



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

MATHEUS LOPES BITTENCOURT

**PROPOSTA SIMHEURÍSTICA PARA RESOLUÇÃO DE UM PROBLEMA DE
SEQUENCIAMENTO EM MÁQUINA ÚNICA COM CONSIDERAÇÕES
AMBIENTAIS E PARÂMETROS ESTOCÁSTICOS**

Recife
2024

MATHEUS LOPES BITTENCOURT

PROPOSTA SIMHEURÍSTICA PARA RESOLUÇÃO DE UM PROBLEMA DE
SEQUENCIAMENTO EM MÁQUINA ÚNICA COM CONSIDERAÇÕES AMBIENTAIS E
PARÂMETROS ESTOCÁSTICOS

Dissertação de Mestrado apresentada ao
Departamento de Engenharia de Produção da
Universidade Federal de Pernambuco, como
requisito parcial para obtenção do título de
Mestre em Engenharia de Produção. Área de
Concentração: Pesquisa Operacional.

Orientador: Prof. Dr. Raphael Harry Frederico Ribeiro Kramer.

RECIFE

2024

.Catalogação de Publicação na Fonte. UFPE - Biblioteca Central

Bittencourt, Matheus Lopes.

Proposta simheurística para resolução de um problema de sequenciamento em máquina única com considerações ambientais e parâmetros estocásticos / Matheus Lopes Bittencourt. – Recife, 2024.

139 f.: il.

Dissertação (Mestrado) – Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia de Produção, 2024.

Orientação: Raphael Harry Frederico Ribeiro Kramer.

1. Sequenciamento Verde; 2. Máquina Única; 3. Simheurística; 4. Tempos de Processamento Estocástico; 5. Time-Of-Use. I. Kramer, Raphael Harry Frederico Ribeiro. II. Título.

UFPE-Biblioteca Central

CDD 658.5

MATHEUS LOPES BITTENCOURT

PROPOSTA SIMHEURÍSTICA PARA RESOLUÇÃO DE UM PROBLEMA DE
SEQUENCIAMENTO EM MÁQUINA ÚNICA COM CONSIDERAÇÕES AMBIENTAIS E
PARÂMETROS ESTOCÁSTICOS

Dissertação de Mestrado apresentada ao
Departamento de Engenharia de Produção da
Universidade Federal de Pernambuco, como
requisito parcial para obtenção do título de
Mestre em Engenharia de Produção. Área de
Concentração: Pesquisa Operacional.

Aprovada em: 30/07/2023.

BANCA EXAMINADORA

Prof. Dr. Raphael Harry Frederico Ribeiro
Kramer (Orientador)
Universidade Federal de Pernambuco

Prof. Dra. Isis Didier Lins (Examinadora Interna)
Universidade Federal de Pernambuco

Prof. Dr. Rommel Dias Saraiva (Examinador Externo)
Universidade de Fortaleza

AGRADECIMENTOS

Gostaria de expressar minha profunda e sincera gratidão aos meus pais e ao meu irmão. Embora a distância física tenha sido uma constante ao longo desta jornada, a presença de vocês em meu coração e em meus pensamentos foi um apoio reconfortante. Cada videochamada e cada meme trocado pelas redes sociais foram verdadeiros tesouros que iluminaram meus dias e fortaleceram minha determinação. O apoio incondicional, o carinho constante e o incentivo em cada passo foram essenciais para que eu alcançasse meus objetivos. O amor e a dedicação que recebi de vocês foram o alicerce que sustentou minha perseverança e coragem. Agradeço de coração por todo o apoio, amor e compreensão que sempre me ofereceram.

À minha amada e parceira Clarissa, com quem compartilhei cada momento desta caminhada, gostaria de dedicar um agradecimento especial. Juntos, enfrentamos inúmeras dificuldades e adversidades, sempre nos apoiando e incentivando mutuamente. Nossa união foi uma força motriz que nos permitiu crescer, desenvolver e aprender, um ao lado do outro. A sua companhia e apoio constante tornaram essa jornada muito mais rica e significativa. Muito obrigado por cada conselho e dica valiosa sobre programação e L^AT_EX.

Ao Prof. Dr. Raphael Kramer, expresso minha mais sincera gratidão pela excelente orientação e pela paciência ao longo de todo o mestrado. Sua dedicação e conhecimento foram essenciais para o desenvolvimento deste trabalho. Obrigado por ser uma peça chave nesse processo e por acreditar no meu potencial.

Agradeço também aos professores da banca examinadora, Dra. Isis Didier Lins e Dr. Rommel Dias Saraiva. Sou grato pelo tempo que dedicaram para analisar meu trabalho e pelas valiosas colaborações e sugestões oferecidas. Suas contribuições foram fundamentais para o aprimoramento deste projeto.

Aos colegas de laboratório, quero agradecer pelos momentos de lazer e descontração que compartilharam comigo. A convivência com todos vocês foi uma parte importante desta jornada, tornando os desafios mais leves e os dias mais agradáveis.

Por fim, agradeço à CAPES pelo apoio financeiro concedido através da bolsa de auxílio, que foi crucial para a realização deste trabalho. Agradeço também a todos os colaboradores do PPGEP, cuja contribuição direta ou indireta tornou possível a conclusão deste estudo.

RESUMO

Esta dissertação aborda a versão estocástica do problema de sequenciamento de máquina única com considerações ambientais. Neste contexto, os tempos de processamento das tarefas se comportam como variáveis aleatórias, e o consumo total de energia depende de quais tarefas serão processadas em quais períodos, uma vez que cada tarefa tem seu próprio consumo de energia e cada período possui sua tarifa de energia devido à política de *Time-Of-Use*. O objetivo deste trabalho é propor um algoritmo simheurístico para minimizar o consumo total de energia sob diferentes cenários de incerteza. O algoritmo proposto, denominado SimSA, combina as meta-heurísticas *Simulated Annealing* e *Greedy Randomized Adaptive Search Procedure* para realizar a busca no espaço de soluções, juntamente com a Simulação de Monte Carlo para gerar os valores aleatórios. O SimSA foi utilizado com três métricas estocásticas distintas: a média, Value at Risk e Conditional Value at Risk. Cada uma para analisar uma característica estocástica do problema. O algoritmo proposto foi implementado na linguagem de programação Julia, e os testes computacionais foram aplicados em 100 instâncias baseadas no trabalho de Zhang *et al.* (2018a). Os resultados do SimSA foram comparados com a melhor solução viável encontrada por uma meta-heurística considerando a entrada determinística, e o SimSA obteve melhores resultados em todas as métricas utilizadas. Isso evidencia que a melhor solução determinística não necessariamente é a melhor solução estocástica. Além disso, foi possível observar o impacto que todos os cenários de incertezas causam nas métricas analisadas. Esses resultados destacam a importância de incorporar as incertezas presentes nos processos e ressaltam a relevância da simheurística proposta.

Palavras-chave: Sequenciamento Verde. Máquina Única. Simheurística. Tempos de Processamento Estocástico. *Time-Of-Use*.

ABSTRACT

This dissertation addresses the stochastic version of the single-machine scheduling problem with environmental considerations. In this context, jobs processing times behave as random variables, and the total energy consumption depends on which tasks are processed in which periods, since each task has its own energy consumption and each period has its energy tariff due to the Time-Of-Use policy. The objective of this work is to propose a simheuristic algorithm to minimize the total energy consumption under different uncertainty scenarios. The proposed algorithm, called SimSA, combines the metaheuristics Simulated Annealing and Greedy Randomized Adaptive Search Procedure to perform the search in the solution space, along with Monte Carlo Simulation to generate random values. SimSA was used with three distinct stochastic metrics, namely the mean, Value at Risk, and Conditional Value at Risk, each to analyze a stochastic characteristic of the problem. The proposed algorithm was implemented in the Julia programming language, and computational tests were conducted on 100 instances based on the work of Zhang *et al.* (2018a). The results of SimSA were compared with the simulation of the best deterministic solution, and SimSA achieved better results in all the metrics used. This shows that the best deterministic solution is not necessarily the best stochastic solution. Furthermore, it was possible to observe the impact that all uncertainty scenarios have on the analyzed metrics. These results highlight the importance of incorporating uncertainties present in processes and emphasize the relevance of the proposed simheuristic.

Keywords: Green Scheduling. Single Machine. Simheuristic. Stochastic Processing Time. Time-Of-Use.

LISTA DE FIGURAS

Figura 1 – Estrutura base de uma simheurística	27
Figura 2 – Análise de risco dentre as opções disponíveis no <i>Pool</i>	28
Figura 3 – Ilustração do VaR e do CVaR para o mesmo θ	30
Figura 4 – Representação do sistema de produção e seus elementos	32
Figura 5 – PSMU com tempos de processamento determinístico	36
Figura 6 – Representação da solução do modelo	39
Figura 7 – Representação do impacto da simulação em uma solução	39
Figura 8 – Justificativa das seções da revisão sistemática	40
Figura 9 – Quantidade de artigos Mono-objetivo e Multiobjetivo por ano	48
Figura 10 – Percentual de artigos em relação as considerações ambientais para o PSVMU	49
Figura 11 – Percentual dos métodos de resolução utilizados para o PSVMU	51
Figura 12 – Percentual dos métodos de resolução utilizados para o Problema de Sequenciamento em Máquina Única Estocástico (PSMUE)	56
Figura 13 – Percentual de artigos em relação aos parâmetro estocásticos PSMUE	57
Figura 14 – Métodos de resolução para o Problema de Sequenciamento Verde e Estocástico (PSVE)	63
Figura 15 – Percentual de artigos em relação as considerações ambientais para o PSVE	64
Figura 16 – Percentual de artigos em relação aos parâmetro estocásticos para o PSVE	64
Figura 17 – Metodologia da pesquisa	69
Figura 18 – Ilustração da distribuição das tarifas no horizonte de tempo	70
Figura 19 – Ilustração da condição 1	71
Figura 20 – Ilustração da condição 2	71
Figura 21 – Ilustração da condições 3	72
Figura 22 – Ilustração da Versão 1 da condições 4	73
Figura 23 – Ilustração da Versão 2 da Condições 4	74
Figura 24 – Ilustração da Condições 6	75
Figura 25 – Exemplo da Simulação	79
Figura 26 – Método do <i>Erro</i> do intervalo de confiança	90
Figura 27 – Boxplot da instância 1 para os resultados do SimSA-Esperado	91

LISTA DE TABELAS

Tabela 1 – Notação adotada para a modelagem matemática	37
Tabela 2 – Dados para o exemplo	38
Tabela 3 – Questões a serem respondidas para cada revisão	41
Tabela 4 – <i>String</i> de busca adotada para cada revisão	42
Tabela 5 – Artigos utilizados para a revisão do PSVMU	43
Tabela 5 – Artigos utilizados para a revisão do PSVMU (Continuação)	44
Tabela 5 – Artigos utilizados para a revisão do PSVMU (Continuação)	45
Tabela 5 – Artigos utilizados para a revisão do PSVMU (Continuação)	46
Tabela 6 – Publicações em cada revista para o PSVMU	47
Tabela 7 – Funções objetivo encontrados	49
Tabela 8 – Artigos utilizados para a revisão do PSMUE	54
Tabela 8 – Artigos utilizados para a revisão do PSMUE (Continuação)	55
Tabela 9 – Publicações em cada revista para o PSMUE	55
Tabela 10 – Artigos utilizados para a revisão do PSVMUE	62
Tabela 11 – Publicações em cada revista para o PSVE	62
Tabela 12 – Instâncias utilizadas	85
Tabela 13 – Parâmetros calibrados	86
Tabela 14 – Resumo dos GIH-GRASP x SimSA	87
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP	107
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	108
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	109
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	110
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	111
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	112
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	113
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	114
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	115
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	116
Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)	117
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP	118
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	119

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	120
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	121
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	122
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	123
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	124
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	125
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	126
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	127
Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)	128
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP	129
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	130
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	131
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	132
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	133
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	134
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	135
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	136
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	137
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	138
Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)	139

LISTA DE ALGORITMOS

Algoritmo 1 – Procedimento GRASP (α, η)	21
Algoritmo 2 – Procedimento SA (T, R, β_{max})	22
Algoritmo 3 – Greedy Insertion Heuristic (n, m, k, c_k, b_k, N, M)	76
Algoritmo 4 – Simulação ($s, \delta, \rho_{min}, Erro_{Limite}, NC$)	77
Algoritmo 5 – SimSA ($\eta, \alpha, \delta, \rho_C, \rho_L, Erro_{LimiteC}, Erro_{LimiteL}, NC, size$)	81
Algoritmo 6 – GIH-GRASP (α, η)	83

LISTA DE ABREVIATURAS E SIGLAS

ABC	<i>Artificial Bee Colony</i>
ACO	<i>Ant Colony Optimization</i>
AG	Algoritmo Genético
CVaR	<i>Conditional Value at Risk</i>
GA	<i>Genetic Algorithm</i>
GIH	<i>Greedy Insertion Heuristic</i>
GRASP	<i>Greedy Randomized Adaptive Search Procedure</i>
ILS	<i>Iterated Local Search</i>
LCR	Lista de Candidatos Restrito
MVO	<i>Multi-Verse Optimizer</i>
OC	Otimização Combinatória
PLIM	Programação Linear Inteira Mista
PO	Pesquisa Operacional
PSE	Problema de Sequenciamento Estocástico
PSMU	Problema de Sequenciamento de Máquina Única
PSMUE	Problema de Sequenciamento em Máquina Única Estocástico
PSO	<i>Particle Swarm Optimization</i>
PSV	Problema de Sequenciamento Verde
PSVE	Problema de Sequenciamento Verde e Estocástico
PSVMU	Problema de Sequenciamento Verde em Máquina Única
PSVMUE	Problema de Sequenciamento Verde em Máquina Única e Estocástico
SA	<i>Simulated Annealing</i>
TEC	<i>Total Energy Consumption</i>
TOU	<i>Time-Of-Use</i>
VaR	<i>Value at Risk</i>
VNS	<i>Variable Neighborhood Search</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	JUSTIFICATIVA E RELEVÂNCIA	15
1.2	OBJETIVOS	17
1.3	ORGANIZAÇÃO DO TRABALHO	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	HEURÍSTICA E META-HEURÍSTICA	19
2.1.1	<i>Greedy Randomized Adaptive Search Procedure (GRASP)</i>	21
2.1.2	<i>Simulated Annealing (SA)</i>	22
2.2	SIMULAÇÃO MONTE CARLO	23
2.3	SIMHEURÍSTICA	25
2.3.1	<i>Métricas Estocásticas</i>	29
2.4	TESTE DE POSTOS SINALIZADOS DE WILCOXON	30
2.5	SEQUENCIAMENTO DA PRODUÇÃO	31
2.5.1	<i>Sequenciamento verde da produção</i>	34
2.5.2	<i>Sequenciamento de máquina única</i>	35
2.5.3	<i>Descrição do problema estudado</i>	36
3	REVISÃO SISTEMÁTICA DA LITERATURA	40
3.1	DEFINIÇÃO DO PROCEDIMENTO	41
3.2	QUANTIFICAÇÃO E ANÁLISE DOS TRABALHOS	42
3.2.1	PROBLEMA DE SEQUENCIAMENTO DE MÁQUINA ÚNICA COM CONSIDERAÇÕES AMBIENTAIS	43
3.2.1.1	<i>Sumarização e análise dos trabalhos</i>	43
3.2.1.2	<i>Abordagem dos artigos</i>	51
3.2.2	PROBLEMA DE SEQUENCIAMENTO DE MÁQUINA ÚNICA COM PARÂMETROS ESTOCÁSTICOS	53
3.2.2.1	<i>Sumarização e análise dos trabalhos</i>	53
3.2.2.2	<i>Abordagem dos artigos</i>	58
3.2.3	PROBLEMA DE SEQUENCIAMENTO COM CONSIDERAÇÕES AMBIENTAIS E PARÂMETROS ESTOCÁSTICOS	61
3.2.3.1	<i>Sumarização e análise dos trabalhos</i>	61
3.2.3.2	<i>Abordagem dos artigos</i>	65

4	METODOLOGIA	68
4.1	CLASSIFICAÇÃO DA PESQUISA	68
4.2	PROCEDIMENTOS COMPUTACIONAIS	69
4.2.1	<i>Heurística Construtiva</i>	70
4.2.2	<i>Etapa da Simulação</i>	76
4.2.3	<i>Meta-heurística</i>	79
4.2.4	<i>Simheurística Proposta</i>	80
4.2.5	<i>Meta-heurística utilizada</i>	83
5	RESULTADOS	84
5.1	INSTÂNCIAS UTILIZADAS	85
5.2	CALIBRAÇÃO DOS PARÂMETROS	86
5.3	AVALIAÇÃO DOS RESULTADOS	87
5.4	TESTE DE WILCOXON PARA GIH-GRASP X ABORDAGENS DO SIMSA ..	91
6	CONCLUSÕES	93
	REFERÊNCIAS	96
	APÊNDICE A –COMPARAÇÃO ENTRE SIMSA-ESPERADO X GIH-GRASP	107
	APÊNDICE B –COMPARAÇÃO ENTRE SIMSA-VAR X GIH-GRASP . .	118
	APÊNDICE C –COMPARAÇÃO ENTRE SIMSA-CVAR X GIH-GRASP ..	129

1 INTRODUÇÃO

Um bom planejamento e programação da produção configura um desafio a ser enfrentado por muitas empresas, uma vez que se tornou essencial que as companhias estejam preparadas para planejar eficientemente sua produção devido à crescente competitividade no mercado (Tubino, 2022). Dessa forma, as organizações buscam solucionar os problemas existentes em seus processos, a fim de evitar a insatisfação e a perda de clientes (Asadpour *et al.*, 2022).

Os problemas na área de produção são decompostos em três níveis hierárquicos: o estratégico, o tático e o operacional. O nível mais alto é o estratégico, em que as decisões são projetadas a longo prazo (e.g., anos ou semestres) e com altos investimentos, tratando da decisão do arranjo das máquinas e com a determinação da capacidade destes, em função de uma demanda futura (Arenales *et al.*, 2015; Tubino, 2022). O nível tático lida com o planejamento das atividades/tarefas, envolvendo decisões de quantidade de mão-de-obra, horas extra e subcontratação, além da determinação para cada produto, de quanto e quando produzir em um horizonte de tempo a médio prazo (e.g., semanas ou meses) (Arenales *et al.*, 2015; Pereira *et al.*, 2020). Por fim, o nível operacional controla as atividades diárias das ordens de produção oriundas do nível tático, visando utilizar eficientemente os recursos (Mateljak e Mihanović, 2016).

