

# UMA NOVA ABORDAGEM DO ALGORITMO GENÉTICO PARA OTIMIZAR O BALANCEAMENTO DA CARGA DE TRABALHO E QUANTIDADE DE TAREFAS ATRASADAS EM UM CASO DE APLICAÇÃO NA INDÚSTRIA CALÇADISTA

Lísia Peroza Ruiz, [ruiz.lisiaperoza@gmail.com](mailto:ruiz.lisiaperoza@gmail.com)<sup>1</sup>  
Adelano Esposito, [adelano.esposito@farroupilha.ifrs.edu.br](mailto:adelano.esposito@farroupilha.ifrs.edu.br)<sup>1</sup>

<sup>1</sup>Instituto Federal do Rio Grande do Sul Campus Farroupilha, R. São Vicente, 785 - Cinquentenario, Farroupilha - RS, CEP - 95174-274.

**Resumo:** *Indústrias estão enfrentando o desafio de ajustar equipamentos e layouts de produção de forma que passem a atender a produção de lotes com menor demanda e maior variedade de peças. Diante desta problemática, os métodos heurísticos de otimização, tais como os algoritmos genéticos (GA), vem demonstrando resultados promissores para a solução de problemas envolvendo o balanceamento de sistemas de manufaturas flexível. Sendo assim, este trabalho tem como objetivo propor uma nova abordagem do algoritmo genético para otimizar o balanceamento da carga de trabalho e quantidade de tarefas atrasadas em um caso de aplicação na indústria calçadista. Com foco no desenvolvimento de um GA aplicado a um framework existente, foi utilizado um cromossomo linear para carregar as informações do sistema de manufatura aos operadores genéticos responsáveis pelo processo de otimização. Um modelo matemático é proposto com o objetivo de minimizar o desbalanceamento do setor aprimorando a capacidade e qualidade deste analisado, a convergência e capacidade de otimização da linha de produção é testada em comparação com estudo de outros autores. A partir disso, permitiu-se montar um novo layout para indústria estudada e contrastá-lo com a configuração atual. Os resultados demonstraram que o algoritmo genético proposto obteve uma melhora de 40% para 22% de desbalanceamento no setor, sendo foi possível comprovar a evolução do setor com aplicação da otimização por GA.*

**Palavras-chave:** *algoritmo genético, otimização, manufatura, indústria calçadista*

## 1. INTRODUÇÃO

Com uma análise do cenário de mercado atual, é possível notar que desde as últimas décadas o perfil de consumo de produtos cotidianos se altera com rapidez, as peças de roupas, acessórios e calçados exclusivos, que são produzidos artesanalmente ou em pequenos lotes passaram a ter maior valor agregado como conferido por Cárdenas *et al.* (2018).

Em frente a esta tendência de consumo, as indústrias que se consolidaram utilizando sistemas de produção em massa têm, atualmente, o desafio de adaptar seus processos a fim de que atendam as novas necessidades de mercado, produzindo maior variedade de modelos em menores lotes, como destacado por Quyen *et al.* (2016). Destarte, a renovação do sistema produtivo deve ocorrer de forma simultânea a produção atual, evitando paradas no parque industrial que comprometam as entregas de pedidos.

Utilizando teorias da área de estudo cuja prioridade é analisar e criar sistemas de produção, a geração de estoques não é uma opção prática ou rentável, isto pois a armazenagem de peças requer espaço físico específico e organizado, com gestão de fluxo realizada por pessoas e sistemas automatizados. O estoque, mesmo que seja capaz de absorver as variações de demanda e ineficiência da produção na implementação de projetos, é um passivo a ser eliminado dado que, itens parados não movimentam a economia das empresas, outro ônus desse mecanismo é o fator de que para gerar estoque as peças são fabricadas sem demanda, e assim, se torna um risco, citado por Lu *et al.* (2020).

Contudo, se mantém imprescindível às empresas a modificação dos processos produtivos atuais, modernizando os sistemas com o intuito de produzir com os mesmos equipamentos, maior diversidade de peças em menores lotes, mantendo, ou se viável, reduzindo o *lead time*. A indispensabilidade de manutenção das estruturas já existentes carrega o movimento de flexibilização destas, de forma que uma máquina ou posto de trabalho dedicado a rotineiramente realizar a mesma etapa de processo, tenha capacidade de variar sua produção, passando a executar um conjunto de diferentes tarefas em cada lote de peças fabricados.

A exploração das possibilidades de arranjo físico de estruturas com base nas adequações realizadas acarreta uma grande variedade de disposições, e estas variações podem diferir conforme a demanda do período de fabricação analisado. Como descrito por Shanker e Srinivasulu (1989) estes sistemas de produção com possibilidade de rearranjo com base na necessidade de um período são chamados de Sistema de Manufatura Flexível (*Flexible Manufacturing System - FMS*)

quando um setor, ou área de produção pode por completo ser modificado, Egilmez e al. (2016) amplia a possibilidade de implementação para Sistema de Manufatura Celular (*Cellular Manufacturing System – CMS*) modificando a estrutura e os componentes entre as células, como também em produção em linha, variando a ordem e quantidade de máquinas e ferramentas em cada posto de trabalho da linha de processo.

Em um esforço para sanar esta necessidade passam a ser estudados meios computacionais para desenvolvimento de testes digitais de produção, formas de prever e aprimorar os processos fabris antes que estes sejam implementados.

Neste contexto, Shanker e Tzen (1985) trabalham com a elaboração de um método matemático que contemple uma das principais problemáticas, citadas no artigo referenciado, de um FMS. Sendo esta, a escolha de quais peças devem ser alocadas para produzir em um mesmo sistema, para um determinado período de produção, de forma que determinadas premissas e restrições de fabricação sejam respeitadas. Para isso, foi desenvolvido um método heurístico de otimização dividido em etapas, cada etapa avalia o cenário conforme as necessidades do processo e então por fim é analisada a necessidade de alteração da hipótese. Ao realizar a modificação aleatória entre peças, operações e máquinas nos pontos de alocação maior do que a capacidade, as etapas são repetidas em dez vezes, o cenário que obtiver a resposta com melhor equilíbrio de produção entre as máquinas é determinada como a melhor solução. Contudo, a parada na repetição das etapas ocorre após determinadas iterações sem que haja um método de parada para verificar a convergência da função, não garantindo o carregamento mais apropriado, assim é possível que o modelo mostre um mínimo local de desbalanceamento como resultado mais adequado.

Mukhopadhyay *et al.* (1992) aprofundou os estudos em FMS a fim de gerar uma solução heurística que tenha capacidade de obter melhores resultados para o processo de seleção de itens a produzir em um mesmo setor, ou célula. Esta tentativa leva em consideração uma entrada de pedidos de tipos de peças aleatórios, sem pré-seleção, empregando à obtenção do melhor resultado o fator da quantidade de peças manufaturadas dentro de um período de produção. Neste, foi possível a obtenção de um resultado aprimorado em relação ao trabalho de Shanker e Tzen (1985), no entanto permanece a possibilidade de o modelo proposto ter encontrado uma solução ótima local, com baixo desbalanceamento quando comparada a cenários semelhantes.

Fazendo o uso de um modelo matemático de caráter heurístico, Tiwa Ri *et al.* (1997) trabalharam no aperfeiçoamento da alocação da produção de peças em um FMS, de forma a aumentar o equilíbrio entre a ocupação das máquinas mantendo a flexibilidade de produção. Ao confeccionar o método, com o propósito de obter respostas mais precisas, o modelo matemático desenvolvido conta com o modelo Rede de Petri como adicional, apesar do esforço para evoluir o procedimento de otimização há um impedimento quanto ao encontro do cenário ideal, isto devido a limitada aleatoriedade nas modificações dos métodos utilizados.

Haja vista o avanço tecnológico ocorrido no início dos anos 2000, Kumar *et al.* (2006) construiu um modelo heurístico acrescentando à forma de seleção das peças o algoritmo genético (*Genetic Algorithm – GA*), um formato que amplia o campo de busca de forma aleatória dentro do domínio determinado por meio das restrições de fabricação. Neste trabalho, assim como os demais mencionados, há uma busca para um equilíbrio de ocupação dos equipamentos disponíveis, contudo, este é simplesmente uma parte da elaboração. A fim de atingir cenários favoráveis para o arranjo de um FMS considerando os pequenos lotes de produção, Kumar *et al.* (2006) inicia restringindo o domínio de busca do algoritmo e impõe que sejam realizados um valor específico de iterações até o ponto de parada, adicionando fatores para considerar o cenário analisado como ótimo. É possível verificar o aumento de complexidade do sistema evolutivo, no entanto, para contemplar diversos pontos de interesse ao realizar a otimização, se faz necessário uma função que contemple mais de um objetivo integrado, onde o algoritmo tenha como tarefa, melhorar o valor gerado nesta função.

Observa-se, com os estudos referenciados, que o balanceamento de sistemas de manufatura flexível consiste em um problema de otimização tipicamente abordado por métodos matemáticos e técnicas heurísticas, cuja solução ótima é obtida pela convergência gradual da função objetivo. Neste aspecto, nos últimos anos, diferentes métodos heurísticos, tais como: *particles swarm optimization*, *ant colony optimization*, *firefly algorithm* e *genetic algorithm* (GA), têm sido frequentemente utilizados para encontrar o balanceamento ótimo dos FMS. Devido aos bons resultados obtidos com o GA, este trabalho propõe uma nova abordagem do algoritmo genético para otimizar o balanceamento da carga de trabalho e quantidade de tarefas atrasadas em um caso de aplicação na indústria calçadista. Os objetivos contemplam a minimização da carga de trabalho e quantidade de tarefas atrasadas, tipicamente explorados de maneira teórica na literatura, os quais, neste trabalho, foram modelados para um caso real de produção em uma linha de montagem do setor calçadista.

