

UNIVERSIDADE FEDERAL DO PARANÁ

IGOR KHATCHERIAN FOGAÇA

PROGRAMAÇÃO DA PRODUÇÃO: DESENVOLVIMENTO DE UM ALGORITMO DE
SWARM INTELLIGENCE PARA O PROBLEMA DO *JOB SHOP SCHEDULING*

JANDAIA DO SUL

2024

IGOR KHATCHERIAN FOGAÇA

PROGRAMAÇÃO DA PRODUÇÃO: DESENVOLVIMENTO DE UM ALGORITMO DE
SWARM INTELLIGENCE PARA O PROBLEMA DO *JOB SHOP SCHEDULING*

Trabalho de Conclusão de Curso II apresentado ao curso de Graduação em Engenharia de Produção, Campus Jandaia do Sul, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia de Produção.

Orientador: Prof. Dr. Marco Aurélio Reis dos Santos

JANDAIA DO SUL

2024

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)
UNIVERSIDADE FEDERAL DO PARANÁ
SISTEMA DE BIBLIOTECAS – BIBLIOTECA JANDAIA DO SUL

Fogaça, Igor Khatcherian

Programação da produção: desenvolvimento de um algoritmo de *Swarm Intelligence* para o problema do *Job Shop Scheduling*. / Igor Khatcherian Fogaça. – Jandaia do Sul, 2024.

1 recurso on-line : PDF.

Monografia (Graduação) – Universidade Federal do Paraná,
Campus Jandaia do Sul, Graduação em Engenharia de Produção.
Orientador: Prof. Dr. Marco Aurélio Reis dos Santos.

1. Programação da produção. 2. Sequenciamento. 3. *Job Shop Scheduling*. 4. *Swarm Intelligence*. 5. Meta-heurísticas. I. Santos, Marco Aurélio Reis dos. II. Universidade Federal do Paraná. III. Título.

CDD: 658.5

Bibliotecário: César A. Galvão F. Conde - CRB-9/1747



UNIVERSIDADE FEDERAL DO PARANÁ

PARECER Nº 123/2024/UFPR/R/JA/CCEP
PROCESSO Nº 23075.079917/2019-87
INTERESSADO: IGOR KHATCHERIAN FOGACA

TERMO DE APROVAÇÃO DE TRABALHO DE CONCLUSÃO DE CURSO

TÍTULO: PROGRAMAÇÃO DA PRODUÇÃO: DESENVOLVIMENTO DE UM ALGORITMO DE *SWARM INTELLIGENCE* PARA O PROBLEMA DO *JOB SHOP SCHEDULING*

Autor(a): IGOR KHATCHERIAN FOGAÇA

Trabalho de Conclusão de Curso apresentado como requisito parcial para a obtenção do grau no curso de Engenharia de Produção, aprovado pela seguinte banca examinadora.

DR. MARCO AURÉLIO REIS DOS SANTOS (Orientador)

DR. RAFAEL GERMANO DAL MOLIN FILHO

DRA. JULIANA VERGA SHIRABAYASHI



Documento assinado eletronicamente por **MARCO AURELIO REIS DOS SANTOS, PROFESSOR DO MAGISTERIO SUPERIOR**, em 18/12/2024, às 10:50, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **RAFAEL GERMANO DAL MOLIN FILHO, PROFESSOR DO MAGISTERIO SUPERIOR**, em 18/12/2024, às 10:57, conforme art. 1º, III, "b", da Lei 11.419/2006.



Documento assinado eletronicamente por **JULIANA VERGA SHIRABAYASHI, PROFESSOR DO MAGISTERIO SUPERIOR**, em 18/12/2024, às 18:10, conforme art. 1º, III, "b", da Lei 11.419/2006.



A autenticidade do documento pode ser conferida [aqui](#) informando o código verificador **7379734** e o código CRC **3BE04E99**.

Dedico este trabalho ao meu avô, Hampartsoum Khatcherian, cujo sonho era estudar e me ver formado.

AGRADECIMENTOS

Primeiramente a Deus, pela vida, pelas oportunidades e pelo direcionamento, e por ter me sustentando com saúde, paz e amor.

A minha família, em especial a minha mãe Nancy Hampartsoum Khatcherian por ser minha inspiração de ser uma pessoa melhor todos os dias, por me apoiar, me ajudar sendo um exemplo de motivação, zelo, conhecimento e amor, a minha tia Julie Hampartsoum Khatcherian por estar sempre ao meu lado, me ouvir, e me apoiar incondicionalmente e ao meu pai, onde quer que ele esteja sempre olhando por mim e me direcionando ao caminho certo.

Ao meu orientador Prof. Dr. Marco Aurélio Reis dos Santos cujo sem seu apoio, motivação, confiança, realizações e orientações este trabalho não seria possível.

A todos os professores da Universidade Federal do Paraná Campus Avançado de Jandaia do Sul pelo acolhimento, conhecimento e parceria, em especial ao Prof. Dr. Rafael Germano Dal Molin Filho e ao Prof. Dr. Rodrigo Clemente Thom de Souza que me direcionaram, apoiaram e ajudaram desde o início até o fim da pesquisa.

Aos meus colegas pelo suporte, motivação e compreensão e por estarem ao meu lado na minha trajetória.

"Somos e seremos a média das cinco pessoas que nos relacionamos, portanto nos cerquemos de pessoas que possuem princípios, amor à família, amor ao próximo, que desejam crescer em conhecimento, prosperar honestamente e sobretudo que ame à Deus sob todas as coisas"

Augusto Souto

RESUMO

A Programação da Produção desempenha um papel crucial nas empresas, sendo responsável por definições importantes dentro do sistema produtivo: quanto, quando e em que ordem produzir, entre outras atribuições. Este estudo aborda o problema de *scheduling* em um ambiente produtivo no formato *job shop*, conhecido na literatura como o problema do *Job Shop Scheduling*. Devido à sua complexidade computacional, meta-heurísticas têm sido frequentemente empregadas para sua solução. No entanto, alcançar um desempenho comparável ao estado da arte depende de uma exploração eficiente das características do espaço de soluções deste problema. Algoritmos meta-heurísticos se destacam por desenvolverem diversas soluções e mesclar as melhores características de cada uma para a busca de uma solução com melhor *fitness* (características que se aproximem ao objetivo estabelecido) ao problema, no caso o menor *makespan* (instante de tempo que a última operação que compõe o roteiro produtivo foi concluída). Porém, métodos já existentes analisam apenas um cenário estático, dificultando sua aplicabilidade em contextos reais. Este estudo visou desenvolver um algoritmo de *Swarm Intelligence* (SI) para o problema do *Job Shop Scheduling* (JSSP), com o objetivo de buscar soluções de diversos cenários para prevenção de imprevistos que ocorrem no cotidiano das empresas. Foram gerados algoritmos para a busca de um ótimo local, servindo como um ponto de partida para o algoritmo de SI buscar novas soluções, um algoritmo no CPLEX para o JSSP foi desenvolvido para a comparação dos resultados junto ao ótimo global de todas as instâncias. Os efeitos alcançados pelo estudo foram satisfatórios, o algoritmo proposto obteve êxito no agendamento em todas as instâncias testadas, e, em comparação a outros algoritmos, apresentou um custo computacional baixo, exibindo um tempo de processamento de 0,3 segundos por iteração, considerado mediano em comparação à outros algoritmos e utilizando 17% da capacidade total do equipamento nas instâncias maiores, e apresentando o menor custo de processamento por iteração em comparação a todos os outros algoritmos testados ao longo da pesquisa requerendo apenas 0,00408 GB por iteração do processador.

Palavras-chave: Programação da Produção. Sequenciamento. *Job Shop Scheduling*. *Swarm Intelligence*. Meta-heurísticas.

ABSTRACT

Production Scheduling plays a crucial role in companies, as it is responsible for key decisions within the production system: how much, when and in what order to produce, among other tasks. This study addresses the scheduling problem in a job shop production environment, commonly referred to in the literature as the Job Shop Scheduling Problem. Due to its computational complexity, metaheuristics have often been employed to solve it. However, achieving performance comparable to the state-of-the-art depends on efficiently exploring the solution space's characteristics for this problem. Metaheuristic algorithms stand out by generating diverse solutions and combining the best characteristics of each one to find a solution with improved fitness (features closer to the established objective). For this problem, the objective is the minimization of the makespan (the time when the last operation in the production sequence is completed). Nevertheless, existing methods typically analyze only a static scenario, which limits their applicability in real-world contexts. This study aimed to develop a Swarm Intelligence (SI) algorithm for the Job Shop Scheduling Problem (JSSP), in order to seek solutions for different scenarios to prevent unforeseen events that occur in the daily routine of companies. Algorithms were generated to search for a local optimum, serving as a starting point for the SI algorithm to search for new solutions, an algorithm in CPLEX for the JSSP was developed to compare the results with the global optimal of all instances. The effects of this study were satisfactory: the proposed algorithm successfully scheduled all tested instances. Compared to other algorithms, it showed a low computational cost, with a processing time of 0.3 seconds per iteration and using 17% of the system's total capacity in larger instances, demonstrating the lowest processing cost per iteration compared to all other algorithms tested throughout the research, requiring only 0.00408 GB of processor memory per iteration.

Keywords: Production Scheduling. Sequencing. Job Shop Scheduling. Swarm Intelligence. Metaheuristics.

LISTA DE EQUAÇÕES E INEQUAÇÕES

EQUAÇÃO 1 - FUNÇÃO OBJETIVO DO MODELO.....	51
INEQUAÇÃO 2 - RESTRIÇÕES DE TEMPO DE INÍCIO PARA O <i>JOB</i> 1	52
INEQUAÇÃO 3 - RESTRIÇÕES DE TEMPO DE INÍCIO PARA O <i>JOB</i> 2	52
INEQUAÇÃO 4 - RESTRIÇÕES DE PRECEDÊNCIA DO <i>JOB</i> 1	52
INEQUAÇÃO 5 - RESTRIÇÕES DE PRECEDÊNCIA DO <i>JOB</i> 2	52
INEQUAÇÃO 6 - VARIÁVEIS BOOLEANAS PRIORIZAÇÃO DE RECURSOS	53
INEQUAÇÃO 7 - RESTRIÇÕES DE RECURSOS PARA MÁQUINA 1	53
INEQUAÇÃO 8 - RESTRIÇÕES DE RECURSOS PARA MÁQUINA 2	53
INEQUAÇÃO 9 - RESTRIÇÕES DE RECURSOS PARA MÁQUINA 3	53
INEQUAÇÃO 10 - RESTRIÇÕES DE NÃO NEGATIVIDADE	53
INEQUAÇÃO 11 - MAKESPAN CONCLUSÃO DA ÚLTIMA OPERAÇÃO	53

LISTA DE FIGURAS

FIGURA 1 - ESTRUTURA DA PESQUISA.....	23
FIGURA 2 - NÍVEIS DE PLANEJAMENTO	26
FIGURA 3 - FATORES QUE AFETAM A CAPACIDADE DE PRODUÇÃO	27
FIGURA 4 - REPRESENTAÇÃO LEAD TIME.....	29
FIGURA 5 - RELAÇÃO LEAD TIME X TEMPO DE CICLO.....	29
FIGURA 6 - ATIVIDADES PPCP X NÍVEL PLANEJAMENTO	30
FIGURA 7 - COMPETÊNCIAS DA PROGRAMAÇÃO DA PRODUÇÃO	33
FIGURA 8 - VOLUME E CUSTOMIZAÇÃO POR AMBIENTE PRODUTIVO	35
FIGURA 9 - ILUSTRAÇÃO FILAS DE PRODUÇÃO	37
FIGURA 10 - REPRESENTAÇÃO GRÁFICO DE GANTT	37
FIGURA 11 - RAMIFICAÇÕES DE ALGORITMOS BIO-INSPIRADOS	39
FIGURA 12 - CAPACIDADES DE SWARM INTELLIGENCE.....	40
FIGURA 13 - FUNCIONAMENTO GERAL DE UMA META-HEURÍSTICA	42
FIGURA 14 - FUNCIONAMENTO GERAL DO CSA	44
FIGURA 15 - PESQUISA CIENTÍFICA EM ENGENHARIA DE PRODUÇÃO	48
FIGURA 16 - ENQUADRAMENTO DA PESQUISA	49
FIGURA 17 - ETAPAS PARA MODELOS EM PESQUISA OPERACIONAL.....	50
FIGURA 18 - ROTEIROS DE PRODUÇÃO	50
FIGURA 19 - ESQUEMATIZAÇÃO <i>JOB SHOP SCHEDULING</i>	51
FIGURA 20 - FLUXOGRAMA ETAPAS DA METODOLOGIA.....	54
FIGURA 21 - ETAPAS APLICAÇÕES.....	56
FIGURA 22 - ALGORITMO 1	57
FIGURA 23 - ALGORITMO 2	58
FIGURA 24 - ALGORITMO 3	58
FIGURA 25 - ALGORITMOS 4 e 5.....	59
FIGURA 26 - ALGORITMO 6	60
FIGURA 27 - ALGORITMO 7	60
FIGURA 28 - SOLUÇÃO INSTÂNCIA INICIAL.....	62
FIGURA 29 - SOLUÇÃO INSTÂNCIA 2	64
FIGURA 30 - INSTÂNCIA 3 X COMBINAÇÃO 1.....	65
FIGURA 31 - INSTÂNCIA 3 X COMBINAÇÃO 2.....	65

FIGURA 32 - SOLUÇÃO INSTÂNCIA 3	66
FIGURA 33 - INSTÂNCIA 4 X COMBINAÇÃO 1	68
FIGURA 34 - INSTÂNCIA 4 X COMBINAÇÃO 2.....	68
FIGURA 35 - SOLUÇÃO INSTÂNCIA 4	69
FIGURA 36 - DESEMPENHO BAT ALGORITHM	71
FIGURA 37 - DESEMPENHO GREY WOLF OPTIMIZER IMPROVED	72
FIGURA 38 - SOLUÇÃO BAT ALGORITHM.....	73
FIGURA 39 - SOLUÇÃO GREY WOLF OPTIMIZER IMPROVED	73
FIGURA 40 - SOLUÇÃO FLOWER POLLINATION ALGORITHM	75

LISTA DE QUADROS

QUADRO 1 - REGRAS DE PRIORIZAÇÃO EM AMBIENTES JOB SHOP	38
QUADRO 2 - FUNCIONAMENTO DO CSA APLICADO AO JSSP	45
QUADRO 3 - ALGORITMOS COMPARATIVOS X CLASSIFICAÇÕES	70

LISTA DE TABELAS

TABELA 1 - DADOS INSTÂNCIA INICIAL	49
TABELA 2 - AGENDAMENTO INSTÂNCIA INICIAL	62
TABELA 3 - AGENDAMENTO INSTÂNCIA 2	63
TABELA 4 - AGENDAMENTO INSTÂNCIA 3	67
TABELA 5 - AGENDAMENTO INSTÂNCIA 4	70
TABELA 6 - COMPARAÇÕES FINAIS.....	76

LISTA DE ABREVIATURAS OU SIGLAS

AP	- <i>Awareness Probability</i>
BA	- <i>Bat Algorithm</i>
CSA	- <i>Crow Search Algorithm</i>
DJSSP	- <i>Dynamic Job Shop Scheduling Problem</i>
FIFO	- <i>First In – First Out</i>
FL	- <i>Flight Length</i>
FPA	- <i>Flower Pollination Algorithm</i>
GA	- <i>Genetic Algorithm</i>
GWOI	- <i>Grey Wolf Optimizer Improved</i>
JSSP	- <i>Problema do Job Shop Scheduling</i>
LIFO	- <i>Last In – First Out</i>
MES	- <i>Manufacturing Execution System</i>
PMP	- <i>Plano Mestre de Produção</i>
PPCP	- <i>Planejamento, Programação e Controle da Produção</i>
PRI	- <i>Priority Service</i>
PSO	- <i>Particle Swarm Optimization</i>
SA	- <i>Simulated Annealing</i>
SI	- <i>Swarm Intelligence</i>
SIRO	- <i>Service In Random Order</i>