Diante disso, um dos problemas mais estudados da Pesquisa Operacional (PO) está alocado no nível operacional, que é o problema de sequenciamento da produção, sendo estudado de maneira sistemática há mais de 50 anos, desencadeando milhares de trabalhos e pesquisas (Ertem *et al.*, 2019).

O problema de sequenciamento visa alocar e ordenar as tarefas para um conjunto de máquinas, com o propósito de otimizar um ou mais objetivos (Gonzalez-Neira *et al.*, 2017). Com isso, Pinedo (2022) afirma que, para realizar o sequenciamento de tarefas, é necessário compreender o ambiente de manufatura da organização, sendo esses ambientes classificados em máquina única, máquinas em paralelo, *flow shop*, *job shop* e *open shop*, além das diversas variantes existentes para cada um deles.

Entre os tipos de manufaturas destaca-se o cenário de máquina única, frequentemente modelado como Problema de Sequenciamento de Máquina Única (PSMU), no qual existe apenas uma máquina no *layout* fabril, que processa uma tarefa por vez (Ertem *et al.*, 2019).

A literatura sobre as variantes e extensões, juntamente com os métodos de resolução do PSMU, é bastante abrangente, como evidenciado no trabalho de Quan e Xu (2013). Mas, atualmente, a redução do consumo de energia e da emissão de poluentes tornaram-se um dos maiores desafios das indústrias manufatureiras, levando muitos governos e pesquisadores a investirem tempo e recursos

em pesquisas (Wu e Sun, 2018). Como resultado, a variante Problema de Sequenciamento Verde em Máquina Única (PSVMU) ganhou significativa notoriedade e destaque na comunidade científica e empresarial, tendo em vista que o PSVMU busca otimizar o sequenciamento e a redução da emissão de poluentes, o consumo e o custo de energia, bem como o impacto ambiental (Yang *et al.*, 2019).

Vários métodos para reduzir o impacto ambiental têm sido aplicados na indústria, com destaque para a abordagem de tarifação por Tempo de Uso (*Time-Of-Use* (TOU)). Nessa estratégia, o preço da eletricidade varia ao longo do dia conforme a demanda de energia. Portanto, as tarefas devem ser programadas para serem executadas nos períodos de tarifas mais baixas, dentro de um horizonte de tempo específico. Essa abordagem visa minimizar o consumo total de energia (*Total Energy Consumption* (TEC)) e, consequentemente, reduzir os impactos ambientais.

Segundo Yang *et al.* (2019), o PSVMU é considerado como um problema *NP-Hard*, o que significa que não há algoritmo que possa resolvê-lo em tempo polinomial. Para Talbi (2009), devido ao grau de complexidade de diversos problemas existentes na PO, os métodos exatos, apesar de garantirem a otimalidade, podem não ser viáveis, do ponto de vista prático, para a resolução de problemas de médio e grande porte, devido ao custo computacional atrelado à resolução do problema, fazendo com que o uso de algoritmos heurísticos sejam uma alternativa. Esses métodos têm sido cada vez mais empregados na solução de diversos problemas da PO. Isso ocorre devido à consideração do tempo computacional necessário para resolver problemas e à qualidade das soluções geradas por esses métodos (Souza, 2022).

Além dos modelos apresentados em Quan e Xu (2013), o PSMU e o PSVMU podem possuir parâmetros determinísticos (i.e., para um conjunto de dados entrada, tem-se apenas um único elemento de saída, como uma média) ou estocásticos (i.e., para um conjunto de informações de entrada, existe um conjunto de resultados de saída, o que implica que as saídas devem ser consideradas como estimativas estatísticas dos dados recebidos). Para Chang *et al.* (2016), as versões determinísticas foram extensivamente estudadas na literatura. Entretanto, essa abordagem não representa bem os ambientes de manufatura, visto que o nível operacional das organizações está sujeito a diversos imprevistos que influenciam diretamente na qualidade da solução implementada (Ertem *et al.*, 2019).

Diante disso, para a resolução de problemas estocásticos, existe uma classe de algoritmos chamada de simheurísticas, que consegue de maneira eficiente trabalhar a incerteza presente nos processos, combinando meta-heurísticas com simulações (Juan *et al.*, 2015).

Dado o exposto, surge a seguinte questão: **Como realizar um sequenciamento eficiente para minimizar o consumo de energia relacionado ao processamento das tarefas em diferentes períodos/tarifas ao longo de um horizonte de tempo determinado, de modo a incorporar as**

incertezas presentes no processo e reduzir os impactos ambientais?

1.1 JUSTIFICATIVA E RELEVÂNCIA

O sequenciamento da produção desempenha um papel fundamental nas organizações, especialmente em ambientes industriais complexos e dinâmicos (Tubino, 2022). Esse processo refere-se à ordem em que as atividades de produção são executadas, buscando otimizar recursos, minimizar tempos de espera e maximizar a eficiência operacional. Para Gonzalez-Neira *et al.* (2017), ao estabelecer uma sequência lógica e coordenada de tarefas, as organizações podem melhorar significativamente sua capacidade de atender à demanda do mercado de forma oportuna e econômica. Portanto, compreender e aplicar princípios de sequenciamento da produção é crucial para alcançar operações mais enxutas, competitivas e adaptáveis às demandas do ambiente empresarial contemporâneo.

No entanto, os objetivos operacionais não devem ser o único foco das organizações. O aquecimento global e as mudanças climáticas preocupam cada vez mais a comunidade internacional e ameaçam seriamente o futuro do planeta (Asadpour *et al.*, 2022). Diante disso, muitos países impuseram um conjunto de regulamentações para que as indústrias reduzissem os impactos ambientais, tendo em vista a parcela do consumo de energia na poluição ambiental (Saberi-Aliabad *et al.*, 2020). Alinhado a isso, existem as pressões públicas sobre a conscientização ambiental das organizações, criando a necessidade de pesquisas voltadas para a redução do consumo de energia sem comprometimento dos níveis de serviços (Mansouri *et al.*, 2016).

Para Wu e Sun (2018), uma abordagem para minimizar o consumo de energia nas indústrias envolve a utilização de máquinas mais eficientes energeticamente. No entanto, o investimento financeiro necessário para a aquisição de tais equipamentos se torna inviável para a maior parte do setor manufatureiro, o que leva muitas organizações a buscarem outras alternativas para reduzir o consumo de energia (Öztop *et al.*, 2020). Diante disso, a atenção e os esforços organizacionais voltaram-se para o desenvolvimento de novas estratégias no ambiente de manufatura, visando contribuir com a redução do consumo de energia (Wu e Sun, 2018).

Nesse sentido, o Problema de Sequenciamento Verde (PSV), conforme destacado por Liu *et al.* (2013), emerge como uma dessas abordagens que tem despertado interesse em diversas organizações e pesquisadores. Sua atratividade reside na capacidade de reduzir os impactos ambientais causados pela indústria sem a necessidade de grandes investimentos, como mudanças no *layout* fabril ou nas características do produto, ao mesmo tempo em que possibilita a redução dos custos operacionais por meio da diminuição do consumo de energia (Mansouri *et al.*, 2016).

Entre as diversas metodologias para lidar com o PSV, a política de tarifação por horário

de uso (TOU) tem se destacado, sendo amplamente implementada em muitos países, como nos Estados Unidos, França, Canadá e China, pois contribui para a redução da poluição ambiental ao incentivar os consumidores a deslocarem o consumo de energia para os períodos de baixa demanda e custo (Kathan *et al.*, 2011). Isso contribui para suavizar as flutuações na carga elétrica, diminuindo, consequentemente, a necessidade de recorrer a outras fontes de energia mais poluentes durante os períodos de pico, incluindo, por exemplo, emissões de dióxido de enxofre (SO_2), dióxido de nitrogênio (NO_2), monóxido de carbono (CO) e dióxido de carbono (CO_2), como é o caso das termelétricas (Wang e Li, 2013; Bussadori, 2019). Essas emissões têm um impacto significativo na qualidade do ar, resultando em diversos efeitos adversos na saúde humana e no meio ambiente. Portanto, são necessárias medidas mitigadoras para reduzir o uso dessas outras fontes de energia.

No Brasil, de acordo com Balanço Energético Nacional (2023), as indústrias consomem 32% da energia total do país, situando-se como o segundo maior setor consumidor de energia. Além disso, a matriz energética brasileira emitiu 423 milhões de toneladas de CO_2 em 2022, destacando-se o crescimento no consumo de energia pelas indústrias, que aumentou 1,6% em relação a 2021 (Balanço Energético Nacional , 2023). Esse cenário tem impulsionado cada vez mais o desenvolvimento e a exploração de novas abordagens para reduzir o consumo de energia nessas organizações.

Diante desse contexto, destaca-se o PSMU, que tem sido objeto de estudo em diversas pesquisas. Esse ambiente de manufatura vem sendo cada vez mais discutido devido aos seus resultados e aplicações na otimização de recursos e no balanceamento de linhas de produção, como evidenciado em estudos como os de Pacheco *et al.* (2018), Zhao e Tang (2015) e Yin *et al.* (2013).

O PSMU possui uma importância excepcional dentre os problemas de sequenciamento, pois ele pode representar um caso especial de todos os outros ambientes (Pinedo, 2022). Os resultados obtidos por meio dos estudos PSMU podem ser extrapolados para diferentes tipos de cenários. Isso acontece porque, mesmo na presença de gargalos em processos com várias máquinas e estágios de produção, a otimização do sequenciamento pode ser alcançada ao desmembrar o problema, de modo que ele seja compreendido como um ambiente de máquina única (Marques, 2015). Essa abordagem é válida, uma vez que o sequenciamento da produção está intrinsecamente ligado à capacidade dessa máquina considerada como gargalo (Marques, 2015).

Além disso, um desafio crucial em operações de sequenciamento da produção é em relação as incertezas que podem existir nesse processo. Estas incertezas podem emergir de múltiplas fontes, como tempos aleatórios de processamento de tarefas e *setups*, data de liberação, pedidos urgentes e máquinas sujeitas a quebras (Pinedo, 2022). Para Mecler *et al.* (2021), a incorporação das incertezas na modelagem dos problemas de sequenciamento torna-os mais semelhantes ao que de fato ocorre nos

ambientes fabris. Diante disso, diversas pesquisas com PSMU incorporam aspectos estocásticos em pelo menos um dos parâmetros, como pode ser visto em Ertem *et al.* (2019), no qual consideram os *setups* como estocásticos, e nos trabalhos de Lu *et al.* (2014a) e Chang *et al.* (2016), que modelaram seus problemas considerando os tempos de processamento como estocásticos.

Os problemas de sequenciamento estão alocados no nível operacional do planejamento e da programação da produção, ou seja, o horizonte de planejamento das atividades nesse nível é tratado no curto prazo (e.g., diariamente), inviabilizando em muitos casos a utilização dos métodos exatos, que necessitam de tempo de processamento muito longo para a resolução desse tipo de problema. Apesar dos inúmeros esforços ao longo dos últimos cinquenta anos, ainda não foi desenvolvido um algoritmo suficientemente eficiente para resolver problemas dessa complexidade em tempo polinomial (Esquivel e Lopez, 2013). Diante disso, a aplicação de heurísticas e meta-heurísticas acaba se tornando uma abordagem mais apropriada para a resolução de problemas de sequenciamento, pois essas metodologias conseguem construir soluções de qualidade em um razoável tempo computacional (Goldbarg *et al.*, 2016).

Apesar da aplicabilidade das simheurísticas em diversos problemas de sequenciamento, como os trabalhos de Gonzalez-Neira *et al.* (2017), Gonzalez-Neira e Montoya-Torres (2019) e Mecler *et al.* (2021). O Problema de Sequenciamento Verde em Máquina Única e Estocástico (PSVMUE) ainda não foi explorado de maneira substancial na literatura, carecendo de dados, métodos e parâmetros para uma análise abrangente dos resultados. Além disso, após a revisão sistemática realizada sobre o tema, até o momento não foram encontrados estudos na literatura que tenham abordado todos esses aspectos por meio de uma simheurística. Portanto, o desenvolvimento de metodologias para abordar essas lacunas trará contribuições significativas tanto para o contexto acadêmico quanto para a resolução de desafios práticos.

1.2 OBJETIVOS

O objetivo geral deste trabalho é propor um algoritmo simheurístico para resolver o PSVMUE com tempos de processamento estocásticos, visando minimizar o consumo total de energia (TEC) por meio da política TOU. Para alcançar esse objetivo é necessário estabelecer objetivos específicos a serem cumpridos, sendo eles:

- Realizar uma revisão da literatura para o PSVMU, PSMUE e PSVE;
- Selecionar o modelo do PSVMUE;
- Definir um procedimento de construção da solução inicial;
- Definir o procedimento de simulação para o modelo;

- Implementar a simheurística a partir dos métodos heurísticos e do procedimento de simulação em linguagem de programação;
- Realizar experimentos computacionais da simheurística em instâncias de teste;
- Discutir os resultados utilizando diversas métricas estocásticas em distintos níveis de incerteza.

1.3 ORGANIZAÇÃO DO TRABALHO

O restante desta dissertação está organizado da seguinte forma: o Capítulo 2 apresenta o referencial teórico com conceitos importantes relacionados à temática de heurísticas e meta-heurísticas, simulação Monte Carlo, simheurística, teste de postos sinalizados de Wilcoxon e sequenciamento da produção. Este referencial teórico fornece a base necessária para a compreensão das técnicas e métodos utilizados ao longo do trabalho. No Capítulo 3, são descritas três revisões sistemáticas que foram realizadas para identificar lacunas e tendências no estado da arte, proporcionando uma visão abrangente sobre as pesquisas existentes e destacando a relevância e a inovação do trabalho proposto. O Capítulo 4 descreve a classificação da pesquisa e os procedimentos computacionais implementados. No Capítulo 5, são apresentados e discutidos os resultados encontrados durante a pesquisa. Por fim, o Capítulo 6 conclui a dissertação, sintetizando os principais pontos e contribuições do estudo, apresentando sugestões para trabalhos futuros, visando a continuidade e o aprofundamento das investigações nesta área.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, são apresentados conceitos fundamentais relacionados a heurísticas e meta-heurísticas (Seção 2.1). Dentro desta mesma seção, é fornecida uma base teórica que explora os conceitos e terminologias frequentemente utilizados ao lidar com esses métodos. Na Seção 2.2, são detalhados os procedimentos para a geração de valores aleatórios por meio da simulação Monte Carlo. Na Seção 2.3, são apresentados os detalhes de um método para resolver problemas de Otimização Combinatória (OC) estocásticos, conhecido como simheurísticas, juntamente com uma subseção dedicada às métricas estocásticas. Na Seção 2.4, são apresentados informações sobre um teste estatístico não paramétrico utilizado para comparar duas amostras relacionadas. Por fim, é fornecida uma fundamentação teórica sobre programação da produção (Seção 2.5), com informações sobre sequenciamento verde, sequenciamento em máquina única, e uma descrição detalhada do problema específico abordado nesta pesquisa.

2.1 HEURÍSTICA E META-HEURÍSTICA

Apesar da constante evolução dos computadores e dos avanços tecnológicos ocorridos nos últimos anos, ainda existe uma limitação na capacidade de resolver problemas de OC de maneira exata (i.e., a solução de melhor desempenho do espaço de soluções viáveis). No pior dos casos, a resolução é realizada através da enumeração sistemática de todas as opções possíveis (Esquirol e Lopez, 2013). Embora seja possível incorporar técnicas que permitam uma resolução exata mais eficiente, como o *branch-and-bound* ou *branch-and-cut*, que conseguem reduzir o número de soluções a serem analisadas, mesmo assim, devido à natureza do problema e à sua complexidade, a resolução exata pode ser inviável para instâncias de tamanho significativo (Souza, 2022).

Os métodos heurísticos são técnicas inspiradas em processos intuitivos que buscam uma boa solução a um custo computacional aceitável, sem garantir sua otimalidade ou informar quão próxima está da solução ótima (Souza, 2022). Além dos benefícios em termos de tempo computacional, as heurísticas oferecem outras vantagens quando comparadas aos métodos exatos. Por exemplo, permitem a intercambialidade de abordagens heurísticas entre diferentes problemas de OC (e.g., as heurísticas do caixeiro viajante podem ser adaptadas para resolver problemas de sequenciamento de máquina única com *setups* dependentes da sequência) e são geralmente mais fáceis de implementar (Esquirol e Lopez, 2013).

Por outro lado, na prática, uma solução de alta qualidade, ainda que não seja a ótima, muitas vezes é suficientemente adequada para problemas reais (ou práticos) de natureza combinatória,

sendo esse o principal impulso para que diversos pesquisadores concentrem seus esforços nos métodos heurísticos (Souza, 2022).

As heurísticas podem ser divididas em heurísticas construtivas e heurísticas de refinamento. As heurísticas construtivas têm como propósito construir uma solução passo a passo, onde a determinação da inserção do próximo elemento é influenciada pela função de avaliação adotada, que varia conforme o problema abordado (Souza, 2022). Por outro lado, as heurísticas de refinamento partem de uma solução já existente, geralmente derivada da heurística construtiva, e buscam aprimorá-la por meio de alterações (Blum e Roli, 2003). Conforme observado por Souza (2022), o refinamento é orientado pela noção de vizinhança, que compreende todas as soluções possíveis derivadas da solução inicial, e nesse processo a solução inicial é modificada por meio de um movimento, permitindo a exploração interativa das soluções vizinhas em busca de melhorias.

Nos últimos anos, uma nova categoria de algoritmos heurísticos emergiu, procurando combinar os métodos heurísticos com estruturas que permitam uma busca mais eficaz no espaço de soluções, sendo esses métodos conhecidos como meta-heurísticas (Blum e Roli, 2003). De maneira formal, uma meta-heurística é caracterizada como um procedimento de iterações sucessivas que guia uma heurística subordinada, combinando de maneira inteligente (i.e., possuem mecanismos para escapar de ótimos locais) diferentes conceitos para uma exploração mais eficiente do espaço de soluções (Osman e Kelly, 1996).

As meta-heurísticas fazem uso de estratégias de manipulação de uma única solução ou de uma coleção de soluções para explorar eficientemente o espaço de solução, mantendo um equilíbrio entre diversificação e intensificação (Blum e Roli, 2003). Os mesmos autores afirmam que a diversificação consiste no deslocamento para outras regiões do espaço de soluções, e a intensificação consiste em permanecer na região do espaço onde a busca se encontra, procurando explorá-la de forma mais efetiva.