A estrutura deste artigo foi organizada da seguinte forma: na introdução está apresentado um resumo das pesquisas realizadas sobre o assunto para contextualização e melhor compreensão. A descrição do problema e formulação do modelo matemático estão demonstradas na sequência. Subsequentemente, o GA e seus operadores genéticos são descritos em conformidade com o problema de otimização em estudo. Adiante, a seção seguinte trata da validação da implementação, bem como apresenta um caso de estudo, expondo os resultados computacionais e as conclusões da pesquisa proposta.

## 2. DESCRIÇÃO DO PROBLEMA E MODELO MATEMÁTICO

Nesta seção, apresentamos o modelo matemático que descreve a função objetivo do problema de otimização abordado, com base na formulação proposta por Shanker e Tzen (1985), quanto aos parâmetros associados, variáveis projeto e restrições. Para tal, os seguintes critérios devem ser considerados:

- A otimização será realizada para um período de fabricação pré-definido.

- As peças que têm possibilidade de produzir neste período foram selecionadas previamente, assim como os tempos e quantidade de recursos humanos necessários.
- As máquinas disponíveis para a produção do período são as estruturas presentes no setor sem alocação prevista.
- Um mesmo tipo de peça pode apresentar variações de operações para montagem.
- Cada variação pode apresentar mais de uma alternativa de máquina.
- Um mesmo tipo de peça pode ser produzido simultaneamente em mais de uma máquina, no entanto, as variações internas a este não.
- Uma peça que tem sua produção iniciada dentro do período estimado, deve finalizar seu lote completo dentro deste.
- Uma máquina processa apenas um lote por vez, sendo assim, o tempo executado por variação de tipo de peça na máquina soma-se a cada alocação.
- As máquinas operam de forma simultânea.
- As quantidades de recursos humanos e estruturais máximas para o setor no período determinado são dimensionadas anteriormente a otimização.
- Os tempos de deslocamento não são considerados nos cálculos de ocupação e/ou disponibilidade.
- A sequência da produção não está sendo avaliada, apenas o dimensionamento de capacidade do setor.

## 2.1. Notações

### 2.1.1. Índices

- $i$  : Peças,  $1 \leq i \leq m$ ,  $m$  = quantidade de peças para produzir  
 $k$  : Operações,  $1 \leq k \leq y_i$ ,  $y_i$  = quantidade de operações possíveis  
 $j$  : Máquinas,  $1 \leq j \leq n$ ,  $n$  = quantidade de máquinas disponíveis

### 2.1.2. Parâmetros

- $H$  = quantidade de minutos disponíveis do período para produção por máquina  
 $t_j$  = quantidade de ferramentas disponíveis por máquina no setor para o período ( $H$ )  
 $P_{ikj}$  = tempo de processamento para cada máquina ( $j$ ) de cada operação ( $k$ ) de uma peça ( $i$ )  
 $S_{ijk}$  = quantidade de ferramentas necessárias para produção da operação ( $k$ ) de uma peça ( $i$ ) em uma máquina ( $j$ )  
 $ai$  = demanda de cada peça ( $i$ ) para o período ( $H$ )  
 $y_i$  = quantidade de operações ( $k$ ) para uma peça ( $i$ )  
 $O_j$  = sobrecarga da máquina ( $j$ )  
 $U_j$  = sub ocupação da máquina ( $j$ )  
 $R_i$  = tempo excedente ou faltante para conclusão da peça ( $i$ ) durante o período ( $H$ )  
 $D$  = parâmetro de valor de baixa grandeza para a seleção de peças ( $i$ ) cujo  $R_j$  seja menor que  $2H$   
 $L$  = quantidade total de restrições violadas

### 2.1.3. Variáveis de Decisão

$$x_i = \begin{cases} 1, & \text{se a peça } i \text{ for selecionado para produzir no período} \\ 0, & \text{se a peça } i \text{ não for selecionado para produzir no período} \end{cases} \quad (1)$$

$$x_{ikj} = \begin{cases} 1, & \text{se a operação } k \text{ da peça } i \text{ for selecionada para produzir na máquina } j \text{ período} \\ 0, & \text{se a operação } k \text{ da peça } i \text{ não for selecionada para produzir na máquina } j \text{ período} \end{cases} \quad (2)$$

## 2.2. Modelo Matemático

Utilizando a notação acima, o modelo matemático do problema de otimização adaptado de Shanker e Tzen (1985), em termos da função objetivo e restrições, pode ser escrito na seguinte forma:

Minimizar:

$$Z_1 = \sum_{j=1}^n w_{oj} |O_j| + \sum_{j=1}^n w_{uj} |U_j| \quad (3)$$

$$Z_2 = \sum_{j=1}^n w_{oj} |O_j| + \sum_{j=1}^n w_{uj} |U_j| - \sum_{i=1}^m \frac{w_{di} x_i}{\max[D, (R_i - 2H)]} \quad (4)$$

Sujeito as condições:

$$\sum_{i=1}^m \sum_{k=1}^{y_i} S_{ikj} x_{ikj} \leq t_j \quad (5)$$

$$Rw_j = \left[ H - \left( \sum_{i=1}^m \sum_{k=1}^{y_i} P_{ikj} x_{ikj} a_i \right) \right] \quad (6)$$

$$O_j = \begin{cases} Rw_j, & \text{se } Rw_j < 0 \\ 0, & \text{se } Rw_j \geq 0 \end{cases} \quad j = 1, 2, \dots, n \quad (7)$$

$$U_j = \begin{cases} 0, & \text{se } Rw_j \leq 0 \\ Rw_j, & \text{se } Rw_j > 0 \end{cases} \quad j = 1, 2, \dots, n \quad (8)$$

A função objetivo apresentada na Eq. (3) minimiza o desbalanceamento do setor com base na disponibilidade final,  $O_j$  e  $U_j$  de cada máquina. Complementando com um terceiro termo, a Eq. (4) tende a minimizar a quantidade de peças entregues com atraso em relação ao período de produção  $H$ . O primeiro e segundo termo destas formulações somados calculam o desbalanceamento total do setor, sendo o terceiro termo da Eq. (4) responsável por identificar a quantidade de peças com atraso na entrega, relacionando o parâmetro  $D$  ao tempo de atraso de cada peça, com isto é possível priorizar pela função a minimização de atrasos e desequilíbrio da produção. Com isso, o parâmetro  $D$  é definido pelo processo industrial visto que em processos de grande complexidade, de execução ou preparação, o atraso pode ser compensado com a preservação da peça na máquina, este parâmetro apresenta diferentes valores para as operações com diferentes processos de fabricação, após este parâmetro definido, se torna um fator fixo para o setor.

A Eq. (5) refere-se à restrição de ferramentas disponíveis por máquina  $t_j$  para o período  $H$ , em relação a quantidade necessária de acordo com as operações  $k$  da peça produzida  $i$  na máquina  $j$ , considerando o arranjo de  $i$  em  $j$ , a formulação mencionada trata-se de uma restrição de domínio pois, se a máquina requisitar mais ferramentas no intervalo de tempo que se tem disponível, não há possibilidade de produzir o conjunto de peças indicado no cenário. Com a Eq. (6) é calculada a divergência de tempo entre o que se havia de disponibilidade para o período e a ocupação da máquina. O primeiro termo é referente a quantidade de minutos disponíveis  $H$  para cada máquina  $j$ , o seguinte, calcula em um somatório para as operações  $k$  de cada peça  $i$  o tempo necessário para produção de todas as unidades do lote, a fim de que seja levado em consideração apenas as peças presentes no cenário é utilizada a variável de decisão  $x_{ikj}$ . Com esta relação é possível definir se a máquina está sobrecarregada, quando o tempo ocupado é maior que o disponível, ou com aproveitamento abaixo de 100%. A restrição delimitada a partir do cálculo da Eq. (6) não restringe o domínio da função em razão de ser possível a execução dos cenários de produção com discrepância de carregamento, sendo a minimização desta flutuação um dos objetivos da otimização. Os resultados da Eq. (7) e Eq. (8) tem dependência atrelada ao valor de resposta da Eq. (6), na Eq. (7) é calculado a quantidade de tempo excedente em máquina, nos casos em que a ocupação da máquina  $j$  é maior que a disponibilidade,  $O_j$  recebe o valor da Eq. (6), do contrário, recebe zero. Nas situações em que uma máquina  $j$  apresenta baixa ocupação, o resultado da Eq. (6) é atribuído a  $U_j$ , se oposto, lhe é atribuído zero, como descrito na Eq. (8).

A metodologia de solução permite que o desenvolvedor atribua pesos as diferentes partes das equações utilizando um valor para a sobrecarga na máquina  $j$ ,  $w_{oj}$ , um peso relativo para o sub carregamento na máquina  $j$ ,  $w_{uj}$ , permitindo avaliar cada objetivo com a criticidade necessária. Neste trabalho foram atribuídos os valores de  $D = 0,002$  e para os pesos assume-se que  $w_{oj} = w_{uj} = w_{di} = 1$ .

### 2.3. Método de Penalização

O problema de otimização que descreve o modelo matemático abordado neste trabalho, conforme apresentado na seção 2.2, é definido como um problema de otimização com restrição. Entretanto, dada a escolha do GA como método de solução do referido problema, o qual é aplicado apenas à otimização irrestrita, faz-se necessário utilizar métodos adicionais para manter a solução na região viável (Yeniay, 2005). Dentre os diversos métodos existentes para manipular as restrições no GA, utilizamos as funções de penalidade na minimização dos problemas de otimização abordados neste trabalho.

