplicada, através da qual uma posição do cromossomo é aleatoriamente determinada, e, assim, marca o ponto onde duas soluções genitoras são particionadas. As quatro partes resultantes do processo são então cruzadas para produzir dois filhos, os quais integrarão a nova população. Além disso, devido ao enorme domínio do estudo de caso que será apresentado na próxima seção, no presente trabalho, uma taxa de probabilidade de cruzamento de 90% é aplicada, valor máximo da faixa compatível (Reed, P. *et al.*, 2004), no intuito de produzir a maior quantidade de soluções utilizando tamanho de população e número de gerações máximo razoavelmente pequenos.

Embora sua contribuição seja desejável para todas as seções do cromossomo, neste trabalho, o operador de cruzamento não será aplicado para a seção [Y]. Isso porque se entende que a aplicação do operador para essa seção em questão implicará, na maioria das ocasiões, soluções inviáveis, em desconformidade com as restrições, e, portanto, a necessidade de alterações corretivas que acarretarão um maior custo computacional.

Para a seção [Z], no entanto, uma função corretiva é aplicada para reabilitar as soluções inviáveis. Como exemplo de solução inadequada, pode-se citar um cromossomo com uma configuração que indique uma mesma máquina para mais de uma posição da fábrica, o que não é possível, gerando a necessidade de retificação.

3.8. Operadores de mutação

Quanto à mutação, sob outra perspectiva, trata-se de um mecanismo com objetivo de introduzir variação, diversidade e inovação na população, e garantir a possibilidade de se atingir qualquer ponto no espaço de soluções, permitindo ao algoritmo explorar novas regiões no domínio viável e assim contornando o problema de convergência prematura em mínimos locais (Arora, 2004). Analogamente ao campo da biologia, em que é definida como uma mudança no DNA que pode ser benéfica ou não para o organismo (Strachan, T. *et al.*, 2015), a mutação aqui abordada resume-se em aplicar alterações anômalas nas variáveis de projeto no intuito de encontrar uma solução distinta, aprimorada e previamente desconhecida.

A mutação da seção [X] é considerada válida apenas quando múltiplas máquinas podem realizar a referida operação (Tavakkoli-Moghadam *et al.*, 2007). Portanto, a maior parte dos movimentos normalmente serão executados nas seções [Y] e [Z], devido à existência de um maior número de permutações possíveis.

Já para a seção [Y], a mutação é aplicada ao adicionar ou remover máquinas do tipo m com o auxílio dos fatores de demanda de máquinas e de células, os quais são apresentados abaixo como Eqs. (11) e (12), respectivamente. O primeiro, F_m , atua como indicador de quanto cada tipo de máquina m está sendo demandada considerando todo *layout*. E o segundo, F_{cm} , como indicador de quanto cada tipo de máquina m está sendo demandada em uma célula c .

$$F_m = \sum_{l=1}^L \frac{D_p t_{o_{jpm}}}{T_m Y_m} \quad (11)$$

$$F_{cm} = \sum_{c=1}^C \sum_{m=1}^M \sum_{l=1}^L \frac{D_p t_{o_{jpm}}}{T_m N_{mc}} \quad (12)$$

Portanto, caso seja selecionada a adição de máquina, seu tipo m deve ser escolhido com base em sua demanda. Em outras palavras, os tipos de máquinas que possuírem maior fator de demanda, F_m , possuirão maior chance de serem selecionados para a aquisição de uma nova unidade. Naturalmente, a adição de máquinas somente será possível caso houver posições disponíveis na fábrica. E, caso haja múltiplas posições disponíveis, em diferentes células, a questão que surge é: em qual das posições, ou seja, em qual das células a nova versão da máquina de tipo m deve ser adicionada? Logicamente, a célula que deve receber a nova máquina é a que mais a necessita, no intuito de reduzir a quantidade de movimentos intercelulares. Portanto, a célula com maior fator de demanda celular do tipo m , F_{cm} , possuirá maior chance de receber a nova máquina.

Para a remoção de máquinas, o menor fator de demanda deve implicar maior chance de eliminação, e tal alteração será possível somente se existirem, na fábrica, múltiplas unidades do tipo de máquina selecionado ou se a demanda para ele for igual a zero. Aliás, se a demanda para um tipo de máquina for nula, suas unidades serão retiradas do *layout* imediatamente. E, caso existam múltiplas versões da máquina de tipo m em diferentes células, a que será eliminada deverá ser, preferencialmente, a que está na célula com menor fator de demanda celular.

E, finalmente, para a seção [Z], a mutação é realizada a partir da inversão de máquinas entre duas posições aleatoriamente selecionadas (Forghani, K. *et al.*, 2014).

Uma taxa de probabilidade de 20% é utilizada para as mutações descritas acima no presente estudo de caso (Imran, M. *et al.*, 2016), a qual está acima da média da bibliografia analisada. No entanto, novamente, dadas as dimensões do domínio de soluções, uma alta taxa de probabilidade de mutação se torna conveniente para permitir que uma maior quantidade de regiões do domínio seja explorada.

3.9. Critério de parada

O número máximo de gerações é utilizado como critério de parada, e, portanto, o algoritmo cessará sua execução quando o número de gerações exceder esse limite (Jayakumar, V. *et al.*, 2010). No presente trabalho, o algoritmo é executado por um número máximo de 100 gerações. Tal valor foi definido buscando bons níveis de otimização e performance. Além disso, conforme será apresentado na seção de resultados, foi observado que evolução da convergência do indivíduo com melhor aptidão (melhor valor da função objetivo) se estabiliza e apresenta comportamento assintótico quando próximo a esse número de gerações.

4. ESTUDO DE CASO EM UMA INDÚSTRIA MOVELEIRA

Nesta seção, um estudo de caso é abordado para apresentar a aplicabilidade do modelo proposto. Trata-se de uma indústria do ramo moveleiro, situada no sul do Brasil, que possui 98 produtos no mercado, compostos por 68 tipos de peças. Seus dados históricos de produção, dos anos de 2019 a 2021, foram coletados e utilizados para constituir séries temporais de demanda para cada produto, e, conseqüentemente, para cada peça. A Fig. 8 exemplifica a aplicação do modelo de regressão linear para a quantidade vendida do produto 43 ao longo dos trimestres, de 2019 a 2021.