Conforme Talbi (2009), as meta-heurísticas podem ser categorizadas em duas principais abordagens: as meta-heurísticas baseadas em busca local e as meta-heurísticas populacionais. As baseadas em busca local se concentram em explorar movimentos aplicados à solução atual para gerar soluções vizinhas promissoras, dentre as mais conhecidas na literatura está a *Simulated Annealing* (SA), *Variable Neighborhood Search* (VNS), *Iterated Local Search* (ILS), *Greedy Randomized Adaptive Search Procedure* (GRASP) e Busca Tabu (Souza, 2022). Por outro lado, as meta-heurísticas populacionais, de acordo com Talbi (2009), partem de uma população inicial e realizam combinações entre seus elementos, com o objetivo de descobrir soluções aprimoradas, entre as abordagens mais reconhecidas estão o Algoritmo Genético (AG) e o *Ant Colony Optimization* (ACO).

2.1.1 Greedy Randomized Adaptive Search Procedure (GRASP)

A metaheurística GRASP, proposta por Feo e Resende (1995), é um método iterativo eficaz capaz de resolver problemas de OC, combinando elementos de construção aleatória e busca local (Gendreau, 2010). O pseudocódigo do GRASP pode ser observado no Algoritmo 1.

Algoritmo 1: Procedimento GRASP (α, η)

```

1:  $s = \emptyset$ 
2:  $f(s) = \infty$ 
3: for  $a = 1, \dots, \eta$  do
4:    $s', f(s') \leftarrow \text{Construtiva}(\alpha)$ 
5:    $s^*, f(s^*) \leftarrow \text{BuscaLocal}(s', f(s'))$ 
6:   if  $f(s^*) < f(s)$  then
7:      $s \leftarrow s^*$ 
8:      $f(s) \leftarrow f(s^*)$ 
9:   end if
10: end for
11: return  $s, f(s)$ 
  
```

Inicialmente, a melhor solução (s) e sua função objetivo ($f(s)$) são definidas como vazia e infinito, respectivamente (Linhas 1–2). Assim, o procedimento começa com a criação de uma solução inicial (Linha 4), onde a abordagem utiliza uma combinação de critérios gulosos e aleatórios. Durante a construção da solução, uma lista de candidatos é formada, e cada candidato é avaliado com base em um critério que mede sua contribuição para a qualidade da solução parcial (Souza, 2022). Posteriormente, cria-se uma Lista de Candidatos Restrito (LCR), composta pelos melhores elementos avaliados, tomando como base o valor do parâmetro α , permitindo uma seleção aleatória entre eles. Essa abordagem promove diversidade nas soluções iniciais, evitando armadilhas em ótimos locais prematuros. Com isso, é aplicada uma busca local nessa solução (s') a fim de encontrar vizinhos que apresentem melhores valores na função objetivo (Linha 5).

O procedimento (i.e., a criação de uma solução inicial combinada a uma busca local) é repetido por um número pré-determinado de iterações (η) ou até que um critério de parada seja satisfeito (Linhas 3-10). A melhor solução (s) é atualizada (sempre que possível) iterativamente ao longo dessas iterações (Linhas 6-8). Este procedimento é fundamental para explorar eficazmente o espaço de soluções e aumentar a probabilidade de encontrar soluções de alta qualidade (Feo e Resende, 1995). O desempenho do GRASP pode ser ajustado por meio de parâmetros como o tamanho da LRC e o número de iterações, proporcionando flexibilidade e adaptabilidade à técnica.

A robustez do GRASP reside na sua capacidade de equilibrar intensificação e diversificação

na exploração do espaço de soluções (Feo e Resende, 1995). A construção aleatória (s') contribui para uma exploração abrangente do espaço de soluções, enquanto a busca local (s^*) garante uma exploração detalhada das áreas promissoras. Esse equilíbrio é particularmente vantajoso em problemas complexos de otimização, onde a busca por soluções ótimas pode ser intratável devido ao tamanho e à complexidade do espaço de soluções (Gendreau, 2010).

2.1.2 Simulated Annealing (SA)

A meta-heurística SA é uma técnica inspirada no processo de recocimento de metais, onde um material é aquecido até uma temperatura elevada e, em seguida, resfriado lentamente para minimizar sua energia interna. A essência do SA está na sua capacidade de explorar o espaço de soluções de forma controlada e probabilística, permitindo uma busca global eficiente por soluções de qualidade (Kirkpatrick *et al.*, 1983). O pseudocódigo desse procedimento pode ser observado no Algoritmo 2.

Algoritmo 2: Procedimento SA (T, R, β_{max})

```

1:  $f(s^*) = \infty$ 
2: Gere uma solução  $s$ 
3: while  $T > 0$  do
4:   while  $\beta < \beta_{max}$  do
5:      $\beta \leftarrow \beta + 1$ 
6:     Gere um vizinho qualquer  $s' \in N(s)$ 
7:      $\Delta = f(s') - f(s)$ 
8:     if ( $\Delta < 0$ ) then
9:        $s \leftarrow s'$ 
10:      if  $f(s') < f(s^*)$  then
11:         $s^* \leftarrow s'$ 
12:      end if
13:    else
14:      Gere um valor para  $x \in [0, 1]$ 
15:      if  $x < e^{-\frac{\Delta}{T}}$  then
16:         $s \leftarrow s'$ 
17:      end if
18:    end if
19:  end while
20:   $T \leftarrow R \times T$ 
21:   $\beta \leftarrow 0$ 
22: end while
23:  $s \leftarrow s^*$ 
24: Retorne  $s$ 

```

Inicialmente, o algoritmo do SA começa com uma solução inicial s (Linha 2), que pode ser

selecionada aleatoriamente ou baseada em uma heurística específica, e uma temperatura inicial elevada T (Linha 3). A escolha de uma temperatura inicial alta é estratégica, pois permite ao algoritmo aceitar temporariamente soluções de menor qualidade, com uma certa probabilidade (Souza, 2022). Esse mecanismo de aceitação probabilística de soluções piores é essencial para escapar de ótimos locais e garantir uma exploração mais ampla do espaço de soluções (Gendreau, 2010). A cada iteração, uma nova solução vizinha s' é gerada por meio de uma pequena perturbação na solução corrente (Linha 6), sendo então avaliada de acordo com a função objetivo do problema.

A aceitação de uma nova solução no SA é determinada por uma função de aceitação probabilística. Se a nova solução apresentar uma melhoria em relação à solução atual, ela é imediatamente aceita (Linha 8). No entanto, se a nova solução for pior, ela ainda pode ser aceita (Linha 15), com uma probabilidade $P = e^{\frac{-\Delta}{T}}$, onde Δ representa a diferença na função objetivo entre a solução corrente ($f(s)$) e a solução vizinha ($f(s')$), e T é a temperatura atual. Essa probabilidade de aceitação decresce conforme a temperatura diminui, permitindo ao algoritmo realizar uma busca global no início e uma busca local mais refinada nas etapas posteriores (Kirkpatrick *et al.*, 1983).

Além disso, é considerado um número fixo de iterações, β_{max} , que representa a quantidade de iterações necessárias para que o sistema atinja o equilíbrio térmico em uma determinada temperatura (Linhas 4-19). Somente após essa etapa a temperatura é gradativamente diminuída pela razão de resfriamento.

O processo de resfriamento gradual (Linha 20) é controlado por uma constante de resfriamento K , que determina como a temperatura é reduzida ao longo das iterações (Kirkpatrick *et al.*, 1983). A função de resfriamento pode ser linear, exponencial ou seguir um padrão adaptativo mais complexo. A escolha adequada da função de resfriamento é crucial para o desempenho do algoritmo, pois influencia diretamente o equilíbrio entre a exploração de novas áreas do espaço de soluções e a exploração detalhada das áreas promissoras (Gendreau, 2010). O algoritmo continua iterando até que a temperatura atinja um valor mínimo pré-definido ou outro critério de parada seja satisfeito, como um número máximo de iterações ou a estabilização da qualidade das soluções encontradas.

2.2 SIMULAÇÃO MONTE CARLO

Para Banks (2005), a simulação Monte Carlo é a imitação do funcionamento de um modelo ou sistema do mundo real ao longo do tempo. O funcionamento da simulação baseia-se em executar o modelo várias vezes, e para cada amostra, variáveis aleatórias são geradas para incorporar a incerteza inerente ao modelo (Thomopoulos, 2014). Essa variabilidade resultante da simulação do modelo é fundamental para entender sua robustez e sua sensibilidade às mudanças nas condições iniciais.

Através da repetição do processo de simulação com diferentes conjuntos de valores de entrada, é possível explorar a gama completa de resultados possíveis e avaliar a probabilidade de ocorrência de diferentes cenários.

A simulação pode ser utilizada para investigar uma ampla variedade de cenários “e se” sobre o sistema do mundo real. Mudanças potenciais no sistema podem ser simuladas inicialmente para prever seu impacto. Dessa forma, a modelagem por simulação pode servir tanto como uma ferramenta de análise para antecipar o efeito de modificações em sistemas existentes, quanto como uma ferramenta de projeto para prever o desempenho de novos sistemas em diferentes conjuntos de circunstâncias (Banks, 2005).

Um ponto fundamental e amplamente discutido em problemas que envolvem simulação é a quantidade de replicações necessárias para garantir uma representação precisa da estocasticidade presente nos modelos analisados. Realizar um número excessivo de replicações pode resultar em um uso desnecessário de tempo computacional. Por outro lado, um número insuficiente de replicações pode levar a resultados imprecisos e, consequentemente, a decisões incorretas. Portanto, encontrar um equilíbrio adequado na determinação do número de replicações é crucial para garantir que os resultados da simulação sejam confiáveis e úteis para a tomada de decisões (Hoad *et al.*, 2007). Em Rabe *et al.* (2020) são apresentados três métodos para determinar o número adequado de replicações em uma simulação: a Regra Prática (Law e McComas, 1991), o Método Gráfico Simples (Robinson, 2004) e o Método do Erro do Intervalo de Confiança (Banks, 2005).

Na Regra Prática, Law e McComas (1991) recomendam realizar pelo menos 3 a 5 replicações. Essa abordagem é útil para alertar os usuários de que confiar nos resultados de uma única execução não é aconselhável. No entanto, ela não considera as particularidades dos resultados de um modelo. Assim, embora 3 a 5 replicações possam ser suficientes para um determinado modelo, para outro, elas podem ser inadequadas.

No Método Gráfico Simples, o usuário realiza uma série de replicações e plota um gráfico com a média cumulativa da função objetivo analisada em função do número de replicações. O usuário então seleciona visualmente o ponto no gráfico onde a linha da média cumulativa se torna “plana” e utiliza isso como o número de replicações. Embora este método seja simples de entender e aplicar, ele é subjetivo e não oferece um nível de precisão mensurável (Robinson, 2004).

Por fim, o Método do Erro do Intervalo de Confiança (com Precisão Especificada) requer que o usuário avalie o tamanho do erro que ele pode tolerar na estimativa da média verdadeira do modelo. Replicações são então executadas e intervalos de confiança são construídos em torno das médias cumulativas sequenciais até que a precisão desejada na saída seja alcançada. Embora essa

abordagem seja mais precisa, ela demanda um julgamento subjetivo do usuário sobre a precisão desejada (Banks, 2005). O autor define o *Erro* como um percentual da média acumulada do intervalo de confiança, sendo calculado como:

$$Erro = \frac{100 \times t_{n-1,NS/2} \times \frac{\sigma}{\sqrt{iter}}}{\mu}, \quad (2.1)$$

onde, $t_{n-1,NS/2}$ representa o valor da distribuição *t-student* para $n - 1$ graus de liberdade e um nível de significância NS , μ é a média acumulada, σ é a estimativa do desvio padrão e $iter$ é o número atual de replicações. Em Banks (2005), assim que o critério de erro é alcançado, a simulação é encerrada e o número de iterações utilizadas é relatado ao usuário. No entanto, em Rabe *et al.* (2020), os autores destacam que essa abordagem pode resultar em uma convergência prematura do *Erro*, resultando em um número inadequado de replicações. Por isso, o autor propõe a definição de um número mínimo de replicações (ρ) que devem ser realizadas para validar o critério de erro calculado pelo procedimento. Dessa forma, o número mínimo real de replicações realizadas é uma função do valor definido pelo usuário ($f(\rho_{min})$), sendo dado por:

$$f(\rho) = \begin{cases} \rho, & iter \leq 100 \\ \lfloor iter \times \frac{\rho}{100} \rfloor, & iter > 100 \end{cases} \quad (2.2)$$

A função é projetada para ajustar o número mínimo de replicações em proporção ao número atual de iterações ($iter$).

2.3 SIMHEURÍSTICA

As técnicas e métodos de simulação-otimização têm sido empregados nas últimas décadas, com os primeiros métodos de classificação e seleção estocástica sendo introduzidos por volta de 1950, conforme destacado por Juan *et al.* (2015). No entanto, somente com os avanços na capacidade computacional, o desenvolvimento de abordagens meta-heurísticas híbridas e a ampla disponibilidade de softwares de simulação é que o campo da simulação-otimização efetivamente ganhou impulso (Juan *et al.*, 2015).

As meta-heurísticas têm sido bastantes utilizadas para a resolução de problemas de OC devido à qualidade das soluções encontradas e pelo tempo computacional (Gendreau, 2010). Entretanto, as meta-heurísticas têm sido aplicadas principalmente em problemas simplificados, em que as incertezas (aleatoriedade) dos problemas reais não são levadas em consideração.

Dessa forma, Gonzalez-Neira *et al.* (2021) indicam que a combinação de meta-heurísticas com outras metodologias está ganhando popularidade, como a combinação de simulação com meta-heurística, que em diversas pesquisas mostrou-se eficaz para tratar problemas complexos. A fusão de

técnicas de simulação com heurísticas/meta-heurísticas resulta em uma nova categoria de algoritmos denominada simheurística (Vieira, 2022).

A combinação entre essas duas metodologias se torna necessária, pois as simulações por si só não constituem técnicas de otimização (Castaneda *et al.*, 2022). Entretanto, os experimentos derivados de simulações permitem entender o comportamento do modelo diante do espaço de decisão em diversos cenários, sendo essa característica muito importante para os modelos da OC (Juan *et al.*, 2018). Para Thomopoulos (2014), os métodos de simulação são baseados na execução do modelo diversas vezes, no qual, para cada amostra, diferentes saída são geradas. Diante disso, as simheurísticas incorporam técnicas de simulação em suas diferentes formas, em uma estrutura de meta-heurística para resolver problemas de OC estocásticos (Mecler *et al.*, 2021).

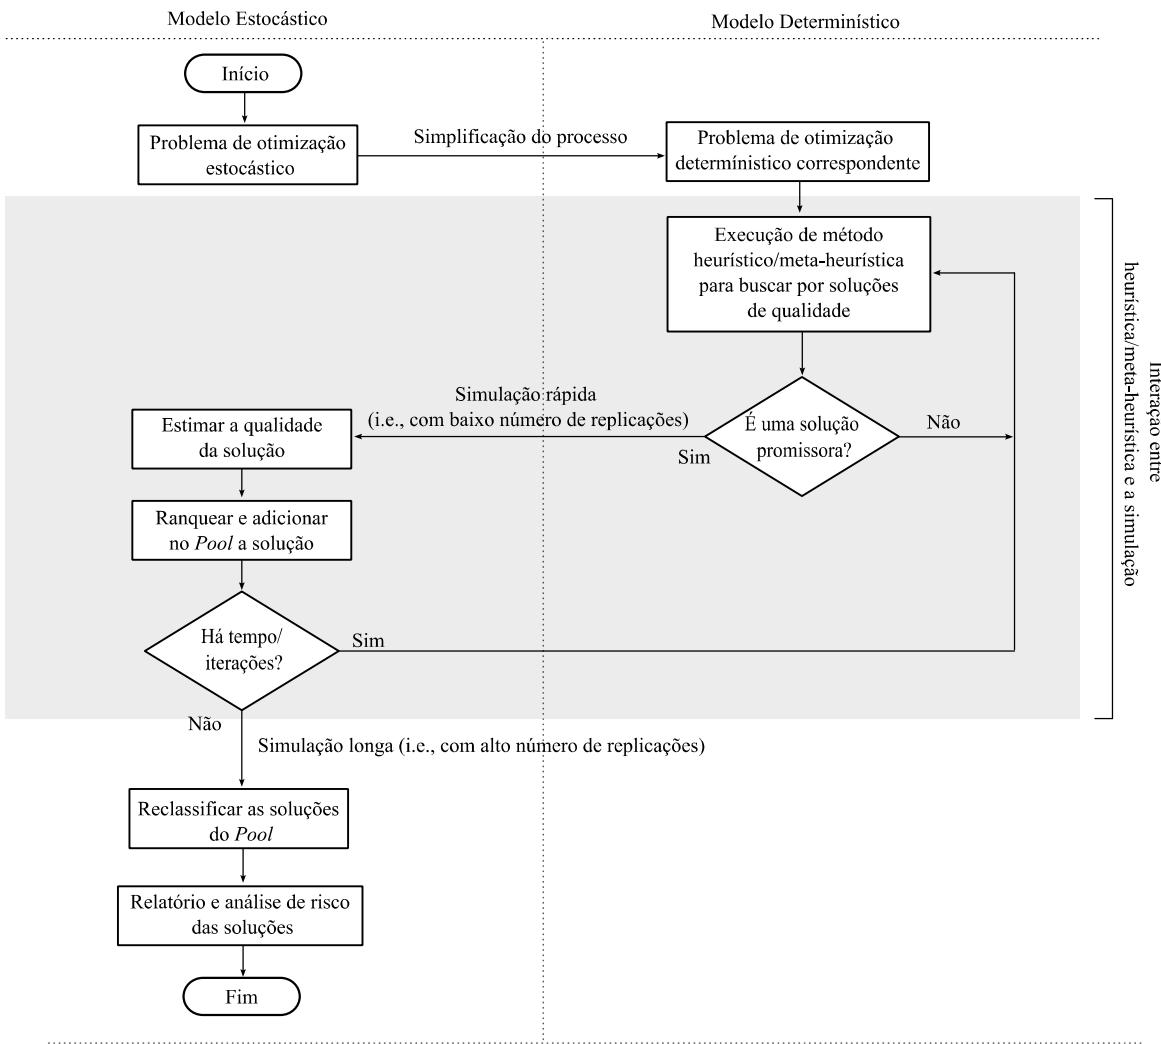
As simheurísticas têm sido aplicadas em uma variedade de problemas de OC. Por exemplo, Gonzalez-Neira *et al.* (2021), Gonzalez-Neira e Montoya-Torres (2019) e Bittencourt *et al.* (2023) utilizam simheurísticas para lidar com problemas de sequenciamento. Em Gonzalez-Neira *et al.* (2021) e Gonzalez-Neira e Montoya-Torres (2019), os autores consideraram os tempos de processamento como variáveis aleatórias, enquanto Bittencourt *et al.* (2023) aborda os *setups* dependentes da sequência como estocásticos. Além disso, essas técnicas também foram empregadas em problemas de otimização de portfólio, nos quais o retorno financeiro apresenta estocasticidade (Kizys *et al.*, 2022). Da mesma forma, em problemas de roteamento, onde tanto a demanda quanto os tempos de viagem são considerados estocásticos,(Keenan *et al.*, 2021, Guimaraes *et al.*, 2018).