SUMÁRIO

1 INTRODUÇÃO	17
1.1 CONTEXTUALIZAÇÃO	17
1.2 PROBLEMA DE PESQUISA	19
1.3 JUSTIFICATIVA	20
1.4 OBJETIVOS	21
1.4.1 Objetivo geral	21
1.4.1.1 Objetivos específicos	22
1.5 APRESENTAÇÃO DO TRABALHO	22
2 REVISÃO BIBLIOGRÁFICA	24
2.1 ADMINISTRAÇÃO DA PRODUÇÃO	24
2.1.1 Níveis de Planejamento	25
2.1.2 Capacidade produtiva	26
2.1.3 Lead Time	28
2.2 PLANEJAMENTO, PROGRAMAÇÃO E CONTROLE DA PRODUÇÃO	30
2.2.1 Programação da Produção	31
2.3 JOB SHOP SCHEDULING	34
2.3.1 Representações do Problema do <i>Job Shop Scheduling</i>	37
2.3.2 Regras de Priorização	38
2.4 SWARM INTELLIGENCE	39
2.4.1 Crow Search Algorithm	43
2.5 CONSIDERAÇÕES FINAIS SOBRE A REVISÃO	45
3 MÉTODOS DE PESQUISA	47
3.1 CLASSIFICAÇÃO DA PESQUISA	47
3.2 CARACTERIZAÇÃO DO OBJETO DE PESQUISA	49
3.3 PROTOCOLO DA PESQUISA	54
3.3.1 Planejamento da pesquisa	54
3.3.2 Coleta, tabulação e análise dos dados	55
3.3.3 Etapas das aplicações	55
4 RESULTADOS E DISCUSSÕES	57
4.1 CONSTRUÇÃO DE SOLUÇÕES INICIAIS	57
4.2 APLICAÇÃO DO <i>CROW SEARCH ALGORITHM</i> (CSA)	61
4.2.1 Instância inicial – 2 <i>jobs</i> X 3 máquinas	61
4.2.2 Instância 2 – 3 <i>jobs</i> X 3 máquinas	63
4.2.3 Instância 3 – 4 <i>jobs</i> X 4 máquinas	64

4.2.4 Instância 4 – 5 <i>jobs</i> X 3 máquinas	67
4.3 APLICAÇÃO OUTROS ALGORITMOS.....	70
4.3.1 Resultados meta-heurísticas <i>Swarm Based</i>	71
4.3.2 Resultados meta-heurística Evolucionária	74
4.3.3 Resultados meta-heurística Física	74
4.3.4 Resultados meta-heurísticas Ecológica	74
4.4 CONSIDERAÇÕES FINAIS	75
5 CONCLUSÃO	77
5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS	78
REFERÊNCIAS.....	79

1 INTRODUÇÃO

Este capítulo contextualizará os conceitos acerca da pesquisa, trará o problema de pesquisa, justificará o trabalho, explanará os objetivos e por fim uma breve apresentação do trabalho.

1.1 CONTEXTUALIZAÇÃO

No atual contexto altamente competitivo, a busca pela excelência operacional deixa de ser um mero diferencial para tornar-se fundamental à sobrevivência das empresas. De acordo com Peinado e Graeml (2007), fator determinante para o sucesso ou fracasso de qualquer organização é a forma de sua administração.

“A principal preocupação das empresas, ao menos no setor privado, tem recentemente se voltado para como gerenciar suas áreas funcionais de modo a obter, manter e ampliar seu poder competitivo” (Corrêa e Corrêa, 2017, p. 424).

Para Tubino (2017), empresas, dentro da Engenharia de Produção, comumente são consideradas como uma entidade transformadora que converte recursos de entrada (insumos) em saídas (produtos acabados) que apresentem utilidade ao consumidor final.

Conforme definido por Caetano Júnior (2018), as empresas se organizam em três níveis de planejamento. O nível estratégico, de longo prazo, é responsável por decisões cujos efeitos serão percebidos somente após um período considerável, impactando a empresa como um todo. O planejamento tático, por sua vez, é uma extensão do estratégico, aplicado aos setores da empresa, com prazos variando de médio a longo prazo. Já o planejamento operacional aborda objetivos específicos e mensuráveis, de curto prazo, e envolve as áreas de gestão mais operacionais da empresa.

O Planejamento, Programação e Controle da Produção (PPCP), como destacado por Tubino (2017), surge como uma das principais áreas de estudo da gestão da produção. Dentro das empresas, o PPCP atua como a área responsável pelo gerenciamento e aplicação dos recursos produtivos que visa atender os planos estabelecidos nos níveis de planejamento.

Corrêa e Corrêa (2017), esclarecem que, a Programação da Produção aborda o planejamento de curto prazo e tem como principal responsabilidade a distribuição de atividades ao longo do tempo disponível, sempre levando em consideração as

restrições dos conjuntos. A Programação da Produção é considerada a primeira etapa do nível organizacional da administração, sendo responsável por funções que estão diretamente ligadas ao processo produtivo dentro das organizações.

Segundo Fernandes (2002), o problema do *Job Shop Scheduling* (JSSP), consiste em sequenciar um conjunto de trabalhos, onde cada trabalho é composto por um número ordenado de operações distribuído a um determinado conjunto de máquinas, em uma ordem pré-estabelecida de precedência do processo, visando melhorar uma determinada medida de desempenho.

De acordo com Tubino (2017), o JSSP é a atividade que visa determinar a melhor sequência de produção para os itens ou lotes que devem ser fabricados, utilizando de forma inteligente os recursos disponíveis, com o objetivo de produzir produtos de qualidade e ao mesmo tempo buscar uma redução de custos.

Yang *et al.* (2013, p. 3, tradução nossa)¹ exploram o alcance e a popularidade da computação bio-inspirada:

A computação bio-inspirada permeou quase todas as áreas das ciências, engenharia e indústrias, desde mineração de dados até otimização, da inteligência computacional ao planejamento de negócios, e da bioinformática às aplicações industriais. De fato, é talvez um dos assuntos de pesquisa mais ativos e populares, com amplas conexões multidisciplinares.

Yang *et al.* (2013), observam que, a *Swarm Intelligence* (SI), uma ramificação da programação bio-inspirada, vem ganhando cada vez mais atenção, cuja razão deve-se ao fato de algoritmos desta natureza expõem notável flexibilidade e versatilidade, além de altamente eficientes na resolução de problemas não lineares com aplicabilidade no contexto industrial.

Thom de Souza (2018, tradução nossa)² explica a inspiração dos algoritmos de SI, sua aplicação e principal premissa:

¹ Bio-inspired computation has permeated into almost all areas of sciences, engineering, and industries, from data mining to optimization, from computational intelligence to business planning, and from bioinformatics to industrial applications. In fact, it is perhaps one of the most active and popular research subjects with wide multidisciplinary connections.

² Swarm Intelligence algorithms are inspired by social behavior of a group of agents. These algorithms are applied in such way that each agent searches adaptively in the feature space for the optimal subset communicating with one other and with their environment to achieve the optimal solution. As the swarm intelligence algorithms modify and combine good solutions to ensure that the search space is explored more efficiently by testing various solutions to the same problem in parallel.

Os algoritmos de *Swarm Intelligence* são inspirados pelo comportamento social de um grupo de agentes. Esses algoritmos são aplicados de forma que cada agente busca adaptativamente no espaço de características pelo subconjunto ótimo, comunicando-se uns com os outros e com seu ambiente para alcançar a solução ideal. À medida que os algoritmos de *Swarm Intelligence* modificam e combinam boas soluções, garantem que o espaço de busca seja explorado de maneira mais eficiente, testando várias soluções para o mesmo problema em paralelo.

Existem diversas técnicas para definir o melhor sequenciamento para o JSSP. No entanto, todas acabam adotando o mesmo cenário, o de que todos os recursos produtivos (máquinas, ferramentas e operadores) estejam disponíveis, o que muitas vezes não é observado na realidade. A partir dessa premissa, surgem diversas soluções tecnológicas, como a aplicação de algoritmos de SI, que oferecem um maior poder de processamento e análise de diversos cenários diferentes.

Um sequenciamento da produção bem definido e adaptável a diversos cenários torna-se um pilar poderoso, podendo ser considerado um diferencial dentro das empresas. Isso ocorre porque não necessariamente requer intervenção humana para lidar com cada cenário adverso no cotidiano empresarial, permitindo uma adaptação dinâmica do sistema de produção.

1.2 PROBLEMA DE PESQUISA

Fontes, Homayouni e Fernandes (2022), discutem o problema do *Job Shop Scheduling* (JSSP) como um desafio que requer a otimização da sequência de operações em um ambiente de produção, onde várias tarefas devem ser executadas em máquinas específicas, uma de cada vez e sem interrupções. Cada tarefa consiste em várias operações que devem ser realizadas em uma ordem específica, de acordo com as precedências impostas pelo processo, e em máquinas designadas, cada uma com seu próprio tempo de processamento.

Muitas métricas de desempenho têm sido estudadas no contexto do JSSP, entretanto, a mais comum é a busca pela sequência de operações que minimize o tempo total de conclusão de todas as tarefas, conhecido como *makespan*.

Segundo Zhang *et al.* (2024), o JSSP representa um desafio significativo devido à falta de informações antecipadas sobre eventos dinâmicos. Além disso, métodos exatos não são eficazes, pois tendem a considerar um único cenário e são

mais adequados para fornecer soluções em pequena escala e em cenários estáticos onde todos os recursos estão disponíveis.

Soluções heurísticas de escalonamento, que utilizam regras de prioridade para a escolha da ordem, como a menor data de entrega ou o menor tempo de processamento, têm sido frequentemente aplicadas para resolver o JSSP. No entanto, os sequenciamentos baseados nesse método são adequados apenas para o cenário específico para o qual foram projetados, não podendo ser aplicados em outros cenários que apresentem adversidades.

Com o objetivo de superar as limitações mencionadas anteriormente, a aplicação de algoritmos de *Swarm Intelligence* (SI), surge como uma solução que tem sido amplamente estudada nos últimos anos para a aplicação de melhores técnicas de sequenciamento em diversos cenários.

Ao longo das últimas décadas, pesquisadores têm se empenhado em buscar soluções mais eficazes para o JSSP. O desenvolvimento de um algoritmo de SI representa uma solução tecnológica que visa suprir as lacunas de métodos menos eficazes já existentes na literatura.

Neste contexto, o presente trabalho visa desenvolver um algoritmo de SI que busque uma solução eficaz para o desafio do JSSP, respondendo à pergunta: “Como adaptar dinamicamente o sequenciamento do sistema de produção para enfrentar cenários não estáticos?”.

1.3 JUSTIFICATIVA

Conforme citado por Ribeiro e Cordeiro (2020), uma proposta eficiente e eficaz no sequenciamento da produção pode trazer diversos benefícios como redução de custos, aumento da produtividade e redução de tempo ocioso dentro dos processos industriais. Portanto, encontrar uma solução efetiva para o problema de programação de ordens de produção resultará em melhorias no desenvolvimento das atividades produtivas.

O estudo do problema do *Job Shop Scheduling* (JSSP), oferece uma base sólida, utilizando técnicas para compreensão de como melhorar a alocação de recursos para o aumento da eficiência e da produtividade em ambientes de produção. Além disso, o JSSP requer um desenvolvimento de habilidades analíticas e de

resolução de problemas por sua complexidade envolvida onde cada trabalho pode exigir uma sequência específica de máquinas e operações.

Deste modo, estudar o JSSP, não só contribui para a compreensão teórica da Engenharia de Produção, bem como prepara para enfrentar os desafios práticos do Planejamento, Programação e Controle da Produção (PPCP) em ambientes industriais reais.

Os métodos atuais para resolver o JSSP não oferecem soluções eficazes para os sistemas de produção. Ao se basearem em métodos determinísticos que procuram uma solução ótima para um único cenário, eles limitam a confiabilidade dos resultados, uma vez que, no dia a dia das empresas, nem sempre todos os recursos estão disponíveis devido a manutenções corretivas, preventivas, falta de operadores, entre outros fatores que podem perturbar o sistema produtivo.

Schneider e Corso (2020), apontam a necessidade de lidar com situações que causam perturbações e oscilações no fluxo de produção dentro das empresas. Neste cenário, algoritmos de *Swarm Intelligence* (SI) vêm se tornando cada vez mais populares como um meio de solucionar o JSSP pela sua flexibilidade e adaptabilidade. Além desses fatores, juntamente destaca-se a integração de outros métodos aliados à aplicação dos algoritmos.

Diante do cenário apresentado, este trabalho se justifica pela oportunidade de aprimoramento dos métodos de determinação de soluções para o JSSP. A aplicação de algoritmos de SI, que realizam análises dinâmicas nos sistemas produtivos para lidar com diversos cenários observados no cotidiano das empresas, é um caminho convergente com a necessidade das empresas de alcançar a excelência em seus sistemas de produção.

1.4 OBJETIVOS

Nesta seção, serão discutidos o objetivo geral e os objetivos específicos do presente trabalho.

1.4.1 Objetivo geral

Este estudo visa desenvolver um algoritmo de *Swarm Intelligence* (SI) para o problema do *Job Shop Scheduling* (JSSP), com o objetivo de buscar soluções de

diversos cenários para prevenção de imprevistos que ocorrem no cotidiano das empresas.

1.4.1.1 Objetivos específicos

1. Mapear os processos que compõe o roteiro de produção dos produtos;
2. Definir as precedências obrigatórias das etapas produtivas;
3. Mensurar tempos de processamento das etapas;
4. Elaborar um algoritmo de SI para o JSSP;
5. Analisar a viabilidade dos resultados obtidos;
6. Propor método de sequenciamento modelo *job shop* da abordagem proposta.

1.5 APRESENTAÇÃO DO TRABALHO

O trabalho ora apresentado será estruturado em 5 principais capítulos, cada um representando uma etapa, a saber pela Figura 1.

FIGURA 1 - ESTRUTURA DA PESQUISA



FONTE: (Autor, 2024).

2 REVISÃO BIBLIOGRÁFICA

Este capítulo está dividido em quatro subcapítulos conexos para contextualização do projeto de pesquisa, a saber:

- Administração da Produção;
- Planejamento, Programação e Controle da Produção (PPCP);
- *Job Shop Scheduling*;
- *Swarm Intelligence*.

2.1 ADMINISTRAÇÃO DA PRODUÇÃO

A Administração da Produção, a fim de manter sua competitividade no mercado, desempenha um papel fundamental na gestão de recursos escassos, sejam eles humanos, maquinários, informacionais ou outros, conforme destacado por Corrêa e Corrêa (2017). Uma boa gestão das operações e uma administração eficaz dos recursos, possibilitam garantir o atendimento das necessidades e desejos dos clientes em termos de qualidade, tempo e custo.

Conforme ressaltado por Slack *et al.* (2002), o conceito de Administração da Produção, abrange as atividades produtivas, as decisões e o planejamento realizados em conjunto com os gerentes de produção.

Segundo Oliveira (2023), a função de produção é a razão da existência das empresas, visto que, é responsável pela estratégia de fabricação de bens e serviços - função central dentro das organizações.

Ademais, a eficiência e eficácia da função de produção impactam diretamente na capacidade da empresa de atender às demandas do mercado e sustentar vantagens competitivas. Uma Administração de Produção juntamente com uma gestão de operações bem estruturada não só assegura a qualidade e a pontualidade na entrega dos produtos como também reduz os custos operacionais. Conforme Shingo (1989), a função produção se caracteriza por sua constante busca pela minimização de custos operacionais relacionados aos processos produtivos, acarretando também uma maior satisfação dos clientes.

A função de produção também mantém a coordenação das atividades produtivas, como o planejamento, organização, sequenciamento, direção e controle, sempre alinhada aos níveis de planejamento da empresa, seguindo os objetivos e estratégias estabelecidos em cada nível. Essa coordenação é essencial para garantir

a integração entre as diversas áreas da empresa, promovendo a consistência e a sinergia necessárias para alcançar os resultados desejados (Oliveira, 2023).

2.1.1 Níveis de Planejamento

Tubino (2017), esclarece que a administração produtiva do sistema de produção de uma empresa deve ser dividida em três níveis de planejamento: estratégico, tático e operacional. Cada um desses níveis, apresenta uma abrangência e um horizonte de tempo distintos.