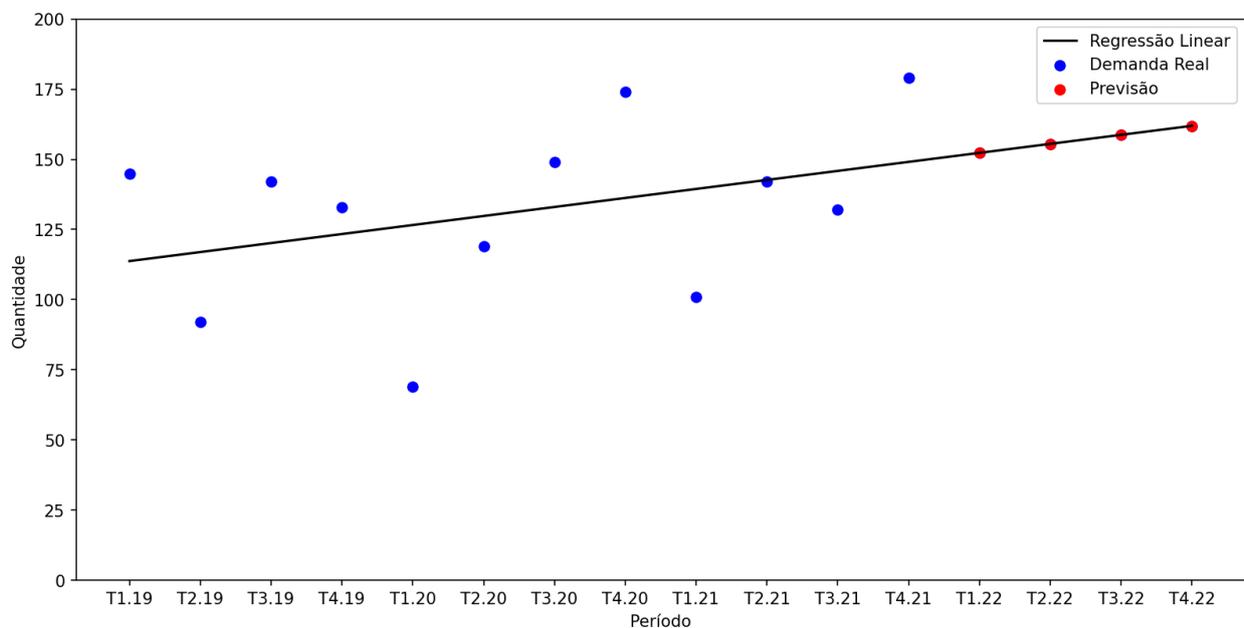


Figura 8. Regressão linear aplicada à série histórica de demanda do produto “43” por trimestre (T).

A partir das previsões realizadas pelo método, foi possível obter os trimestres de demanda que atuarão como base de teste da simulação. Para o presente estudo de caso, no entanto, apenas o primeiro trimestre foi utilizado como base de teste, para fins de economia de custo computacional. Portanto, todos os dados e variáveis de caráter anual obtidos para o emprego do modelo foram transformados em trimestrais, mantidas as suas devidas proporções. O conjunto de dados referente à demanda total resultante para cada tipo de peça é representado pela Tab. 1.

Os setores da fábrica a serem otimizados são os de corte e usinagem, que compreendem uma área de 112 x 30 metros. Tais dimensões compõem um plano retangular, que é a fábrica virtual do modelo e atua como domínio de soluções para a terceira seção dos cromossomos, a qual se refere às posições da fábrica. 70 posições possíveis foram consideradas para a aplicação do método, e sobre essas, 12 células foram delimitadas, conforme demonstrado pela Tab. 2.

Além disso, a empresa possui, atualmente, 66 máquinas para a manufatura de seus produtos, as quais puderam ser classificadas em 42 categorias de máquinas diferentes. Tais equipamentos consistem em serras, fresadoras, furadeiras, lixadeiras, prensas e laminadoras. Seus atributos são representados pela Tab. 3. Além disso, os tempos de *setup* para cada máquina, peça e operação não puderam ser obtidos, e, portanto, para a presente aplicação, também foram considerados nulos.

A capacidade de cada máquina foi definida considerando uma jornada de trabalho de 8 horas diárias, e, embora tenha sido feito dessa maneira devido às características da fábrica em questão, seria possível, caso se julgasse apropriado, considerar maiores capacidades para máquinas específicas, a fim de avaliar a viabilidade de um turno extra de trabalho.

Tabela 1. Demanda por tipo de peça p .

Peça, p	Demanda, D_p	Peça, p	Demanda, D_p	Peça, p	Demanda, D_p
1	396	24	20	47	44
2	422	25	20	48	37
3	128	26	20	49	56
4	716	27	161	50	57
5	344	28	80	51	57
6	2114	29	72	52	86
7	2617	30	218	53	5262
8	1460	31	1445	54	242
9	412	32	371	55	2581
10	2752	33	890	56	139
11	4128	34	985	57	56
12	698	35	79	58	5050
13	764	36	328	59	39826
14	52600	37	303	60	1088
15	881	38	733	61	2745
16	395	39	361	62	8024
17	1471	40	29	63	50
18	274	41	29	64	2891
19	150	42	26	65	153
20	90	43	23	66	155
21	99	44	29	67	76
22	172	45	20	68	460
23	382	46	44		

Tabela 2. Disposição de L posições no *layout* da fábrica.

Posição, l	Célula, c	X_{Cl}	Y_{Cl}	Posição, l	Célula, c	X_{Cl}	Y_{Cl}	Posição, l	Célula, c	X_{Cl}	Y_{Cl}	Posição, l	Célula, c	X_{Cl}	Y_{Cl}
1	1	25,0	23,8	19	4	33,7	27,6	37	7	60,7	19,5	55	10	69,9	25,1
2	1	16,3	12,6	20	4	40,0	22,9	38	7	63,5	19,6	56	10	72,2	23,2
3	1	14,2	15,4	21	4	41,0	29,0	39	8	49,7	24,3	57	10	72,2	28,4
4	1	11,5	22,6	22	4	35,6	29,0	40	8	53,5	18,9	58	10	77,0	23,5
5	1	17,4	18,4	23	4	40,7	17,3	41	8	46,0	26,8	59	10	73,5	17,4
6	1	21,0	17,2	24	4	39,5	12,0	42	8	49,5	29,0	60	11	76,7	7,4
7	1	22,0	13,6	25	5	33,4	1,4	43	8	50,6	19,1	61	11	85,2	7,7
8	1	2,3	24,0	26	5	38,3	6,5	44	8	46,6	20,3	62	11	78,2	10,5
9	2	29,0	18,5	27	5	44,3	1,0	45	8	46,6	17,1	63	11	80,0	6,3
10	2	30,3	13,6	28	5	48,9	1,2	46	8	53,4	13,6	64	11	77,7	0,5
11	2	29,3	10,6	29	5	35,5	2,0	47	8	49,7	17,9	65	11	74,2	3,7
12	3	7,2	1,5	30	6	46,6	9,7	48	9	69,2	5,0	66	12	105,0	16,5
13	3	20,9	1,1	31	6	52,0	5,3	49	9	68,7	12,6	67	12	109,8	20,2
14	3	9,5	4,9	32	6	54,7	2,0	50	9	62,1	11,7	68	12	111,5	18,0
15	3	14,9	4,1	33	6	56,2	2,0	51	9	62,4	4,6	69	12	89,5	29,0
16	3	27,6	5,6	34	6	48,7	7,5	52	9	70,3	9,9	70	12	97,9	20,4
17	3	21,7	4,6	35	6	53,8	7,3	53	10	76,5	16,4				
18	4	35,6	19,3	36	7	59,0	25,4	54	10	70,5	17,4				

No presente trabalho, o ordenamento das linhas ao longo do eixo ‘y’ das listas de produção da base estatística foi feito a partir da demanda, ou seja, as ordens com maior quantidade de peças ocupam o topo das listas, e por isso deverão ser executadas por primeiro, considerando que as condições necessárias citadas sejam satisfeitas, naturalmente. Tal critério foi adotado para fins de simplicidade e devido à característica da empresa de possuir, normalmente, uma lista extensa de ordens em cada equipamento.