Ao incorporar estocasticidade nos processos, os modelos se aproximam mais com a realidade das organizações. Essa consideração incorpora a natureza dinâmica e imprevisível dos ambientes empresariais, nos quais diversos fatores podem variar de forma aleatória (Juan *et al.*, 2018). Assim, ao modelar essas incertezas, os tomadores de decisão têm uma representação mais precisa dos riscos e das possíveis consequências de suas escolhas estratégicas. Isso permite uma avaliação mais abrangente das alternativas e uma melhor preparação para lidar com cenários adversos, tornando os modelos mais robustos e úteis para orientar a gestão e o planejamento nas organizações.

A estrutura básica e lógica das simheurísticas pode ser observada na Figura 1.

A etapa inicial das simheurísticas envolve a simplificação do problema em estudo, resolvendo preliminarmente o modelo de forma determinística. Pois, para Juan *et al.* (2018), em cenários de incerteza moderada, soluções de alta qualidade para a versão determinística de um problema de otimização também são provavelmente soluções de alta qualidade para sua versão estocástica correspondente. No entanto, isso não implica necessariamente que a melhor solução determinística para o problema de otimização seja também a melhor solução para a versão estocástica.

Figura 1 – Estrutura base de uma simheurística



Fonte: Juan *et al.* (2015)

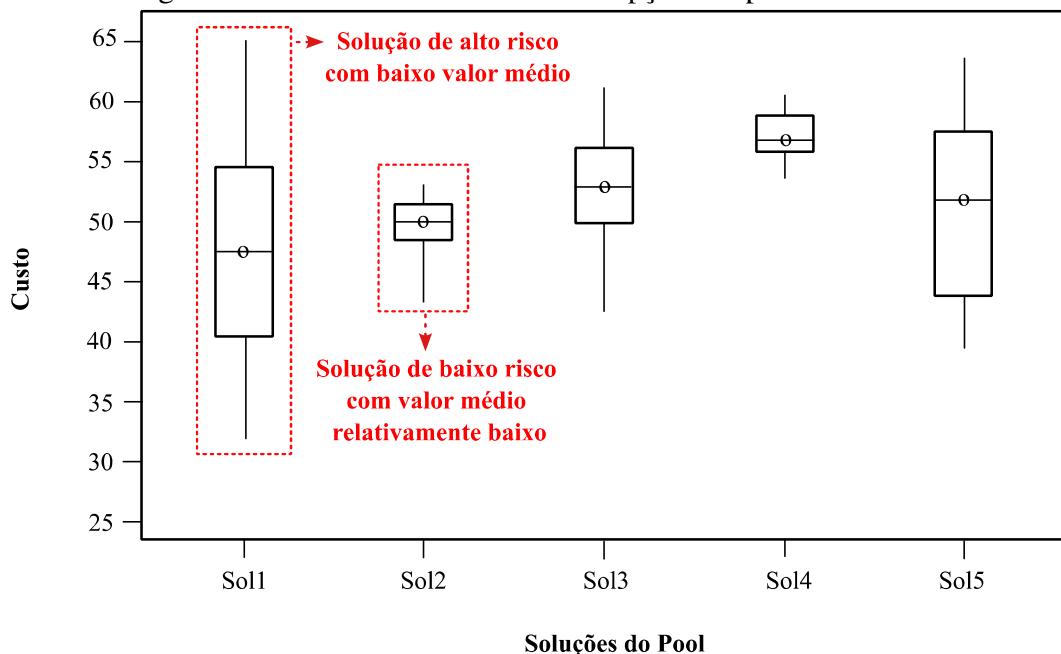
A correlação mencionada oferece a vantagem de filtrar exclusivamente as soluções mais promissoras (i.e., quando a solução atual possui um valor melhor na função objetivo no ambiente determinístico do que a solução previamente salva como a melhor) para conduzir a etapa de simulação. Isso implica na execução de um número reduzido de replicações (simulação curta), visto que apenas estimativas aproximadas são necessárias nessa fase (Gonzalez-Neira *et al.*, 2017). Essa abordagem estratégica permite gerenciar eficientemente o esforço computacional durante o processo de busca interativa, assegurando tempo suficiente para que a meta-heurística realize uma exploração intensiva do espaço de soluções (Juan *et al.*, 2015). Posteriormente, as soluções promissoras são adicionadas e classificadas em um conjunto denominado *Pool*.

Após o término do tempo computacional ou das iterações designadas para o processo de busca iterativa da meta-heurística, uma simulação mais extensa é conduzida em todas as soluções do *Pool*, utilizando um número maior de replicações. Isso possibilita a obtenção de estimativas mais

precisas para cada uma das soluções, nas quais diferentes métricas podem ser utilizadas para avaliar sua qualidade estocástica. Na subseção 2.3.1, são apresentadas e detalhadas as métricas estocásticas mais utilizadas nas simheurísticas. Por fim, após a simulação longa, as soluções são reclassificadas de acordo com a métrica estocástica escolhida, permitindo ao decisor realizar uma análise dos riscos associados a partir das soluções do *Pool*, concluindo assim o procedimento da simheurística.

Adicionalmente, conforme destacado por Mecler *et al.* (2021), é importante ressaltar que as simheurísticas têm a capacidade de fornecer informações sobre a distribuição de probabilidade de cada solução, como demonstrado na Figura 2.

Figura 2 – Análise de risco dentre as opções disponíveis no *Pool*



Fonte: Juan *et al.* (2015)

Dante disso, a distribuição de probabilidade de cada solução pode fornecer informações adicionais para a introdução de critérios de análise de risco e confiabilidade no processo de tomada de decisão, permitindo que o decisor selecione uma solução alinhada ao seu perfil e preferências individuais (Street, 2010). Por exemplo, na Figura 2, um decisor avesso ao risco tende a escolher uma solução com menor variabilidade ou risco (Sol2), enquanto um decisor mais propenso ao risco poderia optar por uma solução com maior variabilidade (Sol1), desde que proporcionasse um valor médio inferior às demais.

2.3.1 Métricas Estocásticas

As métricas estocásticas desempenham um papel crucial na compreensão e avaliação de problemas estocásticos, oferecendo diferentes abordagens para caracterizar a variabilidade e a aleatoriedade presentes em sistemas. Além de quantificar a aleatoriedade, essas métricas também proporcionam informações significativas para a tomada de decisão e uma compreensão mais profunda dos processos em análise. Entre as métricas mais comuns estão a média, e as medidas relacionadas ao risco, como o *Value at Risk* (VaR) e o *Conditional Value at Risk* (CVaR).

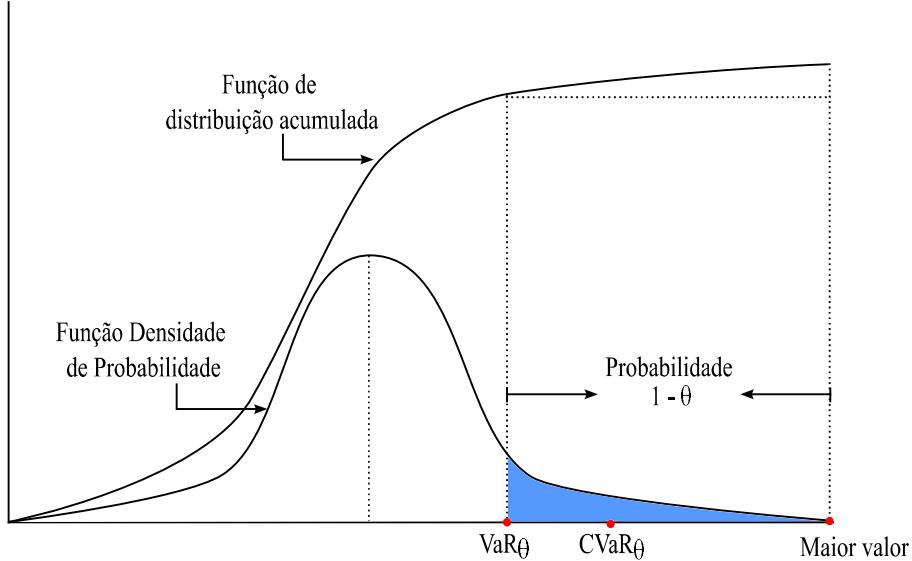
Em termos de simplicidade, a métrica média é a mais básica de todas. Consiste essencialmente em somar todos os valores da função objetivo analisada para cada iteração e dividir pelo número total de iterações da simulação, resultando na média dos valores simulados. Esse cálculo fornece uma medida representativa do desempenho esperado da solução em questão. Assim, é possível capturar uma visão geral do comportamento médio da solução, o que é fundamental para a compreensão de seu desempenho e para embasar decisões estratégicas.

Quanto às métricas estocásticas que visam mitigar os riscos, conforme apontado por Heckmann *et al.* (2015), a busca por mecanismos de controle ou redução do risco é uma preocupação abrangente em diversas áreas, incluindo finanças, gestão da cadeia de suprimentos, energia e medicina. Como resultado, as medidas de risco ganharam rapidamente grande popularidade durante a primeira década do século XXI, destacando-se o VaR e o CVaR (Rockafellar e Uryasev, 2000).

Segundo Kisiala (2015), o VaR, ou quantil $1 - \theta$, é o risco mínimo que não será excedido com probabilidade θ . Em outras palavras, é o menor risco entre os piores casos para $1 - \theta$. Por exemplo, considerando uma distribuição de probabilidade X que representa todos os valores simulados de TEC para uma solução, um $\text{VaR}_{95\%} = 50$ indica que 95% de todos os valores simulados serão menores que 50, enquanto 5% desses valores serão maiores ou iguais a 50. Esse método amplamente utilizado como uma medida de risco porque o seu conceito é facilmente comprehensível e foca nos piores cenários, ou seja, no risco da cauda. No entanto, para Rockafellar e Uryasev (2000), a grande deficiência dessa métrica é que ela não fornece qualquer indicação sobre a gravidade dos riscos além de seu valor.

Devido às limitações e críticas enfrentadas pelo VaR, Rockafellar e Uryasev (2000) propuseram o CVaR, também conhecido como Valor em Risco Condicional. Essa métrica quantifica a média das perdas (risco) a que se está sujeito em uma determinada solução, fornecendo, assim, informações sobre os valores extremos da distribuição. Portanto, para um mesmo θ , o VaR é um limite inferior ao CVaR (Filippi *et al.*, 2020). Na Figura 3 é apresentado uma representação do VaR e do CVaR.

Figura 3 – Ilustração do VaR e do CVaR para o mesmo θ



Fonte: Elaborado pelo autor (2024)

2.4 TESTE DE POSTOS SINALIZADOS DE WILCOXON

O teste de postos sinalizados de Wilcoxon é uma técnica estatística não paramétrica utilizada para comparar a mediana da amostra com um valor de referência ou para testar diferenças em amostras pareadas (Woolson, 2007). Diferente de testes paramétricos como o *t-test* pareado, o teste de Wilcoxon não assume que os dados seguem uma distribuição normal.

Quando a variável de interesse é a diferença da mediana entre as observações pareadas e utiliza-se o teste bilateral, emprega-se o símbolo M_d para a mediana populacional da variável diferença, e normalmente adota-se o valor 0 como referência. A hipótese nula é que $M_d = 0$, e a hipótese alternativa é que $M_d \neq 0$.

Ao aceitar a hipótese nula no teste de Wilcoxon para dados pareados, conclui-se que não há diferença significativa nas medianas das duas amostras relacionadas. Formalmente, isso significa que a distribuição das diferenças entre as observações pareadas é simétrica em torno de zero (Seward e Doane, 2014). Em outras palavras, qualquer diferença observada entre os pares de dados pode ser atribuída ao acaso, não havendo evidências estatísticas para suportar a existência de uma diferença sistemática entre os grupos ou condições comparadas. Por outro lado, a aceitação da hipótese alternativa sugere que existe uma diferença significativa entre as medianas das duas amostras pareadas. Isso indica que a diferença observada não é devida ao acaso, proporcionando evidências estatísticas de uma diferença sistemática entre os grupos ou condições comparadas.

O procedimento do teste de Wilcoxon envolve calcular as diferenças entre as observações pareadas e, em seguida, classificar essas diferenças em ordem crescente em valor absoluto (Seward e

Doane, 2014). Posteriormente, os sinais originais das diferenças são reaplicados às suas respectivas posições na classificação. Em seguida, somam-se os postos positivos (W). Com os postos positivos somados, calcula-se o valor esperado da estatística (μ_w) e o desvio padrão da estatística (σ_w). Esses valores permitem calcular a estatística do teste de Wilcoxon (Z_{calc}), que é então utilizada para determinar a significância estatística.

$$W = \sum_{i=1}^n R^+ \quad (2.3)$$

$$\mu_w = \frac{n(n+1)}{4} \quad (2.4)$$

$$\sigma_w = \sqrt{\frac{n(n+1)(2n+1)}{24}} \quad (2.5)$$

$$Z_{calc} = \frac{W - \mu_w}{\sigma_w} \quad (2.6)$$

Nesta dissertação, foi utilizado o teste de postos sinalizados de Wilcoxon para amostras pareadas para realizar a comparação entre duas abordagens, buscando determinar se há diferenças significativas entre elas.

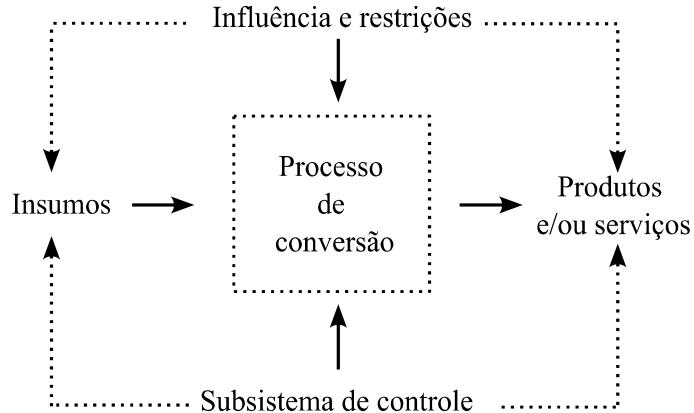
2.5 SEQUENCIAMENTO DA PRODUÇÃO

Para Tubino (2022) as organizações são compreendidas como sistemas transformadores, que recebem como entrada *inputs* (insumos) e informações, e a partir disso, as empresas transformam em saídas (produtos) úteis aos clientes.

Dante disso, Moreira (2008) lista que influência e restrições, insumos, processo de conversão, produtos e/ou serviço, e os subsistema de controle são elementos fundamentais de uma organização. Primeiramente, há a influência e restrições que afetam o ambiente de produção, impactando o desempenho das empresas (Moreira, 2008). Em seguida, tem-se os insumos, que são os recursos a serem transformados em produtos (e.g., matéria-prima) e os recursos responsáveis pelo funcionamento do sistema (e.g., mão-de-obra, capital, máquinas, instalações, etc) (Correa e Correa, 2017). O processo de conversão transforma os insumos, resultando em produtos ou serviços com valor de mercado (Correa e Correa, 2017). Por fim, o subsistema de controle, que garante o cumprimento das programações, otimizando a utilização dos recursos (Moreira, 2008). A representação desses elementos do sistema produtivo pode ser vista na Figura 4.

Dessa forma, é necessário que os sistemas produtivos sejam organizados em diferentes horizontes de planejamento, para que de fato todo o processo de transformação das entradas seja realizado de maneira eficiente (Xavier, 2020). Dante disso, para Arenales *et al.* (2015), o planejamento pode ser estruturado em três níveis e em três planos, compreendendo o planejamento estratégico

Figura 4 – Representação do sistema de produção e seus elementos



Fonte: Moreira (2008)

junto ao plano de produção, o planejamento tático com o plano mestre de produção, e por último, o planejamento operacional com a programação.

Diante do curto horizonte de tempo do planejamento do operacional, existe a necessidade de trabalhar de maneira eficiente com as demandas desse nível organizacional. Pois, uma programação de produção eficiente possibilita a realização de vários objetivos e para vários setores de uma empresa, incluindo a redução dos custos, o cumprimento de prazos de entrega, a minimização de atrasos e a diminuição do tempo total de processamento das tarefas (Slack *et al.*, 2018).

Entretanto, embora a modelagem de problemas de manufatura, como o problema de programação de máquinas, possa parecer simples, nunca devemos subestimar o esforço computacional necessário para encontrar a solução (Esquirol e Lopez, 2013). Encontrar a solução ótima para esse tipo de problema é bastante desafiador. Por essa razão, os pesquisadores da área classificam diversos desses problemas como *NP-Hard*, sendo recomendada a utilização de métodos heurísticos para a resolução (Esquirol e Lopez, 2013).

Devido à crescente pesquisa sobre sequenciamento da produção, Graham *et al.* (1979) desenvolveram uma notação que visa abranger a grande maioria dessas pesquisas presentes na literatura, utilizando a configuração $(\alpha \mid \beta \mid \gamma)$. O campo α descreve o ambiente de manufatura e possui uma única entrada. Os principais ambientes são classificados e descritos, segundo Esquirol e Lopez (2013) e Brucker e Knust (2012), como:

- Máquina única (1): Apenas um estágio de produção e uma máquina disponível para o processamento das tarefas;
- Máquina paralela (P_m): Várias máquinas estão disponíveis para o processamento de tarefas, mas cada tarefa só pode ser processada uma única vez e em uma única máquina, e o ambiente possui apenas um estágio de produção. Assim, um conjunto de máquinas operando em paralelo

constitui uma configuração relevante tanto do ponto de vista teórico quanto prático. Do ponto de vista teórico, essa configuração se torna uma generalização das máquinas individuais. Já sob a perspectiva prática, essa configuração é significativa devido à sua ocorrência frequente de recursos operando em paralelo no contexto real. As Máquinas Paralelas podem ser sub-classificadas em três tipos: Máquinas Paralelas Idênticas (P), onde os tempos de processamento das tarefas são iguais em todas as máquinas; Máquinas Paralelas Uniformes (Q), nas quais os tempos de processamento variam de acordo com um fator multiplicativo específico para cada máquina; e Máquinas Paralelas Não-Relacionadas (R), em que os tempos de processamento das tarefas variam de forma independente e sem correlação entre as máquinas;

- *Flow shop (F)*: Nesse cenário, há uma disposição de máquinas em série pelas quais as tarefas devem ser encaminhadas para processamento, no qual cada máquina dessa sequência representa um estágio de produção. Essa problemática reflete com precisão diversos cenários de produção do mundo real, uma vez que muitos processos reais envolvem múltiplas etapas para concluir uma única tarefa. Além disso, esse tipo de ambiente possui dois casos particulares amplamente estudados na literatura: o *Flow shop* permutacional (PF), onde a sequência de tarefas a serem processadas é a mesma em cada estágio do processo produtivo, e o *Flow shop* híbrido (HF), onde há mais de uma máquina em cada estágio, permitindo o processamento em paralelo;
- *Job shop (J)*: Cada tarefa segue uma trajetória individual ou caminho específico nas máquinas. Este modelo é considerado um caso especial do ambiente *Flow shop*;
- *Open shop (O)*: Semelhante ao *Job shop*, mas com a distinção de que as tarefas não têm uma rota específica predefinida, não necessitando passar pelas mesmas máquinas em todas as rotas.