Corrêa e Corrêa (2017), sustentam esta premissa, defendendo que o plano deve dividir o problema de Planejamento da Produção em subproblemas de menor escala, resolvendo-os em sequência. A prioridade deve ser dada aos subproblemas com maior horizonte de tempo, seguindo então para os de menor horizonte.

O planejamento no nível estratégico de uma organização corresponde à um horizonte de tempo de longo prazo e as decisões afetam a empresa como um todo por sua complexidade. São exemplos de decisões no nível estratégico definição de políticas empresariais, escolha de linhas de produto, instalações da empresa tais como: fábricas, armazéns e centros produtivos (Tubino, 2017).


No contexto da produção, a estratégia é definida como um plano de longo prazo para a produção de produtos e serviços de uma empresa, atuando como um guia que direciona a função de produção para garantir que suas estratégias de negócios sejam efetivamente implementadas. Conforme destacado por Corrêa e Corrêa (2017), o objetivo da estratégia de operações é assegurar que os processos de produção e entrega de valor ao cliente estejam alinhados com a intenção estratégica da empresa, tanto em relação aos resultados financeiros esperados quanto aos mercados-alvo, além de estarem adaptados ao ambiente em que a empresa opera.

No nível tático, há um horizonte de tempo de médio prazo, e as decisões nesse nível envolvem principalmente a preparação do sistema de produção para atender à demanda esperada no período estipulado. As responsabilidades no nível tático incluem o planejamento das necessidades de materiais, recursos de fábrica e operadores necessários para a produção, conforme descrito por Oliveira (2023) em relação ao Plano Mestre de Produção (PMP).

Sua principal importância está em servir como um elo entre os níveis estratégico e operacional, orientando as etapas de programação e execução das

atividades entre o planejamento estratégico e as atividades operacionais por meio do PMP.

No nível operacional, são englobadas as decisões diretamente ligadas às operações produtivas do sistema de produção e se enquadram em decisões de curto prazo. Exemplos deste nível de planejamento são a Programação da Produção e controle de estoques (Corrêa e Corrêa, 2017). Os níveis de planejamento são representados na Figura 2.



FONTE: (Scoreplan, 2023).


Na Figura 2 é ilustrada a perspectiva das responsabilidades de cada nível de planejamento, juntamente com as respectivas escalas de tempo, indicando quando suas decisões impactarão a realidade da empresa.

2.1.2 Capacidade produtiva

Segundo Chiavenato (2022), a capacidade produtiva de uma empresa é definida como o potencial produtivo disponível. Em outras palavras, é o que a empresa consegue produzir com seu sistema de produção nas condições de volume ideal para a fabricação de produtos e serviços. O autor também destaca que o volume ideal nem sempre corresponde ao máximo de produção que a empresa pode atingir, mas sim ao volume em que a empresa consegue obter o máximo de lucratividade e o mínimo de custos de produção, manutenção e mão de obra.

Chiavenato (2022), também destaca que existem fatores-chave para a definição da capacidade produtiva de uma empresa, que afetam diretamente o quanto ela pode produzir em condições normais do seu sistema. Os quatro subfatores principais são a capacidade instalada, a mão de obra disponível, a matéria-prima disponível e os recursos financeiros conforme ilustrado na Figura 3.

FIGURA 3 - FATORES QUE AFETAM A CAPACIDADE DE PRODUÇÃO



FONTE: (Chiavenato, 2022).

Chiavenato (2022), expande o significado desses quatro subfatores. Segundo o autor, a capacidade instalada é a quantidade de máquinas e equipamentos, e o potencial produtivo que a empresa possui em seu sistema de produção. A capacidade instalada representa a produção possível se todas as máquinas e equipamentos estiverem disponíveis em sua plenitude, operando no máximo desempenho e de forma contínua.

Vale ressaltar que cada máquina apresenta um tempo de processamento específico para o processo que está realizando e um limite de tempo disponível para o funcionamento. Estes fatores devem ser levados em consideração, especialmente no contexto da Programação da Produção.

A mão de obra disponível refere-se à quantidade de operadores que a empresa pode alocar dentro de seus processos produtivos, uma vez que, para efeito de produção são necessários operadores para operacionalização das máquinas e dos equipamentos (Chiavenato, 2022).

A matéria-prima disponível representa os insumos e materiais básicos que o processo necessita e que são fornecidos diretamente à empresa pelos fornecedores. A falta desses, pode causar paralisação ou atraso na produção (Chiavenato, 2022).

Os recursos financeiros remetem à capacidade financeira que a empresa possui para os investimentos na produção, como a aquisição de máquinas e equipamentos. Este subfator é essencial quando a empresa busca aumentar sua capacidade produtiva, pois afeta outros subfatores que limitam diretamente o seu potencial produtivo (Chiavenato, 2022).

2.1.3 Lead Time


De acordo com Martins (2003), o *lead time* é o período necessário para que um produto passe do estágio de pedido até a entrega, incluindo o tempo de produção. Em resumo, o *lead time* é o intervalo em que o cliente receberá o produto encomendado da empresa. Isto é, o tempo total que um produto leva para ser entregue ao consumidor, desde o momento do pedido, passando pela produção, despacho e entrega.

Tubino (1999), explica que, ao calcular o *lead time* de produção, considera-se o tempo de manufatura até que o item esteja disponível em estoque, focando exclusivamente no tempo de fabricação. É crucial analisar onde ocorrem atrasos nos processos para tornar o *lead time* mais eficiente. Assim, ao longo do processo produtivo, o *lead time* pode ser entendido como a soma de todos os tempos de ciclo ³ individuais de cada etapa do processo. Reduzir esse período implica em uma gestão eficiente, priorizando entregas ágeis em um mercado que exige respostas rápidas e um ritmo acelerado de consumo.

O conceito de *lead time* desde seu início (pedido do cliente) até o final (entrega do produto ao cliente) é ilustrado na Figura 4.

³ O tempo necessário para a execução de uma peça ou a duração de uma etapa na fabricação da peça. (Becker e Scholl, 2006).


FIGURA 4 - REPRESENTAÇÃO LEAD TIME



FONTE: (Voitto, 2019).

Conforme mencionado anteriormente, o *lead time* é o tempo total desde a realização do pedido do cliente até sua entrega. Para Tubino (1999), é o tempo necessário para que o produto esteja disponível no estoque da empresa. Seguindo esse entendimento, o *lead time* pode ser considerado como a soma de todos os tempos de ciclo que compõem o processo, conforme ilustrado na Figura 5.

FIGURA 5 - RELAÇÃO LEAD TIME X TEMPO DE CICLO



FONTE: (Voitto, 2019).

Uma boa Programação da Produção desempenha um papel crucial na melhoria dos tempos de *lead time*. Ao planejar eficientemente as etapas de produção, é possível minimizar os tempos de espera e maximizar a utilização dos recursos disponíveis. Isso inclui a organização das atividades de maneira a evitar gargalos, a sincronização dos processos e a antecipação de possíveis problemas que possam causar atrasos (Lustosa *et al.*, 2008).

As empresas podem reduzir significativamente o *lead time* com uma programação bem estruturada, aumentando assim a satisfação do cliente e a

competitividade no mercado. A Programação da Produção permite uma visão mais clara e controlada do fluxo de trabalho, facilitando ajustes em tempo real e garantindo que os prazos sejam cumpridos de forma mais eficiente (Oliveira, 2023).


2.2 PLANEJAMENTO, PROGRAMAÇÃO E CONTROLE DA PRODUÇÃO

Chiavenato (2022), elucida que, nenhuma empresa que visa atingir seus objetivos produz na base do improviso, sendo imprescindível o planejamento e controle eficaz da produção. Nesse sentido, o Planejamento, Programação e Controle da Produção (PPCP) desempenha um papel fundamental para as organizações que buscam aumentar sua eficiência e eficácia.

O PPCP, conforme descrito por Bugor e Filho (2021), corresponde às atividades técnicas e administrativas que propõem planos que orientam e controlam a produção. Posto isto, o PPCP é definido como um conjunto de ações inter-relacionadas que coordenam o sistema produtivo em conjunto com os demais setores da empresa.

“O Planejamento e Controle da Produção é responsável pela coordenação e aplicação dos recursos produtivos de modo a atender da melhor forma possível aos planos estabelecidos nos níveis estratégico, tático e operacional” (Lustosa, 2008, p. 15). Dessa forma, podemos compreender o PPCP como uma função de apoio. Cada nível de planejamento executa uma atividade importante que compõe o PPCP como elucidado na Figura 6.

FIGURA 6 - ATIVIDADES PPCP X NÍVEL PLANEJAMENTO



FONTE: (Menezes e Marinho, 2023).

Conforme demonstrado na Figura 6, o PPCP desempenha um papel decisivo na integração dos diferentes níveis de planejamento dentro de uma empresa: estratégico, tático e operacional.

Segundo Tubino (2017), PPCP atua como o elo que liga estes níveis, garantindo uma coordenação eficiente entre eles. A conexão entre o PPCP e cada um dos níveis de planejamento, conforme descrito pelo autor, segue:

No nível estratégico: O PPCP está envolvido na criação do Plano de Produção, que estabelece as diretrizes de longo prazo para a capacidade produtiva, investimentos em infraestrutura e alinhamento com as metas corporativas. Este plano é fundamental para garantir que a empresa esteja preparada para atender à demanda futura, considerando fatores como previsão e expansão de capacidade.

No nível tático: O PPCP elabora o Plano-Mestre de Produção (PMP), que traduz as diretrizes estratégicas em ações concretas de médio prazo. O PMP detalha os volumes de produção necessários para atender à demanda prevista, distribuindo os recursos de forma eficiente e ajustando a capacidade produtiva conforme necessário.

No nível operacional: O PPCP se concentra na Programação da Produção, onde as atividades diárias e semanais são organizadas para garantir que os produtos sejam fabricados de acordo com os prazos estabelecidos. A Programação da Produção envolve a alocação de tarefas específicas às máquinas e operadores, redução dos tempos de setup e redução de paradas e de tempos ociosos, garantindo que a operação diária seja eficiente e alinhada com os objetivos táticos e estratégicos da empresa.

2.2.1 Programação da Produção

A Programação da Produção é a primeira a ser enquadrada no nível operacional de planejamento dentro das empresas, e aborda o planejamento de curto prazo. Corrêa e Corrêa (2017), indicam que, a Programação da Produção está no coração do *Manufacturing Execution System* (MES).

A definição de MES de acordo com Corrêa e Corrêa (2017, p. 437)

É um sistema de informações e comunicação com várias funções e competências. Inclui funções como alocação e acompanhamento da situação de recursos, programação detalhada de operações, despacho de unidades produzidas e controle de documentação. Pode prover realimentação do que ocorre na unidade fabril em tempo real.

Corrêa e Corrêa (2017), ressalta ainda, que a Programação da Produção se define como a alocação das atividades em determinado instante de tempo, respeitando as restrições do processo produtivo.

De acordo com Ramos e Ferreira (2017), a Programação da Produção é responsável por definir as quantidades a serem produzidas e estabelecer o sequenciamento dos lotes.

Martins *et al.* (2015) elucida que, a Programação da Produção é uma das tarefas mais difíceis e complexas do Planejamento, Programação e Controle da Produção (PPCP), que envolve a combinação de diversos recursos dentro de um sistema de produção para criar um cronograma de operações, sendo uma atividade essencial para as empresas.

Slack, Brandon-Jones e Burgess (2023), destacam que a Programação da Produção é uma das tarefas mais desafiadoras na gestão de produção. Primeiramente, os programadores precisam gerenciar simultaneamente diversos tipos de recursos. As máquinas possuem capacidades e especializações distintas, enquanto o pessoal apresenta diferentes níveis de habilidades. O desafio principal é que, o número de combinações possíveis de programação cresce exponencialmente conforme aumenta o número de atividades e processos. Por exemplo, se uma máquina tem cinco trabalhos distintos para processar, qualquer um deles pode ser o primeiro, seguido por qualquer um dos quatro restantes, assim sucessivamente.

Segundo Prado *et al.* (2012), uma programação bem-feita resulta na utilização eficiente dos recursos, sendo um dos principais fatores que influenciam o desempenho do sistema produtivo da empresa.

Stevenson (2001), esclarece que uma programação bem elaborada e com uso inteligente dos recursos disponíveis pode proporcionar vantagem competitiva no mercado atual. Enquanto uma programação inadequada resulta em um sistema de produção subutilizado.


Slack, Brandon-Jones e Burgess (2023), salientam conjuntamente algumas técnicas de Programação da Produção habitualmente adotadas pelas empresas. A programação para frente envolve iniciar o trabalho tão logo ele chegue. A programação para trás envolve iniciar o trabalho no último momento possível sem que ele sofra atraso. A escolha entre técnicas dependerá das circunstâncias específicas

do sistema produtivo. Porém, o planejamento e controle de uma operação deve permitir a avaliação dos efeitos de programações alternativas.

Conforme Nunes, Melo e Nigro (2009), é necessário adotar uma abordagem de curtíssimo prazo na Programação da Produção, para que possa responder às suas três principais perguntas: 1) Quais ordens de produção executar; 2) Qual quantidade produzir e 3) Quando a ordem deve ser executada. Isso permite que os responsáveis elaborem um conjunto de rotinas que atendam à demanda, respeitando a capacidade produtiva do sistema.

As competências gerais da Programação da Produção podem ser observadas na Figura 7.

FIGURA 7 - COMPETÊNCIAS DA PROGRAMAÇÃO DA PRODUÇÃO



FONTE: (Adaptado de Slack, 2002).

A Programação da Produção, por via de regra, visa responder as três principais perguntas citadas na Figura 7, atreladas ao volume de produção, o momento de produzir e a prioridade em que devem ser feitas.

O presente trabalho tem como finalidade abordar o sequenciamento das operações como o objeto de estudo. Especificamente o sequenciamento em

ambientes de produção *job shop* comumente denominado como o problema do *Job Shop Scheduling*.

2.3 JOB SHOP SCHEDULING

“Sequenciamento das operações refere-se a definir as prioridades (a ordem) segundo as quais as atividades devem ocorrer num sistema de operações, no intuito de atingir um conjunto de objetivos de desempenho” (Corrêa e Corrêa, 2017, p. 497).

Rosa (2019), evidencia que, os problemas de *scheduling* são ramificações de problemas de otimização combinatória que possuem grande importância. Eles são aplicados tanto no âmbito acadêmico quanto em indústrias manufatureiras. Dentro dos ambientes produtivos, podemos destacar três principais modelos de *scheduling*: o *job shop*, o *flow shop* e o *open shop*.

A autora expande seu entendimento para cada um dos ambientes de Programação da Produção, como segue:


Job Shop: Em um ambiente de produção tipo *job shop*, as tarefas (*jobs*) possuem suas próprias sequências e roteiros de produção específicos, ou seja, cada *job* deve passar por máquinas específicas em uma ordem determinada, respeitando a restrição de precedência das operações. Neste ambiente, realça-se ademais que, os *jobs* devem passar apenas uma vez por cada máquina.

Flow Shop: O ambiente produtivo tipo *flow shop* é uma variação do *job shop*, onde as máquinas disponíveis estão dispostas em série. Cada *job* deve ser processado em uma das máquinas e todos os *jobs* seguem a mesma sequência de máquinas. Após ser processado em uma máquina, o *job* entra em uma fila para aguardar o processamento na próxima máquina do seu roteiro de produção. Normalmente, as filas seguem o critério *First In First Out* (FIFO), onde um *job* que entrou na fila posteriormente não pode ser processado antes de um *job* que estava aguardando na fila anteriormente.

Open Shop: No ambiente do *open shop*, outro modelo de Programação da Produção, os *jobs* não têm uma sequência fixa de máquinas a serem seguidas. Ao contrário, cada *job* pode ser processado em qualquer máquina, desde que as operações sejam realizadas na ordem correta.

A Figura 8 mostra os ambientes produtivos conforme o volume de produção e a customização dentro dos possíveis ambientes de Programação da Produção.

FIGURA 8 - VOLUME E CUSTOMIZAÇÃO POR AMBIENTE PRODUTIVO



FONTE: (Becker e Schutte, 2009).