Esta técnica permite penalizar as soluções inviáveis, aumentando os valores da função objetivo (isto, reduzindo a aptidão do indivíduo) proporcionalmente ao grau de violação das restrições. Sendo assim, a formulação geral para um problema de minimização é escrita conforme a Eq. 9 (Smith e Fogel, 2002).

$$f_p(x) = f(x) + \sum_{i=1}^m C_i d_i^k \quad (9)$$

Onde:

$$d_i = \begin{cases} |g_i(x) \leq 0|, \text{ para } i = 1, \dots, q \\ |h_i(x) = 0|, \text{ para } i = q + 1, \dots, m \end{cases} \quad (10)$$

$f_p(x)$  é a função objetivo penalizada,  $f(x)$  é a função objetivo não penalizada e  $C_i$  a constante imposta pela violação da  $i$ -ésima restrição.  $d_i$  corresponde à distância da  $i$ -ésima restrição em relação à solução  $x$ , e  $k$  é o expoente definido pelo usuário, variando entre 1 e 2.  $g_i$  são as restrições de desigualdades, cuja penalidade será ativada apenas quando a restrição for violada.  $h_i$  são as restrições de igualdade, ativas se houver qualquer distância entre o valor da solução e o valor da restrição. Se  $g_i$  ou  $h_i$  forem violadas, a correspondente distância  $d_i$  adiciona uma penalidade à função objetivo, a qual torna-se mais severa quanto maior a distância da solução com a restrição. Sendo assim, a formulação apresentada na Eq. 9 é reescrita como uma função objetivo irrestrita conforme Eq. 11, onde  $C_i$  e  $k$  foram tomados como 3 e 2, respectivamente.

Minimizar:

$$f_p(x) = Z(x) + \sum_{l=1}^L 3d_l^2 \quad (11)$$

Sujeita as condições:

$$d_l = \begin{cases} |g_l(x) \leq 0|, \text{ para } l = 1, \dots, q \\ |h_l(x) = 0|, \text{ para } l = q + 1, \dots, L \\ x \in X, X = \{X_{ki}, Y_i\} \end{cases} \quad (12)$$

As restrições do problema de otimização, apresentadas nas Eq. 6-7, são agora reescritas em termos da distância  $d_l$ , conforme Eq. 13-14.

$$g_l \leq \frac{t_j}{\sum_{i=1}^m \sum_{k=1}^{y_i} S_{ikj} x_{ikj}} - 1 \quad (13)$$

$$h_l = \frac{H}{\sum_{i=1}^m \sum_{k=1}^{y_i} P_{ikj} x_{ikj} a_i} - 1 \quad (14)$$

### 3. METODOLOGIA

Com a finalidade de solucionar a problemática referente aos conjuntos de peças a serem produzidos, a utilização de um método que seja capaz de trabalhar com simultaneidade de processamentos e problemas não lineares é imprescindível. A partir de uma análise da situação problema apresentada neste, e contraponto a configuração do sistema de produção com os trabalhos desenvolvidos por Venugopal e Narendran (1992) e Jayakumar e Raju (2011) em processos de manufatura celular, juntamente as construções acerca de sistemas de manufatura com variação de processos em uma mesma máquina como artigos já citados neste (Shanker, 1985; Mukhopadhyay, 1992; Tiwari, 1997; Kumar, 2006). Sendo assim, esta seção descreve a metodologia de otimização por evolução natural e as adequações desenvolvidas nos operadores genéticos a fim de permitir ao GA resolver o problema de otimização abordado neste trabalho. A implementação computacional desenvolvida para este estudo foi realizada em linguagem Matlab®.

#### 3.1. Algoritmo Genético (GA)

O algoritmo genético consiste em um método estocástico baseado na teoria da evolução biológica de Darwin, onde o indivíduo mais adequado possui maior probabilidade de sobrevivência e, conseqüentemente, evolução da espécie; enquanto os menos aptos não sobrevivem (Arora, 2004). Dentre as características que favorecem a aplicação do GA no balanceamento de FMS, pode-se destacar sua boa eficiência para lidar como problemas que envolvem grandes espaços de busca, sem conhecimento da função objetivo. Além disso, para casos de alta estocasticidade, os métodos tradicionais podem apresentar dificuldades para encontrar a solução global (Jackson *et al.*, 2018).

O formato da busca de resultados por meio de GA é construído com a inicialização de uma população povoada por conjuntos de dados relacionados ao problema, onde para todos, são calculados os critérios necessários que compõe a situação estudada. A partir da população inicial, estes conjuntos de dados, intitulados cromossomos, são avaliados pelo cálculo das restrições e função objetivo para então alterarem sua estrutura de forma a aproximar os resultados de um valor ótimo, estas alterações são os processos de mutação e cruzamento (Holland, 1975). Como defendido por Forghani and Mohammadi (2013), os procedimentos evolutivos são repetidos continuamente gerando diferentes gerações com variadas características que buscam reduzir o valor da função objetivo, até o momento em que há convergência dos valores obtidos para população, para análise da convergência dos resultados obtidos em um mínimo global, há possibilidades variadas de

critérios. Para facilitar a compreensão do algoritmo desenvolvido, a Fig. 1 apresenta o fluxograma de iterações entre o GA e o módulo responsável pela decodificação e cálculo da função objetivo, resumidamente descrito nas etapas a seguir:

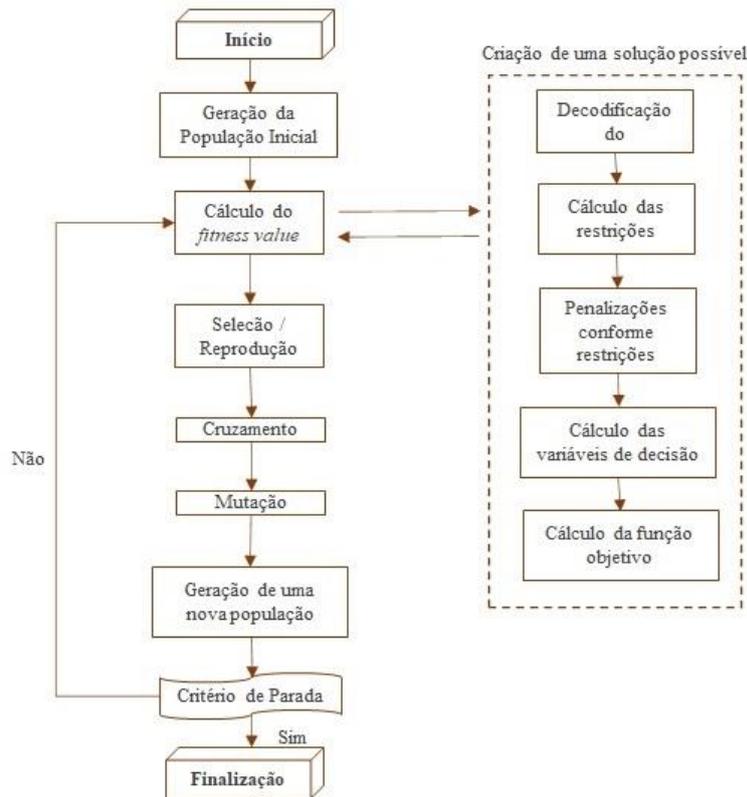


Figura 1. Fluxograma do processo evolutivo de um algoritmo genético e sub-rotinas.

### 3.1.1. Codificação do Cromossomo

O procedimento de codificação e decodificação acerca das informações de um processo de produção para uma lista com elementos representativos, que será o cromossomo do GA, pode ser escrito de formas variadas, conforme a necessidade do estudo e informações indispensáveis. Contudo, a criação do formato de armazenamento das informações dentro de um vetor de cromossomo é parte crucial de todo desenvolvimento de otimização, de acordo com Jackson *et al.* (2018), é fundamental a construção de um cromossomo que represente adequadamente o processo industrial abordado com suas variáveis, pois este é a fonte de transmissão da informação para otimização, neste trabalho os parâmetros variáveis contemplam as possíveis combinações de máquinas e peças que resultam no balanceamento do tempo do processo de fabricação.

Sendo assim, o modelo de cromossomo proposto neste trabalho é dividido em duas seções. A primeira seção contempla as máquinas escolhidas pelos operadores genéticos, onde cada gene contém a  $j$ -ésima máquina responsável por realizar a  $k$ -ésima operação da  $i$ -ésima peça, isto é, cada gene possui um conjunto de máquinas possíveis de executar a  $k$ -ésima operação da  $i$ -ésima peça, tal que, ao aplicar os operadores genéticos durante o processo evolutivo, o valor do gene na primeira seção do cromossomo indicará máquina selecionada para a geração. Já a segunda seção do cromossomo é responsável pela escolha das peças a serem produzidas no período corrente, com base em uma demanda definida. Para tal, a posição do gene indica o número da peça e o valor do gene, resultado dos operadores genéticos binários, representa o processamento ou não da peça no período em análise. Sendo assim, quando o valor do gene for igual a um, significa que a peça deve ser considerada no período, caso contrário, a peça é excluída do processo.

A Fig. 2(a) apresenta a matriz de incidência do problema, onde as linhas correspondem às  $k$  operações, suas colunas indicam as  $i$  peças previstas para o período. Os elementos da matriz contêm uma ou mais máquinas associadas à operação/peça. Na Fig. 2(b), é apresentado o cromossomo como resultado dos operadores genéticos aplicados aos elementos com mais do que uma máquina na matriz da Fig. 2(a), conforme descrito anteriormente.

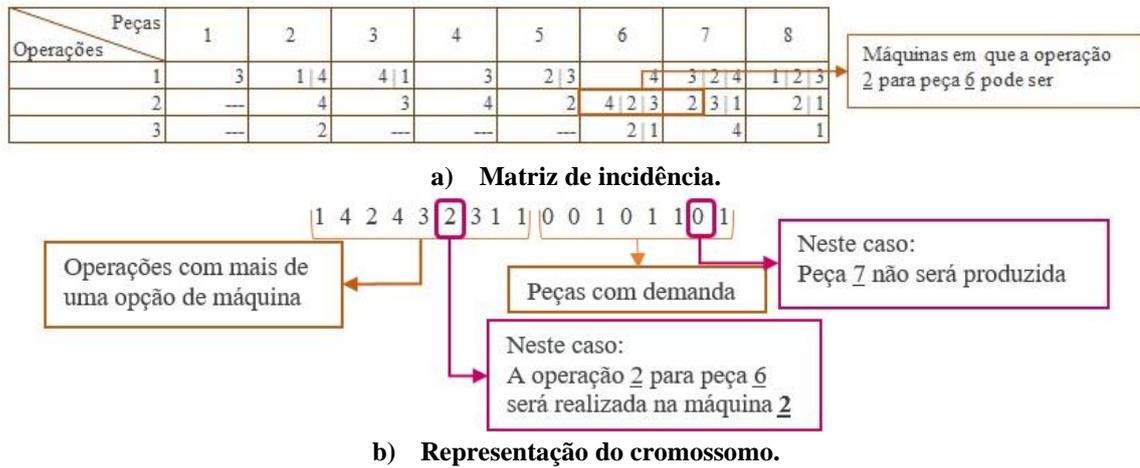


Figura 2. Informações para o cromossomo.