De maneira semelhante, o campo β que fornece características e restrições relacionadas ao processamento das tarefas, e nele é possível ter nenhuma, uma ou múltiplas entradas (Graham *et al.*, 1979). Em Fuchigami (2021) são apresentadas as principais características do campo, sendo elas:

- s_{ij} : Indica a presença de tempos *setups* dependentes da sequência;
- r_j : Aponta a existência de datas de liberação para as tarefas;
- d_j : Evidencia a presença de prazos de entrega para cada tarefa ou lote;
- $prmp$: Possibilita que os processamentos possam ser interrompidos;
- $brkdwn$: Indica a possibilidade de quebra e indisponibilidade de maquinário;
- $block$: Aponta que existe um capacidade finita de armazenamento entre processos fabril;
- $no-wait$: As tarefas não podem esperar entre duas máquinas sucessivas.

Por fim, existe o campo γ , que descreve a função objetivo do problema e normalmente possui uma única entrada (Graham *et al.*, 1979). Em Pinedo (2022) e Fuchigami (2021) são apresentados

os modelos mais utilizados na literatura:

- C_{max} : Esse objetivo busca a minimização do C_{max} (*makespan*), no qual busca-se reduzir o tempo de término da última tarefa a ser processada;
- L_{max} : Refere-se a busca pela minimização do atraso máximo, em que o atraso é calculado pela diferença do tempo em que uma tarefa t é finalizada, pelo tempo de término desejado dessa mesma tarefa;
- E_{max} : Nessa medida de desempenho busca minimizar o maior adiantamento possível de tarefas;
- $F(\sum F_j)$: Busca-se minimizar o tempo total de fluxo das tarefas.

Com diferentes configurações de α , β e γ , é possível criar diversos modelos de sequenciamento para representar sistemas de produção reais. Ainda que um modelo possa não ser idêntico à realidade, ele pode ser suficientemente similar para que as conclusões derivadas de sua análise ou operação possam ser extrapoladas para a realidade (Goldbarg *et al.*, 2016). Por exemplo, em Wu *et al.* (2023) é modelado um problema de sequenciamento de máquina única, no qual a data de liberação é incorporada como característica do processo, diante disso, os autores buscaram minimizar o consumo de energia total (TEC) por meio da programação de tarefas nos momentos em que a tarifa de energia é mais baixa. A configuração desse trabalho, seguindo as diretrizes de Graham *et al.* (1979), seria $(1 \mid r_j \mid TEC)$.

Dessa forma, cada abordagem se destaca por explorar um aspecto específico do problema de sequenciamento, seja relacionado ao ambiente de manufatura, às características do processo ou à métrica de desempenho, tornando o campo de pesquisa na área de sequenciamento bastante diversificado (Graham *et al.*, 1979).

2.5.1 Sequenciamento verde da produção

A Revolução Industrial é um marco fundamental na trajetória da humanidade e desencadeou transformações profundas na sociedade, impulsionando o desenvolvimento econômico e tecnológico em escala sem precedentes. No entanto, esse progresso veio acompanhado de um aumento significativo no consumo de energia e recursos, resultando em um crescente conflito entre a humanidade e a natureza (Li e Wang, 2022).

Com isso, embora o nível de serviço dos sistemas de manufatura seja amplamente reconhecido como um indicador crucial na tomada de decisões, o contexto atual exige uma atenção redobrada às questões ambientais (Amiri e Behnamian, 2020). De acordo com Mansouri *et al.* (2016), uma estratégia eficaz para integrar a sustentabilidade na manufatura é através do conceito de sequenciamento verde, também conhecido como *Green Scheduling*. Este enfoque não apenas prioriza a eficiência

operacional, mas também visa reduzir o consumo de energia elétrica e minimizar o impacto ambiental.

A adoção do sequenciamento verde é um avanço substancial rumo à manufatura ecoeficiente. Em um cenário global marcado por desafios de sustentabilidade, a incorporação de práticas ecoeficientes não apenas impulsiona a competitividade das organizações, mas também desempenha um papel crucial na preservação do meio ambiente para as futuras gerações (Amiri e Behnamian, 2020).

Dante dessas considerações, Mansouri *et al.* (2016) apresenta três estratégias para reduzir o custo de energia por meio do sequenciamento de produção. O primeiro método consiste em desligar as máquinas durante os períodos de ociosidade, complementando o sequenciamento tradicional das operações. Essa abordagem, discutida por Wu e Sun (2018) e Che *et al.* (2017), envolve a tomada de decisão sobre ligar ou desligar equipamentos conforme a demanda, contribuindo para uma gestão mais eficiente da energia.

Outra estratégia sugerida é ajustar a velocidade das máquinas de acordo com as metas de desempenho estabelecidas. Isso implica reduzir a velocidade de operação em máquinas ou processos que não são gargalos, conforme discutido por Zhang *et al.* (2019b) e Wang *et al.* (2023). Essa abordagem não apenas otimiza o consumo de energia, mas também pode melhorar a eficiência global do processo produtivo, maximizando o aproveitamento dos recursos disponíveis.

Por fim, o sequenciamento de tarefas fora dos períodos de pico de demanda elétrica, seguindo uma estratégia conhecida como Tarifa de Uso do Tempo (TOU). Essa política, abordada por Cheng *et al.* (2017a), visa agendar as atividades produtivas nos horários em que a tarifa de energia é mais baixa, resultando em uma significativa redução nos custos operacionais. Essas medidas não apenas contribuem para a redução dos custos energéticos, mas também para uma gestão mais sustentável e eficiente dos recursos.

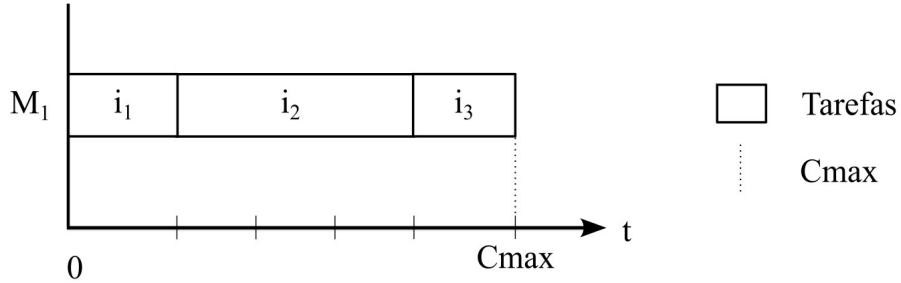
A importância da eficiência energética através do sequenciamento verde nos processos de fabricação tem sido destacada por diversos pesquisadores como uma estratégia fundamental para reduzir o impacto ambiental da indústria (Yan *et al.*, 2016). De acordo com Zhang *et al.* (2019a), o interesse no sequenciamento verde tem despertado a atenção de diversos pesquisadores no campo, incentivando-os a explorar e aprimorar continuamente essa abordagem. Esta crescente tem se manifestado em uma variedade de estudos conduzidos nos últimos anos, os quais buscam aprofundar a compreensão dos princípios e das aplicações do sequenciamento verde na indústria.

2.5.2 Sequenciamento de máquina única

O problema de sequenciamento em uma única máquina é frequentemente considerado o mais básico, uma vez que envolve a alocação e processamento de todas as tarefas em um único

equipamento. Na Figura 5 é apresentado uma ilustração desse problema.

Figura 5 – PSMU com tempos de processamento determinístico



Fonte: Elaborado pelo autor (2024)

Para Pinedo (2022), o problema de sequenciamento em uma única máquina é crucial por várias razões. Primeiramente, serve como um modelo acessível para explorar uma variedade de conceitos de sequenciamento, contribuindo para um melhor entendimento das técnicas de resolução e medidas de desempenho. Além disso, ao compreender o funcionamento de sistemas complexos, o estudo desse problema elementar proporciona ideias valiosas sobre o comportamento global do sistema. Por fim, sua aplicação independente e integração em problemas mais amplos oferecem oportunidades para otimizar processos e influenciar decisões em toda a cadeia de produção.

2.5.3 Descrição do problema estudado

O modelo selecionado para este estudo foi proposto por Che *et al.* (2016), mas também já foi estudado por Zhang *et al.* (2018a), porém ambos os estudos se concentraram especificamente em contextos onde os parâmetros eram determinísticos. Os autores propuseram algoritmos voltados para a resolução de um PSVMU sob tarifa TOU, com o objetivo de minimizar o TEC, considerando três tipos de tarifa (baixa, média e alta).

Dessa forma, consideramos um conjunto de tarefas $N = \{1, 2, \dots, n\}$ que precisam ser executadas em uma única máquina com o objetivo de minimizar o custo energético. Cada tarefa $i \in N$ possui o tempo de processamento t_i e consumo de energia por hora p_i . A máquina tem a capacidade de processar apenas uma tarefa por vez, e não é permitida a interrupção do processamento quando uma tarefa está em andamento.

A máquina é alimentada por eletricidade, e o custo da eletricidade segue um esquema de tarifação conhecido como TOU. Esse esquema é representado por um conjunto de períodos de tempo, denotados por $M = \{1, 2, \dots, m\}$, onde cada período $k \in M$ possui um preço de eletricidade c_k e um horário de início b_k . O intervalo de tempo do período k é representado por (b_k, b_{k+1}) , onde $k \in M$.

Além disso, tanto os trabalhos quanto a máquina estão disponíveis para processamento desde o início (i.e., período 1) e que $b_1 = 0$.

O foco principal deste problema reside na alocação de um conjunto de tarefas em intervalos de tempo com diferentes tarifas de eletricidade dentro do horizonte de tempo $[0, b_{m+1}]$, com o intuito de minimizar o custo total de eletricidade (TEC). Portanto, o objetivo é determinar o tempo de início e término de cada tarefa, ou, implicitamente, em qual(is) período(s) uma tarefa é atribuída e por quanto tempo ela é processada em cada período (i.e., uma tarefa pode ser processada em um ou mais períodos, caso seja processada em mais de um período, estes devem ser consecutivos, pois a preempção não é considerada). Para isso, fazemos uso das variáveis de decisão x_{ik} e y_{ik} , onde x_{ik} representa o tempo atribuído à tarefa $i \in N$ no período $k \in M$, enquanto y_{ik} assume o valor 1 se a tarefa $i \in N$ ou parte dela foi processada no período $k \in M$, e 0 caso contrário.

Na Tabela 1, são apresentadas as notações utilizadas no modelo. Com base nisso, este problema determinístico pode ser formulado da seguinte maneira:

Tabela 1 – Notação adotada para a modelagem matemática

Notação	Descrição
N	Conjunto de tarefas
M	Conjunto de períodos
n	Número de tarefas
m	Número de períodos
c_k	Preço da eletricidade no período $k \in M$
b_k	Início do período no período $k \in M$
t_i	Tempo de processamento da tarefa $i \in N$
p_i	Consumo de energia da tarefa $i \in N$
x_{ik}	Tempo atribuído à tarefa $i \in N$ no período $k \in M$
y_{ik}	1, se a tarefa for processada no período $k \in M$, ou 0, caso contrário

Fonte: Elaborado pelo autor (2024)

$$\text{Min } TEC = \sum_{i=1}^n \sum_{k=1}^m p_i x_{ik} c_k \quad (2.7)$$

$$\text{sujeito a } \sum_{k=1}^m x_{ik} = t_i \quad \forall i \in N; \quad (2.8)$$

$$\sum_{i=1}^n x_{ik} \leq b_{k+1} - b_k \quad \forall k \in M; \quad (2.9)$$

$$x_{ik} \leq t_i y_{ik} \quad \forall i \in N, k \in M; \quad (2.10)$$

$$\sum_{k=j+1}^{l-1} y_{ik} \geq (l-j-1)(y_{il} + y_{ij} - 1) \quad \forall i \in N, 3 \leq l \leq m, 1 \leq j \leq l-2; \quad (2.11)$$

$$x_{ik} \geq (y_{i,k-1} + y_{i,k+1} - 1)(b_{k+1} - b_k) \quad \forall i \in N, 2 \leq k \leq m-1; \quad (2.12)$$

$$y_{ik} + y_{i,k+1} + y_{jk} + y_{j,k+1} \leq 3 \quad \forall i \in N, j \in N, 1 \leq k \leq m-1, i \neq j; \quad (2.13)$$

$$x_{ik} \geq 0 \quad \forall i \in N, k \in M; \quad (2.14)$$

$$y_{ik} \in \{0, 1\} \quad \forall i \in N, k \in M. \quad (2.15)$$

O objetivo deste estudo é minimizar o TEC para processar todos os trabalhos. As Restrições (2.8), (2.9) e (2.10) referem-se aos tempos de processamento atribuídos aos períodos. A Restrição (2.8) exige que a soma total dos tempos de processamento atribuídos a um trabalho em todos os períodos seja igual ao seu tempo de processamento. A Restrição (2.9) assegura que a soma total dos tempos de processamento atribuídos a um período não excede sua duração. A Restrição (2.10) estipula que, se o trabalho i não for processado no período k (ou seja, $y_{ik} = 0$), o tempo de processamento atribuído ao trabalho i no período k deve ser igual a zero.

As Restrições (2.11) e (2.12) garantem que um trabalho seja processado em períodos contínuos de forma não preemptiva. A Restrição (2.11) assegura que um trabalho deve ser processado em períodos contínuos se ele ocupar mais de um período. Para ser mais específico, para qualquer par de períodos j e l tal que $3 \leq l \leq m$, $1 \leq j \leq l-2$, se $y_{ij} = 1$, e $y_{il} = 1$, então $y_{ik} = 1$ para todos os $j+1 \leq k \leq l-1$ para garantir a continuidade na atribuição dos períodos. A Restrição (2.12) assegura que se um trabalho for processado nos períodos $k-1$ e $k+1$, $2 \leq k \leq m-1$, então o tempo de processamento atribuído ao trabalho no período intermediário (i.e., período k) deve ser igual à duração do período. A Restrição (2.13) garante que, no máximo, um trabalho seja processado em qualquer par de períodos adjacentes, cujo processamento comece no período anterior e termine no período subsequente. Finalmente, as Restrições (2.14) e (2.15) definem os domínios das variáveis. A quantidade de restrições em função de n e m são, respectivamente: n , m , $n \times m$, $n \times \sum_{i=1}^{m-2} i$, $n \times (m-2)$, $m \times (n^2 - n)$, $n \times m$ e $n \times m$.

Dante disso, um exemplo pode ser utilizado para demonstrar a representação de uma solução do modelo. Na Tabela 2 é apresentado os dados utilizado no exemplo.

Tabela 2 – Dados para o exemplo

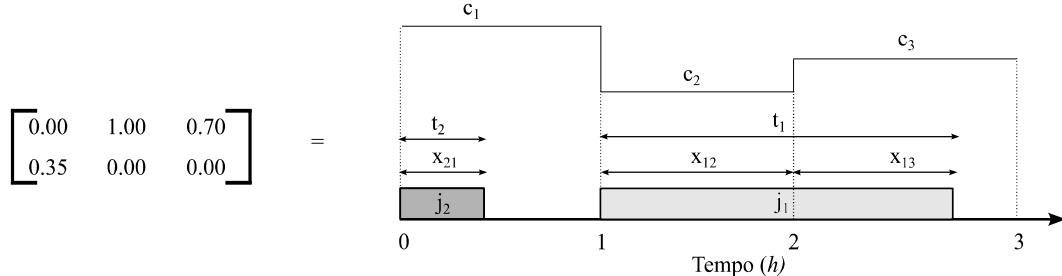
Parâmetros	Valores
n	2
m	3
$c_k \forall k \in M$	[1.2473, 0.4430, 0.8451]
$b_k \forall k \in M$	[0, 1, 2]
$t_i \forall i \in N$	[1.70, 0.35]
$p_i \forall i \in N$	[2600, 1200]

Fonte: Elaborado pelo autor (2024)

Uma solução viável para esse problema é apresentada na Figura 6, juntamente com uma

ilustração da resposta. Dessa forma, podemos observar que a resposta obtida por meio da resolução do modelo pode ser compreendida como uma matriz 2×3 , onde as linhas representam as tarefas e as colunas os períodos. Assim, a matriz pode ser interpretada como a alocação das tarefas aos períodos, que, neste exemplo, resultou em um TEC de 3213.75.

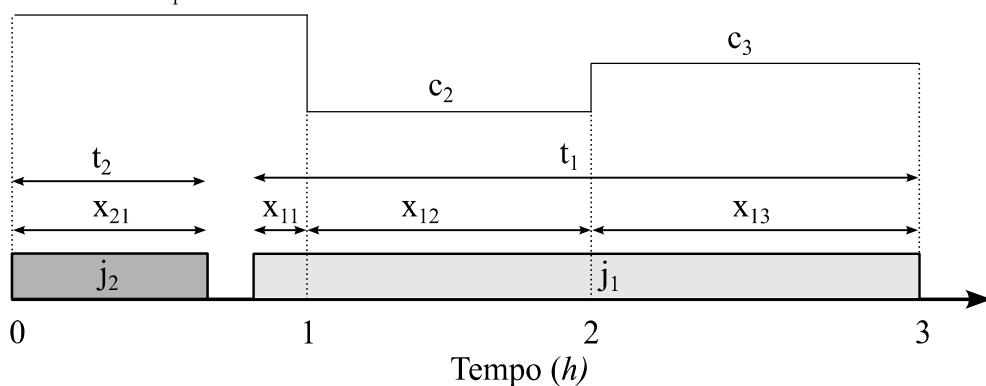
Figura 6 – Representação da solução do modelo



Fonte: Elaborado pelo autor (2024)

Entretanto, o modelo considerado nesta pesquisa está voltado para a utilização de parâmetros estocásticos (i.e., que considera as incertezas presentes nos processos). Nessa abordagem, os tempos de processamentos são modelados por uma variável aleatória que segue uma distribuição de probabilidade Lognormal. Para auxiliar na compreensão de como o problema abordado nesta pesquisa é afetado pelas incertezas, é apresentada na Figura 7 uma simulação hipotética para a solução obtida na Figura 6.