De acordo com Wang, Zhang e Yang (2019), o problema do *Job Shop Scheduling* (JSSP) é um dos mais conhecidos problemas de otimização combinatória. Ao longo das últimas décadas, os JSSPs receberam muita atenção e diversas técnicas foram desenvolvidas para resolver JSSPs estáticos. Entretanto, os ambientes industriais são complexos por natureza, com a ocorrência de eventos em tempo real, como a chegada de novos trabalhos, falhas de máquinas e alterações nas datas de entrega. Estes eventos podem tornar o cronograma inicial ineficaz ou até inválido, exigindo o agendamento dinâmico (ou reprogramação) para atualizar o cronograma com base nas novas condições. Entre estes eventos, a chegada de novos trabalhos pode ocorrer com mais frequência em um mercado em constante mudança. Portanto, é essencial focar nos problemas de agendamento dinâmico considerando a chegada de novos trabalhos no ambiente de manufatura moderno.

Nos últimos anos, os problemas de agendamento dinâmico têm recebido mais atenção. Diversas abordagens de reprogramação foram desenvolvidas em diferentes ambientes de manufatura, incluindo sistemas de manufatura de máquina única, sistemas de manufatura de máquinas paralelas, *flow shops*, *job shops* e sistemas de manufatura flexíveis. No entanto, em comparação com outros ambientes de manufatura, há menos estudos sobre o problema de agendamento dinâmico do *job shop* (DJSSP)⁴ devido à sua alta complexidade. Os estudos sobre DJSSPs remontam

⁴ Dynamic Job Shop Scheduling Problem

a 1974, quando Holloway e Nelson (1974) desenvolveram um procedimento heurístico de agendamento multi-passos para DJSSPs com datas de entrega e tempos de processamento variáveis. Posteriormente, eles ampliaram o problema para incluir chegadas intermitentes de trabalhos e tempos de processamento estatísticos. Desde então, o interesse pelo problema de agendamento dinâmico tem aumentado.

O JSSP pode ser descrito como um conjunto de n *jobs* que devem ser processados em um conjunto de m máquinas, com cada *job* contendo um número específico de operações, onde cada operação possui seu tempo de processamento determinado, na máquina correspondente, conforme posto por Rosa (2019).

Lin *et al.* (2010), explica que no contexto do JSSP, cada operação usa uma das máquinas para completar o trabalho de um *job* em um intervalo de tempo fixo. Uma vez que uma operação é processada em uma determinada máquina, ela não pode ser interrompida antes do término do processamento da operação. A sequência de operações de um *job* deve ser predefinida e pode ser diferente para cada *job*. Em geral, um *job* sendo processado em uma máquina é considerado uma operação.

Os autores ainda ressaltam que, cada máquina pode processar apenas uma operação durante o intervalo de tempo. O objetivo do JSSP é encontrar uma permutação apropriada das operações para todos os *jobs* que minimize o *makespan*, melhor dizendo, o tempo de conclusão da última operação no cronograma de operações (Lin *et al.*, 2010).


“No caso de *job shops*, múltiplas tarefas necessitam ser realizadas, passando por múltiplos centros de trabalho; para tanto, elas têm de ser roteirizadas ao longo de sequências de centros de trabalho para que possam ser completadas.” (Corrêa e Corrêa, 2017, p. 498).

Corrêa e Corrêa (2017), exemplificam que uma ordem de produção recém-chegada no sistema entra para uma fila junto a outras ordens, aguardando que as máquinas necessárias para seu processamento fiquem livres para que possam seguir para a preparação e execução. Sendo assim, evidencia-se a necessidade da gestão de operação em decidir qual a posição na fila que a ordem receberá de acordo com critérios definidos pela empresa.

Na Figura 9, é possível observar o comportamento de um ambiente *job shop*, ilustrando como as ordens de produção competem pelas mesmas máquinas. Isso confirma a importância de definir bem as regras de priorização das filas, o que resulta

em um menor tempo de conclusão das operações (*makespan*) e permite entregas mais rápidas aos clientes.

FIGURA 9 - ILUSTRAÇÃO FILAS DE PRODUÇÃO




FONTE: (GRV, 2018).

2.3.1 Representações do Problema do *Job Shop Scheduling*

O problema do *Job Shop Scheduling* (JSSP), comumente utiliza a ferramenta do Gráfico de Gantt para a melhor representação visual das utilizações das operações nas máquinas ao longo do tempo, bem como facilita a visualização do tempo total de conclusão de todas as operações, ou seja, o *makespan* (Rosa, 2019), conforme mostrado na Figura 10.

FIGURA 10 - REPRESENTAÇÃO GRÁFICO DE GANTT



FONTE: (Lin *et al.*, 2022).

A Figura 10 representa a ferramenta Gráfico de Gantt no contexto do JSSP. Verifica-se que o gráfico utilizado por Lin *et al.* (2022) apresenta o eixo das abscissas representando a unidade de tempo enquanto o eixo das ordenadas representa as máquinas presentes no ambiente produtivo (M1, M2 e M3)⁵. As formas de retângulos dentro do gráfico representam as operações e onde elas foram alocadas (máquina e instante de tempo). Ainda é possível observar que o *makespan* da solução apresentada é igual a 15 unidades de tempo, pois é neste instante que todas as operações são finalizadas.

2.3.2 Regras de Priorização

Corrêa e Corrêa (2017), evidenciam que:

Por muitos anos, a pesquisa em sequenciamento de operações debruçou-se sobre descobrir qual a regra de sequenciamento mais eficaz. Como se trata de problema multiobjetivo e complexo, logo ficou claro que não há uma regra de sequenciamento mágica que maximize o desempenho da unidade produtiva em todos os aspectos.

Costa (1996), demonstrou que existem fatores que afetam a adaptabilidade de um sistema à uma determinada regra de priorização no sequenciamento produtivo, desde a capacidade produtiva às peculiaridades e volume das ordens de produção que o ambiente produtivo recebe.

As regras de sequenciamento usuais para a definição de prioridades na operação em ambientes *job shop* é elucidado no Quadro 1.

QUADRO 1 - REGRAS DE PRIORIZAÇÃO EM AMBIENTES JOB SHOP

Sigla	Regra	Definição
FIFO	<i>First In First Out</i>	Primeiro a chegar ao centro de trabalho, recebe prioridade na operação
FSFO	<i>First In the System, First Out</i>	Primeira ordem que chega na unidade é a que recebe prioridade na operação
SOT	<i>Shortest Operation Time</i>	A tarefa com menor tempo de processamento, recebe prioridade na operação
EDD	<i>Earliest Due Date</i>	A tarefa que apresenta prazo de entrega mais apertado, é a que recebe priorização na operação

FONTE: (Adaptado de Corrêa e Corrêa, 2017).


⁵ M1 – Máquina 1, M2 – Máquina 2 e M3 – Máquina 3.

2.4 SWARM INTELLIGENCE

Os algoritmos bio-inspirados desempenham um papel significativo na identificação de respostas otimizadas para problemas dados em modelos matemáticos conforme abordado por Anuradha, Krishna e Mallik (2023). A origem desses algoritmos começa com o Algoritmo Genético, inspirado no processo de reprodução dos seres vivos, que foi posteriormente expandido para resolver um número considerável de problemas no campo da otimização.

A Figura 11 apresenta as principais ramificações dos algoritmos bio-inspirados, separados em evolucionários, baseados em teorias da evolução, *Swarm Based*, inspirados em comportamentos de grupos de animais e os ecológicos, cujo desenvolvimento baseiam-se em sistemas da ecologia. Entre estes algoritmos, destacam-se, por sua popularidade, a Otimização por Enxame de Partículas, a Otimização por Colônia de Formigas, a Busca do Cuco, os Algoritmos de Colônia de Abelhas Artificiais, o Otimizador Lobo Cinzento, entre outros.


FIGURA 11 - RAMIFICAÇÕES DE ALGORITMOS BIO-INSPIRADOS



FONTE: (Adaptado de Thomas, 2020).

Yang *et al.* (2019), definem *Swarm Intelligence* (SI) como uma abordagem de computação inspirada em sistemas biológicos que tem despertado considerável interesse nas últimas duas décadas, com diversos algoritmos de otimização baseados em SI ganhando ampla popularidade. Este interesse e popularidade podem ser atribuídos a várias razões, dentre as quais se destacam a flexibilidade e versatilidade desses algoritmos, bem como sua alta eficiência na solução de problemas não lineares com aplicações práticas em empresas e indústrias.

De acordo com Dehuri, Ghosh e Cho (2011), SI lida com o comportamento coletivo de sistemas compostos por muitos indivíduos que interagem localmente entre si e com o ambiente, utilizando formas de controle descentralizado e auto-organização para alcançar seus objetivos, simulando um sistema biológico presente na natureza. A Figura 12 traz uma perspectiva desse cenário.



FONTE: (TechFerry, 2021).

A Figura 12 aponta algumas capacidades e possíveis aplicações da SI em problemas observados no cotidiano das empresas. As aplicações variam em diversas áreas, desde a busca por soluções ótimas (*optimization*) em problemas onde apresentam um ótimo bem definido, problemas de classificação e divisão (*clustering*), aplicações em roteamento (*routing*) à problemas de sequenciamento (*scheduling*)

onde a SI apresenta desempenho muito promissor em problemas onde existem inúmeros ótimos locais sem um ótimo global bem definido (Yang *et al.*, 2019).

O estudo das meta-heurísticas pertence ao subcampo da otimização estocástica, uma área que engloba algoritmos e técnicas utilizando algum nível de aleatoriedade para encontrar soluções ótimas para problemas complexos (*NP-Hard*)⁶. As meta-heurísticas são métodos inteligentes e flexíveis, com uma estrutura de componentes genéricos que podem ser adaptados a diferentes problemas. Elas combinam procedimentos de busca locais com estratégias de alto nível, criando um processo que consegue escapar de mínimos locais e realizar uma busca abrangente no espaço de soluções (Luzia e Rodrigues, 2009; Marrouche, 2024).

As meta-heurísticas são consideradas por Mishra *et al.* (2022), um procedimento de alto nível, projetadas para encontrar e gerar uma heurística que possa produzir uma solução suficientemente boa para problemas de otimização, especialmente em cenários com informações incompletas ou imperfeitas ou que não possuem um ótimo fixo. Métodos meta-heurísticos descrevem os resultados sempre observados com base em experimentos computacionais com os algoritmos. Além disso, as meta-heurísticas são mais flexíveis do que os métodos tradicionais porque, inicialmente, são definidos em termos gerais, permitindo que sejam adaptados para atender às necessidades da maioria dos problemas de otimização do mundo real se provando uma alternativa viável e, muitas vezes, superior aos métodos tradicionais (exatos) de otimização inteira mista e programação dinâmica.

Isto posto, as meta-heurísticas são métodos inteligentes e flexíveis, caracterizados por uma estrutura de componentes genéricos adaptáveis ao problema específico conforme abordado por Arroyo (2002). Essas abordagens são capazes de integrar novas situações e explorar o espaço de soluções, permitindo a seleção estratégica de soluções previamente encontradas, com o objetivo de superar a otimalidade local. Embora não garantam a otimalidade global, as meta-heurísticas são eficazes em identificar múltiplos ótimos locais.

Algoritmos meta-heurísticos são métodos de otimização que visam encontrar soluções aproximadas para problemas complexos de otimização, onde métodos exatos podem ser inviáveis devido à alta complexidade. Eles são particularmente úteis

⁶ Problemas cujo o número de escolhas é elevado e é difícil encontrar um algoritmo polinomial apropriado para resolvê-lo (Tkatek *et al.*, 2020)


em problemas que possuem um grande espaço de busca e múltiplos ótimos locais como o problema do *Job Shop Scheduling*.

As características principais dos algoritmos meta-heurísticos são: a) Flexibilidade: Podem ser aplicados a uma ampla gama de problemas de otimização; b) Exploração e Exploração: Equilibram a exploração (a capacidade do algoritmo de investigar novas áreas do espaço de busca) e exploração (a capacidade do algoritmo de refinar soluções promissoras encontradas durante a exploração) e c) Adaptabilidade: Podem ajustar seus parâmetros e estratégias com base no progresso da busca.

Vale destacar que, um dos maiores desafios no design de algoritmos meta-heurísticos é encontrar o equilíbrio certo entre exploração e exploração. Muitas vezes realizado por tentativa e erro.

Landes (2017), exemplifica o comportamento de uma meta-heurística como uma aplicação de perturbações em soluções preliminarmente encontradas a fim de encontrar novas soluções que se aproximem mais do possível ótimo global do problema.

A Figura 13 explana visualmente o funcionamento da lógica apresentada, sendo o ponto s descrito na imagem como uma solução inicial. Uma perturbação é aplicada gerando o ponto s' , uma solução menos viável, e partir deste ponto pós-perturbação encontrou-se o ponto s'' , um ponto de melhor desempenho se comparado ao inicial na busca de uma possível minimização.



FONTE: (Temponi, 2007).

Thom de Souza (2018), esclarece que esses algoritmos analisam soluções candidatas viáveis no espaço de busca. As avaliações ocorrem de maneira iterativa, com várias soluções sendo avaliadas em cada geração. Entre essas técnicas, os algoritmos bio-inspirados, aqueles que são inspirados em sistemas naturais, se destacam.

2.4.1 Crow Search Algorithm

O *Crow Search Algorithm* (CSA) foi desenvolvido por Askarzadeh, inspirado nos comportamentos dos corvos em relação ao seu alimento. Corvos possuem um alto nível de inteligência, sendo capazes de reconhecer indivíduos pela aparência. Devido a essa inteligência, os corvos têm um comportamento único com seu alimento: quando não o consomem completamente, tendem a escondê-lo em locais seguros e lembram-se perfeitamente desses lugares para se alimentarem posteriormente. Além disso, corvos seguem uns aos outros na tentativa de localizar os esconderijos de alimentos de outros corvos, buscando roubar esses estoques (Hussien *et al.*, 2020).

No contexto do CSA, essa lógica comportamental é replicada. Os agentes do algoritmo (corvos) atuam como exploradores em seu ambiente. Sua memória é influenciada aleatoriamente por parâmetros estabelecidos durante o desenvolvimento, e a proximidade aos esconderijos de alimentos serve como função objetivo. O local com o melhor esconderijo, ou seja, o que contém a maior quantidade de alimento, é considerado o ótimo global (Lee *et al.*, 2023).

Lee *et al.* (2023), salienta a existência de dois parâmetros principais no CSA: o *Awareness Probability* (AP) e o *Flight Length* (FL). AP determina a probabilidade de um agente (corvo) ser influenciado pelo agente mais próximo da função objetivo (melhor *fitness*). Sendo um parâmetro probabilístico, varia de 0 a 1. Em problemas com múltiplos ótimos, um valor baixo de AP é geralmente adotado para favorecer a exploração do espaço de busca. Em problemas com um único ótimo bem definido, um valor alto de AP é mais comum.

O parâmetro FL define a distância máxima que um agente pode percorrer em uma iteração. Ele é crucial para equilibrar a exploração e a exploração na busca por soluções. Valores altos de FL favorecem a exploração, expandindo o espaço de busca, enquanto valores baixos restringem os movimentos dos agentes, promovendo uma exploração mais localizada (Thaher *et al.*, 2024). O algoritmo CSA tem seu funcionamento geral descrito pela Figura 14.

FIGURA 14 - FUNCIONAMENTO GERAL DO CSA

Algorithm 1: Crow Search Algorithm

```

1: begin
2: Randomly initialize the position of a flock of  $N$  crows
3: Evaluate the position of the crows
4: Initialize the memory of each crow
5: while maximum generation is not reached do
6:   for  $i = 1 : N$  (all  $N$  crows of the flock)
7:     Randomly choose one of the crows to follow
8:     Define an awareness probability
9:     if  $r_j > AP^{j,t}$ 
10:       $x^{i,t+1} = x^{i,t} + r_j \times fl^{i,t} \times (m^{j,t} - x^{i,t})$ 
11:    else
12:       $x^{i,t+1}$  = a random position of search space
13:    end if
14:  end for
15:  Check the feasibility of new positions
16:  Evaluate the new position of the crows
17:  Update the memory of crows
18: end while
19: end

```

FONTE: (Thom de Souza, 2018).