A taxa de 11,45% ao ano, valor médio da taxa básica de juros da economia brasileira, Taxa Selic, dos últimos 20 anos, foi adotado como taxa básica livre de risco para o emprego do modelo (BCB, 2022). Já para a taxa de depreciação e vida útil dos equipamentos, foram utilizados os valores 10% e 10 anos, os quais constam no Anexo I da Instrução Normativa SRF N° 162, documento que indica as taxas de depreciação da Receita Federal, sob o código NCM 8465 (RFB, 1998).

Quanto aos valores em R\$/kWh e R\$/m² de aluguel, por sua vez, esses foram obtidos através de pesquisa realizada na empresa em questão e no mercado imobiliário regional, respectivamente.

Tabela 3. Atributos de cada tipo de máquina m .

Tipo de máquina, m	Valor nominal (R\$), Va_m	Potência (kWh), P_m	Custo de consumíveis (R\$/ano), C_m	Custo de manutenção (R\$/ano), M_m	Área ocupada (m ²), A_m	Tempo de <i>setup</i> , ts_{jpm}	Capacidade (h/ano), T_m
M1	*	4,44	-	-	15	-	2000
M2	*	4,6	-	-	8	-	2000
M3	*	2,46	108,00	-	6	-	2000
M4	*	3,88	-	-	16	-	2000
M5	*	16,28	180,00	-	20	-	2000
M6	*	42,9	288,00	3168,75	20	-	2000
M7	*	22,2	252,00	3168,75	11,22	-	2000
M8	*	13,32	180,00	-	6,4	-	2000
M9	*	2,59	-	1408,33	1,5	-	2000
M10	*	41,5	201,60	4225,00	14,08	-	2000
M11	*	5,5	144,00	-	4	-	2000
M12	*	5,9	183,60	-	8,25	-	2000
M13	*	3,7	176,40	-	4,82	-	2000
M14	*	3,7	219,60	-	4	-	2000
M15	*	1,88	-	-	1,37	-	2000
M16	*	13,73	360,00	2957,50	12	-	2000
M17	*	4,4	-	-	19	-	2000
M18	*	3,7	-	-	17	-	2000
M19	*	5,2	-	-	2	-	2000
M20	*	2,2	-	-	2,2	-	2000
M21	*	17,6	-	-	9,45	-	2000
M22	*	0	-	1584,38	1,28	-	2000
M23	*	3,7	-	1659,82	4,4	-	2000
M24	*	12	187,20	-	5,25	-	2000
M25	*	4,5	190,80	1868,75	4,68	-	2000
M26	*	42	432,00	3380,00	8,16	-	2000
M27	*	3	151,20	-	2,72	-	2000
M28	*	50	-	-	13	-	2000
M29	*	1,65	90,00	-	8,4	-	2000
M30	*	2,2	-	-	4,18	-	2000
M31	*	7,4	-	-	3,6	-	2000
M32	*	0	-	-	2,5	-	2000
M33	*	3,7	-	-	8	-	2000
M34	*	2,25	82,80	2112,50	3,25	-	2000
M35	*	5,9	64,80	-	4,56	-	2000
M36	*	8,2	57,60	2028,00	1,5	-	2000
M37	*	12,4	-	-	12,1	-	2000
M38	*	3,3	50,40	-	6	-	2000
M39	*	2,2	-	-	1	-	2000
M40	*	2,2	-	-	4,16	-	2000
M41	*	3,7	-	-	1,2	-	2000
M42	*	0,18	-	-	1	-	2000

*Dados sensíveis cuja divulgação não foi autorizada pela empresa.

As informações referentes ao roteamento de processos e tempos de operação são apresentados na Tab. 4, onde é possível perceber que, para a finalização da peça 1, exemplificativamente, é necessária uma sequência de 8 operações: a primeira deve ser realizada em M1, e seu tempo de operação consiste em 95 segundos; a segunda, em M2 ou M5, e para ambos os tipos de máquina são necessários 39 segundos; a terceira, em M3, e seu tempo consiste em 99 segundos; a quarta, em M6 ou M12, e seus respectivos tempos equivalem a 54 e 220 segundos; e assim sucessivamente. Essas são as informações que promovem a flexibilidade de rotas para o fluxo de material no chão de fábrica.

Tabela 4. Roteamento de processos para cada peça e seus respectivos tempos de operação.