### 3.1.2. População Inicial

A população inicial será o ponto de partida do algoritmo na geração e avaliação de cromossomos. Este primeiro passo consiste em transformar cada resposta em um cromossomo para criar uma população inicial. Nesta fase, cada cromossomo é gerado aleatoriamente, cuja solução pode violar ou não alguma restrição. Muito embora existam alternativas para recusar os indivíduos que extrapolam o domínio de solução, garantindo que a população inicial pertença ao domínio viável, se teria uma baixa probabilidade de gerar soluções próximas aos limites da região viável. Por essa razão, a alternativa adotada neste trabalho consiste em manter os indivíduos inaptos e, ao aplicar a penalização conforme Eq. 12, torná-los menos aptos na escolha para reprodução.

O formato de identificação acerca de quais foram as máquinas selecionadas para cada operação e do conjunto de peças a fabricar ocorre utilizando as variáveis de decisão descritas na seção 2 deste trabalho, para auxiliar na compreensão a construção da estrutura destas pode ser vista na Fig. 3.

Cada cromossomo será analisado de acordo com as restrições e então calculado seu valor na função objetivo, o fluxo de evolução do GA segue, partindo desta etapa, uniforme para todas as gerações.

Peças	1	2	3	4	5	6	7	8
$x_i$	0	0	1	0	1	1	0	1

a) Variável de decisão quanto às peças selecionadas.

Peças \ Operações	1	2	3	4	5	6	7	8
1	3	1	4	3	2	4	4	3
2	---	4	3	4	2	2	3	1
3	---	2	---	---	---	1	4	1

b) Variável de decisão quanto à operação e máquina selecionadas.

Figura 3. Representação da variável de decisão  $x_i$  e  $x_{ikj}$ , os campos destacados identificam quais foram as máquinas escolhidas dentre as opções apresentadas.

### 3.1.3. Cálculo e Análise do Cromossomo

Nesta etapa ocorre a decodificação do vetor do cromossomo para termos do tipo de processo analisado, estas informações são utilizadas para identificar as opções de máquina escolhidas, entre as alternativas, e as peças que serão produzidas, analisando pela posição do dado no cromossomo, o valor a ele atribuído. As tabelas de entrada, como a matriz de incidência, são lidas pelo algoritmo para cada operação de uma peça sendo produzida em uma máquina específica de forma a calcular os tempos de duração de cada processamento nas máquinas, apenas para as peças a serem fabricadas.

A partir desta interpretação dos dados de processo e decodificação do cromossomo, as informações extraídas são aplicadas na verificação das restrições, quando um valor não corresponde ao *range* indicado pelas variáveis de decisão das Eq. 7-8, há uma penalização de valor variável em consonância com a discrepância do valor obtido em relação aos valores dentro do domínio, utilizando o método de penalização descrito na seção 2.3.

Ao finalizar o cálculo das restrições se busca obter o *fitness value* para o cromossomo com a utilização da Eq. 3, os termos presentes nesta equação são obtidos pelo cálculo da Eq. 6 que analisa cada uma das máquinas do setor, o

*fitness value* é responsável por carregar a informação do quão bom o cromossomo gerado é para as etapas seguintes da otimização do processo.

**3.1.4. Processo de Seleção**

Este procedimento é responsável por selecionar quais serão os indivíduos (cromossomos) que seguirão no processo de evolução para reprodução de acordo com o seu *fitness value*. Neste estudo, o método da roleta (Hazarika e Laha, 2018), é empregado para a seleção de tais indivíduos, denominados como pais. Assim, a seleção baseia-se na qualidade dos pais, cuja probabilidade de seleção é calculada através do valor de sua função de aptidão, normalmente igual ao valor da função objetivo.

Neste processo, primeiramente, os indivíduos são classificados em ordem crescente de acordo com seu valor de aptidão e, posteriormente calcula-se a correspondente probabilidade de seleção com base na Eq. 15:

$$P_i = \frac{f_i}{\sum_{l=1}^N f_l} \tag{15}$$

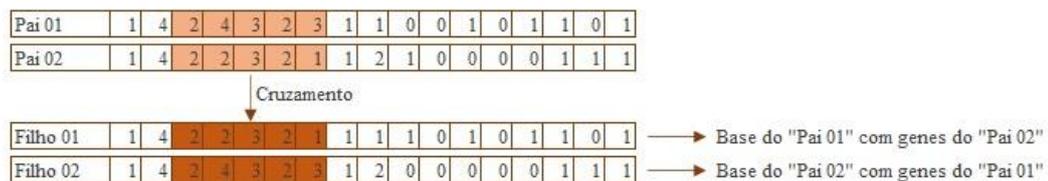
Onde N representa o tamanho da população. A probabilidade acumulada é calculada para cada indivíduo e um número ideal de pais é selecionado aleatoriamente entre 0 e 1, combinando esse número com a probabilidade acumulada.

A fim de incorporar o efeito das restrições na otimização com o GA, a função objetivo do problema de otimização com restrição na Eq. 3 foi modificada para uma função objetivo penalizada da Eq. 12, conforme descrito na seção 2.3. Sendo assim, para os indivíduos selecionados para reprodução, sempre que algum operador genético for aplicado (isto é: cruzamento ou mutação), as duas restrições são verificadas, Eq. 13-14. Para a restrição violada, a penalização é aplicada conforme Eq. 12.

**3.1.5. Cruzamento**

O operador genético incumbido de transformar os cromossomos selecionados em novas versões com chances de melhor desempenho é o cruzamento. Este processo segue a metodologia biológica da genética onde os materiais genéticos de dois indivíduos serão misturados para originar os filhos. A troca de indivíduos entre os cromossomos selecionados, chamados de “pais”, é aleatória e pode ocorrer de diferentes formas, como cita Rabbani *et al.* (2019) tem-se o método *single-point*, *double-point* e uniforme.

Neste estudo, conforme descrito na seção 3.2, o cromossomo contempla a digitalização das variáveis de interesse na forma de códigos manipuláveis que, a partir de uma matriz tridimensional ( $m \times y_i \times n$ ) e unidimensional ( $m \times 1$ ), são concatenados em linha para codificação dos cromossomos dos pais, cada qual formado por duas classes. Assim, os cromossomos podem ser combinados, selecionando dois pontos de corte em cada pai, para criar os dois cromossomos filhos, conforme apresentado na Fig. 4.



**Figura 4. Exemplo de cruzamento por *double-point*.**

**3.1.6. Mutação**

Este processo procura manter a diversidade no campo de busca de soluções, auxiliando para que o algoritmo encontre soluções nos mínimos globais, sendo assim, não garante que as mutações produzam melhores resultados. Análogo ao processo biológico de mutação, este operador trabalha com a variação aleatória entre genes de dois cromossomos, chamados de pais, da mesma população.

Para criar uma mutação no cromossomo, este é dividido em suas duas seções, a seção referente as máquinas para executar cada operação das peças passa por uma seleção aleatória de uma posição do cromossomo para permuta de dados entre os pais, criando os filhos, e o mesmo ocorre com a segunda parte do cromossomo, referente as peças a serem produzidas.

Assim como o cruzamento, atua com uma taxa de probabilidade, os novos itens da população são identificados como filhos. O método de mutação está exemplificado na Fig. 5.

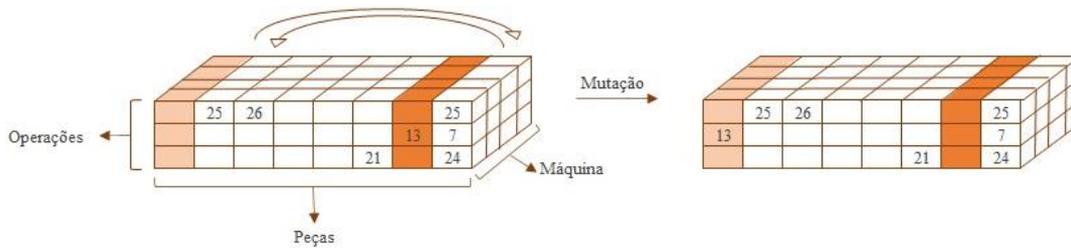


Figura 5. Exemplo do operador genético de mutação.

### 3.1.7. Critério de Parada

O princípio básico dos métodos numéricos de otimização, tais como o Algoritmo Genético, consiste na busca pelo ponto ótimo de forma iterativa, produzindo uma sequência de possibilidades (Arora, 2004). O sucesso do algoritmo depende da garantia de convergência global do método numérico. Para finalizar a busca no domínio da problemática deve-se adotar algum critério de parada eficiente, garantindo confiança na solução encontrada com baixo custo computacional. De acordo com Innocente (2006), os critérios de parada normalmente utilizados consideram dois subcritérios, a saber: número máximo de tentativas; medidas de erro.

No GA, o número de tentativas ou número de gerações, compreende a multiplicação do número de iterações pelo número de indivíduos da população. Portanto, características desejáveis como evolução e exploração, podem ser satisfeitas ao combinar um grande número de gerações com uma grande quantidade de indivíduos. O segundo subcritério estabelece que a finalização do método é satisfeita quando não houver melhoria nas soluções ao longo das iterações subsequentes. Como métrica, normalmente são consideradas medidas de erros, isto é: distância entre as duas últimas posições (norma Euclidiana); diferença entre a melhor solução da iteração atual com a solução precedente; coeficiente de variação, como garantia de precisão e repetibilidade. O segundo subcritério é satisfeito ao comparar tais métricas com uma tolerância definida de acordo com o processo industrial estudado.