Embora os parâmetros do algoritmo muitas vezes sejam definidos por tentativa e erro, alcançar um equilíbrio entre exploração e exploração é geralmente o ideal. Em suma, os parâmetros devem ser ajustados conforme a natureza do problema em questão. O funcionamento do CSA aplicado o problema do *Job Shop Scheduling* (JSSP) com todas as suas etapas é ilustrado no Quadro 2.

QUADRO 2 - FUNCIONAMENTO DO CSA APLICADO AO JSSP

Passos	Descrição
Passo 1	Inicializar o problema com a modelagem matemática definida
Passo 2	Inicializar a posição e memória dos agentes (corvos) de maneira aleatória
Passo 3	Avaliar a função objetivo com a solução inicial encontrada no passo 2
Passo 4	Gerar novas posições para o processo de novas soluções (Loop principal do Algoritmo)
Passo 5	Avaliar a função objetivo com a solução encontrada no passo 4
Passo 6	Atualizar memória dos agentes (corvos)
Passo 7	Verificar o critério de parada. Caso satisfeito, encerra o Algoritmo. Caso não satisfeito retorna ao passo 4

FONTE: (Adaptado de Thom de Souza, 2018).

2.5 CONSIDERAÇÕES FINAIS SOBRE A REVISÃO

Após a discussão da revisão bibliográfica, onde foram estabelecidos diversos conceitos relevantes para a aplicação da pesquisa, fica evidenciada a relevância da Programação da Produção, especialmente do sequenciamento produtivo em ambientes *job shop*, diretamente ligados à capacidade produtiva das empresas.

Este capítulo começou com a abordagem do cenário competitivo atual e a importância histórica que a Administração da Produção teve no desenvolvimento de técnicas para uma melhor gestão e aumento da produtividade das empresas desde o seu surgimento. Foram apresentados alguns dos conceitos que compõe a Administração da Produção, como os níveis de planejamento, capacidade produtiva e o *lead time*.

Em seguida, abordou-se uma das áreas de atuação da Engenharia de Produção: o Planejamento, Programação e Controle da Produção (PPCP), atuando como uma ferramenta para aumentar o controle acerca do sistema produtivo, focando, mais especificamente, na Programação da Produção - o segmento que primeiro se enquadra no nível operacional das empresas.

Subsequentemente, discutiu-se temas específicos sobre o *Job Shop Scheduling*, caracterizando ambientes, apresentando suas peculiaridades e o problema de sequenciamento que este ambiente apresenta. Exemplificou-se ferramentas e regras de priorização comumente aplicadas pelas empresas para sequenciar sua produção.

Adiante, conceitos acerca de *Swarm Intelligence* e computação bio-inspirada foram colocados, juntamente com sua crescente aplicação em diversas áreas de conhecimento, com destaque para o *Crow Search Algorithm*, o algoritmo proposto pela pesquisa.

Acerca dessa lógica, todos os conceitos necessários para o desenvolvimento da pesquisa foram abordados neste capítulo. Embasando e direcionando a pesquisa para as próximas etapas da elaboração de um algoritmo de *Swarm Intelligence* para o problema do *Job Shop Scheduling*.

3 MÉTODOS DE PESQUISA

A metodologia da pesquisa refere-se à aplicação de um método que serve como um guia para conduzir e aplicar uma pesquisa científica, utilizando caminhos, ferramentas e procedimentos (Nascimento, 2016).

Uma pesquisa deve ser planejada metodologicamente para cumprir os requisitos. Neste viés, essa seção classificará o enquadramento da pesquisa, caracterizará o objeto de pesquisa, apresentará as etapas de desenvolvimento e o cronograma de realizações.

3.1 CLASSIFICAÇÃO DA PESQUISA

A natureza da pesquisa deste trabalho, conforme a classificação de pesquisa em Engenharia de Produção, enquadra-se na categoria de pesquisa aplicada. A pesquisa aplicada é aquela que possui interesse prático, com o objetivo de aplicar os resultados na solução de problemas concretos observados na realidade (Turrioni e Mello, 2012; Appolinário, 2013).

Segundo Cauchick (2019), como a pesquisa visa desenvolver estratégias e ações para melhorar os resultados previamente obtidos na literatura e comparar o desempenho com outras abordagens que trataram do problema em questão, ela apresenta objetivos normativos. Bertrand e Fransoo (2002) definem que a pesquisa normativa tem como principal interesse o desenvolvimento de políticas, estratégias e ações para aperfeiçoar resultados e comparar várias abordagens a um problema específico.

A pesquisa adota uma abordagem quantitativa, uma vez que as informações relacionadas ao problema em questão podem ser todas convertidas e traduzidas em números. “Dessa forma, como vários autores afirmam, o ato de mensurar variáveis de pesquisa é a característica mais marcante da abordagem quantitativa. Isso, por vezes, é a única forma de justificar a adoção da abordagem” (Cauchick, 2018, p.47).


Consequentemente, serão aplicadas modelagens matemáticas, definindo a função objetivo e suas restrições para analisar as informações do problema do *Job Shop Scheduling* (JSSP) presentes neste trabalho. Ao final da aplicação do modelo, será determinado o melhor *makespan* encontrado. Reforçando assim, sua abordagem quantitativa.

Referente ao método e seus procedimentos, emprega-se a modelagem e simulação. Este método é aplicado quando deseja-se realizar experimentações através de um modelo que simula um sistema real a fim de observar e determinar como este sistema se comportaria com as abordagens especificadas pela pesquisa como descrito por Turrioni e Mello (2012).

“A Modelagem e Simulação é considerado um delineamento de pesquisa muito comum em estudos de Programação da Produção, principalmente em se tratando de ambientes complexos e dinâmicos” (Dall'agnol, 2023).

A Figura 15 apresenta as classificações de pesquisa comumente adotadas em pesquisas científicas dentro da área de Engenharia de Produção.


FIGURA 15 - PESQUISA CIENTÍFICA EM ENGENHARIA DE PRODUÇÃO



FONTE: (Turrioni e Mello, 2012).

A Figura 16 ilustra o enquadramento da pesquisa adotadas e descritas neste trabalho.

FIGURA 16 - ENQUADRAMENTO DA PESQUISA



FONTE: (Autor, 2024).

Nessa perspectiva, a pesquisa se classifica como uma pesquisa axiomática normativa. Ela busca variar um modelo de otimização já existente na literatura para estudar e desenvolver um novo método de resolução para o problema do *Job Shop Scheduling*, visando obter melhores resultados (Cauchick, 2019).

3.2 CARACTERIZAÇÃO DO OBJETO DE PESQUISA

O problema abordado neste trabalho consiste em um sistema de produção baseado em dados adaptados da literatura (Administração de Produção e Operações, Corrêa e Corrêa, 2017) que simulam o funcionamento de um ambiente produtivo caracterizado pelo modelo *job shop*. Nesse ambiente, são observados dois tipos distintos de *jobs* que precisam ser processados em três máquinas.

Este objeto de estudo aborda um ambiente onde são produzidas duas famílias de produtos, cada uma com um roteiro de produção exclusivo. Cada família de produtos possui três operações realizadas em três máquinas disponíveis na empresa. Estas máquinas são compartilhadas entre os *jobs*, e o objetivo é encontrar a melhor sequência para reduzir o *makespan*.

Os dados do problema, despontando as operações de cada tarefa (*job*), a máquina envolvida e os tempos de processamento necessários para cada operação, representados pelos números entre parênteses são mostrados na Tabela 1.


TABELA 1 - DADOS INSTÂNCIA INICIAL

<i>Jobs</i>	Operação 1 Máquina (Tempo)	Operação 2 Máquina (Tempo)	Operação 2 Máquina (Tempo)
J1	1 (10)	2 (7)	3 (5)
J2	3 (5)	1 (6)	2 (9)

FONTE: (Adaptado de Corrêa e Corrêa, 2017).

Seguem as etapas para resolução dos problemas de Pesquisa Operacional para a preparação, formulação e avaliação do modelo a ser analisado. A Figura 17 explica as principais fases adotadas nesse processo de acordo com Cauchick (2018).


FIGURA 17 - ETAPAS PARA MODELOS EM PESQUISA OPERACIONAL



FONTE: (Cauchick, 2018).

Com o sistema real definido na Tabela 3 a próxima etapa foi a modelagem matemática que constituirá o modelo. De início, foi analisado cada roteiro de produção dos *jobs* em questão no problema. A Figura 18 separa os *jobs* e apresenta seus roteiros de maneira organizada.


FIGURA 18 - ROTEIROS DE PRODUÇÃO



FONTE: (Autor, 2024).

De acordo com a Figura 18, as máquinas, representadas pelas siglas M1, M2 e M3, são disputadas pelos *jobs* que compõe o ambiente produtivo em questão, evidenciando a relação de precedência das operações dos *jobs*. Sendo assim, confirmando uma necessidade de um sequenciamento estruturado e robusto. A Figura 19 explana a esquematização do JSS.

FIGURA 19 - ESQUEMATIZAÇÃO JOB SHOP SCHEDULING



FONTE: (Autor, 2024).

Na Figura 19, é representado o esquema do problema estudado como um todo. Com O representando a operação, sendo que i representa o *job* em questão, j refere-se ao número da operação e k à máquina que a operação vai ser processada. Os números da sequência (setas), concebem o tempo de processamento das operações das referidas máquinas. As linhas tracejadas com dupla orientação representam as operações que disputam as mesmas máquinas k .

A função objetivo é definida pela Equação (1), ela visa minimizar o *makespan* simbolizado por C .

$$FO = \min C \quad (1)$$

O modelo está sujeito a diversas restrições, seja de tempo de início, precedência das operações e de recursos, quando existem operações que disputam a mesma máquina em determinado instante de tempo. As restrições de tempo de

início se referem aos instantes de tempo que as operações subsequentes podem iniciar. As Inequações (2) e (3) apresentam as restrições sendo S_{ijk} o instante de tempo que representa o início da operação j do *job* i na máquina k .

$$S_{111} \geq 0; S_{122} \geq 10; S_{133} \geq 17 \quad (2)$$

$$S_{213} \geq 0; S_{221} \geq 5; S_{232} \geq 11 \quad (3)$$

Em outras palavras, as restrições apresentadas nas Inequações (2) e (3) garantem que as operações que não dão início ao processo produtivo só possam ser processadas em suas respectivas máquinas no instante de conclusão mínimo que suas operações antecessoras podem ser concluídas, isto é, a soma do tempo de processamento das operações anteriores.

Consequentemente, após definidas as restrições de tempo de início foram definidas as restrições de precedência dos processos. Estas restrições garantem que as operações só serão processadas após a conclusão da operação anterior. Vale ressaltar que as restrições de precedência só são válidas dentro dos *jobs*, ou seja, o roteiro de produção do *job* 1 não interfere o roteiro do *job* 2.

$$S_{122} \geq S_{111} + 10; S_{133} \geq S_{122} + 7 \quad (4)$$

$$S_{221} \geq S_{213} + 5; S_{232} \geq S_{221} + 6 \quad (5)$$

As Inequações (4) e (5) garantem as restrições de sequência correta para cada um dos *jobs* presentes no ambiente *job shop*, as inequações definem o instante de tempo das operações seguintes como o instante de tempo das operações anteriores somado aos tempos de processamento das operações que antecedem a próxima.

No ambiente *job shop*, podem existir disputas entre operações que necessitam do mesmo recurso, neste caso máquinas nas quais as operações

precisam passar. Assim, as restrições de recursos são entre *jobs* diferentes, ou seja, as restrições de recursos vão englobar operações de diferentes *jobs* que são processadas na mesma máquina.

Com a disputa por máquinas sendo um cenário a se definir por restrições, evidencia-se a necessidade de adicionar restrições através de uma regra para a identificação de qual operação deve ter prioridade na alocação do recurso. Para tal, utiliza-se uma variável booleana para o auxílio desta função.

$$\begin{aligned} Y_{ipk} &= 0, \text{ se } S_{ijk} \geq S_{pwk} \\ Y_{ipk} &= 1, \text{ se } S_{ijk} \leq S_{pwk} \end{aligned} \quad (6)$$

Analisando a Inequação (6), a variável Y é definida como binária e analisa duas operações. Se o valor for igual a 1, no caso apresentado, a operação do *job i* será processada na máquina k antes da operação do *job p*, pois seu tempo de início é menor. E vice-versa quando o valor da variável Y for igual a zero.

$$S_{221} - S_{111} + H(1 - Y_{121}) - 10 \geq 0; S_{111} - S_{221} + H \times Y_{121} - 6 \geq 0 \quad (7)$$

$$S_{232} - S_{122} + H(1 - Y_{122}) - 7 \geq 0; S_{122} - S_{232} + H \times Y_{122} - 9 \geq 0 \quad (8)$$

$$S_{213} - S_{133} + H(1 - Y_{123}) - 5 \geq 0; S_{133} - S_{213} + H \times Y_{123} - 5 \geq 0 \quad (9)$$

As Inequações (7), (8) e (9) garantem que as operações com o instante de tempo de início menor sejam prioritárias na alocação de recursos, utilizando a lógica da variável booleana. A variável H presente nas equações se caracteriza como a somatória de todos os tempos de processamento.

$$S_{ijk} \geq 0, \quad \forall i, \forall j \text{ e } \forall k. \quad (10)$$

$$S_{133} + 5 \leq C; S_{232} + 9 \leq C \quad (11)$$

A Inequação (10) é de suma importância, pois garante uma restrição de não negatividade aos instantes de tempo de início das operações, sem ela as operações poderiam apresentar instantes de tempo negativos, descredibilizando a solução. A Inequação (11) garante que o *makespan* (representado pela sigla C) adote o valor da conclusão da última operação que contempla o roteiro de produção do *job* 1 ou do *job* 2, a depender do sequenciamento da solução.


Após a determinação da solução do cenário inicial, diversas experimentações computacionais, com instâncias maiores, serão aplicadas, aumentando sucessivamente o número de máquinas e de *jobs*, gerando sequências aleatórias de operações e tempos de processamento com o intuito de avaliar o desempenho do método pelo tempo de resolução.

3.3 PROTOCOLO DA PESQUISA

3.3.1 Planejamento da pesquisa

Baseando-se na Figura 17, as etapas foram adaptadas especificamente para o problema de pesquisa abordado neste trabalho. Essas etapas estão detalhadas no fluxograma apresentado na Figura 20.

FIGURA 20 - FLUXOGRAMA ETAPAS DA METODOLOGIA



FONTE: (Autor, 2024).

A metodologia deste trabalho está dividida em sete principais etapas como apontada pela Figura 20, cada uma detalhada a seguir, explicando como serão desenvolvidas e conduzidas para alinhar-se aos objetivos previamente definidos:

Etapa 1: Definição do contexto e delimitação do objeto de pesquisa no trabalho;

Etapa 2: Desdobramento da revisão bibliográfica com base em artigos, livros, teses e dissertações correlatos aos temas de Programação da Produção, problema do *Job Shop Scheduling*, *Swarm Intelligence* e algoritmos bio-inspirados;

Etapa 3: Seleção e adaptação de dados presentes na literatura para a pesquisa;

Etapa 4: Construção do modelo matemático a ser implementado no algoritmo, incluindo a função objetivo, suas restrições e critérios de parada.

Cada etapa foi executada com rigor metodológico, garantindo a coerência e a robustez dos resultados obtidos.

3.3.2 Coleta, tabulação e análise dos dados


Conforme estabelecido anteriormente, a pesquisa é caracterizada como axiomática normativa, com o intuito de variar um modelo de otimização já existente. Portanto, os dados a serem utilizados foram adaptados da literatura, subsequentemente, a tabulação e análise dos dados.

Os dados utilizados para a construção do cenário inicial, descrito na Caracterização do Objeto da Pesquisa, foram retirados e adaptados de Corrêa e Corrêa - Administração de Produção e Operações: Manufatura e serviços: uma abordagem estratégica (2017). Com o aumento das instâncias, feita de maneira gradual, foram geradas quantidades de *jobs* e máquinas aleatoriamente juntamente com a sequência tecnológica e tempo de processamento ao longo do estudo.

3.3.3 Etapas das aplicações

Com base no objeto de pesquisa, foram desenvolvidos diversos algoritmos para a criação do ambiente experimental. O primeiro algoritmo foi projetado para determinar uma solução inicial, servindo como ponto de partida para as etapas seguintes. Em seguida, foi implementado um algoritmo no ambiente do CPLEX para a obtenção do ótimo global. Após essa etapa, aplicou-se o *Crow Search Algorithm* (CSA), cujos resultados foram avaliados em comparação com o ótimo global e outros algoritmos. As etapas realizadas são apresentadas na Figura 21.