Peça p	Número de operações	Sequência de operações (roteamento)	Tempo de operação (seg), t_{jpm}
P1	8	M1 - M2/M5 - M3 - M6/M12 - M17/M18 - M14 - M14/M24/M25 - M13/M35	95 - 39/39 - 99 - 54/220 - 40/68 - 27 - 93/55/55 - 105/105
P2	6	M1 - M2/M5 - M3 - M6/M12 - M17/M18 - M14	95 - 39/39 - 99 - 54/220 - 40/68 - 27
P3	5	M1 - M2/M5 - M3 - M6/M12 - M17/M18	95 - 39/39 - 99 - 54/220 - 40/68
P4	6	M1 - M2/M5 - M3 - M6/M12 - M17/M18 - M34/M36	95 - 39/39 - 99 - 54/220 - 40/68 - 54/54
P5	8	M1 - M2/M5 - M3 - M6/M7/M12/M13 - M16/M17/M18 - M14 - M13 - M10/M26	87 - 39/39 - 99 - 54/72/220/156 - 60/40/68 - 27 - 105 - 97/95
P6	5	M2/M5 - M1/M4 - M3 - M6/M7/M12/M13 - M15/M24	39/39 - 60/63 - 99 - 46/72/220/156 - 85/55
P7	6	M2/M5 - M1/M4 - M3 - M6/M7/M12/M13 - M16/M17/M18 - M15/M24/M27	39/39 - 60/63 - 99 - 46/72/220/156 - 60/40/68 - 85/55/45
P8	5	M29 - M10/M26 - M17/M18 - M15/M24/M25 - M13	110 - 97/95 - 40/105 - 85/55/45 - 31,8
P9	2	M40 - M25/M42	105 - 45/75
P10	7	M2/M5 - M1/M4 - M3 - M6/M7/M12/M13 - M23 - M15/M24 - M29	39/39 - 60/63 - 99 - 46/72/220/156 - 340 - 55/55 - 154
P11	4	M2 - M3 - M6/M7/M12/M13 - M16	39 - 99 - 46/72/220/156 - 102
P12	5	M17/M18 - M10/M26 - M15/M24/M25 - M13 - M34	40/105 - 97/95 - 80/80/80 - 70 - 54
P13	4	M2/M5 - M6/M7/M12/M13 - M10/M26 - M17/M18	39/39 - 46/72/220/156 - 7,6/7,6 - 40/68
P14	6	M2/M5 - M1/M4 - M7/M19 - M10/M26 - M20 - M22	4,2/4,2 - 5,8/4,2 - 6,8/14,2 - 0,76/1,52 - 1,46 - 2,2
P15	4	M2/M5 - M1/M4 - M6/M7 - M17/M18	39/39 - 60/39 - 46/72 - 40/68
P16	3	M40 - M41 - M25/M42	105 - 54 - 45/75
P17	5	M2/M5 - M1/M4 - M6/M7/M12 - M17/M18 - M15/M25/M42	39/39 - 60/39 - 46/72/220 - 40/68 - 87,5/45/75
P18	6	M1 - M2/M5 - M3 - M6/M7 - M16 - M13	60 - 39/39 - 99 - 46/72 - 102 - 135
P19	2	M13 - M10/M26	40 - 45/95
P20	8	M2/M5 - M1/M4 - M3 - M6/M7/M12/M13 - M17/M18 - M14 - M15/M24/M25 - M13	39/39 - 60/39 - 99 - 46/72/220/156 - 40/68 - 27 - 93/55/55 -
P21	6	M2/M5 - M1/M4 - M3 - M6/M7/M12/M13 - M17/M18 - M14	39/39 - 60/39 - 99 - 46/72/220/156 - 40/68 - 27
P22	5	M2/M5 - M1/M4 - M3 - M6/M7/M12/M13 - M17/M18	39/39 - 60/39 - 99 - 46/72/220/156 - 40/68
P23	4	M2/M5 - M1/M4 - M6/M7/M12 - M10/M26	39/39 - 60/39 - 46/72/220 - 38/70
P24	4	M2/M5 - M1/M4 - M3 - M17/M18	39/39 - 60/39 - 99 - 40/68
P25	7	M2/M5 - M1/M4 - M3 - M17/M18 - M14 - M15/M24/M25 - M13	39/39 - 60/39 - 99 - 40/68 - 27 - 93/55/55 - 38,8
P26	5	M2/M5 - M1/M4 - M3 - M17/M18 - M14	39/39 - 60/39 - 99 - 40/68 - 27
P27	8	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M13 - M10/M26 - M38	92 - 39/39 - 99 - 46/72/220 - 40/68 - 31,9 - 38/70 - 75
P28	7	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M14 - M10/M26	92 - 39/39 - 99 - 46/72/220 - 40/68 - 27 - 38/70
P29	4	M1 - M2/M5 - M3 - M6/M7/M12	92 - 39/39 - 99 - 46/72/220
P30	6	M1 - M2/M5 - M3 - M6/M7/M12 - M13 - M10/M26	92 - 39/39 - 99 - 46/72/220 - 105 - 38/70
P31	6	M1 - M2/M5 - M3 - M6/M7/M12 - M16 - M13	92 - 39/39 - 99 - 46/72/220 - 87 - 105
P32	7	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M15/M24 - M13	92 - 39/39 - 99 - 46/72/220 - 40/68 - 85/55 - 105
P33	4	M29 - M26 - M17/M18 - M36/M39	1320 - 70 - 40/105 - 150/150
P34	7	M1 - M2/M5 - M3 - M6/M7/M12 - M18 - M13 - M10/M26	92 - 39/39 - 99 - 46/72/220 - 150 - 45 - 38/70
P35	2	M34 - M36	75 - 150
P36	9	M2/M5 - M1/M4 - M3 - M6/M7/M12 - M17 - M11 - M10/M26 - M31 - M32/M33	92 - 39/39 - 99 - 46/72/220 - 250 - 20,8 - 38/70 - 44 - 26/26
P37	4	M17 - M37 - M34 - M36	250 - 540 - 75 - 150
P38	9	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M21 - M26 - M34 - M38	103 - 39/39 - 99 - 46/72/220 - 40/68 - 102 - 70 - 75 - 75
P39	7	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M14 - M26	103 - 39/39 - 99 - 46/72/220 - 40/68 - 27 - 70
P40	6	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M10/M26	103 - 39/39 - 99 - 46/72/220 - 40/68 - 38/70
P41	7	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M13 - M10/M26	103 - 39/39 - 99 - 46/72/220 - 40/68 - 31,8 - 38/70
P42	8	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M14 - M13 - M10/M26	103 - 39/39 - 99 - 46/72/220 - 40/68 - 27 - 31 - 38/70
P43	5	M1 - M2/M5 - M3 - M6/M7/M12 - M10/M26	103 - 39/39 - 99 - 46/72/220 - 38/70
P44	5	M1 - M2/M5 - M6/M7/M12 - M13 - M10/M26	103 - 39/39 - 46/72/220 - 66,2 - 38/55
P45	7	M1 - M2/M5 - M3 - M6/M7/M12 - M10/M26 - M13 - M18	103 - 39/39 - 99 - 46/72/220 - 38/55 - 30 - 40
P46	7	M1 - M2/M5 - M3 - M6/M7/M12 - M18 - M15/M24 - M13	103 - 39/39 - 99 - 46/72/220 - 68 - 85/55 - 135
P47	7	M1 - M2/M5 - M3 - M6/M7/M12 - M18 - M15/M27 - M13	103 - 39/39 - 99 - 46/72/220 - 68 - 85/55 - 135
P48	9	M1 - M2/M5 - M3 - M6/M7/M12 - M13 - M18 - M23 - M15/M24 - M13	103 - 39/39 - 99 - 46/72/220 - 49 - 68 - 340 - 75/55 - 47
P49	7	M1 - M2/M5 - M3 - M6/M7/M12 - M18 - M15/M27 - M13	103 - 39/39 - 99 - 46/72/220 - 68 - 85/45 - 47
P50	8	M2/M5 - M3 - M6/M7/M12 - M31 - M32/M33 - M18 - M10 - M13	39/39 - 99 - 46/72/220 - 44 - 26/26 - 68 - 38/55 - 35
P51	5	M1 - M2/M5 - M3 - M6/M7/M12 - M13	103 - 39/39 - 99 - 46/72/220 - 31,9
P52	2	M2/M5 - M6/M7/M12	39/39 - 46/72/220
P53	6	M2/M5 - M1/M4 - M3 - M6/M7/M12 - M11 - M10/M26	5,57/5,57 - 5/4,28 - 14,14 - 3,28/5,14/15,71 - 5,78 - 5,43/7,85
P54	1	M18	72
P55	3	M2/M5 - M6/M7/M12 - M11	1,77/1,77 - 2,45/4,91/10 - 0,54
P56	1	M2/M5	12/12
P57	3	M2/M5 - M6/M7/M12 - M11	13/13 - 18/36/73 - 4
P58	4	M2/M5 - M1/M4 - M6/M7/M12/M13 - M10/M26	13/13 - 34,17/13 - 18/36/73/19 - 3,16/4,5
P59	3	M2 - M8 - M9	3 - 1 - 1,5
P60	4	M2 - M12 - M16 - M13	39 - 220 - 20 - 135
P61	7	M1 - M2 - M2 - M3 - M6/M7/M12 - M10/M26 - M13	103 - 39 - 42 - 99 - 54/108/220 - 38/55 - 105
P62	1	M30	95
P63	4	M1 - M2/M5 - M7 - M10/M26	103 - 39/39 - 108 - 9,5/13,7
P64	3	M2/M5 - M10/M26 - M11	39/39 - 7,2/14,4 - 3,5
P65	6	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M28	103 - 39/39 - 99 - 46/72/220 - 40/68 - 5,5
P66	3	M21 - M34 - M38	102 - 75 - 75
P67	7	M1 - M2/M5 - M3 - M6/M7/M12 - M17/M18 - M28 - M14	103 - 39/39 - 99 - 46/72/220 - 40/68 - 5,5 - 27
P68	4	M2/M5 - M1/M4 - M6/M7/12/13 - M28	13/13 - 34,17/13 - 18/36/73/19 - 5,5