Figura 7 – Representação do impacto da simulação em uma solução



Fonte: Elaborado pelo autor (2024)

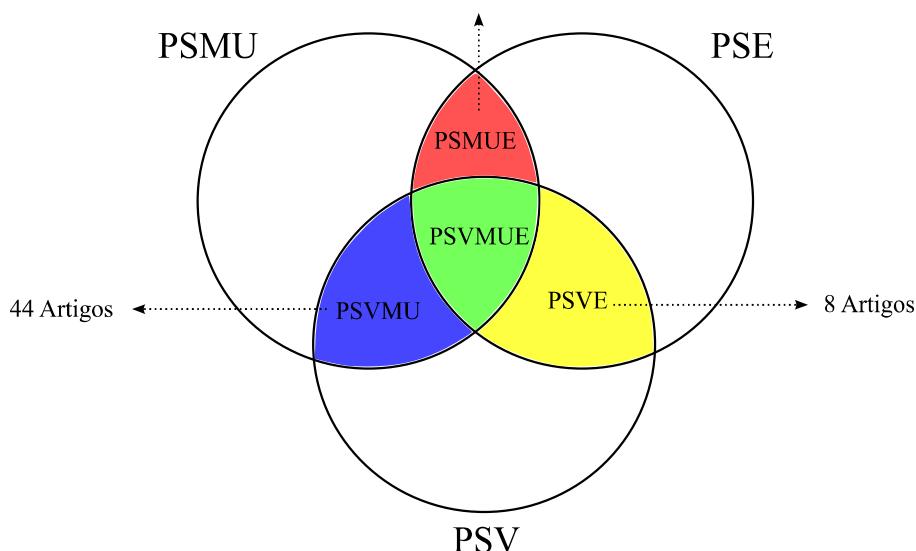
Neste exemplo, apresentado na Figura 7, podemos observar que devido as variações apresentadas em j_1 e j_2 , os novos tempos de processamento são $t_1 = 0.75$ e $t_2 = 1.25$, resultando em um TEC de 5045.39.

3 REVISÃO SISTEMÁTICA DA LITERATURA

Neste capítulo, buscou-se realizar uma revisão sistemática sobre o PSVMUE. No entanto, em uma pesquisa preliminar sobre o tema principal, foi evidenciada uma escassez de artigos que abordam a temática central desta pesquisa, com apenas dois artigos encontrados. Diante disso, com o objetivo de compreender o estado atual da arte, encontrar lacunas e tendências envolvendo essa temática, o tema principal foi dividido em três áreas: PSMU, PSV e Problema de Sequenciamento Estocástico (PSE). No entanto, o que de fato contempla e tangencia os assuntos desta dissertação são as interações dessas áreas, representadas pelo PSMUE, PSVMU e o PSVE. Na Figura 8, é possível observar uma ilustração de como essas três interseções estão relacionadas entre si e com o tema principal abordado nesta dissertação.

Figura 8 – Justificativa das seções da revisão da sistemática

22 Artigos



Fonte: Elaborado pelo autor (2024)

Diantre disso, foram realizadas três revisões sistemáticas, uma para cada uma das interseções apresentadas. Essa metodologia visa identificar, analisar e integrar todas as evidências disponíveis de forma imparcial, seguindo um protocolo pré-definido que inclui critérios de inclusão e exclusão, além de métodos de busca (Donthu *et al.*, 2021). Na Seção 3.1 é apresentado o protocolo estabelecido para cada uma das revisões, e na Seção 3.2 são apresentadas as análises e discussões dos artigos de cada revisão.

3.1 DEFINIÇÃO DO PROCEDIMENTO

Esta etapa visa estabelecer os protocolos das revisões, os quais especificam os objetivos, as questões a serem respondidas, as bases de dados a serem consultadas, os tipos de estudos a serem analisados, as palavras-chave a serem pesquisadas, os idiomas, os anos de publicação e os critérios de inclusão e exclusão dos estudos obtidos. Assim, esses protocolos buscam fornecer uma estrutura clara e pré-definida que delimita e orienta todo o processo dessas revisões, descrevendo de forma transparente todos os aspectos metodológicos para a busca e seleção de artigos, garantindo assim a reprodutibilidade do estudo.

Diante disso, temos três objetivos, um para cada revisão. Para o PSVMU, buscamos encontrar lacunas e tendências acerca desse modelo. Para o PSMUE, avaliar o estado da arte. E para o PSVE, analisar o panorama atual das pesquisas sobre essa temática. As questões a serem respondidas para cada objetivo estão presentes na Tabela 3.

Tabela 3 – Questões a serem respondidas para cada revisão

Revisão	Questões
PSVMU	(1) Classificação dos modelos quanto à quantidade de funções objetivo; (2) Qual(is) função(ões) objetivo(s) é(são) considerada(s); (3) Quais as principais considerações ambientais; (4) Quais métodos são utilizados para a resolução desse tipo de problema.
PSMUE	(1) Quais métodos são utilizados para a resolução desse tipo de problema; (2) Quais os parâmetros estocásticos mais abordados na literatura.
PSVE	(1) Quais métodos são utilizados para a resolução desse tipo de problema; (2) Quais os parâmetros estocásticos mais abordados na literatura; (3) Quais as principais considerações ambientais.

Fonte: Elaborado pelo autor (2024)

A revisão foi realizada exclusivamente utilizando a base de dados *Web of Science* como fonte para a condução da revisão sistemática. Esta escolha foi feita tendo em vista que essa base é reconhecida por sua abrangência multidisciplinar e por sua extensa cobertura de periódicos científicos de renome internacional. Além disso, a busca foi limitada a apenas um tipo de documento, que são os artigos, tendo em vista que eles representam uma fonte primária e consolidada de conhecimento acadêmico, geralmente submetidos a um rigoroso processo de revisão por pares, o que confere credibilidade e confiabilidade às informações contidas neles.

Preliminarmente, foi realizada uma pesquisa no *Google Scholar* para identificar palavras-chave presentes nos trabalhos já existentes na literatura. Isso possibilitou a formulação de uma *string* de busca que assegurasse a abrangência e precisão da revisão, buscando evitar tanto a exclusão de estudos pertinentes quanto a inclusão de pesquisas irrelevantes. Além disso, todas as buscas pelas palavras-chave foram realizadas somente nos títulos (TI) e no *abstract* (AB) dos trabalhos, e o caractere

“*” foi utilizado como um operador de truncagem para possibilitar encontrar todas as pesquisas com o mesmo radical. Dessa forma, as *strings* de busca adotadas podem ser observadas na Tabela 4.

Tabela 4 – *String* de busca adotada para cada revisão

Revisão	<i>String</i> de busca
PSVMU	TI=(single machine) AND TI=(sched*) AND (TI=(green) OR TI=(sustainab*) OR TI=(energ*) OR TI=(carbon*) OR TI=(nois*) OR TI=(pollut*) OR TI=(tariff*) OR TI=(Time Of Use) OR TI=(Energy-effici*) OR TI=(Electricity prices*))
PSMUE	TI=(single machine) AND TI=(sched*) AND (TI=(simheuristic) OR TI=(stoch*) OR TI=(uncert*)) AND (AB=(heuristi*) OR TI=(simheuris*) OR TI=(optimiz*))
PSVE	TI=(sched*) AND (TI=(green) OR TI=(sustainab*) OR TI=(energ*) OR TI=(carbon*) OR TI=(nois*) OR TI=(pollut*)) AND (TI=(simheuristic) OR TI=(stoch*) OR TI=(uncert*)) AND (TI=(single machine) OR TI=(parallel machines) OR TI=(flow shop) OR TI=(flow-shop) OR TI=(flowshop) OR TI=(jop shop) OR TI=(jop-shop) OR TI=(jopshop) OR TI=(open shop) OR TI=(open-shop) OR TI=(openshop))

Fonte: Elaborado pelo autor (2024)

Dante disso, conforme apresentado no Tabela 4, para a revisão do PSVMU, os termos “green”, “sustainab*”, “energ*”, “carbon*”, “nois*”, “pollut*”, “tariff*”, “Time of use” e “Energy-effici*” foram adotados como um filtro para buscar somente trabalhos que tenham considerações ambientais em seu escopo, o campo “single machine*” serviu para delimitar o ambiente de manufatura e o termo “sched*” foi adotado para especificar o problema abordado. Dessa forma, adotando essa *string* de busca, foram retornados 44 trabalhos.

De mesma forma, para o PSMUE, os termos “simheuristic”, “stoch*”, “uncert*” foram utilizados para buscar somente por trabalhos que tratem com variáveis aleatórias, e os termos “heuristi*”, “simheuris*” e “optimiz*” foram utilizados para filtrar somente as abordagens que utilizam de métodos otimização. Essa busca retornou 22 resultados.

Por fim, para a revisão do PSVE, onde os termos “single machine”, “parallel machine”, “flow shop”, “job shop”, “open shop”, e suas variantes, são adotados para representar todos os ambientes de manufatura existentes na literatura de sequenciamento. Essa busca retornou 8 resultados. Todas as buscas e contabilização de artigos presentes em cada revisão foram realizadas dia 01/03/2024.

A busca foi realizada sem considerar nenhuma limitação de tempo nem pelo tipo de publicação do documento (ou seja, congressos, simpósios e revistas). Todos os trabalhos foram lidos por completo, sendo excluídos apenas os artigos que não abordavam o tema de sequenciamento e aqueles que não estavam completamente disponíveis.

3.2 QUANTIFICAÇÃO E ANÁLISE DOS TRABALHOS

Nas Subseções 3.2.1, 3.2.2 e 3.2.3 são expostos todos os artigos selecionados para cada revisão de acordo com as delimitações impostas pelos protocolos. Além disso, uma summarização e quan-

tificação são apresentadas sobre as questões levantadas para cada revisão. Por fim, são apresentados e discutidos os trabalhos mais relevantes de cada revisão.

3.2.1 PROBLEMA DE SEQUENCIAMENTO DE MÁQUINA ÚNICA COM CONSIDERAÇÕES AMBIENTAIS

Nas Subseções 3.2.1.1 e 3.2.1.2, são apresentadas a sumarização e as abordagens dos artigos mais relevantes para a revisão do problema de sequenciamento de máquina única com considerações ambientais.

3.2.1.1 Sumarização e análise dos trabalhos

Nessa subseção, foram analisados 40 dos 44 artigos encontrados na busca realizada. Dois artigos foram excluídos por se dedicarem exclusivamente ao problema de dimensionamento de lotes, enquanto os outros dois já foram abordados nas demais subseções da revisão da literatura. Na Tabela 5 são apresentados todos os artigos considerados nessa revisão sistemática.

Tabela 5 – Artigos utilizados para a revisão do PSVMU

Referência	Título do artigo
Liu <i>et al.</i> (2019)	An Enhanced MOPSO Algorithm for Energy-Efficient Single-Machine Production Scheduling
Chen <i>et al.</i> (2019a)	An energy-efficient single machine scheduling problem with machine reliability constraints
Aghelinejad <i>et al.</i> (2019a)	Complexity analysis of energy-efficient single machine scheduling problems
Che <i>et al.</i> (2017)	Energy-efficient bi-objective single-machine scheduling with power-down mechanism
Wu <i>et al.</i> (2023)	Energy-efficient single-machine scheduling with release dates under time-of-use electricity tariffs
An <i>et al.</i> (2022)	An optimal energy-efficient scheduling with processing speed selection and due date constraint in a single-machine environment
Tsao <i>et al.</i> (2020)	Energy-efficient single-machine scheduling problem with controllable job processing times under differential electricity pricing

Continua na página seguinte

Tabela 5 – Artigos utilizados para a revisão do PSVMU (Continuação)

Referência	Título do artigo
Bektur (2021)	A hybrid heuristic solution based on simulated annealing algorithm for energy efficient single machine scheduling problem with sequence dependent setup times
Zhou <i>et al.</i> (2020)	Energy-efficient scheduling of a single batch processing machine with dynamic job arrival times
Lee <i>et al.</i> (2017)	A dynamic control approach for energy-efficient production scheduling on a single machine under time-varying electricity pricing
Abedi <i>et al.</i> (2017)	A hybrid particle swarm optimisation approach for energy-efficient single machine scheduling with cumulative deterioration and multiple maintenances
Roshani <i>et al.</i> (2023)	The capacitated lot-sizing and energy efficient single machine scheduling problem with sequence dependent setup times and costs in a closed-loop supply chain network
Fang <i>et al.</i> (2016)	Scheduling on a single machine under time-of-use electricity tariffs
Kim <i>et al.</i> (2022)	Single-machine scheduling with energy generation and storage systems
Cheng <i>et al.</i> (2016a)	Bi-objective optimization of single-machine batch scheduling under time-of-use electricity prices
Zhang <i>et al.</i> (2018b)	Single-Machine Green Scheduling to Minimize Total Flow Time and Carbon Emission
Aghelinejad <i>et al.</i> (2019b)	Single-machine scheduling problem with total energy consumption costs minimization
Qiao <i>et al.</i> (2022)	Research on green single machine scheduling based on improved ant colony algorithm
Tian e Zheng (2024)	Single machine parallel-batch scheduling under time-of-use electricity prices: New formulations and optimisation approaches
Che <i>et al.</i> (2015)	Energy Consumption Minimization for Single Machine Scheduling with Bounded Maximum Tardiness

Continua na página seguinte

Tabela 5 – Artigos utilizados para a revisão do PSVMU (Continuação)

Referência	Título do artigo
Cheng <i>et al.</i> (2014)	Bi-objective optimization for single-machine batch scheduling considering energy cost
Liao <i>et al.</i> (2017)	Multi-objective optimization of single machine scheduling with energy consumption constraints
Cheng <i>et al.</i> (2016b)	Single-machine batch scheduling under time-of-use tariffs: new mixed-integer programming approaches
Cheng <i>et al.</i> (2017b)	Bi-criteria single-machine batch scheduling with machine on/off switching under time-of-use tariffs
Salama e Srinivas (2021)	Adaptive neighborhood simulated annealing for sustainability-oriented single machine scheduling with deterioration effect
Wang <i>et al.</i> (2016)	Bi-objective optimization of a single machine batch scheduling problem with energy cost consideration
Shrouf <i>et al.</i> (2014)	Optimizing the production scheduling of a single machine to minimize total energy consumption costs
Che <i>et al.</i> (2016)	An efficient greedy insertion heuristic for energy-conscious single machine scheduling problem under time-of-use electricity tariffs
Jiang <i>et al.</i> (2020)	Energy-Saving Production Scheduling in a Single-Machine Manufacturing System by Improved Particle Swarm Optimization
Wang <i>et al.</i> (2019)	Energy Saving Scheduling of A Single Machine System Based on Bi-objective Particle Swarm Optimization
Chen <i>et al.</i> (2019b)	Order Acceptance and Scheduling Problem with Carbon Emission Reduction and Electricity Tariffs on a Single Machine
Wu <i>et al.</i> (2021)	Large-scale energy-conscious bi-objective single-machine batch scheduling under time-of-use electricity tariffs via effective iterative heuristics
Choi (2016)	Dispatching rule-based scheduling algorithms in a single machine with sequence-dependent setup times and energy requirements

Continua na página seguinte

Tabela 5 – Artigos utilizados para a revisão do PSVMU (Continuação)

Referência	Título do artigo
Rubaiee <i>et al.</i> (2018)	An energy-aware multiobjective optimization framework to minimize total tardiness and energy cost on a single-machine nonpreemptive scheduling
Zhang <i>et al.</i> (2018c)	Improved mixed-integer linear programming model and heuristics for bi-objective single-machine batch scheduling with energy cost consideration
Jia <i>et al.</i> (2022)	Energy Saving in Single-Machine Scheduling Management: An Improved Multi-Objective Model Based on Discrete Artificial Bee Colony Algorithm
Rubaiee e Yildirim (2019)	An energy-aware multiobjective ant colony algorithm to minimize total completion time and energy cost on a single-machine preemptive scheduling
Tarakçi <i>et al.</i> (2022)	Energy-Based Scheduling Optimization To Minimize The Total Energy Consumption And The Total Tardiness In A Single Machine Manufacturing System With The Sequence-Dependent Setup Times
Buechler <i>et al.</i> (2019)	Optimal Energy Supply Scheduling for a Single Household: Integrating Machine Learning for Power Forecasting
Schorn e Mönch (2022)	Learning dispatching rules for energy-aware scheduling of jobs on a single batch processing machine

Fonte: Elaborado pelo autor (2024)

A análise dos 40 artigos revela que foram publicados no período de 2014 a 2024. Com isso, é notável que os primeiros estudos relacionados ao PSVMU são relativamente recentes, ressaltando a emergência e a evolução contínua da pesquisa nesta área específica. Tal evolução sugere uma mudança de paradigma na abordagem dos desafios enfrentados pela indústria em relação à sustentabilidade, refletindo a crescente conscientização sobre os impactos ambientais das operações de produção.

Dentre esses 40 trabalhos analisados na revisão, 29 (72.5%) deles são de revistas acadêmicas e 11 (27.5%) deles são de congressos. Esses artigos estão distribuídos em 18 revistas, com destaque para as revistas *Journal of Cleaner Production*, *Annals of Operations Research*, *Computers &*

Industrial Engineering e Sustainability, que juntas representam 44,82% de todos os artigos presentes em revistas. Conforme demonstrado na Tabela 6.