FIGURA 21 - ETAPAS APLICAÇÕES



FONTE: (Autor, 2024).

4 RESULTADOS E DISCUSSÕES

Este capítulo trará os resultados obtidos, uma discussão e detalhamento das aplicações abordadas ao longo da pesquisa.

4.1 CONSTRUÇÃO DE SOLUÇÕES INICIAIS

Primeiramente, funções foram desenvolvidas com o intuito de capacitar o algoritmo a encontrar soluções iniciais que respeitassem todas as restrições impostas por problemas do *Job Shop Scheduling* (JSSP). As soluções iniciais encontravam um mínimo local, assim permitindo um ponto de partida para o algoritmo principal buscar melhores soluções. A primeira função, calcula combinações $C(n, k)$ para ações de troca de tarefas possíveis dentro do ambiente do JSSP como mostra a Figura 22.

FIGURA 22 - ALGORITMO 1

Algorithm 1 Combinatorial Function

```

1: function COMBINACAO(n, k)
2:   return  $\frac{n!}{k! \cdot (n-k)!}$ 
3: end function

```

FONTE: (Autor, 2024).

Já na função Arco, representada na Figura 23, determina os custos (ou pesos) associados a transições entre operações no grafo levando em consideração dependências entre tarefas da mesma sequência, restrições de uso de máquinas e penalidades representadas pelo valor M (BIG M) para condições inviáveis.

FIGURA 23 - ALGORITMO 2

Algorithm 2 Arco Function

```

1: function ARCO( $op, i1, j1, k1, i2, j2, k2, M, N_{op}, N_{Maquinas}$ )
2:   if  $(j1 + 1 = j2 \wedge i1 = i2)$  or  $(k1 = k2 \wedge i1 \neq i2)$  then
3:      $r \leftarrow op[i1, j1, k1]$ 
4:   else
5:      $r \leftarrow M$ 
6:   end if
7:   if  $(i1 = 0 \wedge j1 = 0 \wedge k1 = 0 \wedge j2 = 1)$  then
8:      $r \leftarrow 0$ 
9:   end if
10:  Compute last valid sequences  $p1, p2$ 
11:  if  $(i2 = M \wedge j2 = M \wedge k2 = M \wedge j1 = p1 \wedge k1 = p2)$  then
12:     $r \leftarrow op[i1, j1, k1]$ 
13:  end if
14:  return  $r$ 
15: end function

```

FONTE: (Autor, 2024).

A função Binário, apresentada na Figura 24, tem a finalidade de criar uma matriz y , que representa se uma tarefa precede outra na mesma máquina (valores binários 0 ou 1).

FIGURA 24 - ALGORITMO 3

Algorithm 3 Binário Function

```

1: function BINARIO( $N_{Jobs}, N_{Maquinas}$ )
2:   Initialize  $y$  matrix with 1s
3:   for each pair of jobs  $i, j$  and machine  $k$  do
4:     if  $\text{rand}() \leq 0.5$  then
5:       Define precedence randomly
6:     end if
7:   end for
8:   return  $y$ 
9: end function

```

FONTE: (Autor, 2024).

A Figura 25 é atrelada as funções grafo e solução. A atribuição do algoritmo 4 foi construir a matriz de adjacência de um grafo, onde cada nó representa uma operação. Subsequentemente, o algoritmo 5 resolve o problema no grafo utilizando uma abordagem de busca para encontrar o caminho mais longo viável, gerando a sequência de operações no caminho crítico.

FIGURA 25 - ALGORITMOS 4 e 5

Algorithm 4 Construção do Grafo

```

1: function GRAFO(I, J, K, M, y, N_op, N_Maquinas, operação)
2:   Initialize graph with BIG M values
3:   for each task  $i$  do
4:     Compute weights for initial, final, and internal edges
5:   end for
6:   return graph
7: end function

```

Algorithm 5 Cálculo do Caminho Crítico

```

1: function SOLUCAO(v, grafo, M)
2:   Initialize labels and distances
3:   for each node do
4:     Update DMC values and labels
5:   end for
6:   if  $v = 1$  then
7:     return DMC
8:   else
9:     return orientations
10:  end if
11: end function

```

FONTE: (Autor, 2024).

A Figura 26 descreve o algoritmo 6 e sua função de aplicar um procedimento de melhoria iterativa ao caminho crítico para tentar reduzir o *makespan*, buscando um ótimo local.

FIGURA 26 - ALGORITMO 6

Algorithm 6 Melhoria do Caminho

```

1: function MELHORIA(ori, n, grafo, M, I, J, K, y, N_op, N_Maquinas,
   operação)
2:   Apply iterative improvements on the critical path
3:   return new solution (DMC)
4: end function

```

FONTE: (Autor, 2024).

As funções ainda contaram as ações possíveis para troca do sequenciamento das operações e realizava um ajuste a matriz y conforme necessário. Uma função para a criação de um gráfico de Gantt para visualização do agendamento foi definida também.

A classe apresentada na Figura 27, representa o ambiente que foi utilizado para resolver o JSSP, utilizando 4 atributos principais para sua definição: as tarefas, a sequência tecnológica, as máquinas disponíveis e os tempos de processamento associados.

FIGURA 27 - ALGORITMO 7

Algorithm 7 Classe JobshopEnv

```

1: function JOBSHOPENV.__INIT__(jobs, sequencia, maquinas, duracao)
2:   Define input attributes
3:   Initialize 'operacao', 'y', 'grafo' and calculate initial makespan
4: end function
5: function JOBSHOPENV.STEP(y)
6:   Update  $y$  matrix and recalculate graph and makespan
7:   Apply iterative improvements to scheduling
8:   Calculate reward
9:   Check remaining steps and define done
10:  return reward
11: end function
12: function JOBSHOPENV.RESET
13:   Reset the environment to its initial state
14: end function

```

FONTE: (Autor, 2024).

O método de passo foi utilizado para ajustar o agendamento de tarefas com base na matriz binária y , que define precedências entre tarefas em diferentes máquinas, ele também recalcula o grafo, avalia o *makespan*, e verifica possíveis melhorias na solução. Na execução este método foi aplicado para modificar o agendamento, avaliando uma recompensa que reflete o *makespan* e outras métricas do problema, por fim o ambiente era restaurado ao estado inicial.

4.2 APLICAÇÃO DO CROW SEARCH ALGORITHM (CSA)

Previamente à implementação do algoritmo proposto neste trabalho para o problema do JSSP, os problemas a serem aplicados foram antes levados ao ambiente do CPLEX.

A aplicação de um algoritmo para a resolução de sequenciamento no modelo *job shop* (respeitando todas as restrições apresentadas nos tópicos anteriores) no CPLEX, apresentaria o ótimo global do problema. Sendo assim, quanto mais próximo o algoritmo do *Crow Search Algorithm* desenvolvido para o JSSP chegasse aos valores obtidos pelo CPLEX, melhor seria seu desempenho. Para todas as instâncias aplicadas, o ótimo global foi calculado no CPLEX.

O algoritmo do *Crow Search Algorithm* (CSA) foi desenvolvido e adaptado ao problema do JSSP. Primeiramente aplicado à instância inicial do estudo, caracterizada por completo nos métodos de pesquisa.

Os parâmetros de *Awareness Probability* (AP) e *Flight Length* (FL), foram ajustados ao longo das aplicações para a verificação de qual se aproximaria do ideal. Os valores de AP aplicados foram de 0,02 e 0,1 e os valores de FL foram de 1,5 e 2,0 e todas as aplicações do algoritmo foram definidas em 1000 iterações.

Todos os algoritmos foram aplicados em um equipamento com as seguintes especificações: Processador Intel Core i7-7500U 2.70GHz 2.90 GHz e CPU com 24GB de memória RAM dentro do ambiente do *Google Colab*. O CSA variou o uso da capacidade do equipamento entre 12% e 17% com o aumento das instâncias.

4.2.1 Instância inicial – 2 jobs X 3 máquinas

O ótimo global calculado desta instância é igual a 26 instantes de tempo, e o CSA obteve êxito, alcançando-o já na primeira iteração. Ambas as combinações de parâmetros obtiveram o *makespan* como o ótimo global na primeira iteração.

Entretanto, para a combinação de $AP = 0,02$ e $FL = 1,5$ o tempo de execução total foi de 149 segundos, já na combinação de $AP = 0,1$ e $FL = 2,0$ o tempo de execução cai para 63 segundos, apontando uma economia no custo computacional. O agendamento ótimo encontrado e o *makespan* (em verde) são descritos na Tabela 2.


TABELA 2 - AGENDAMENTO INSTÂNCIA INICIAL

Máquina	Job, Operação	Instante de início	Duração	Instante de término
M1	J1,01	0	10	10
M1	J2,02	10	7	17
M2	J2,03	0	5	5
M2	J1,02	17	5	22
M3	J1,03	10	6	16
M3	J2,01	17	9	26

FONTE: (Autor, 2024).

O gráfico de Gantt da solução gerada pelo CSA é apresentado na Figura 28.

FIGURA 28 - SOLUÇÃO INSTÂNCIA INICIAL



FONTE: (Autor, 2024).

4.2.2 Instância 2 – 3 jobs X 3 máquinas

Após o sucesso da aplicação do CSA na instância inicial, deu-se início ao aumento gradativo das instâncias, desta vez o algoritmo foi testado para uma instância de 3 jobs para 3 máquinas. O ótimo global calculado desta instância foi igual a 32 instantes de tempo.

O CSA novamente obteve êxito ao encontrar a solução ótima, contudo, desta vez, foi identificada uma leve mudança com a alteração dos parâmetros do algoritmo. A combinação de AP = 0,02 e FL = 1,5 encontrou o ótimo na quarta iteração, enquanto a combinação AP = 0,1 e FL = 2,0 obteve o estado da arte na segunda iteração, levantando a possibilidade da segunda combinação apresentar um desempenho melhor. No que diz respeito ao tempo de execução 88 segundos e 85 segundos respectivamente para cada combinação de parâmetros. O agendamento ótimo encontrado é evidenciado na Tabela 3.

TABELA 3 - AGENDAMENTO INSTÂNCIA 2


Máquina	Job, Operação	Instante de início	Duração	Instante de término
M1	J1,01	0	10	10
M1	J2,02	10	6	16
M1	J3,03	25	7	32
M2	J3,01	0	10	10
M2	J1,02	10	7	17
M2	J2,03	17	9	26
M3	J2,01	0	5	5
M3	J3,02	10	15	25
M3	J1,03	25	5	30

FONTE: (Autor, 2024).

As tabelas de agendamentos proporcionam uma visão clara principalmente para a área de Planejamento, Programação e Controle da Produção (PPCP), oferecendo dados descritos de cada uma das instâncias estudadas.

Com isso, os departamentos responsáveis, teriam maior controle e uma rastreabilidade mais robusta das etapas produtivas, podendo identificar com maior precisão em que etapa o processo está e identificações de melhoria. Além de ser possível gerar análises extras como a porcentagem de carregamento de máquinas, nesta instância 31% do tempo total de operação para a máquina 1, 35% para a máquina 2 e 34% para a máquina 3, apontando uma boa distribuição. A Figura 29 traz o gráfico de Gantt, ilustrando a solução encontrada pelo CSA.

FIGURA 29 - SOLUÇÃO INSTÂNCIA 2



FONTE: (Autor, 2024).


4.2.3 Instância 3 – 4 jobs X 4 máquinas

Apesar da suspeita que uma das duas combinações dos parâmetros do algoritmo ser superior a outra, ainda seriam necessárias mais verificações antes de qualquer validação. A instância de 4 jobs por 4 máquinas sustentou a teoria.

Com o ótimo global para esta instância sendo igual a 36 instantes de tempo, o CSA novamente apresentou resultados promissores e minimizou o *makespan*. Ambas as combinações de parâmetros encontraram o melhor resultado possível, porém, com uma grande diferença de desempenho.

A combinação de AP = 0,02 e FL = 1,5 só conseguiu sair do ótimo local encontrado na solução inicial após a iteração 781, e, foi gradativamente melhorando até encontrar o ótimo na iteração 838. A evolução do *makespan* desta instância é apresentada no gráfico da Figura 30.


FIGURA 30 - INSTÂNCIA 3 X COMBINAÇÃO 1



FONTE: (Autor, 2024).

Posteriormente, a combinação dos parâmetros foi alterada para $AP = 0,1$ e $FL = 2,0$ e com a alteração o algoritmo mostrou um desempenho totalmente diferente. A Figura 31 ilustra o gráfico de evolução do *makespan* encontrado ao longo das iterações, e com as alterações dos parâmetros o ótimo foi encontrado na iteração 116.


FIGURA 31 - INSTÂNCIA 3 X COMBINAÇÃO 2



FONTE: (Autor, 2024).

Analisando os resultados de ambas as combinações, a combinação 1 necessitou de 78,1% das iterações para sair da solução inicial e 83,1% das iterações para encontrar a solução ótima. Na combinação 2, foram necessárias 11,6% das iterações para minimizar o *makespan*. O tempo de processamento foi de 330 e 300 segundos respectivamente para cada combinação.

Com isso, apesar de ambas as combinações encontrarem o melhor agendamento, ficou claro que a combinação 1 dos parâmetros apresenta uma necessidade muito maior de iterações, tornando-a assim mais dependente de um número mais elevado de iterações em instâncias mais altas. Apontando assim, que para instâncias mais altas, o custo computacional da combinação 1 seria mais elevado do que a combinação 2 por necessitar de mais iterações. O gráfico de Gantt da solução é apresentado na Figura 32.



FONTE: (Autor, 2024).

O agendamento ótimo da instância, uma análise à carga máquina aponta que as máquinas 1 e 4 apresentam, cada uma, 27,17% do tempo de processamento total dos *jobs*, enquanto a máquina 2 tem 25% e a máquina 3 com 20,65% sob o tempo total, conforme ilustra a Tabela 4.

TABELA 4 - AGENDAMENTO INSTÂNCIA 3

Máquina	Job, Operação	Instante de início	Duração	Instante de término
M1	J1,02	6	3	9
M1	J4,02	10	3	13
M1	J3,03	13	9	22
M1	J2,03	22	10	32
M2	J2,01	0	8	8
M2	J4,01	8	2	10
M2	J1,03	10	6	16
M2	J3,04	22	7	29
M3	J3,01	0	5	5
M3	J1,01	5	1	6
M3	J2,02	8	5	13
M3	J4,03	13	8	21
M4	J3,02	5	8	13
M4	J1,04	16	4	20
M4	J4,04	21	9	30
M4	J2,04	32	4	36


FONTE: (Autor, 2024).

4.2.4 Instância 4 – 5 jobs X 3 máquinas

Com o prosseguimento do aumento gradativo da complexidade, a instância 4 apresenta 5 jobs a serem realizados por 3 máquinas e apresenta um ótimo global igual a 55 instantes de tempo. Novamente, o CSA mostrou-se eficaz, conseguindo minimizar o *makespan* em ambas as combinações de parâmetros testados.

Convergente à tendência apresentada na instância anterior, a combinação 2 obteve resultados superiores à combinação 1 dos parâmetros do CSA. A solução inicial partiu de uma solução com um *makespan* no valor de 248, e a combinação 1 necessitou de 567 iterações para sair desse ótimo local, chegando ao agendamento de *makespan* igual a 55 na iteração 641. A evolução do *makespan* para a combinação 1 é dada pela Figura 33.


FIGURA 33 - INSTÂNCIA 4 X COMBINAÇÃO 1



FONTE: (Autor, 2024).


No caso da combinação 2, a solução ótima chegou bem antes, na iteração 235. Mostrando uma maior aptidão e convergência às instâncias maiores no JSSP. A Figura 34 ilustra a evolução do *makespan* para os parâmetros de AP = 0,1 e FL = 2,0.

FIGURA 34 - INSTÂNCIA 4 X COMBINAÇÃO 2



FONTE: (Autor, 2024).