5. RESULTADOS E CONSIDERAÇÕES FINAIS

O modelo apresentado foi implementado com os dados de entrada apresentados na seção anterior utilizando a linguagem Matlab®. Conforme mencionado anteriormente, o algoritmo foi mantido em execução por 100 gerações, com uma população de 10 indivíduos, probabilidade de 90% para cruzamento, 20% para elitismo e 20% para mutação.

A Fig. 9 apresenta o comportamento do custo total de produção para o período típico ao longo das gerações, por intermédio da evolução do melhor indivíduo e da média populacional. Na septuagésima geração foi possível obter o valor de R\$ 495.086,67, cifra mínima da série temporal, o qual indica uma generosa melhoria quando comparado ao custo da configuração existente na fábrica, análise que será abordada com maiores detalhes na próxima subseção.

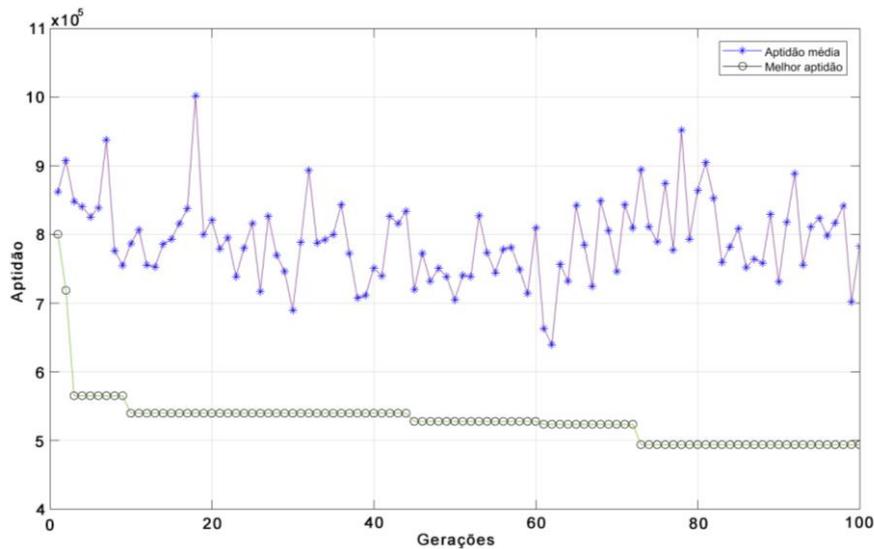


Figura 9. Comportamento da função da função custo total de produção ao longo das gerações.

O resultado indica que o método é eficaz para a busca de boas soluções para a configuração de *layout* e roteamento de processos. Observa-se, na Fig. 9, um comportamento esperado por métodos evolutivos, considerando o provável formato da função que descreve o problema. A topologia de tal função, que, ao que tudo indica, possui diversos mínimos locais, pode ser responsável por manter indivíduos presos às soluções prematuras, resultando em alta volatilidade da aptidão média da população, a qual revela que, apesar de ter sido possível a descoberta de indivíduos com aptidão superior, a população como um todo não convergiu para tal caráter, apresentando um nível de evolução da média bastante sucinto. Especula-se que tal variabilidade de aptidão média pode ser também característica do método de simulação, dado que pequenas variações nos cromossomos podem implicar em grandes “saltos” no domínio de soluções.

As seções $[X]_{jp}$, $[Y]_m$ e $[Z]_l$ do cromossomo resultante da otimização, referentes ao roteamento de processos, à quantidade de máquinas e a organização de *layout*, são apresentadas pelas Tabs. 5, 6 e 7, respectivamente. Conforme indicado pela Tab. 2, a configuração de células proposta compreende 12 células. Tais células contemplam máquinas conforme representado pela Tab. 7.

Tabela 5. Representação da seção $[X]_{jp}$ do cromossomo da melhor solução encontrada.