## 3.2. Exemplo da Literatura

Com o intuito de verificar a coerência da metodologia aplicada e confiabilidade da programação desenvolvida, um estudo comparativo entre trabalhos de autores que se dedicaram a tratar de situações industriais para manufatura flexível foi desenvolvido. A problemática trabalhada na literatura aborda uma situação industrial com uma planta composta por diferentes máquinas, capazes de produzir mais de um tipo de operação. Neste contexto, é utilizado o GA para definir quais máquinas irão executar cada uma das operações que compõe o processo de produção das peças, e quais os conjuntos de peças que serão fabricados em um período. Sendo assim, o problema de otimização consiste em minimizar o desbalanceamento de produção, conforme a Eq. 3, sujeito as restrições apresentadas nas Eq. 5-8. O exemplo conta com uma estrutura industrial de quatro máquinas para produzir oito diferentes peças. A Tab. 1 apresenta as informações de produção referente a um período com demanda para as oito peças, tendo para cada uma o tempo de processamento das operações, a demanda a produzir, diferentes opções de rotas e quantidade necessária de ferramental. Os dados apresentados foram obtidos de trabalhos de Shanker e Tzen (1985), Kumar *et al.* (2006), Tiwa Ri *et al.* (1997), Mukhopadhyay (1992) e comparados com os resultados obtidos no desenvolvimento deste trabalho com o framework acima mencionado.

No gráfico da Fig. 6, é apresentada a evolução da convergência para o melhor valor da função objetivo, bem como o valor médio associado. Observa-se que logo das primeiras iterações, o GA converge para valores próximos à solução ótima. Entretanto, devido ao caráter exploratório do método em encontrar soluções potencialmente melhores que garantam a convergência global, somente após a 80ª iteração, ou geração, que o valor médio se aproximou da melhor solução. Neste exemplo, o intervalo de 110ª a 160ª contém as gerações com o melhor indivíduo (cromossomo), visto que é possível observar a sobreposição entre os valores médios com o melhor valor da função objetivo, assegurando que a solução ótima global do problema foi encontrada.

Na Fig. 7 a convergência da função em relação a ocupação das máquinas é apresentada para cada iteração, sendo possível notar a busca em um amplo domínio até que a ocupação convergisse a um valor considerado mínimo global.

A topologia da função objetivo apresentada na Eq. 3, graficamente representada na Fig. 8-9, é o resultado dos seguintes conjuntos de variáveis de projeto: combinação de máquina {2 – 3 – 4} disponível para operação 2 da peça 6 e máquinas {1 – 2 – 3} viáveis para 2ª operação da peça 7, como visível na Fig. 8. Combinação de máquina {1 – 2 – 3} disponíveis para 2ª operação da peça 7 com a mesma combinação de máquinas disponíveis para 1ª operação da peça 8, esta topologia está mostrada na Fig. 9. Para este conjunto de combinações há um domínio de segurança observado ( $\Omega_{segurança}$ ) onde poucas restrições são violadas ( $\Omega_{segurança} \in$  espaços de ferramentas). A função objetivo é contínua em VA 4 e 5, contudo, VA 5 e 7 apresenta mínimos locais em ambos os domínios de segurança e falha. Sendo assim, como pode-se observar nos referidos gráficos, as poucas combinações para a função Z1, descrevem um pequeno domínio das possíveis soluções do problema de otimização. Entretanto, a topologia deste domínio pode prejudicar a convergência dos métodos de otimização para o mínimo global. Por essa razão, o GA representa uma boa alternativa para contornar tais dificuldades.

**Tabela 1. Descrição do problema, adaptado de Shanker e Tzen (1985).**

<b>Peça</b>	<b>Operação</b>	<b>Demanda</b>	<b>Tempo por unidade (s)</b>	<b>Máquina</b>	<b>Ferramentas</b>
1	1	8	1080	3	1
2	1	9	1500	1	1
2	1	9	1500	4	1
2	2	9	1440	4	1
2	3	9	1320	2	1
3	1	13	1560	4	2
3	1	13	1560	1	2
3	2	13	660	3	3
4	1	6	840	3	1
4	2	6	1140	4	1
5	1	9	1320	2	2
5	1	9	1320	3	2
5	2	9	1500	2	1
6	1	10	960	4	1
6	2	10	420	4	1
6	2	10	420	2	1
6	2	10	420	3	1
6	3	10	1260	2	1
6	3	10	1260	1	1
7	1	12	1140	3	1
7	1	12	1140	2	1
7	1	12	1140	4	1
7	2	12	780	2	1
7	2	12	780	3	1
7	2	12	780	1	1
7	3	12	1380	4	1
8	1	13	1500	1	1
8	1	13	1500	2	1
8	1	13	1500	3	1
8	2	13	420	2	1
8	2	13	420	1	1
8	3	13	1440	1	3

**Tabela 2. Resultados estatísticos para dez execuções independentes do GA.**

<b>Balanceamento médio</b>	<b>Desvio padrão</b>	<b>Pc</b>	<b>Pm</b>	<b>Tamanho da população</b>	<b>Gerações</b>
81,90	2,33	0,4	0,5	45	160

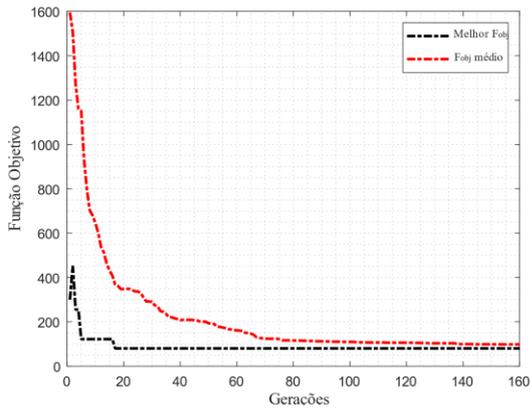


Figura 6. Redução dos valores da função objetivo Z1 ao decorrer das gerações.

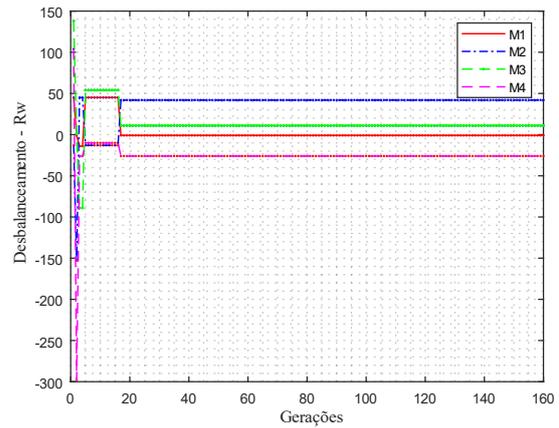


Figura 7. Comportamento do carregamento excessivo,  $O_j$ , e sub carregamento,  $U_j$ , em cada máquina  $j$ .

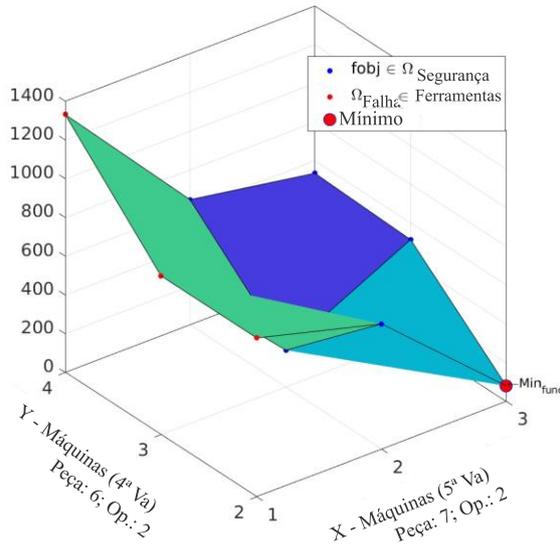


Figura 8. Função objetivo Z1 para as máquinas {2 – 3 – 4} x {1 – 2 – 3}

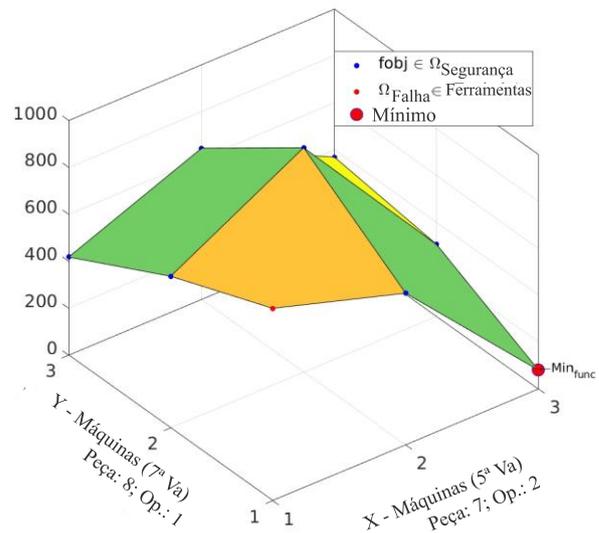


Figura 9. Função objetivo Z1 para as máquinas {1 – 2 – 3} x {1 – 2 – 3}

Com propósito de validação da implementação desenvolvida, a Tab. 3 apresenta os resultados da melhor solução obtida com GA proposto, e sua comparação com os autores referenciados neste trabalho. Neste aspecto, para avaliar a qualidade dos resultados, uma diferença percentual entre as soluções obtidas com o GA e os autores da literatura, foi utilizada com base na Eq. 16, esta variação apresenta o quanto a solução obtida neste trabalho está mais otimizada em relação aos demais autores.

$$\Delta_{função\ objetivo} (\%) = \frac{F_{obj}^{literatura} - F_{obj}^{GA}}{F_{obj}^{literatura}} \times 100 \quad (16)$$

Esta comparação foi utilizada como critério para julgamento da capacidade de otimização do código de programação implementado e está apresentada na Tab. 3. Nas colunas destacadas encontram-se os resultados obtidos com o desenvolvimento para este trabalho.