Dessa maneira, novamente, a combinação 2 apresentou uma maior convergência às instâncias maiores do JSSP, alcançando o ótimo global com 173% menos iterações quando comparado a combinação 1. O gráfico de Gantt da solução ótima alcançada pelo CSA é dada pela Figura 35.



FONTE: (Autor, 2024).

A Tabela 5 traz o agendamento ótimo da instância final, juntamente com o *makespan* destacado em verde. Em relação a carga máquina, a máquina 1 tem 28,23% do total do tempo de processamento, 44,35% vai para a segunda máquina e 27,42% para a terceira máquina do sistema.

Nesta instância, fica evidente que a máquina 2 é a que tem maior carga em relação as outras máquinas, e, fica compreensível tanto pela Figura 34 que ilustra o caminho máximo na máquina 2 quanto pela Tabela 5.

TABELA 5 - AGENDAMENTO INSTÂNCIA 4

Máquina	Job, Operação	Instante de início	Duração	Instante de término
M1	J1,01	0	10	10
M1	J4,01	10	7	17
M1	J5,03	27	5	32
M1	J2,02	32	6	38
M1	J3,03	38	7	45
M2	J3,01	0	10	10
M2	J5,02	10	17	27
M2	J1,02	27	7	34
M2	J4,03	34	12	46
M2	J2,03	46	9	55
M3	J5,01	0	4	4
M3	J2,01	4	5	9
M3	J3,02	10	15	25
M3	J4,02	25	5	30
M3	J1,03	34	5	39

FONTE: (Autor, 2024).

4.3 APLICAÇÃO OUTROS ALGORITMOS

Com o sucesso do *Crow Search Algorithm* (CSA) para todas as 4 instâncias testadas, diversos outros algoritmos foram desenvolvidos, aplicados e comparados com o CSA em relação à desempenho e custos computacionais. Os algoritmos adicionais seguem listados juntamente com sua classificação no Quadro 3.

QUADRO 3 - ALGORITMOS COMPARATIVOS X CLASSIFICAÇÕES

Algoritmo	Classificação
<i>Particle Swarm Optimization</i>	Meta-heurística <i>Swarm Based</i>
<i>Bat Algorithm</i>	Meta-heurística <i>Swarm Based</i>
<i>Grey Wolf Optimizer Improved</i>	Meta-heurística <i>Swarm Based</i>
<i>Genetic Algorithm</i>	Meta-heurística Evolucionária
<i>Simulated Annealing</i>	Meta-heurística Física
<i>Flower Pollination Algorithm</i>	Meta-heurística Ecológica

FONTE: (Adaptado de Thomas, 2020).


Na lista de algoritmos selecionados são observados 4 diferentes tipos classificações de meta-heurísticas. O *Genetic Algorithm* (GA), *Particle Swarm Optimization* (PSO) e o *Simulated Annealing* (SA) são abordagens já consideradas validadas por serem aplicadas em diversas pesquisas. Outros algoritmos semelhantes ao CSA foram aplicados para verificar se teriam a mesma convergência ao JSSP. Para a aplicação dos algoritmos foi considerada apenas a(s) instância 3 (e 4).

4.3.1 Resultados meta-heurísticas *Swarm Based*

Os algoritmos meta-heurísticos *Swarm Based* aplicados nesta comparação se assemelham ao *Crow Search Algorithm* (CSA) por apresentarem a mesma classificação. No caso do *Particle Swarm Optimization* (PSO) encontrando o ótimo da instância 3 na 38ª (trigésima oitava) iteração, contudo, cada iteração levou 2,42 segundos para conclusão e a capacidade do equipamento ficou entre 17% a 24%.

Os outros dois algoritmos, a seguir, desta classificação aplicados na instância não conseguiram encontrar o ótimo global, apresentando uma estagnação em um ótimo local. O *Bat Algorithm* (BA) chegou a um ótimo local com *makespan* igual a 38 e o *Grey Wolf Optimizer Improved* (GWOI) apresentou *makespan* igual a 43. As Figuras 36 e 37 mostram a evolução do *makespan* para cada um dos algoritmos.


FIGURA 36 - DESEMPENHO BAT ALGORITHM



FONTE: (Autor, 2024).

O BA saiu da solução inicial na iteração 79, conforme mostra a Figura 36, além de encontrar um *makespan* de valor igual a 38 na iteração 85. Complementarmente, é possível observar uma semelhança ao CSA na instância 3 quando utilizada a combinação 1 cuja evolução das iterações é dada pela Figura 30, com o BA apresentando uma facilidade maior de sair da solução inicial.

FIGURA 37 - DESEMPENHO GREY WOLF OPTIMIZER IMPROVED




FONTE: (Autor, 2024).

Ambos os algoritmos, ao início da execução, mostraram uma facilidade maior de sair da solução inicial, o *Grey Wolf Optimizer Improved* (GWOI) na iteração 13 já conseguiu melhorar o *makespan*. O GWOI teve seu melhor desempenho com um valor de 43 na iteração 17, não alcançando uma boa convergência à instância testada.

Com isso, ambos os algoritmos se mostraram mais sensíveis a soluções ótimas locais ao longo do tempo e não apresentaram um desempenho tão bom quanto o CSA. A Figura 38 mostra o gráfico de Gantt da solução encontrada pelo BA.


FIGURA 38 - SOLUÇÃO BAT ALGORITHM



FONTE: (Autor, 2024).

Além de demonstrar uma menor eficácia para o JSSP, o custo computacional de ambos os algoritmos se mostrou mais elevado em comparação ao CSA. O BA requereu de 15% a 17% da capacidade do equipamento e um tempo de execução total de 287 segundos, enquanto o GWOI precisou de 20% a 22% da capacidade do equipamento e executou em 150 segundos. A Figura 39 ilustra o gráfico de Gantt da solução encontrada pelo GWOI.

FIGURA 39 - SOLUÇÃO GREY WOLF OPTIMIZER IMPROVED



FONTE: (Autor, 2024).

Na classificação dos algoritmos meta-heurísticos *Swarm Based* o CSA obteve resultados melhores que outros 2 algoritmos que simulam comportamentos de animais, tendo um desempenho tão bom quanto a um algoritmo com um *background* bibliográfico como PSO.

4.3.2 Resultados meta-heurística Evolucionária

O algoritmo meta-heurístico evolucionário aplicado no estudo foi o *Genetic Algorithm* (GA), utilizado em diversas outras aplicações e pesquisas correlatas. O algoritmo obteve resultados impressionantes, na iteração 14 foi alcançado a solução ótima da instância estudada.

Em contrapartida, o custo computacional foi um dos mais elevados, seu processamento necessitou de 22% a 26% da capacidade do equipamento, cada iteração do algoritmo levava em torno de 2,63 segundos, apresentando um tempo total de aproximadamente 44 minutos para sua conclusão. Com isso, apesar de apresentar uma capacidade e convergência impressionantes para o JSSP, em termos de custo computacional o CSA foi muito superior ao GA.

4.3.3 Resultados meta-heurística Física

A meta-heurística selecionada desta categoria, foi o *Simulated Annealing* (SA), um algoritmo amplamente estudado e clássico dentro da literatura. Já na primeira iteração alcançou uma solução de *makespan* igual a 44 e necessitou de 58 segundos para encontrar a solução ótima, com um tempo de 68 segundos para completar todas as iterações.


No que diz respeito ao custo computacional, exigiu cerca de 20% da capacidade do equipamento. Quando comparado ao CSA, seu custo foi superior, mas seu desempenho quando aplicado ao JSSP foi satisfatório.

4.3.4 Resultados meta-heurísticas Ecológica

O *Flower Pollination Algorithm* (FPA) foi o algoritmo escolhido para a categoria de meta-heurísticas ecológicas. O FPA mostrou uma capacidade de sair da solução inicial surpreendente, no entanto, apresentou uma sensibilidade quanto à ótimos locais. Em sua aplicação, encontrou o valor de *makespan* de 42 com apenas 16 iterações, contudo, não conseguiu sair desta solução nas 984 iterações seguintes. No

que diz respeito ao seu custo computacional, 75 segundos para sua execução total e 20% da capacidade do equipamento. Essa solução é ilustrada na Figura 40.

FIGURA 40 - SOLUÇÃO FLOWER POLLINATION ALGORITHM



FONTE: (Autor, 2024).

A Figura 40 traz a solução representada pelo gráfico de Gantt encontrada pelo FPA, com ênfase ao melhor *makespan* da aplicação dada pela linha tracejada vermelha com valor igual a 42 instantes de tempo.

4.4 CONSIDERAÇÕES FINAIS

O resultado obtido através dessa pesquisa levou a compreensão de que o algoritmo de *Swarm Intelligence* (SI) foi bem-sucedido quanto à sua capacidade de apresentar resultados melhores para um sequenciamento mais robusto para o problema do *Job Shop Scheduling* (JSSP).

O algoritmo do *Crow Search Algorithm* (CSA), provou ter uma maior convergência para solucionar o problema de agendamento em comparação à diversos outros algoritmos testados.

Em resumo, o CSA e o BA destacaram-se por apresentar o menor custo de processamento. As iterações do CSA, por sua vez, ocuparam um tempo satisfatório, e a mais surpreendente descoberta foi seu *fitness* à todas as instâncias testadas.

Vale ressaltar que, apenas algoritmos amplamente estudados conseguiram alcançar convergência total na instância examinada, conforme discutido ao longo do estudo. As comparações finais entre todos os algoritmos, incluindo métricas de *fitness*, tempo por iteração e o processamento utilizado em cada iteração são apresentados na Tabela 6.

TABELA 6 - COMPARAÇÕES FINAIS

Algoritmo	Fitness instância testada	Tempo por iteração (seg)	Processamento por iteração (GB)
<i>Crow Search Algorithm</i> - CSA	100%	0,3	0,00408
<i>Particle Swarm Optimization</i> - PSO	100%	2,42	0,00576
<i>Bat Algorithm</i> - BA	0,947368421	0,287	0,00408
<i>Grey Wolf Optimizer Improved</i> - GWOI	0,837209302	0,15	0,00528
<i>Simulated Annealing</i> - SA	100%	0,068	0,0048
<i>Genetic Algorithm</i> - GA	100%	2,63	0,00624
<i>Flower Pollination Algorithm</i> - FPA	0,857142857	0,075	0,0048

FONTE: (Autor, 2024).

Pela comparação exibida na Tabela 6, o CSA obteve um tempo de processamento de 0,3 segundos por iteração, considerado mediano em comparação aos outros algoritmos e apresentou o menor custo de processamento por iteração em comparação a todas as outras abordagens testadas ao longo da pesquisa requerendo apenas 0,00408 GB por iteração do processador.

Conforme abordado no Capítulo 2 da presente pesquisa, problemas que não apresentam um ótimo bem definido, geralmente necessitam de parâmetros que favoreçam a exploração e exploração equilibrados para que não fiquem estagnados em ótimos locais.

Logo, além da validação da aplicação do CSA ao JSSP, apresentou-se uma outra contribuição. Ao decorrer do estudo das diversas instâncias, a combinação dos parâmetros que melhor enquadraram-se foi a de $AP = 0,1$ e $FL = 2,0$, podendo contribuir com futuras pesquisas sobre o tema ou aplicações do CSA em geral.

5 CONCLUSÃO

As evidências apresentadas neste trabalho mostram que os resultados obtidos foram positivos, confirmando que o estudo atingiu seu objetivo geral de desenvolver um algoritmo de *Swarm Intelligence* (SI) eficaz para o problema do *Job Shop Scheduling* (JSSP).

Além disso, os objetivos específicos definidos foram abordados de forma detalhada ao longo do estudo. O mapeamento de processos, conforme descrito no Capítulo 3, estabeleceu uma base sólida para a instância inicial, o que se mostrou fundamental para o avanço das análises subsequentes.

Continuando, as relações de precedência emergiram como elementos-chave para o entendimento do JSSP, assim como para a modelagem matemática necessária e para a elaboração do algoritmo proposto. Além do mais, os tempos de processamento associados a cada operação que compõe os *jobs*, desempenharam um papel fundamental.

Subsequentemente, a elaboração das estruturas dos algoritmos desenvolvidos gerou uma adaptabilidade a diversas instâncias propostas. Nesse sentido, os algoritmos da solução inicial serviram como um ponto de partida para o *Crow Search Algorithm* (CSA), permitindo sua aplicação para diversas variedades de quantidades de *jobs* e máquinas sem depender de ajustes para cada instância.

Ademais, a análise dos resultados obtidos foi comparada aos ótimos globais das instâncias definidas no ambiente do CPLEX. Além disso, as comparações com outros algoritmos meta-heurísticos mostraram que nem todos os algoritmos apresentam a convergência que o CSA obteve com o JSSP.

Em suma, a pesquisa mostrou-se capaz de propor um modelo de sequenciamento para o JSSP, com etapas bem definidas que oferecem diretrizes sólidas para agendamentos do modelo *job shop*.

Os efeitos alcançados pelo estudo foram satisfatórios, o algoritmo proposto obteve êxito no agendamento em todas as instâncias testadas, e, em comparação a outros algoritmos, apresentou um custo computacional baixo, exibindo um tempo de processamento de 0,3 segundos por iteração, considerado mediano em comparação à outros algoritmos e utilizando 17% da capacidade total do equipamento nas instâncias maiores, e apresentando o menor custo de processamento por iteração em

comparação a todos os outros algoritmos testados ao longo da pesquisa requerendo apenas 0,00408 GB por iteração do processador.

A aplicação proposta foi de um algoritmo de SI, no entanto, a compreensão do modelo permite a realização de testes com diversos outros algoritmos, aplicando os ajustes necessários.

5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

O sucesso da pesquisa vislumbra diversas possibilidades para a continuidade de aplicações futuras. A simulação computacional dos resultados obtidos, juntamente com dados de sistemas produtivos reais que apresentam uma variação nos tempos de processos, são recomendações para uma validação posterior do modelo que poderiam enriquecer as contribuições do estudo.

Posto isto, com a aplicação das recomendações em estudos futuros, é possível que se prove a necessidade de ajustes adicionais ao modelo, visando uma melhor convergência com os cenários reais observados em empresas que operam no modelo *job shop*.

REFERÊNCIAS

ANDRADE, E. E. De. **Introdução à Pesquisa Operacional - Método e Modelos para Análise de Decisões**, 5. ed. Rio de Janeiro: LTC, 2015.

ANURADHA, K.; KRISHNA, M. V.; MALLIK, B. **Bio inspired Boolean artificial bee colony based feature selection algorithm for sentiment classification**. Elsevier Measurement: Sensors. Science Direct, 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2665917424000102>. Acesso em: 25 mai. 2024.

APPOLINÁRIO, F. **Metodologia da Ciência: Filosofia e Prática da Pesquisa**, 2 Ed. São Paulo: Cengage Learning Brasil, 2013.

ARROYO, J. E. C. Heurísticas E Metaheurísticas Para Otimização Combinatória Multiobjetivo, Brasil. 2022. 227 f. Tese (Doutorado em Engenharia Elétrica) - Setor de Engenharia Elétrica, Universidade Estadual De Campinas, Campinas, 2022. Disponível em: <https://repositorio.unicamp.br/Busca/Download?codigoArquivo=468181>.

BERTRAND, J. W. M.; FRANSOO, J. C. **Operations management research methodologies using quantitative modeling**. *International Journal of Operations & Production Management*, v. 22, n. 2, p. 241-264, 2002.

BROOKS, R.; ROBINSON, S. **Simulation and Inventory Control**. Basingstoke: Palgrave, 2001.

BUGOR, F. B.; FILHO, J. L. **A Importância Do Planejamento, Programação E Controle Da Produção (PPCP) Para O Desenvolvimento Das Indústrias Atuais**. *Revista Interface Tecnológica* 18(1):461-473., Nov 2021. Disponível em: https://www.researchgate.net/publication/355888880_A_IMPORTANCIA_DO_PLANEJAMENTO_PROGRAMACAO_E_CONTROLE_DA_PRODUCAO_PPCP_PARA_O_DESENVOLVIMENTO_DAS_INDUSTRIAS_ATUAIS. Acesso em: 21 Abr. 2024. <http://dx.doi.org/10.31510/inf.v18i1.1106>.