Xjp 1/2	P1	P2	P3	P4	P5	P6	P7	P8	P9	P10	P11	P12	P13	P14	P15	P16	P17	P18	P19	P20	P21	P22	P23	P24	P25	P26	P27	P28	P29	P30	P31	P32	P33	P34
OP1	1b	1b	1a	1ab	1a	5a	5a	29b	40a	2ad	2d	18ab	2abc	2abc	2bd	40a	5a	1b	13abc	2b	2bc	5a	2c	2bc	2abd	2abc	1ab	1ab	1a	1ab	1b	1a	29ac	1b
OP2	2bd	5a	5a	5a	5a	1ab	1a	26a	25a	1a	3cd	26a	6b	4a	4a	41a	4a	2abc	26a	4a	4a	4a	1ab	1b	1a	2bd	2ad	5a	5a	2abcd	5a	26a	2bcd	
OP3	3ac	3abc	3bd	3bd	3abc	3d	3c	18c	0	3abcd	7a	25a	10a	19b	6a	42a	7a	3bcd	0	3ac	3c	3ab	6b	3ad	3ab	3abc	3a	3ac	3bd	3abd	3b	3abc	18ac	3ad
OP4	6ab	12a	12b	6ab	13ac	12b	6b	15ab	0	6b	16ab	13c	17b	26a	18bc	0	18abc	7b	0	13acd	7ab	13bcd	26a	17ab	17a	18ac	6a	7b	7ab	7ab	6a	6a	39a	7ab
OP5	17b	18bc	18ac	17b	17ab	24a	18b	13acd	0	23acd	0	34a	0	20a	0	0	42a	16a	0	18a	17ab	18c	0	0	14a	14a	18bc	17a	0	13ad	16b	18bc	0	18b
OP6	14a	14a	0	36a	14a	0	27a	0	0	15b	0	0	0	22a	0	0	0	13abd	0	14a	14a	0	0	0	24a	0	13a	14a	0	26a	13cd	15b	0	13b
OP7	15ab	0	0	0	13acd	0	0	0	0	29c	0	0	0	0	0	0	0	0	0	15a	0	0	0	0	10a	10a	0	0	0	0	13d	0	10a	
OP8	35a	0	0	0	26a	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13acd	0	0	0	0	0	0	38a	0	0	0	0	0	0	
OP9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
Xjp 2/2	P35	P36	P37	P38	P39	P40	P41	P42	P43	P44	P45	P46	P47	P48	P49	P50	P51	P52	P53	P54	P55	P56	P57	P58	P59	P60	P61	P62	P63	P64	P65	P66	P67	P68
OP1	34a	5a	17b	1a	1ab	1a	1b	1b	1b	1b	1a	1a	1b	1a	1a	5a	1a	2ad	5a	18a	5a	2abd	2bcd	2ab	2c	2ab	1ab	30ab	1ab	2bcd	1ab	21a	1ab	2bc
OP2	36a	4a	37a	2a	2acd	2abd	5a	5a	2bcd	5a	5a	5a	5a	5a	5a	3ab	5a	6b	4a	0	7b	0	6b	1b	8a	12b	2abd	0	2ac	10a	2abc	34a	5a	4a
OP3	0	3abcd	34a	3bc	3b	3b	3d	3d	3b	6b	3acd	3abd	3b	3c	3b	12a	3bcd	0	3bcd	0	11a	0	11a	7b	9a	16ab	2ab	0	7a	11a	3ab	38a	3bc	13c
OP4	0	7a	36a	7b	7ab	12b	6a	6b	6ab	13d	12a	7b	12b	6a	7ab	31a	6a	0	12ab	0	0	0	0	10a	0	0	0	26a	0	7b	0	6a	28a	
OP5	0	17ab	0	17b	18abc	18c	18ab	18b	10a	26a	10a	18c	18ab	13abc	18bc	32a	13bd	0	11a	0	0	0	0	0	0	0	6a	0	0	0	17b	0	17b	0
OP6	0	11a	0	21a	14a	26a	13ab	14a	0	0	13bcd	24a	27a	18ac	15b	18c	0	0	10a	0	0	0	0	0	0	0	26a	0	0	0	28a	0	0	0
OP7	0	26a	0	26a	26a	0	10a	13abcd	0	0	18abc	13d	13a	23ac	13b	10a	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
OP8	0	31a	0	38a	0	0	0	26a	0	0	0	0	0	24a	0	13ad	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
OP9	0	32a	0	38a	0	0	0	0	0	0	0	0	0	13d	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Tabela 6. Representação da seção $[Y]_m$ do cromossomo da melhor solução encontrada.

M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15	M16	M17	M18	M19	M20	M21
2	4	4	1	1	2	2	1	1	1	1	2	4	1	2	2	2	3	2	1	1
M22	M23	M24	M25	M26	M27	M28	M29	M30	M31	M32	M33	M34	M35	M36	M37	M38	M39	M40	M41	M42
2	4	1	1	1	1	1	3	3	1	1	1	1	1	1	1	1	1	1	1	1

Tabela 7. Representação da seção $[Z]_l$ do cromossomo da melhor solução encontrada.

POS	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35
M	15a	1a	3a	2a	2b	13a	2c	1b	3b	3c	3d	4a	16a	6a	6b	12a	8a	9a	10a	30a	14a	13b	36a	7a	22a	26a	18a	5a	15b	7b	2d	16b	13c	23a	18b
POS	36	37	38	39	40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65	66	67	68	69	70
M	18c	19a	20a	21a	17a	22b	23b	17b	24a	25a	13d	27a	28a	29a	29b	29c	30b	30c	31a	32a	33a	12b	34a	35a	0	37a	38a	39a	40a	41a	42a	19b	11a	23c	23d

Naturalmente, um posto de trabalho deve possuir dimensões que abranjam os operadores e os equipamentos necessários. Dito isso, torna-se importante apontar que, embora tenham sido consideradas, no que se refere ao processo de otimização do vetor $[Z]$, dimensões iguais para cada posição disponível na fábrica, tal premissa pode não se mostrar fielmente realizável, já que poderia implicar em sobreposição de postos de trabalho. No entanto, presume-se que a classificação de qualquer sobreposição, independentemente de sua magnitude, como inviável, no processo de otimização, pode incorrer no descarte de soluções de boa qualidade, enquanto, possivelmente, uma análise final realizada pelo modelador e a gerência da organização seria suficiente para desfazer as sobreposições ao espaçar os equipamentos conforme necessário, preservando a essência da solução obtida.

Os componentes de custo individuais obtidos pela melhor configuração de *layout* e processos proposta pelo modelo são descritos pela Tab. 8.

Tabela 8. Resultados obtidos para cada componente de custo.

Custo de produção (R\$)	Custo de energia elétrica (R\$)	Custo de manutenção (R\$)	Custo de consumíveis (R\$)	Custo de área ocupada (R\$)	Custo de depreciação (R\$)	Custo de oportunidade (R\$)	Rend. com venda de máquinas (R\$)
443.815,67	36.494,00	6.875,00	856,00	5.208,00	1.413,00	1.518,00	1.093,00

5.1. Comparação com a configuração existente

Para respeitar sua privacidade e evitar que os dados atuais sejam expostos, uma visualização é proposta no intuito de comparar a configuração existente na fábrica em questão com a configuração proposta pelo modelo. A Fig. 10 apresenta uma espécie de disputa, em que a porcentagem de ordens concluídas é gradativamente desenvolvida ao longo do tempo para as duas disposições em questão.

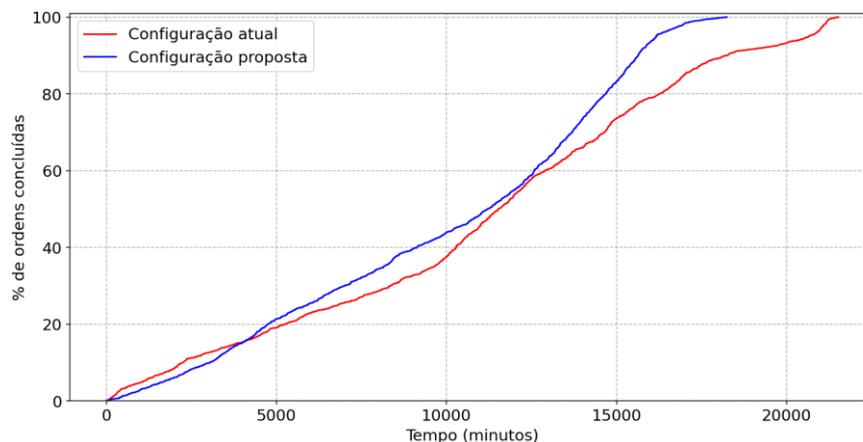


Figura 10. Configuração atual da fábrica versus configuração proposta pelo modelo. Porcentagem de ordens concluídas para a base de teste da simulação ao longo do tempo.