Nos trabalhos estudados, com os resultados apresentados na Tab. 3, há o desenvolvimento da otimização de duas diferentes funções objetivos. Implementando a função objetivo de minimização do desbalanceamento, Eq. 3, com a utilização de GA obtivemos resultados satisfatórios quanto a otimização proposta. Com isso, a flutuação da ocupação das máquinas foi reduzida definindo quais as peças que devem ser executadas no período de produção e em qual máquina realizar cada operação, isto foi possível a partir da utilização dos parâmetros citados na Tab. 2.

Partindo da utilização dos mesmos parâmetros da situação citada anteriormente, o algoritmo de GA foi implementado com o objetivo de minimizar, além do desbalanceamento, as peças com entregas atrasadas no período, Eq. 4. Desta forma,

a aplicação incrementa um fator importante para o ambiente industrial pois, além de definir as peças para fabricação e as alocações das máquinas para fornecer o melhor aproveitamento do setor, também é imprescindível entregar as demandas no tempo planejado. Como mostrado na Tab. 3 o algoritmo genético desenvolvido neste trabalho apresentou redução significativa no desbalanceamento do setor, contudo manteve uma peça com entrega atrasada no melhor cenário. Isto ocorre pois o parâmetro D da Eq. 4 permite que a indústria defina o quanto o atraso pode ser mantido visto que este compensaria o tempo de setup investido para alocar o produto em outra máquina.

Analisando os resultados obtidos com a implementação do GA em comparação com os demais trabalhos, o algoritmo desenvolvido tem potencial de otimização para o processo industrial uma vez que é possível adequar suas restrições e objetivos de forma a atender diferentes tipos de setores. Portanto, a função que tem como objetivo reduzir o desbalanceamento e entregar menos peças em atraso foi considerada para aplicação no caso de estudo com utilização do GA para otimização.

**Tabela 3. Comparação de resultados entre métodos de otimização.**

		Minimização do DB					Minimização do DB e peças com atraso	
		Shanker 1985	Kumar 2006	Tiwari 1997	Mukhopadhyay 1992	GA	Shanker 1985	GA
Ferramentais	Máq. 1	1	2	2	3	5	5	5
	Máq. 2	4	2	4	1	3	3	2
	Máq. 3	3	4	3	3	2	2	4
	Máq. 4	5	3	3	4	4	3	3
DB	Máq. 1	270	99	45	45	-1	248	-55
	Máq. 2	13	57	-141	-13	42	141	-13
	Máq. 3	12	-30	182	54	11	252	12
	Máq. 4	70	-126	-10	-10	-26	75	18
Sistema	DB	365	312	378	122	80	761	98
	Peças	4,5,6,7	4,7,2,5	1,2,4,5,6	1,4,5,6,8	1,6,7,8	1,2,4,5,8	3,5,6,8
	Demandas atrasadas	1	1	-	-	2	-	1
	$\Delta$ comparação literatura (%)	78,08	74,36	78,84	34,43	-	87,12	-

DB = desbalanceamento.

#### 4. APLICAÇÃO E RESULTADOS

Um estudo de caso com aplicação na indústria calçadista é apresentado nesta seção, tendo como propósito apresentar o balanceamento ótimo de uma linha de montagem, considerando uma determinada demanda de peças, a fim de permitir uma melhor ocupação do setor para o período definido. A formulação deste problema de otimização compreende uma adaptação da função objetivo desenvolvida por Kripa Shanker (1985), apresentada na seção 2.2, Eq. 3. Portanto as seguintes adequações foram realizadas: as peças passaram a ser os produtos da indústria calçadista, as operações são agora representadas pelas cores dos produtos e a formulação para porta ferramenta será utilizada para quantidade de efetivos necessários na produção. Os demais termos se mantêm referentes as suas atribuições anteriores, alterando apenas as unidades de medida da demanda, que neste estudo de aplicação é considerada por pares de calçado, e o tempo para processamento de cada par está escrito em segundos.

##### 4.1. Descrição do Caso de Aplicação

A etapa de montagem dos calçados produzidos na indústria calçadista em questão é realizada em esteiras de velocidade constante, onde nesta estão posicionados postos de trabalho que podem receber operadores disponíveis para realizar a tarefa. A planta fabril é dividida em áreas de acordo com o processo realizado e estas subdivididas em setores com equipamentos específicos para manufaturar diferentes famílias de produtos, as quais são agrupadas por características de produção. Produtos com atributos semelhantes tem a possibilidade de serem produzidos no mesmo subsetor.

O layout de produção do subsetor estudado está representado na Fig. 10 com suas possibilidades de rota. Os produtos têm sua demanda subdividida em cores que serão alocadas para produzir em uma das esteiras disponíveis. Na esteira em que a cor será produzida estarão os postos de trabalho necessários para os operadores realizarem suas tarefas no produto, ao final da esteira o produto pronto segue para o setor seguinte da produção.

Para fabricação de calçados em uma fábrica cuja produção incorpora mais de uma marca e com isso, diferentes arquétipos de produtos dependentes da indústria de moda, são fabricados lotes com baixos volumes para cada modelo, os quais são diferenciados por pequenas variações, como cores e adornos. Para cada uma das variações há uma grade de numeração a ser produzida, dentro da grade, o processo não tende a mudar. Os atributos para definição das famílias e a composição destas está exemplificado na Fig. 11.

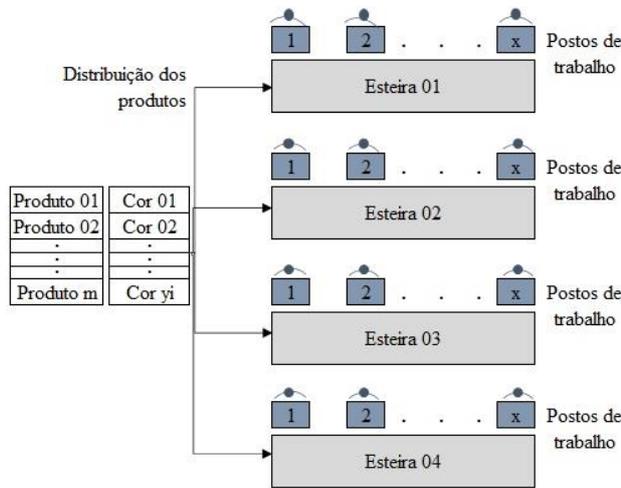


Figura 10. Layout setor de montagem.

	Familia A	Familia B	Familia C	Familia D
Marca	ABC	ABC	ACD	EFS
Arquétipo	Sandália	Chinelo	Chinelo	Sandália
Enfeites	Sim	Sim	Não	Sim
Numeração	23/4 ao 27	23/4 ao 27	33/4 ao 39	35 ao 41
Quantidade de efetivos	11 a 14	15 ao 23	17 a 23	20 a 30
Quantidade de técnicas necessárias	7 a 12	4 a 11	4 a 10	11 a 19

Comparação dos atributos da família com a cor do produto

Produto	XXXXX	XXXXX	XXXWZ
Cor	AA000	AB000	CB000
Marca	ABC	ABC	ACD
Arquétipo	Sandália	Chinelo	Chinelo
Enfeite	Sim	Sim	Não
Numeração	23/4 ao 27	23/4 ao 27	34 ao 39
Efetivos	12	18	17
Técnicas	8	10	5

Informações relevantes para definição da família

Definição da família

Familia	A	B	C
---------	---	---	---

Figura 11. Exemplo de definição da família para cor de um produto com base nos atributos de semelhança.

Em um detalhamento do sistema analisado, no local destinado para produção de um período de três dias, tem-se quatro esteiras disponíveis para toda duração do mesmo. Cada esteira tem a sua disponibilidade um total de 100 pessoas no somatório da necessidade para cada um dos modelos a passarem por esta. Têm-se os seguintes parâmetros de análise:

- Quatro esteiras disponíveis (variáveis de projeto).
- Seis produtos com demanda no período.
- Período de três dias.
- Demanda total do período igual a 16 cores.

Todos os produtos possuem um lote, tempos de execução para cada cor e esteiras em que estas cores podem ser produzidas de acordo com a família do produto definidos previamente. Algumas considerações iniciais devem ser notadas:

- Uma esteira pode receber mais de uma família no mesmo período.
- Todas as famílias de cada tipo de produto foram definidas previamente.
- A demanda alocada para o subsetor no período contém apenas modelos de famílias com afinidade de características.
- Os produtos que não compuserem o conjunto a produzir serão posteriormente alocadas para outro subsetor que possua disponibilidade e famílias com atributos relacionados.
- Os produtos não têm necessariamente as mesmas quantidades de cores, cada um é único.
- Cada cor possui um tempo de esteira e quantidade de pessoas necessárias para ser processada.
- As pessoas devem permanecer alocadas para a esteira onde produziram durante todo o tempo de montagem.
- Ao final de cada lote, um novo produto pode entrar com diferente necessidade de pessoas e operações.

Com base no processo mencionado, o problema de otimização consiste em selecionar os produtos a serem montados em um período, para cada produto há uma demanda que deve ser produzida nas esteiras disponíveis. É importante considerar que uma cor deve ser produzida em somente uma esteira, sem que a demanda do período seja dividida.

O processo de montagem final de calçados, o qual é abordado neste estudo, é realizado em esteiras de velocidade constante. Ao longo do comprimento das esteiras, são dispostos postos de trabalhos e equipamentos para execução das operações responsáveis por unir as partes do calçado e dar acabamento estético a ele. As operações e a quantidade de pessoas requeridas dependem das características do produto. Uma variação de cor, mesmo que de um mesmo produto, pode passar por mais operações ou levar mais tempo que outra devido a necessidade do design como a troca de uma fivela em uma sandália por um velcro de fechamento, estas diferentes opções variam o processo de montagem e com isso o layout das esteiras onde a cor será trabalhada.

Os dados para realização do processo de montagem dos modelos analisados foram fornecidos pela empresa considerada como objeto de estudo deste trabalho, os quais estão apresentados na Tab. 4. As informações de tempo, disponibilidade, técnicas e lotes que influenciam na otimização serão mantidos de acordo com o processo executado na empresa. Para codificação do algoritmo, os modelos foram numerados como produtos de um a seis e as cores de um a três.