Tabela 6 – Publicações em cada revista para o PSVMU

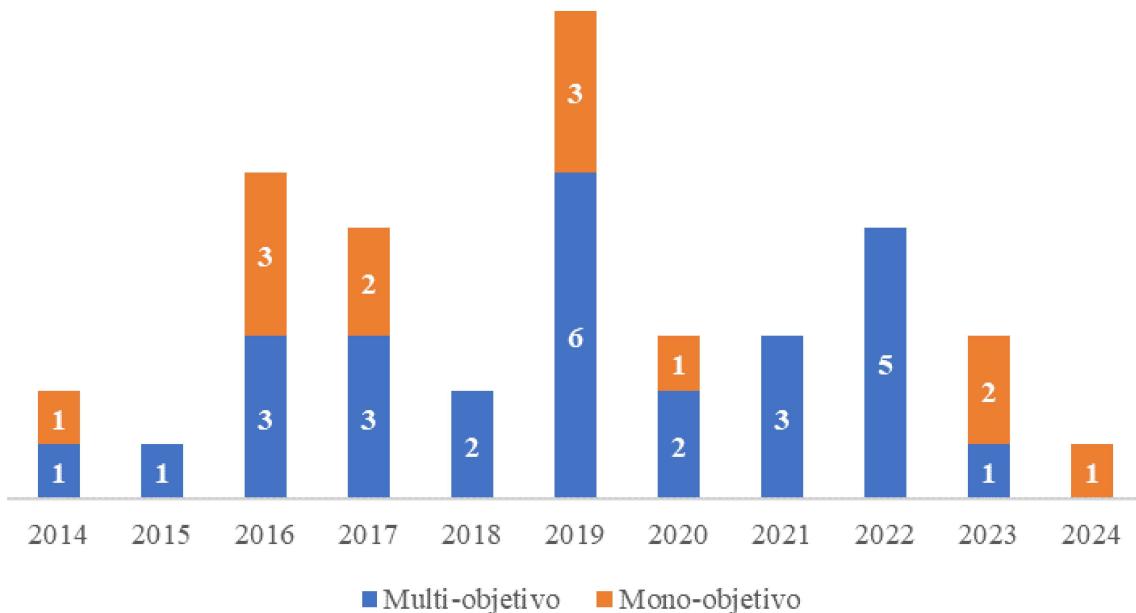
x	= Revistas	Quantidade de artigos
Journal of Cleaner Production		5
Computers & Industrial Engineering		4
Annals of Operations Research		3
Sustainability		3
Applied Soft Computing		1
Computers & Operations Research		1
Energy		1
Engineering Optimization		1
European Journal of Operational Research		1
Transactions on Engineering Management		1
International Journal of Production Research		1
Mathematical Problems in Engineering		1
Measurement & Control		1
Operations Research Perspectives		1
Journal of Engineering Manufacture		1
RAIRO-Operations Research		1
Resources Conservation and Recycling		1
Symmetry-Basel		1

Outro ponto é que ao abordar questões de sequenciamento com implicações ambientais, surge uma complexidade inerente derivada desse problema, que são os objetivos conflitantes. Por um lado, busca-se minimizar o consumo de energia para atender às preocupações ambientais; por outro lado, busca-se minimizar os objetivos operacionais que potencializam a produção. Esta dicotomia conduz à necessidade de abordagens de resolução que se concentrem em duas vertentes distintas. Uma delas consiste na consideração do problema como multiobjetivo, onde múltiplos objetivos são incorporados ao modelo, refletindo a dualidade entre metas ambientais e operacionais. A outra vertente reside na abordagem mono-objetivo, na qual um dos objetivos, seja ele operacional ou ambiental, é convertido em uma restrição dentro do modelo ou os objetivos operacionais e ambientais são somados/ponderados e ambos são considerados como uma única função objetiva. Ambas as abordagens apresentam vantagens e desafios próprios, destacando a complexidade dos problemas de sequenciamento em contextos ambientais.

Nesta revisão, foi constatado que a maioria dos artigos, representando 67,5%, adota uma abordagem multiobjetivo, enquanto 32,5% adotam uma abordagem mono-objetivo. Essa distribuição revela uma preferência notável pela consideração de múltiplos objetivos ao enfrentar problemas de sequenciamento com implicações ambientais, destacando a necessidade de uma maior atenção aos

estudos mono-objetivo. Na Figura 9 é apresentado uma relação da quantidade de trabalhos mono-objetivo e multiobjetivo com o passar dos anos.

Figura 9 – Quantidade de artigos Mono-objetivo e Multiobjetivo por ano



Fonte: Elaborado pelo autor (2024)

Entre as funções objetivo consideradas, destaca-se, no aspecto ambiental, o TEC, presente em 95% dos estudos analisados. O TEC é recorrente em diversos artigos, como nos trabalhos desenvolvidos por Tian e Zheng (2024), Shrouf *et al.* (2014) e Che *et al.* (2016), pois representa os custos associados ao consumo de energia, uma das principais considerações ambientais no contexto do problema de sequenciamento, sendo alvo de diversas abordagens para mitigar seu impacto.

No contexto dos objetivos operacionais, o *makespan* e o atraso total destacam-se como os mais abordados, presentes em várias pesquisas, como demonstrado nos estudos Zhou *et al.* (2020) e Bektur (2021), respectivamente. Essas métricas combinadas representam 48% dos estudos revisados. A redução do *makespan* não apenas incrementa a eficiência dos processos, mas também contribui para uma maior utilização dos recursos disponíveis. De maneira similar, a minimização do atraso total não só reforça a capacidade da organização de cumprir com as demandas do mercado dentro dos prazos estabelecidos, mas também consolida sua reputação. Assim, ao explorar essas métricas, os estudos conseguem melhorar o desempenho operacional e fomentar a excelência competitiva das organizações. Uma síntese dessas funções objetivo é apresentada na Tabela 7.

Conforme mencionado anteriormente, a integração de aspectos ambientais e a redução do

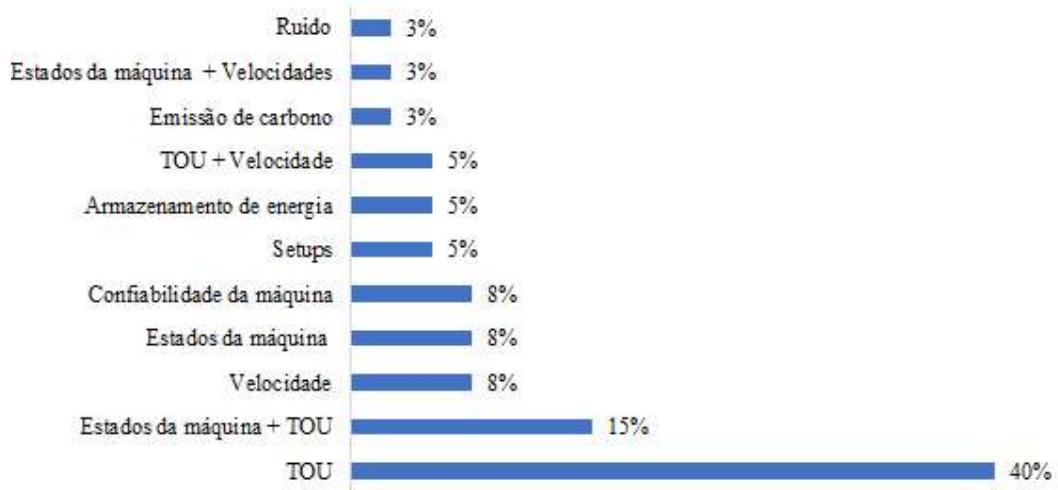
Tabela 7 – Funções objetivo encontrados

Função objetivo	Quantidade de artigo
TEC	12
Atraso total + TEC	10
Makespan + TEC	9
Atraso máximo + TEC	2
Antecipação/Atraso Ponderado + TEC	1
Atraso total ponderado + TEC	1
Custo Ponderado + TEC	1
Custo total de penalização por antecipação e atraso + TEC	1
Antecipação/Atraso + Poluição sonora	1
TEC + Custo de produção	1
Tempo total de fluxo + Emissão de carbono	1

Fonte: Elaborado pelo autor (2024)

TEC envolvem a consideração de diversas abordagens, muitas vezes combinadas simultaneamente. Ao examinar os estudos existentes, nota-se uma ampla gama de métodos empregados para influenciar o TEC. Estes métodos incluem políticas de tarifação de energia TOU (Chen *et al.*, 2019a), estratégias com velocidades escalonáveis (Liao *et al.*, 2017), diferentes estados de máquina (Wang *et al.*, 2019), tempos de *setup* (Qiao *et al.*, 2022), confiabilidade de equipamentos (Chen *et al.*, 2019a), armazenamento de energia (Buechler *et al.*, 2019), controle de ruído (Jia *et al.*, 2022) e redução de emissões de carbono (Zhang *et al.*, 2018b). Na Subseção 3.2.1.2, cada uma dessas abordagens é detalhada. A variedade dessas abordagens reflete as múltiplas opções e a flexibilidade que diversos estudos desenvolveram para mitigar os impactos ambientais causados pelas organizações. A quantificação desses artigos pode ser observada na Figura 10.

Figura 10 – Percentual de artigos em relação as considerações ambientais para o PSVMU



Fonte: Elaborado pelo autor (2024)

Conforme evidenciado na Figura 10, um dos aspectos mais estudados é a política de

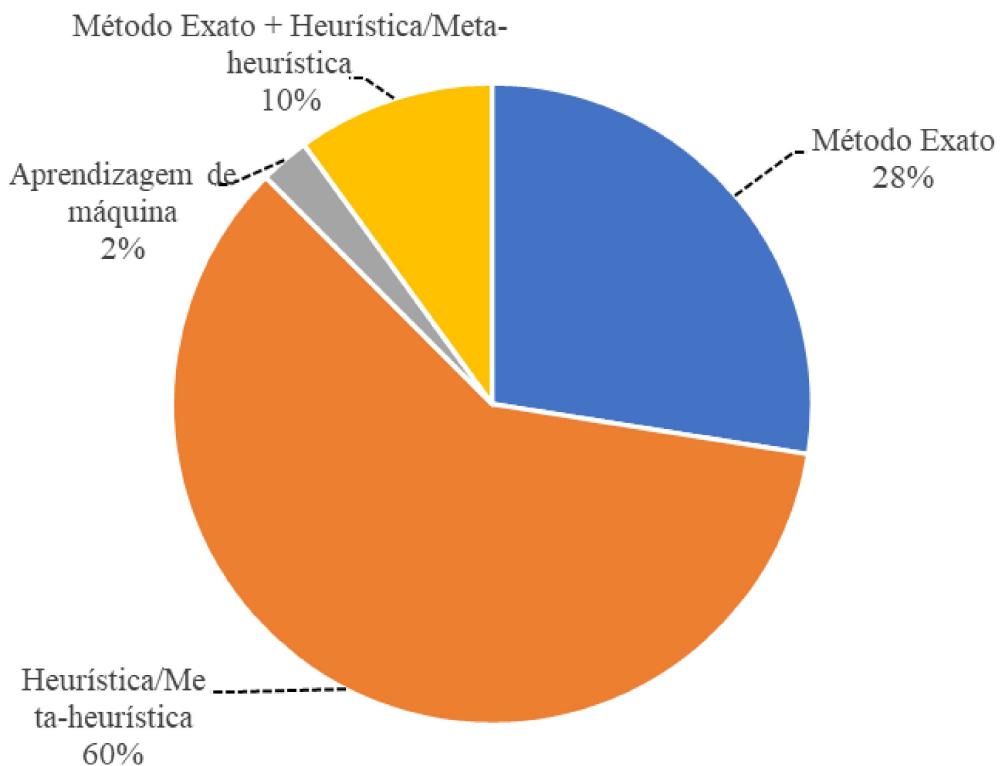
tarifação TOU, presente em 60% dos trabalhos analisados nesta revisão. O expressivo número de estudos dedicados a essa temática ressalta sua relevância e importância, pois as metodologias adotadas trazem benefícios tanto para as organizações quanto para o meio ambiente. Para as empresas, a vantagem significativa reside na opção de utilizar apenas as tarifas mais econômicas durante períodos específicos do dia, o que resulta em uma redução dos custos operacionais. Os benefícios ambientais associados a essa prática são igualmente relevantes. Durante os horários de pico de demanda por energia, as companhias elétricas frequentemente recorrem a fontes de energia mais agressivas para o meio ambiente, como as termelétricas, para atender a essa demanda elevada. Ao evitar o consumo durante esses períodos de pico, as companhias reduzem a necessidade de recorrer a tais fontes de energia, diminuindo assim os impactos ambientais decorrentes de suas operações.

Por fim, no que diz respeito ao método de resolução adotado, a maioria dos estudos recorreu a métodos heurísticos/meta-heurísticos, representando 60% das abordagens utilizadas para enfrentar esse tipo de problema. Esta predominância sugere que, diante da complexidade desses problemas, notadamente classificados como *NP-hard*, a utilização de métodos aproximados se mostra como a abordagem mais eficaz. Tal preferência destaca a necessidade de estratégias computacionalmente viáveis e eficientes para lidar com esses desafios, onde a busca por soluções ótimas pode ser inviável em termos práticos. Conforme demonstrado na Figura 11.

Com destaque para as meta-heurísticas inspiradas em fenômenos da natureza, essas abordagens representam 45% dos métodos de resolução. Entre elas, merecem menção especial as variantes do *Genetic Algorithm* (GA), como evidenciado nos trabalhos de autores como An *et al.* (2022), Tsao *et al.* (2020), Bektur (2021), entre outros. Além disso, as variantes do *Particle Swarm Optimization* (PSO), presentes em estudos conduzidos por Zhou *et al.* (2020), Liao *et al.* (2017) e Wang *et al.* (2019), também se destacam. Outras meta-heurísticas dessa mesma categoria também apareceram, como o ACO, discutido por Rubaiee e Yildirim (2019), e o *Artificial Bee Colony* (ABC), conforme abordado Jia *et al.* (2022).

Dante disso, este presente estudo busca preencher as lacunas encontradas por meio da revisão, e também incorporar as tendências mais relevantes sobre o tema. Utilizando um modelo de resolução mono-objetivo ainda pouco explorado na literatura, este estudo tem como objetivo a minimização do TEC, levando em consideração a política de tarifação por horário de uso (TOU). Para isso, propõe-se a aplicação de métodos heurísticos (simheurística) para resolver essa problemática.

Figura 11 – Percentual dos métodos de resolução utilizados para o PSVMU



Fonte: Elaborado pelo autor (2024)

3.2.1.2 Abordagem dos artigos

Nesta subseção, são abordados alguns dos trabalhos mais relevantes relacionados ao PSVMU, buscando destacar e explicar as formas como as considerações ambientais são abordadas, bem como os métodos de resolução adotados e as funções objetivo analisadas neste contexto.

Na pesquisa conduzida por Liu *et al.* (2019) e Rubaiee *et al.* (2018), é abordada a minimização simultânea de dois objetivos: o total ponderado de antecipação/atraso e o TEC, utilizando uma política de tarifação do tipo TOU. Sob essa política, os consumidores são cobrados com base nos horários de pico e fora de pico, refletindo os custos variáveis de produção e distribuição de energia ao longo do dia. Em Liu *et al.* (2019), é proposto um algoritmo híbrido e multiobjetivo do PSO, que incorpora um procedimento de mutação baseado no AG para introduzir variabilidade na população, além de um procedimento de busca local baseado no operador de reinserção. Já em Rubaiee *et al.* (2018), os autores utilizaram um AG multiobjetivo baseado em uma classificação de dominância.

Em Che *et al.* (2015) e An *et al.* (2022) foram conduzidos estudos que envolvem o processamento de um conjunto de tarefas em uma única máquina, onde as velocidades são ajustáveis. Isso implica que velocidades mais elevadas reduzem o tempo de processamento, porém aumentam o consumo de energia e a emissão de carbono. Além disso, ambos os autores modelaram o problema

considerando que cada tarefa só pode assumir uma velocidade durante o processamento. Em Che *et al.* (2015), foram empregados dois modelos de Programação Linear Inteira Mista (PLIM) para minimizar o atraso máximo e o TEC, enquanto An *et al.* (2022) utilizaram uma variante do AG para minimizar o TEC.

Nos estudos de Aghelinejad *et al.* (2019b) e Wang *et al.* (2019) foram analisados os três possíveis estados de uma máquina: ligada (*ON*), desligada (*OFF*) e ociosa (*Idle*). Essa abordagem foi adotada para programar a produção nos momentos em que a tarifa de energia é mais baixa e para evitar o consumo de energia do equipamento em períodos de ociosidade. Os autores modelaram o problema considerando que, em cada estado, o equipamento consome uma certa quantidade de energia e, em cada faixa de horário, o preço da energia varia. Além disso, eles também consideraram a existência de um custo energético para a transição entre os estados. Para resolver esse modelo, Aghelinejad *et al.* (2019b) propuseram um método exato baseado no algoritmo de Dijkstra para minimizar o TEC, enquanto em Wang *et al.* (2019), os autores desenvolveram uma abordagem bi-objetivo do PSO para minimizar tanto o atraso total quanto o TEC.

Qiao *et al.* (2022) e Choi (2016) abordam uma característica de processamento específica, que se refere aos *setups* dependentes da sequência das tarefas, considerando também implicações ambientais nos custos de energia. Nesse contexto, quanto maior o *setup* entre as tarefas, maior será o tempo de uso do maquinário. Durante o *setup*, a máquina permanece em um estado de preparação que consome energia. Portanto, minimizar os tempos de *setup* dependentes resulta em um menor consumo de energia (TEC). Em Qiao *et al.* (2022), a resolução do estudo é fundamentada na meta-heurística ACO para minimizar o atraso total e o TEC, enquanto em Choi (2016), dois algoritmos baseados em regras de despacho são considerados para minimizar o atraso médio e o TEC.

Em Chen *et al.* (2019a) e Abedi *et al.* (2017) é abordado um problema no qual a confiabilidade das máquinas tem um impacto significativo no consumo de energia. A modelagem desse problema considera que o consumo de energia no processamento de trabalhos aumenta devido à degradação (vida útil) das máquinas ao longo do tempo. No estudo de Chen *et al.* (2019a) é apresentada uma aplicação prática em uma fábrica de rotores, onde os autores buscam minimizar tanto o atraso total quanto o TEC, empregando uma variante da meta-heurística ACO. Já em Abedi *et al.* (2017), os autores utilizaram as meta-heurísticas AG e PSO, além de uma abordagem híbrida do PSO, para minimizar o TEC.

Nas pesquisas conduzida por Kim *et al.* (2022) e Buechler *et al.* (2019), os autores exploram a utilização de duas fontes de energia: energia comprada e energia gerada e armazenada por fontes renováveis, como eólica ou solar. O modelo proposto considera que os preços da energia variam ao longo do dia, seguindo a política de tarifação TOU. Durante períodos de tarifa baixa, o modelo prioriza

o uso da energia comprada, enquanto em momentos de tarifas mais elevadas, o algoritmo decide o quanto utilizar da energia armazenada. Em particular, Kim *et al.* (2022) empregaram uma variante do AG para minimizar o TEC, enquanto que Buechler *et al.* (2019) fizeram uso de um modelo de aprendizagem de máquina que buscava minimizar o atraso total e o TEC.