Como é possível observar, a solução proposta supera a configuração existente por boa margem. É fato que, produzir com maior velocidade não é somente o que importa. Porém, mesmo considerando a soma de todos os custos da Tab. 8, um nível de 15% em redução de custos foi atingido para o trimestre típico utilizado como base de teste para a simulação, resultado muito próximo aos obtidos em trabalhos da literatura, como Forghani *et al.* (2014).

6. CONCLUSÕES

No presente trabalho, uma abordagem que integra os métodos de AG e SED foi apresentada para resolver a complexa problemática de otimização de *layout* e processos industriais, com foco em formação de células de manufatura (CM), considerando fatores diversos, no intuito de tornar o método mais fiel à realidade. Entre tais fatores, encontram-se a demanda de peças formada a partir de dados estatísticos, sequências de operações e seus tempos, roteamento de processos, duplicação e eliminação de máquinas com base em seus atributos e tempos de movimentação de material com base nas distâncias entre os equipamentos.

Um estudo de caso foi empregado em uma indústria moveleira do sul do Brasil e tomado como exemplo numérico. Os dados da empresa foram coletados para a execução do modelo, através do qual foi possível obter resultados que indicam uma redução de aproximadamente 15% no custo total de produção.

Este trabalho pode ser ampliado ao contemplar novos atributos, como distâncias de movimentação que considerem os trajetos dos corredores do *layout* e flexibilidade para o tamanho e geometria das células, além de outros métodos estatísticos para a formação da base de teste da simulação.

Apesar dos apontamentos, de acordo com os resultados, conclui-se que, quando configurações de *layout*, roteamento de processos e formação de células de manufatura são otimizadas simultaneamente, os custos totais de produção podem diminuir consideravelmente, e, trazendo resultados mais fidedignos do que aqueles obtidos através de métodos que não consideram um ou mais dos fatores aqui apresentados.

7. AGRADECIMENTOS

Em especial, ao professor Adelano, cuja paciência, dedicação e excelência foram traduzidos em apoio e orientação para desenvolver esse trabalho. Também à empresa, aos profissionais Sidinei e Letícia, que trabalharam comigo para a obtenção dos dados necessários. Meus familiares, Rui, Maria e Jaíne, que apoiam os meus projetos de sucesso incerto, tornando-os também os seus objetivos. Ao meu amor, que não mediu esforços para me apoiar e esteve comigo nos momentos de trabalho.

8. REFERÊNCIAS

- Ahn, C. e Ramakrishna, R., 2003, “Elitism-Based Compact Genetic Algorithms”, IEEE transactions on evolutionary computation, Vol. 7, No. 4, pp. 367-385.
- Armstrong, J., 2001, “Extrapolation for Time-Series and Cross-Sectional Data”, em: Armstrong, J. Principles of Forecasting. International Series in Operations Research & Management Science, Vol. 30, pp. 217-243.
- Arora, J., 2004, “Introduction to Optimum Design”, 2nd ed., pp. 534-563.
- Azadeh, A., Asadzadeh, S., Mehrangohar, M. e Fathi, E., 2014, “Integration of genetic algorithm, analytic hierarchy process and computer simulation for optimisation of operator allocation in manufacturing systems with weighted variables”, Int. J. Logistics Systems and Management, Vol. 17, No. 3, pp. 318-339.
- BCB, 2022, “Meta para a taxa Selic”. Disponível em: <<https://www.bcb.gov.br/estatisticas/grafico/graficoestatistica/metaselic>>. Acesso em 14 de nov. de 2022.
- Box, G., Jenkins, G. e Reinsel, G., 1994, “Time series analysis: forecasting and control”, pp. 1-45.
- Brown, E. e Sumichrast R., 2001, “CF-GGA: A grouping genetic algorithm for the cell formation problem”, International Journal of Production Research, pp. 3651-3669.
- Burbidge, J., 1992, “Change to group technology: process organization is obsolete”, International Journal of Production Research, pp. 1209-1219.
- Corrêa, H. e Corrêa, C., 2004, “Administração de produção e operações: manufatura e serviços: uma abordagem estratégica”, 2. Ed. – São Paulo: Atlas, 2007, pp. 415-417.
- Desai, A. e Mital, A., 2018, “Production Economics: Evaluating Costs of Operations in Manufacturing and Service Industries”, pp. 7-394.
- Dimopoulos, C., 2007, “Explicit consideration of multiple objectives in cellular manufacturing”, Engineering Optimization, Vol. 39, No. 5, pp. 551-565.
- Domanski, C., 2020, “Cost Engineering: A Practical Method for Sustainable Profit Generation in Manufacturing”, pp. 97-104.
- Esen, H., Fırlı, N., Aydınoğlu, N. e Hatipoğlu, T., 2017, “Application of lean production techniques in the manufacturing industry”, Int. J. Services and Operations Management, Vol. 27, No. 3, pp. 324-344.
- Forghani, K. and Mohammadi, M., 2014, “A genetic algorithm for solving integrated cell formation and layout problem considering alternative routings and machine capacities”, Scientia Iranica, Transactions E: Industrial Engineering, pp. 2326-2346.
- Gan, C. e Learmonth, G., 2016, “An improved chromosome formulation for genetic algorithms applied to variable selection with the inclusion of interaction terms”, pp 1-20.