**Tabela 4. Dados de produção para o período de três dias.**

<b>Código do produto</b>	<b>Código da cor</b>	<b>Demanda (pares)</b>	<b>Tempo por unidade (s)</b>	<b>Esteira</b>	<b>Quantidade de efetivos</b>
1	1	2316	16,55	1	19
1	2	2316	16,50	2	18
1	2	2316	16,50	1	18
1	3	2316	17,39	2	18
1	3	2316	17,39	1	18
2	1	3360	20,36	3	17
2	2	3360	20,44	3	17
2	3	3360	20,44	3	17
3	1	2256	17,78	4	23
3	2	2256	17,80	4	23
4	1	8114	10,75	3	11
4	2	8114	10,99	3	12
5	1	4988	15,84	1	20
5	1	4988	15,84	4	20
5	2	4988	15,95	1	20
5	2	4988	15,95	4	20
5	3	4988	15,85	1	20
5	3	4988	15,85	4	20
6	1	4450	18,18	3	16
6	1	4450	18,18	2	16
6	2	4450	18,16	3	16
6	2	4450	18,16	2	16
6	3	4450	18,15	3	16
6	3	4450	18,15	2	16

#### 4.2. Parâmetros para GA

Para que a otimização possa convergir para uma solução ótima global, evitando a parada prematura em mínimos locais, são necessários parâmetros de calibração para executar e analisar as probabilidades de mutação (Pm) e cruzamento (Pc), configurações importantes como o tamanho das populações e quantidade de gerações devem ser definidas mediante a testes de convergência em que o algoritmo deve apresentar repetidamente resultados semelhantes, ou seja, com baixo desvio padrão. Neste trabalho foram utilizados os parâmetros apresentados na Tab. 5.

**Tabela 5. Parâmetros de configuração para geração do GA.**

<b>Balanceamento médio</b>	<b>Desvio Padrão</b>	<b>Pc</b>	<b>Pm</b>	<b>Tamanho da população</b>	<b>Gerações</b>
4279,10	0,32	0,4	0,6	60	160

#### 4.3. Resultados

O GA programado obteve o resultado ótimo para balanceamento em 110 gerações. A convergência do método pode ser analisada na Fig. 12 que apresenta a curva de convergência da função objetivo em cada geração, o valor médio obtido para função objetivo em todas as populações. Com o intuito de analisar o comportamento da curva de que apresenta a ocupação das esteiras, uma vez que o equilíbrio deste parâmetro é o principal ponto de otimização da situação problema, a Fig. 13 contém esta visualização e permite analisar o campo de busca do algoritmo até a geração de melhor resultado. O cromossomo da 110ª geração, que gerou o menor desbalanceamento, e a decodificação do mesmo está apresentado na Fig. 14.

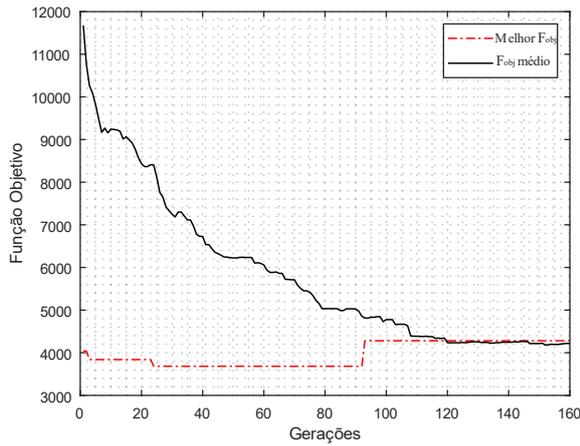


Figura 12. Gráfico de convergência do GA, relação melhor resultado da população com o valor médio.

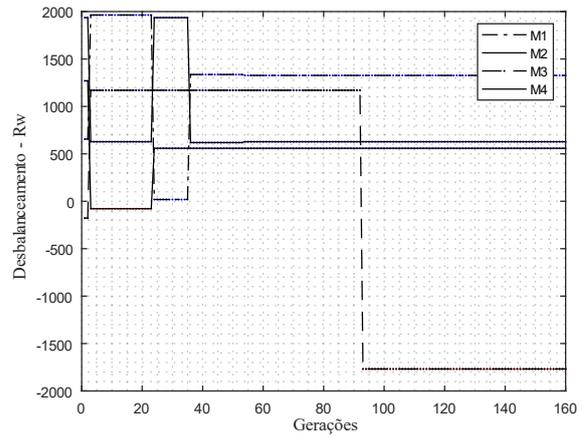


Figura 13. Visualização da ocupação de cada máquina ao longo das gerações. M1 a M4 são as esteiras de 1 a 4.

Cromossomo:	4	2	1	1	2	1	4	2	1	1	1	1	1	1
-------------	---	---	---	---	---	---	---	---	---	---	---	---	---	---

a) Representação do melhor indivíduo (cromossomo).

Peças	1	2	3	4	5	6
$x_i$	1	1	1	1	1	1

Peças \ Operações	1	2	3	4	5	6
1	1	3	4	3	4	2
2	1	3	4	3	1	2
3	1	3	-	-	4	2

b) Representação das variáveis de decisão da solução ótima.

Figura 14. Resultado da otimização por GA.

Os resultados de ocupação e consequentemente desbalanceamento das máquinas obtidos com a otimização por GA estão apresentados na Tab. 6. Nesta, pode-se perceber uma ocupação total de 76% das máquinas do setor, além da análise de variação de pessoas necessárias por máquina, que, de acordo com as restrições de disponibilidade do setor de montagem, é um limitante do domínio. Pode-se observar que a restrição quanto a quantidade máxima de efetivos não foi violada.

Tabela 6. Resultados da otimização para o setor de montagem.

Máquinas	Máximo de efetivos	Ocupação (%)	DB (%)
1	75	84	16
2	32	75	25
3	90	54	46
4	86	99	01
<b>Total</b>		<b>78</b>	<b>22</b>

#### 4.4. Comparação do Setor de Produção Atual e Após Aplicar GA

A partir dos resultados obtidos com o emprego do GA para definição do conjunto de peças a produzir no período de produção da demanda requisitada, é possível verificar analiticamente as diferenças de balanceamento da produção e quantidade de pessoas necessárias no setor para o período, como mostrado na Tab. 7. Ademais, dispondo da construção do cromossomo com melhor resultado, é factível a montagem de um layout de produção fixo para cada esteira, portanto, possibilita uma análise qualitativa da área fabril em comparação do cenário proposto com o atualmente executado em fábrica.

Tabela 7. Comparação entre a configuração atual com a otimizada pelo processo.

Esteiras	Configuração Atual				GA			
	Máx. de efetivos	Δefetivos	Ocupação (%)	DB (%)	Máx. de efetivos	Δefetivos	Ocupação (%)	DB (%)
1	115	3	118	-18	75	2	84	16
2	0	0	0	100	32	0	75	25
3	122	6	108	-08	90	6	54	46
4	46	3	66	34	86	3	99	01
<b>Total</b>	<b>283</b>	<b>12</b>	<b>73</b>	<b>40</b>	<b>283</b>	<b>11</b>	<b>78</b>	<b>22</b>

Permite-se com uma análise da Tab. 6 inferir que o algoritmo genético reduziu o desbalanceamento atual do setor e gerou um cenário de produção em que é respeitado o limite de trabalhadores máximos com menor necessidade de trocas no decorrer do período. Estas modificações permitem um equilíbrio favorável ao aumento do aproveitamento dos recursos, apesar da redução de ocupação das máquinas. Esta configuração permite a entrega da demanda das peças iniciadas no período. Com a análise dos resultados percebe-se a estabilização dos recursos no setor.

O resultado da aplicação de algoritmo genético no layout das esteiras para produção pode ser visto na Fig. 15, a qual apresenta os layouts de produção da situação atual contrastados com os obtidos por GA. A simbologia ilustrada nas colunas de 1 a 4, compreendem os postos de trabalho para o layout atual e otimizado, respectivamente. A esquerda está disposta a direita dos postos de trabalho, conforme layout de montagem apresentado esquematicamente na Fig. 15. Para cada período de produção são montados novos layouts e estes devem comportar todos os equipamentos e postos para os efetivos.