CAETANO JÚNIOR, M. B. A importância do Planejamento Estratégico, Tático E Operacional no Gerenciamento De Projetos: **Revista Saber Eletrônico**, Jussara, v. 2, n. 1 (9), 2018. Disponível em: <https://sabereletronico.emnuvens.com.br/saber/article/view/15/36>. Acesso em: 16 mar. 2024.

CAUCHICK, P. **Metodologia Científica para Engenharia**. São Paulo: Grupo GEN LTC, 2019.

CAUCHICK, P. **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. São Paulo: Grupo GEN, 2018.

CHIAVENATO, I. **Iniciação ao Planejamento e Controle da Produção**. Ed. 5. São Paulo: Atlas, 2022.

CORRÊA, H. L.; CORRÊA, C. A. **Administração de Produção e Operações: Manufatura e serviços: uma abordagem estratégica**. Ed. 4. São Paulo: Atlas, 2017.

COSTA, R. S. Pontualidade total na produção sob encomenda: conceito, tecnologia e uso da simulação computacional na gestão do chão-de-fábrica. 1996. 498 f. Tese (Doutorado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1996. Disponível em: <http://www.trilhaprojetos.com.br/home/node/115>. Acesso em: 15 mai. 2024.

DALL'AGNOL, G. **Programação da Produção em Ambientes de Manufatura Aditiva: análise do estado-da-arte e proposta de método de resolução**. 2023. 89 f. Dissertação (Mestrado em Engenharia de Produção) - Setor de Engenharia de Produção, Universidade Federal de São Carlos, São Carlos (SP), 2023. Disponível em: <https://repositorio.ufscar.br/bitstream/handle/ufscar/18419/Disserta%c3%a7ao%20-%20Gabriela%20Dall%27Agnol.pdf?sequence=1&isAllowed=y>. Acesso em: 12 mai. 2024.

DEHURI, S.; GHOSH, S.; CHO, S. **Integration Of Swarm Intelligence And Artificial Neural Network**. Londres: World Scientific, 2011.

FERNANDES, S. **Técnicas heurísticas para o problema Job Shop Scheduling**. Research Gate, 2002. Disponível em: https://www.researchgate.net/publication/277108505_Tecnicas_heuristicas_para_o_problema_Job_Shop_Scheduling. Acesso em: 17 mar. 2024.

FONTES, D. B. M. M.; HOMAYOUNI, S. M.; FERNANDES, J. C. **Energy-efficient job shop scheduling problem with transport resources considering speed adjustable resources**. International Journal of Production Research. Taylos&Francis Online, 2022. Disponível em: https://www.tandfonline.com/doi/full/10.1080/00207543.2023.2175172?casa_token=9SdetwYX5NYAAAAA%3ADQ2ELDRprHTx-Vte6Tm7-Alola3ioAFNtaCdT0-b9y4HU5dJB9nasYATPp3LsRfehddkszwLvb68Kw. Acesso em: 17 mar. 2024.

HOLLOWAY, C. A.; NELSON, R. T. Job Shop Scheduling with Due Dates and Variable Processing Times. **Management Science**, v.20, n9, p. 1264-1275, Mai 1974. Disponível em: <https://pubsonline.informs.org/doi/10.1287/mnsc.20.9.1264>. Acesso em: 20 mai. 2024. <https://doi.org/10.1287/mnsc.20.9.1264>.

HUSSIEN, A. G. et al. **Crow Search Algorithm: Theory, Recent Advances, and Applications**. Research Gate, 2020. Disponível em: https://www.researchgate.net/publication/344248191_Crow_Search_Algorithm_Theory_Recent_Advances_and_Applications. Acesso em: 19 mai. 2024.

LANDES, F. B. Optimistic: Um Framework Para Implementação E Uso De Meta E Hiper-Heurísticas. 59 f. Trabalho de Graduação (Licenciatura em Computação) – Setor de Ciências da Computação, Univeridade Federal Fluminense, Santo Antônio de Pádua, 2017.

LEAL, F.; ALMEIDA, D. A.; MONTEVECHI, J. A. B. **Uma proposta de técnica de modelagem conceitual para a simulação através de elementos do IDEF.**

Universidade Estadual de Maringá, 2008. Disponível em:

<https://www.din.uem.br/sbpo/sbpo2009/artigos/55581.pdf>. Acesso em: 11 mai. 2024.

LEE, D. et al. **An Advanced Crow Search Algorithm for Solving Global**

Optimization Problem. MDPI, 2023. Disponível em: [https://www.mdpi.com/2076-](https://www.mdpi.com/2076-3417/13/11/6628)

3417/13/11/6628. Acesso em: 7 jun. 2024.

LIN, G. et al. **An approximate evaluation method for neighbourhood solutions in job shop scheduling problem.** IET Collaborative Intelligent Manufacturing.

ResearchGate, 2022. Disponível em:

https://www.researchgate.net/publication/363518183_An_approximate_evaluation_method_for_neighbourhood_solutions_in_job_shop_scheduling_problem/download.

Acesso em: 18 mai. 2024.

LIN, T. et al. **An efficient job-shop scheduling algorithm based on particle**

swarm optimization. Expert Systems with Applications, Volume 37. Science Direct, 2010. Disponível em:

[https://www.sciencedirect.com/science/article/pii/S0957417409007696?casa_token=LUP0Gt0pi-gAAAAA:_lbmqCBuFX-](https://www.sciencedirect.com/science/article/pii/S0957417409007696?casa_token=LUP0Gt0pi-gAAAAA:_lbmqCBuFX-KYiktJA4Dae3DODkQum5wzaY1X6EjIGfwcS8brFxMLOn9GaXkWxyNRtEvXfuitrE)

[KYiktJA4Dae3DODkQum5wzaY1X6EjIGfwcS8brFxMLOn9GaXkWxyNRtEvXfuitrE](https://www.sciencedirect.com/science/article/pii/S0957417409007696?casa_token=LUP0Gt0pi-gAAAAA:_lbmqCBuFX-KYiktJA4Dae3DODkQum5wzaY1X6EjIGfwcS8brFxMLOn9GaXkWxyNRtEvXfuitrE).

Acesso em: 15 mai. 2024.

LUSTOSA, L. **Planejamento e Controle da Produção** Ed. 4. Rio de Janeiro:

Elsevier, 2008.

LUZIA, L. F.; RODRIGUES, M. C. Estudo sobre as Metaheurísticas. Disponível em: Ime USP, 2009.

<https://www.ime.usp.br/~gold/cursos/2009/mac5758/LeandroMauricioHeuristica.pdf>.

Acesso em: 17 mai. 2024.

MARROUCHE, W. Unlocking the Potential of Metaheuristics for NP-Hard Problems, Reino Unido. 2024. 187 f. Tese (Doutorado em Filosofia da Ciência da Computação)

- Setor de Pesquisa de Inteligência Computacional, Universidade de Portsmouth, Portsmouth, 2024. Disponível em:

https://pure.port.ac.uk/ws/portalfiles/portal/82984899/Wissam_Marrouche_PHD.pdf.

Acesso em: 20 mai. 2024.

MARTINS, D. A. et al. **Estrutura E Procedimento Para Uso Integrado De**

Softwares De Programação Da Produção E De Simulação. Abepro, 2015.

Disponível em: https://abepro.org.br/biblioteca/TN_STP_215_270_28141.pdf

MARTINS, F. A. A. **MODELO PARA AVALIAÇÃO DO LEAD TIME PRODUTIVO**

NAS EMPRESAS TÊXTEIS. 2003. Dissertação (Mestrado em Engenharia de Produção) – Setor de Engenharia de Produção. Universidade Federal de Santa Catarina, Florianópolis (SC), 2003. Disponível em:

<https://core.ac.uk/download/pdf/30366916.pdf>

MENEZES, L. L. F.; MARINHO, F. J. E. **Construção Enxuta: O Uso Da Gestão Da Qualidade Através Da Implementação De Ferramentas De Planejamento E Controle Na Construção Civil**. Revistafth, Nov 2023. Disponível em: <https://revistafth.com.br/construcao-enxuta-o-uso-da-gestao-da-qualidade-atraves-da-implementacao-de-ferramentas-de-planejamento-e-controle-na-construcao-civil/>. Acesso em: 20 Abr. 2024. DOI:10.5281/zenodo.10247119

MISHRA, S. *et al.* **Cognitive Big Data Intelligence with a Metaheuristic Approach**. Academic Press: Elsevier, 2022.

MOREIRA, D. A. **Pesquisa Operacional: Curso Introdutório**, 2. ed. São Paulo: Cengage Learning Brasil, 2017.

NASCIMENTO, L. P. Do. **Elaboração de Projetos de Pesquisa: Monografia, Dissertação, Tese e Estudo de Caso, com Base em Metodologia Científica**. São Paulo: Cengage Learning Brasil, 2016.

NIGISCHER, C. *et al.* **Finding the proper level of detail to achieve sufficient model fidelity using FlexSim: An industrial use case**. Science Direct, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2212827123006455>. Acesso em: 12 mai. 2024.

NUNES, D. M.; MELO, P. A. C.; NIGRO, I. S. C. **Planejamento, Programação E Controle Da Produção: O Uso Da Simulação Do Preactor Em Uma Indústria De Alimentos**. Abepro, 2009. Disponível em: https://www.abepro.org.br/biblioteca/enegep2009_tn_sto_091_616_12552.pdf

OLIVEIRA, M. A. **Administração da produção Série Universitária**. São Paulo: SENAC, 2023.

PEINADO, J.; GRAEML, R. A. **Administração da Produção (Operações Industriais e de Serviços)**. Curitiba: UnicenP, 2007.

PRADO, E. C. *et al.* **PCP: Utilização Do Ms Project No Auxílio À Programação Da Produção Em Uma Indústria De Caldeiraria**. Abepro, 2012. Disponível em: https://abepro.org.br/biblioteca/enegep2012_tn_sto_157_914_20297.pdf

RAMOS, V. M. N.; FERREIRA, D. **Programação Da Produção Em Indústrias De Bebidas: Uma Revisão De Literatura**. Abepro, 2017. Disponível em: https://abepro.org.br/biblioteca/TN_WPG_243_407_33927.pdf

RIBEIRO, V.; CORDEIRO, N. H. M. **Sequenciamento Da Produção: Uma Proposta Paraosistemamake To Order**. Produção Online, 2020. Disponível em: <https://www.producaoonline.org.br/rpo/article/view/3863>. Acesso em: 5 mai. 2024.

ROCHA, P. L. *et al.* **Eficiência no laboratório de hemodinâmica: em busca de melhorias baseadas em valor seguindo uma abordagem sociotécnica**. Science Direct, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0870255122002645>. Acesso em: 14 mai. 2024.

ROSA, A. F. C. Algoritmo Genético Híbrido Baseado na Análise de Componentes Principais do Fitness Landscape para o Problema de Job Shop Scheduling. 2019. 138 f. Tese (Doutorado em Informática e Gestão do Conhecimento) – Setor de Informática, Universidade Nove de Julho, São Paulo, 2019. Disponível em: <https://bibliotecatede.uninove.br/handle/tede/2577>. Acesso em: 20 mai. 2024.

SAVIA, T. D.; MACIEL, T. C. P.; SILVA, K. O. A. N. **Simulação A Eventos Discretos Aplicado Em Um Restaurante Universitário**. Abepro, 2018. Disponível em: https://www.abepro.org.br/biblioteca/TN_STO_263_512_35266.pdf. Acesso em: 19 mai. 2024.

SCHNEIDER, A. C; ZANOTTO, M. R.; CORSO, L. L. **Estudo Da Teoria Das Filas Aplicada Na Otimização Do Setor De Montagem De Uma Empresa Fabricante De Placas Eletrônicas**. SIMEP, 2023. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/xmlui/bitstream/handle/riufcg/32950/ESTUDO%20DA%20TEORIA%20DAS%20FILAS%20APLICADA%20NA%20OTIMIZA%C3%87%C3%83O%20DO%20SETOR%20DE%20MONTAGEM%20-%20ANAI%20IX%20SIMEP%20ARTIGO%202023.pdf?sequence=1&isAllowed=y>. Acesso em: 11 mai. 2024.

SCHNEIDER, L. L.; CORSO, L. L. **Aplicação de um algoritmo evolutivo na solução de problemas de sequenciamento da produção**. Research Gate, 2020. Disponível em: https://ieeexplore.ieee.org/abstract/document/10065588?casa_token=4tqt8xC-uwwAAAAA:UyrOpc0-c8sEgd_wLa3wJknCwjg5mQGR69vTo98GBj6B-TI2e1i-AjULLt1oJrtsLxJkxrr0ZG0. Acesso em: 17 mar. 2024

SCOREPLAN. Disponível em: <https://scoreplan.com.br/blog/>. Acesso em: 10 abr. 2024.

SHINGO, S. **A study of the Toyota Production System from an industrial engineering viewpoint**. Cambridge: Productivity Press, 1989.

SILVA, E. L. Da e MENEZES, E. M. **Metodologia da pesquisa e elaboração de dissertação**. Departamento de Ciência da Informação, 4 Ed. Florianópolis: UFSC, (138 p.), 2005.

SLACK, N.; BRANDON-JONES, A.; BURGESS, N. **Administração da Produção**. Ed. 10. São Paulo: Atlas, 2023.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da produção**. São Paulo: Atlas, 2002.

STEVENSON, W. J. **Administração das Operações de Produção**, 6 Ed. Rio de Janeiro: LTC, 2001.

TECHFERRY. Disponível em: <https://www.techferry.com>. Acesso em: 8 mai. 2024.

TEMPONI, E. C. C. Uma Proposta de Resolução do Problema de Corte Bidimensional via Abordagem Metaheurística. 2007. 70 f. Dissertação (Mestrado em Matemática) - Setor de Matemática Computacional, Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2007. Disponível em: <https://www.escavador.com/sobre/3117729/elias-carlos-correa-temponi>.

THAHER, T. et al. **Enhanced variants of crow search algorithm boosted with cooperative based island model for global optimization**. Science Direct, 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417423022145>. Acesso em: 4 jun. 2024.

THOM DE SOUZA, R. C. et al. **A V-Shaped Binary Crow Search Algorithm for Feature Selection**. Congress on Evolutionary Computation. IEEE Xplore, 2018. Disponível em: <https://ieeexplore.ieee.org/document/8477975>. Acesso em: 10 mai. 2024.

THOMAS, K. P. **BIO-Inspired Algorithms and Its Application**. Research Gate, 2020. Disponível em: <https://www.researchgate.net/publication/bio-inspired-algorithms-and-its-application-thomas-k-p>. Acesso em: 10 mai. 2024.

TUBINO, D. F. **Planejamento e Controle da Produção – Teoria e Prática**. Ed. 3. São Paulo: Atlas, 2017.

TUBINO, D.F. **Sistemas de Produção: A produtividade no chão de fábrica**. Porto Alegre: Artes Médicas, 1999.

TURRIONI, J. B. e MELLO, C. H. P. **Metodologia de pesquisa em engenharia de produção**. Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Itajubá – UNIFEI, 2012.

VOITTO. Disponível em: <https://voitto.com.br/blog>. Acesso em: 27 abr. 2024.

WANG, W.; BROOKS, R.J. **Empirical investigations of conceptual modeling and the modeling process**. Washington: Atas, 2007.

WANG, Z.; ZHANG, J.; YANG, S. **An improved particle swarm optimization algorithm for dynamic job shop scheduling problems with random job arrivals**. Swarm and Evolutionary Computation, Volume 51. Science Direct, 2019. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2210650219302317>. Acesso em: 15 mai. 2024. <https://doi.org/10.1016/j.swevo.2019.100594>.

YANG, X. et al, M. **Swarm Intelligence and Bio-Inspired Computation: Theory and Applications**. Elsevier, 2013. p. 3-21.

ZHANG, F. et al. **Survey on Genetic Programming and Machine Learning Techniques for Heuristic Design in Job Shop Scheduling**. IEEE Transactions on Evolutionary Computation. IEEE Xplore, 2024. Disponível em: https://ieeexplore.ieee.org/abstract/document/10065588?casa_token=4tqt8xC-

uwwAAAAA:UyrOpc0-c8sEgd_wLa3wJknCwjg5mQGR69vTo98GBj6B-Tl2e1i-AjULLt1oJrtsLxJkxrr0ZG0. Acesso em: 17 mar. 2024.