- Godwin, G., Kohli, S. e Urolagin, S., 2021, "Sales Prediction Using Linear and KNN Regression", S. Patnaik et al. (eds.), *Advances in Machine Learning and Computational Intelligence, Algorithms for Intelligent Systems*, pp. 321-329.
- Goldberg, D., 1989, "Genetic Algorithms in Search, Optimization, and Machine Learning", pp. 1-25.
- Gopalakrishnan, T., Choudhary, R. e Prasad, S., 2018, "Prediction of Sales Value in online shopping using Linear Regression", 4th International Conference on Computing Communication and Automation (ICCCA), pp 1-6.
- Hazarika, M., 2021, "An improved genetic algorithm for the machine-part cell formation problem", *Int J Syst Assur Eng Manag*, pp. 1-14.
- Heragu, S., 2008, "Facilities design, 3rd ed.", pp. 237-368.
- Holland, J., 1975, "Adaptation in Natural and Artificial Systems", Ed. de 1992, pp. 1-19.
- Imran, M., Kang, C., Lee, Y., Jahanzaib, M e Aziz, H., 2017, "Cell formation in a cellular manufacturing system using simulation integrated hybrid genetic algorithm", *Computers & Industrial Engineering* 105, pp. 123–135.
- Jahanzaib, M., Masood, S., Nadeem, S., Akhtar, K. e Shahbaz, M., 2013, "Application of Genetic Algorithm (GA) Approach in the Formation of Manufacturing Cells for Group Technology", *Life Science Journal*, pp. 799-809.
- Javadian, N., Rezaeian, J. e Maali, Y., 2007, "Multi-Objective Cellular Manufacturing System under Machines with Different Life-Cycle using Genetic Algorithm", *International Journal of Applied Science, Engineering and Technology* Vol. 4 No. 4, pp. 223-227.
- Jayakumar, V. e Raju, R., 2010, "An Adaptive Cellular Manufacturing System Design with Routing Flexibility and Dynamic System Reconfiguration", *European Journal of Scientific Research*, ISSN 1450-216X Vol.47 No.4 (2010), pp. 595-611.
- Jayakumar, V. e Raju, R., 2011, "A multi-objective genetic algorithm approach to the probabilistic manufacturing cell formation problem", *South African Journal of Industrial Engineering* May 2011 Vol 22 (1): pp. 199-212.
- Kim, I. e Weck, O., 2004, "Variable chromosome length genetic algorithm for progressive refinement in topology optimization", pp. 1-12.
- Lam, J., Hui, S. e Chan, A., 1996, "Approach to the Development of a Typical Meteorological Year for Hong Kong", *Architectural Science Review*, pp. 201-209.
- Mahdavi, I., Paydar, M., Solimanpur, M. and Heidarzade, A., 2009, "Genetic algorithm approach for solving a cell formation problem in cellular manufacturing", *Expert Systems with Applications* 36 (2009), pp. 6598–6604.
- Makridakis, S., Wheelwright, S. and Hyndman, R., 1997, "Forecasting methods and applications", pp. 9-239.
- Mansouri, S., Husseini, S. e Newman, S., 2000, "A review of the modern approaches to multi-criteria cell design", *INT. J. PROD. RES.*, Vol. 38, No. 5, pp. 1201-1218.
- Morad, M. e Zalzal, A., 1995, "The formation of manufacturing cells using genetic algorithms", pp. 1-8.
- Mungwattana, A., 2000, "Design of Cellular Manufacturing Systems for Dynamic and Uncertain Production Requirements with Presence of Routing Flexibility", Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State University in partial fulfillment of the requirements for the degree of Doctor of Philosophy in Industrial and Systems Engineering, pp. 1-252.
- Murata, T., Ishibuchi, H. e Gen, M., 2001, "Specification of Genetic Search Directions in Cellular Multi-objective Genetic Algorithms", pp. 82-95.
- Potkány, M and Škultétyová, M., 2019, "Innovation of calculations through the use of machine hour rates in the furniture industry", 12th International Scientific Conference WoodEMA 2019, pp. 189-194.
- Reed, P., Minsker, B. e Goldberg, D., 2004, "The Practitioner's Role in Competent Search and Optimization Using Genetic Algorithms", pp. 1-8.

RFB: Receita Federal do Brasil. Normas da Receita Federal, Instrução Normativa SRF nº 162, de 31 de dezembro de 1998, Anexo I. Disponível em: <http://normas.receita.fazenda.gov.br/sijut2consulta/link.action?idAto=15004&visao=original>. Acesso em 17 de nov. de 2022.

Spencer, H., 1864, “The principles of biology”, Vol. 1, pp. 444.

Strachan, T., Goodship, J. and Chinnery, P., 2015, “Genetics and genomics in medicine”, Garland Science, Taylor & Francis Group LLC, pp. 19-116.

Tavakoli-Moghadam, R., Javadi, B., Jolai, F. e Mirgorbani, S., 2005, “An efficient algorithm to inter and intra-cell layout problems in cellular manufacturing systems with stochastic demands”, IJE Transactions A: Basics, Vol. 19, No. 1, pp. 67-78.

Tavakoli-Moghadam, R., Safaei, N. e Sassani, F., 2007, “A new solution for a dynamic cell formation problem with alternative routing and machine costs using simulated annealing”, Journal of the Operational Research Society (2008) 59, pp. 443-454.

Thomassey, S. e Zeng, X., 2018, “A Discrete Event Simulation Model with Genetic Algorithm Optimisation for Customised Textile Production Scheduling”, Artificial Intelligence for Fashion Industry in the Big Data, pp. 153-171.

Venugopal, V. e Narendran, T., 1990, “Cell formation in manufacturing systems through simulated annealing: An experimental evaluation”, European Journal of Operational Research, Vol. 63, pp. 409-422.

Venugopal, V. e Narendran, T., 1992, “A genetic algorithm approach to the machine-component grouping problem with multiple objectives”, Computers ind. Engng Vol. 22, No. 4, pp. 469-480.

Wemmerlov, U. e Johnson, D., 1997, “Cellular manufacturing at 46 user plants: implementation experiences and performance improvements”, INT. J. PROD. RES., Vol. 35, No. 1, pp. 29-49.

Wu, X., Chu, C., Wang, Y. and Yan, W., 2006, “A genetic algorithm for cellular manufacturing design and layout”, European Journal of Operational Research 181 (2007), pp. 156-167.

Žilinskas, J., Goldengorin, B. e Pardalos, P., 2014, “Pareto-optimal front of cell formation problem in group technology”, pp. 1-18.

GENETIC ALGORITHM AND DISCRETE EVENT SIMULATION: A HYBRID APPROACH APPLIED IN LAYOUT OPTIMIZATION AND INDUSTRIAL PROCESSES

Jean Carlos Cendron, jeancendron@hotmail.com¹

Adelano Esposito, adelano.esposito@farroupilha.ifrs.edu.br²

^{1,2} Instituto Federal do Rio Grande do Sul, Campus Farroupilha, Av. São Vicente – Cinquentenário, Farroupilha – RS, 95180-000.

Abstract: *Given the current market situation, it is becoming increasingly necessary for companies to adopt manufacturing strategies and technologies to produce with more speed, better quality and fewer resources. To achieve this goal, optimizing layout and processes proves to be efficient. In the present study, a hybrid approach contemplating genetic algorithm and discrete event simulation is presented as a solution to the complex problem of industrial layout and processes optimization, focusing on the formation of manufacturing cells, applied to a furniture factory in the south of Brazil. Such approach dispenses the use of multiplier weights in its objective function and considers parameters such as demand for parts (based on a period of the company's production history), their different routes through the process flow, operation times, addition and removal of machines, and their actual dimensions and positions. The performance of the solution proposed by the algorithm was compared to the current factory configuration. The results indicate a 15% reduction in the total cost of production, suggesting that optimizing these settings can significantly improve manufacturing conditions.*

Keywords: *industrial optimization, manufacturing cells, genetic algorithm, discrete event simulation.*