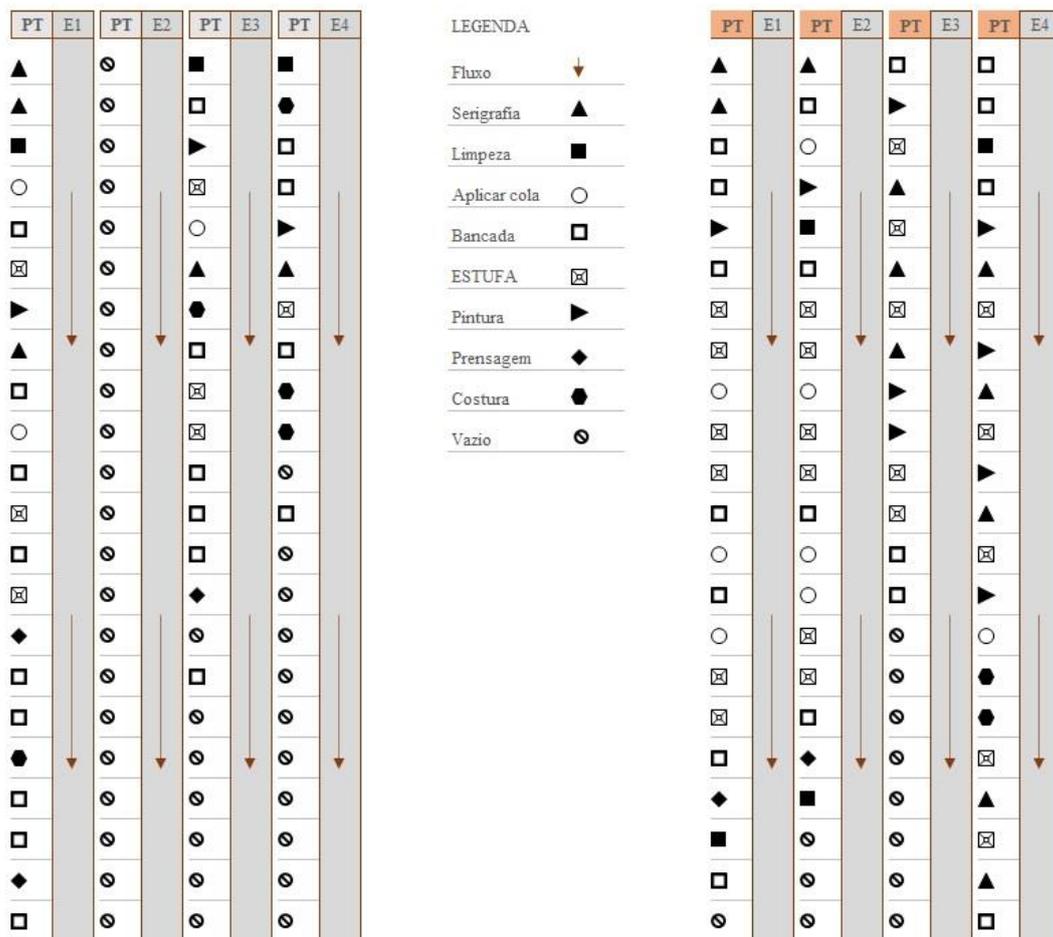


Figura 15. Comparação dos layouts de produção da situação atual, sem GA, e do resultado da otimização, com GA. Onde: PT = Posto de Trabalho; E1 a E4 = Numeração das esteiras de 1 a 4.

Contrastando os layouts apresentados, atual e pós GA, entende-se o efeito de uma produção com carga balanceada. Na figura do cenário atual é possível notar a esteira 02 sem necessidade de postos de operação ou equipamentos pois não receberia produtos, isto pois a empresa em questão trabalha atualmente com uma estratégia de distribuição de cores que não aloca um produto em mais de uma esteira, gerando espaços não produtivos, como visto na Fig. 15. Com isso, as demais esteiras do setor, como a esteira 01 ficam repletas de operações para que possa atender a todos os tipos de peças alocados, dessa forma além de grande variação e necessidade de efetivos, há uma necessidade de espaço físico que transforma o ambiente em desconfortável para o trabalhador. Com o cenário otimizado as operações estão distribuídas de forma mais uniforme nas esteiras evitando o aglomerado de máquinas e postos de trabalho que causam desconforto.

## 5. CONCLUSÃO

Este trabalho apresentou o desenvolvimento de um modelo numérico com propósito de balancear a produção de linhas de montagem, implementando algoritmo genético, um método meta-heurístico para solução.

Para validação do modelo numérico desenvolvido, um caso de literatura foi investigado inicialmente, o qual permitiu avaliar característica como a topologia da função objetivo e convergência da solução em termos do balanceamento da carga de trabalho bem como o excedente e sobressalente de alocação para cada máquina. O GA desenvolvido obteve resultados mais satisfatórios para ambas as funções, em comparação com os autores referenciados, sendo 78,08% para Z1 e 87,12% para Z2 para Shanker e Tzen (1985).

Quanto ao caso de estudo, a comparação dos layouts construídos corrobora com a análise numérica da situação, tal qual apresentou uma redução de 16% no desbalanceamento e 8% na variação de efetivos. Sendo o modelo desenvolvido aplicando GA uma opção viável e que proporciona maior conforto para os trabalhadores da fábrica.

Em conclusão, o algoritmo elaborado para o estudo de forma adaptada ao exposto por Shanker e Tzen (1985) é uma solução viável de execução para o setor industrial de montagem, estabelecendo novas áreas de pesquisa para inovações no sistema produtivo. Este trabalho apresenta potencial para desenvolvimentos futuros com a expansão para uma análise do setor de montagem completo e adição de restrições para aperfeiçoar a efetividade das soluções encontradas.

## 6. REFERÊNCIAS

- Arora, J.S., 2004, "Introduction to optimum design", 2nd ed. Elsevier Inc., pp 532 – 534.
- Cárdenas, J.C., Chávez, P.A. and Guadalupe, J., 2018, "Consumer expenditures on clothing and footwear: a mixed methods study", *Journal of Fashion Marketing and Management: An International Journal*, <https://doi.org/10.1108/JFMM-12-2016-0121>.
- Egilmez, G., Mese, E. M., Erenay, B., and Sürer, G.A., 2016, "Group scheduling in a cellular manufacturing shop to minimise total tardiness and nT: a comparative genetic algorithm and mathematical modelling approach". *International Journal of Services and Operations Management*, 24(1), 125-146.
- Forghani, K. and Mohammadi, M., 2013, "A genetic algorithm for solving integrated cell formation and layout problem considering alternative routings and machine capacities", Department of Industrial Engineering, Faculty of Engineering, Kharazmi University, Tehran, P. O. Box 15719-14911, Iran.
- Hazarika, M. and Laha, D., 2018, "Genetic algorithm approach for machine cell formation with alternative routings", Selection and Peer-review under responsibility of International Conference on Processing of Materials, Minerals and Energy (July 29th – 30th) 2016, Ongole, Andhra Pradesh, India.
- Holland, J.H., 1975, "Adaptation in natural and artificial systems.", 1975 The University of Michigan.
- Innocente, M.S., 2006, "Population-Based Methods: Particle Swarm Optimization – Development of a General-Purpose Optimizer and Applications", Universitat Politècnica de Catalunya, Barcelona, Master's thesis.
- Jackson I., Tolujevs J. and Reggelin T., 2018, "The Combination of Discrete-Event Simulation and Genetic Algorithm for Solving the Stochastic Multi-Product Inventory Optimization", *Transport and Telecommunication*, Vol. 19, no. 3, pp. 237.
- Jayakumar, V. and 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): 199-212.
- Kumar, A., Prakash, Tiwari, M.K., Shankar, R. Baveja, A., 2006, "Solving machine-loading problem of a flexible manufacturing system with constraint-based genetic algorithm", *European Journal of Operational Research* 175 (2006) 1043–1069.
- Lu, Y., Xu, X. and Wang, L., 2020, "Smart manufacturing process and system automation – A critical review of the standards and envisioned scenarios", *Journal of Manufacturing Systems* Vol. 56, July 2020, pp. 312-325.
- Mukhopadhyay, S.K., Midha, S. and Krishna, V.M., 1992, "A heuristic procedure for loading problems in flexible manufacturing systems", *The International Journal of Production Research*, 30:9, 2213-2228, DOI: 10.1080/00207549208948146.
- Quyen, N.T., James, C.C. and Yang, C., 2016, "Hybrid genetic algorithm to solve resource constrained assembly line balancing problem in footwear manufacturing", Springer-Verlag Berlin Heidelberg 2016, DOI 10.1007/s00500-016-2181-3.
- Rabbani, M., Farrokhi-Asl, H. and Ravanbakhsh, M., 2019, "Dynamic cellular manufacturing system considering machine failure and workload balance", *Journal of Industrial Engineering International*, pp. 25–40.

- Shanker, K. and Srinivasulu, A., 1989, “Some solution methodologies for loading problems in a flexible manufacturing system”, International Journal of Production Research, 27:6, 1019-1034, DOI: 10.1080/00207548908942605.
- Shanker, K. and Tzen, Y.J., 1985, “A loading and dispatching problem in a random flexible manufacturing system”, International Journal of Production Research, 23:3, 579-595, DOI: 10.1080/00207548508904730.
- Smith, E. A., Fogel, D., 2002, “Constraint-Handling Techniques - Penalty Functions. Handbook of Evolutionary Computation”, Institute of Physics Publishing and Oxford University Press, Bristol, U.K., Chapter C5.2 (2002)
- Tiwa Ri, M.K., Haza Rika, B., Vidya Rthi, N.K., Jaggi, P. and Mukhopadhyay, S.K., 1997, “A heuristic solution approach to the machine loading problem of an FMS and its Petri net model”, International Journal of Production Research, 35:8, 2269-2284, DOI: 10.1080/002075497194840.
- Venugopal, V. and Narendaran, T.T., 1992, “A genetic algorithm approach to the machine-component grouping problem with multiple objectives”, Computers and Industrial Engineering, 22, pp. 478-490.
- Yeniay, O., 2005, “Penalty Function Methods for Constrained Optimization with Genetic Algorithms”, Mathematical and Computational Applications, vol. 10, no. 1, pp. 45-56 (2005). doi:10.3390/mca10010045

## **A NEW GENETIC ALGORITHM APPROACH TO OPTIMIZE THE WORKLOAD BALANCE AND AMOUNT OF DELAYED PRODUCTION IN A CASE STUDY OF A FOOTWEAR INDUSTRY**

**Lísia Peroza Ruiz, ruiz.lisiaproza@gmail.com<sup>1</sup>**  
**Adelano Esposito, Adelano.esposito@farroupilha.ifrs.edu.br<sup>1</sup>**

<sup>1</sup>Federal Institute of Technology of Rio Grande do Sul, Av. São Vicente, 785, Farroupilha-RS, CEP 95174-274.

**Abstract.** Industries are facing the challenge of rearranging their layouts and equipment in a way it allows them to produce batches with less demand and greater variety of parts. Faced with this problem, heuristic optimization methods, such as genetic algorithms (GA), have shown promising results for solving problems involving the balancing of flexible manufacturing systems. Therefore, this work aims to propose a new approach to the genetic algorithm to optimize the workload balance and the number of delayed tasks in an application case in the footwear industry. Focusing on the development of a GA applied to an existing framework, a linear chromosome representation was used to load the manufacturing system information to the genetic operators responsible for the optimization process. A mathematical method is proposed with the aim to minimize the unbalance of the sector, improving the capacity and quality of this analysis, the convergency and capability to optimize a factory line is tested in comparison with other authors works. As so, it was allowed to assemble a new layout for the studied industry and contrast it with the current configuration. The results of 40% unbalance improved to 22% showing that the standard GA obtained a better balance.

**Keywords:** genetic algorithm, optimization, manufacture, footwear