Em Jia *et al.* (2022), as emissões de ruído são consideradas como um índice de otimização ambiental. A poluição sonora tornou-se uma preocupação significativa nos ambientes de produção devido aos seus impactos negativos na saúde e no bem-estar dos trabalhadores. O modelo proposto leva em conta a disponibilidade de máquinas com diferentes velocidades de processamento, cada uma associada a níveis distintos de emissão de ruído. Assim, a velocidade de processamento de um trabalho pode ser ajustada selecionando a velocidade correspondente da máquina. Quanto maior a velocidade de processamento, maior a emissão de ruído e vice-versa. Dessa forma, os autores utilizaram da meta-heurística *Artificial Bee Colony* para a resolução desse problema.

Zhang *et al.* (2018b), por sua vez, desenvolveram uma pesquisa focada em minimizar a soma do tempo total de fluxo e o índice de emissão de carbono. Nessa pesquisa, os parâmetros ambientais foram analisados por meio da emissão de carbono nas etapas de processamento, desligamento e ociosidade. Para abordar esse problema, os autores apresentaram duas abordagens: um algoritmo baseado em programação dinâmica, eficaz para resolver instâncias menores, e um método conhecido como algoritmo do enxame de pássaros, capaz de lidar com instâncias de diversos tamanhos. A comparação entre essas duas abordagens foi realizada em diferentes instâncias para avaliar a eficácia dos métodos propostos.

3.2.2 PROBLEMA DE SEQUENCIAMENTO DE MÁQUINA ÚNICA COM PARÂMETROS ESTOCÁSTICOS

Nas Subseções 3.2.2.1 e 3.2.2.2, são apresentadas a sumarização e as abordagens dos artigos mais relevantes para a revisão do problema de sequenciamento de máquina única com considerações ambientais.

3.2.2.1 Sumarização e análise dos trabalhos

Nesta Subseção, são apresentados 19 dos 22 artigos encontrados na busca, sendo três excluídos da revisão por ter apenas o resumo disponível, conforme demonstrado na Tabela 8.

Tabela 8 – Artigos utilizados para a revisão do PSMUE

Referência	Título do artigo
Halim <i>et al.</i> (2020)	Single-machine Integrated Production Preventive Maintenance Scheduling: A Simheuristic Approachv Switching Model
Szmarekowsky (2007)	Single machine scheduling under market uncertainty
Fay e Glazebrook (1992)	On a no arrivals heuristic for single-machine stochastic scheduling
Li e Wang (2009)	A Stable Scheduling for Single Machine under Uncertainty
Jang (2002)	Dynamic scheduling of stochastic jobs on a single machine
Gascon <i>et al.</i> (1994)	Multiitem, single-machine scheduling problem with stochastic demands - a comparison of heuristics
Ertem <i>et al.</i> (2019)	Single machine scheduling problem with stochastic sequence-dependent setup times
Daniels e Carrillo (1997)	Beta-robust scheduling for single-machine systems with uncertain processing times
Bold e Goerigk (2022)	Investigating the recoverable robust single machine scheduling problem under interval uncertainty
Soroush e Fredendall (1994)	The stochastic single-machine scheduling problem with earliness and tardiness costs
Gascon (1988)	The lookahead heuristic for multi-item single-machine production scheduling with dynamic, stochastic demands
Soroush e Amin (2013)	Scheduling in stochastic bicriteria single machine systems with job-dependent learning effects
Yue <i>et al.</i> (2018)	Robust single machine scheduling problem with uncertain job due dates for industrial mass production
Soroush (2013).	Scheduling stochastic jobs on a single machine to minimize weighted number of tardy jobs
Yue <i>et al.</i> (2020)	Robust single machine scheduling with uncertain release times for minimising the maximum waiting time
Lu <i>et al.</i> (2014b)	Robust single machine scheduling for minimizing total flow time in the presence of uncertain processing times

Continua na página seguinte

Tabela 8 – Artigos utilizados para a revisão do PSMUE (Continuação)

Referência	Título do artigo
Soroush (2007)	Minimizing the weighted number of early and tardy jobs in a stochastic single machine scheduling problem
Leachman e Gascon (1988)	A heuristic scheduling policy for multi-item, single-machine production systems with time-varying, stochastic demands
Sabri <i>et al.</i> (2024)	Reinforcement learning and stochastic dynamic programming for jointly scheduling jobs and preventive maintenance on a single machine to minimise earliness-tardiness

Fonte: Elaborado pelo autor (2024)

A análise dos 19 artigos revela que estes foram publicados no período de 1988 a 2024. Essa ampla extensão temporal evidencia o interesse contínuo dos pesquisadores em explorar diversas técnicas e abordagens para lidar com a incerteza inerente aos processos de fabricação. Pois, mesmo após décadas de investigação, a temática permanece aberta para novas pesquisas, demonstrando a complexidade e a relevância contínua do assunto.

Dentre os 19 trabalhos analisados, 95% foram publicados em revistas acadêmicas, abrangendo um total de 11 periódicos. Destacam-se, entre esses, o *European Journal of Operational Research*, o *International Journal of Production Research* e o *Kuwait Journal of Science*, os quais, em conjunto, concentram 56% dos estudos revisados. Conforme demonstrado no Tabela 9.

Tabela 9 – Publicações em cada revista para o PSMUE

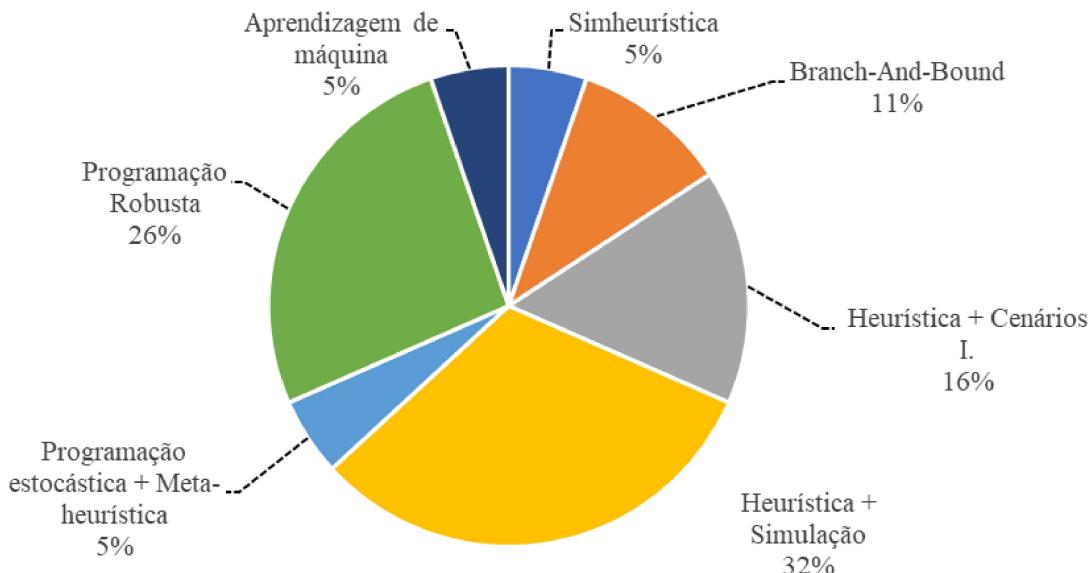
Revista	Quantidade de artigos
European Journal of Operational Research	4
International Journal of Production Research	4
Kuwait Journal of Science	2
Computers & Industrial Engineering	1
Discrete Applied Mathematics	1
Transactions	1
Infor	1
Journal of Systems Engineering and Electronics	1
Management Science	1
Matematika	1
Operations Research	1

Fonte: Elaborado pelo autor (2024)

Quanto aos métodos de resolução para esse tipo de problema, foram apresentadas diversas abordagens para lidar com o PSMUE. Destacam-se, em particular, aquelas que empregam heurísticas

combinadas com simulação e a programação robusta. Essas estratégias combinadas representam 58% dos estudos analisados. Essa variedade de abordagens ressalta a diversidade de técnicas e metodologias exploradas na tentativa de resolver eficazmente o problema em questão. Na Figura 12, são apresentados todos os quantitativos relacionados aos métodos de resolução encontrados.

Figura 12 – Percentual dos métodos de resolução utilizados para o PSMUE



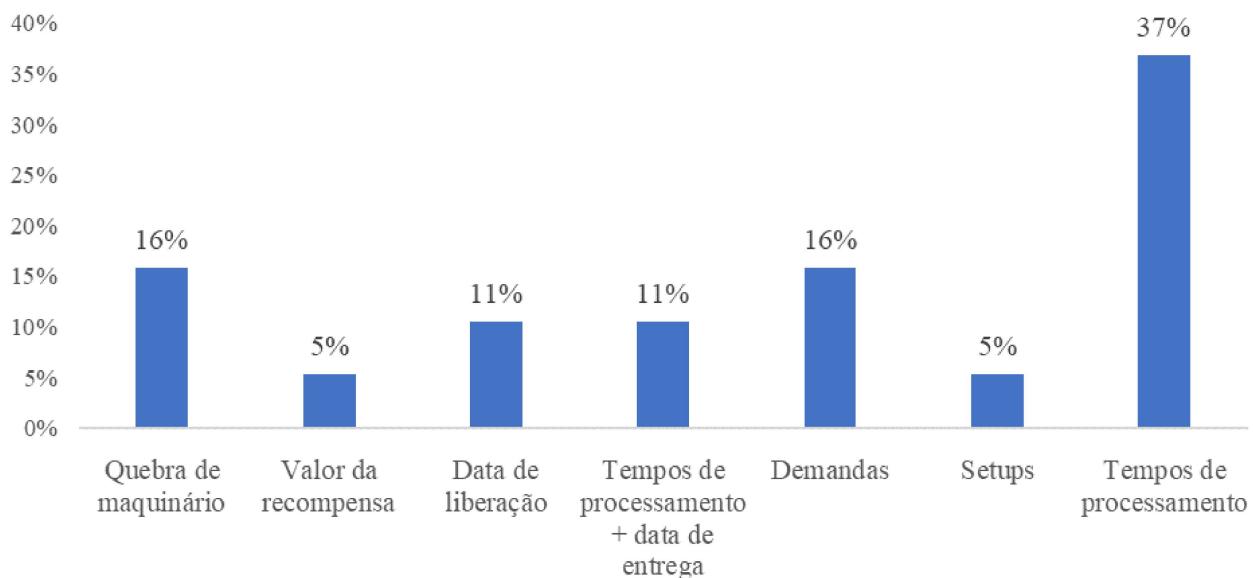
Fonte: Elaborado pelo autor (2024)

Outro ponto, é quanto aos parâmetros estocásticos mais utilizados nessa temática, A Figura 13 fornece uma consideração adicional de grande relevância, detalhando os parâmetros estocásticos mais amplamente discutidos e explorados na literatura, dentro do contexto apresentado nesta seção.

O parâmetro mais abordado é o tempo de processamento. As pesquisas que consideram exclusivamente esse parâmetro como estocástico compreendem 37% dos trabalhos presentes na literatura. No entanto, se incluirmos todos os estudos em que os tempos de processamento são tratados como estocásticos, a quantidade de trabalhos aumenta para 48%, representando quase metade dos estudos na literatura.

Dante disso, este trabalho adota uma abordagem ainda não muito explorada, diferenciando-se das técnicas mais comuns apresentadas na revisão. O método escolhido é denominado simheurística, um híbrido ainda pouco explorado no contexto do PSMUE, representando apenas 5% das pesquisas revisadas. Essa estratégia combina meta-heurísticas para uma busca eficiente no espaço de solução com simulação Monte Carlo para avaliar a solução em diversos cenários. Tal combinação proporciona informações estatísticas cruciais para a tomada de decisões, tudo isso dentro de tempos computacionais razoáveis.

Figura 13 – Percentual de artigos em relação aos parâmetro estocásticos PSMUE



Fonte: Elaborado pelo autor (2024)

As simheurísticas se assemelham levemente à combinação de procedimentos heurísticos com simulação apresentada também nesta revisão. No entanto, nesses estudos, a simulação é realizada apenas uma vez, com um determinado número de iterações, para uma única solução encontrada pelo método. Nessas abordagens, o objetivo principal é encontrar a melhor solução determinística para o problema e, em seguida, simular essa solução para obter informações sobre seu desempenho no ambiente estocástico. Por outro lado, nas simheurísticas, durante a busca no espaço de solução, já é considerada a procura por soluções que sejam boas estocasticamente, ou seja, que possuam baixo valor esperado. Isso significa que a análise estocástica é incorporada diretamente no processo de busca por soluções. Outro diferencial das simheurísticas é que elas incorporam a análise de risco e a utilização de um *pool* de soluções, elementos cruciais para a análise de problemas de OC estocásticos. Com isso, essa metodologia vem sendo cada vez mais estudada e aplicada em diferentes problemas de OC, evidenciando o potencial dessa abordagem na resolução de problemas estocásticos.

Além disso, o parâmetro estocástico considerado nesta pesquisa foram os tempos de processamento. Essa escolha se baseia na diversidade de fatores reais que podem influenciar sua variação, como desgaste do equipamento, falhas no processamento e habilidade do operador, entre outros. Essa variabilidade torna os tempos de processamento altamente incertos, com potencial significativo para afetar a função objetivo. Portanto, sua consideração como estocástico é crucial para uma modelagem precisa e abrangente do problema em questão.

3.2.2.2 Abordagem dos artigos

Nesta Subseção, são discutidos todos os trabalhos relacionados ao PSMUE, com ênfase nos métodos de resolução adotados e em quais parâmetros a estocacidade é incorporada.

No estudo de Halim *et al.* (2020), os autores enfatizam a importância de um planejamento eficaz da manutenção preventiva dos equipamentos para garantir o cumprimento dos cronogramas operacionais de uma empresa. O objetivo principal do artigo é minimizar o *makespan*, levando em consideração a quebra de maquinário como um parâmetro estocástico. Para alcançar esse objetivo, os autores empregam uma simheurística, que combina um Algoritmo Genético (AG) para a busca por soluções e a Simulação Monte Carlo para analisar os diferentes cenários resultantes dessas soluções. Além disso, é adotada e testada uma estratégia que aborda o problema com diferentes níveis de variação, visando gerar uma compreensão mais abrangente do impacto do parâmetro estocástico na função objetivo analisada.

Em Szmerekovsky (2007), foi desenvolvido um problema onde os tempos de processamento dos trabalhos são conhecidos e determinísticos, mas onde a recompensa recebida após a conclusão de um trabalho muda estocasticamente. Dessa forma, são considerados os objetivos de maximizar o valor presente líquido (VPL) esperado, minimizar a variância do VPL e maximizar a probabilidade de atingir um VPL de referência mínimo. Os autores implementaram o procedimento *branch-and-bound* e obtiveram resultados satisfatórios quando comparada a uma heurística gulosa já presente na literatura.

A pesquisa realizada por Fay e Glazebrook (1992) aborda a natureza imprevisível da chegada de trabalhos ao longo do dia, considerando essa característica como uma variável aleatória no modelo. No contexto desse problema, cada tarefa concluída resulta em uma recompensa, e o objetivo é encontrar uma estratégia de processamento que maximize a recompensa total esperada ao longo do sequenciamento. Para abordar essa questão, os autores exploram seis cenários de incerteza ao aplicar sua heurística proposta, resolvendo o problema em cada cenário individualmente.

No estudo de Li e Wang (2009) os autores modelaram a quebra de maquinário como um parâmetro estocástico do problema, juntamente com a data de liberação. O objetivo principal é minimizar o atraso total ponderado, para o qual propuseram uma heurística específica. Após a obtenção dos resultados através dessa abordagem, aplicaram a simulação em dez iterações para extrair informações sobre o desvio e a média da função objetivo. Os resultados computacionais indicam que o cronograma gerado pela heurística proposta é mais estável e menos sensível às diferentes situações de quebra de máquinas do que as heurísticas previamente existentes na literatura, em grande parte dos

casos.

Em Jang (2002), o objetivo é minimizar o número esperado de trabalhos atrasados, considerando os tempos de processamento e as datas de entrega dos trabalhos como variáveis aleatórias. Com a consideração da estocasticidade, os autores conseguiram avaliar o papel da variância do tempo de processamento, por meio de uma heurística proposta que desenvolve uma política de sequenciamento dinâmico, simples e robusta, para ser utilizada em ambientes de fabricação incertos e em rápida mudança. A heurística desenvolvida é aplicada para encontrar uma solução no espaço de soluções e, posteriormente, é aplicada a simulação com cem iterações em três níveis de incerteza (baixo, moderado e alto), para analisar o pior cenário possível para o sequenciamento encontrado.

Em Gascon *et al.* (1994), são comparadas diferentes heurísticas para um problema que envolve demandas estocásticas e *setup* entre tarefas. Os autores assumiram na modelagem que o sequenciamento é feito mensalmente e dependente das demandas estocásticas. Dessa forma, foi analisada a estocasticidade considerando até cinco meses à frente e como essas demandas estocásticas influenciam no sequenciamento das tarefas devido às quantidades a serem produzidas e aos *setups* presentes. Assim, com o resultado de cada heurística, dez replicações foram feitas para diferentes níveis de variância, com a finalidade de analisar o impacto no nível de serviço e no custo de produção.

Nas pesquisas de Daniels e Carrillo (1997), Lu *et al.* (2014b), Yue *et al.* (2018), Yue *et al.* (2020), Bold e Goerigk (2022), foi utilizada uma abordagem robusta para criar soluções que são resilientes às incertezas, garantindo um desempenho satisfatório em diferentes cenários possíveis. Para isso, foram formulados modelos de otimização que consideram múltiplos cenários estocásticos e que conseguem incorporar estratégias para lidar com a variabilidade existente nos processos, no caso, cada autor possui uma abordagem diferente devido a natureza de cada problema abordado. Em Daniels e Carrillo (1997), Lu *et al.* (2014b), Yue *et al.* (2018) e Bold e Goerigk (2022), é abordado a estocasticidade por meio dos tempos de processamento, no qual busca-se minimizar o tempo total de atraso, somatório do tempo de conclusão, o tempo máximo de espera e o *makespan* respectivamente. Já em Yue *et al.* (2020), tem-se a data de liberação como parâmetro estocástico, com o objetivo de minimizar o atraso máximo no pior cenário.

No estudo desenvolvido por Ertem *et al.* (2019), é considerado que os tempos de configuração são dependentes da sequência e incertos, enquanto os tempos de processamento e as datas de vencimento são determinísticos. Com isso, o objetivo da pesquisa desses autores é minimizar o atraso total esperado. Dessa forma, são utilizados dois métodos de resolução: o primeiro é o método de programação estocástica em dois estágios, capaz de encontrar a solução ótima, empregado para a resolução das instâncias de pequeno porte; e o outro é uma variante do AG, capaz de resolver

problemas de otimização combinatória estocásticos, utilizado para problemas de grande porte. Como resultado, os autores observaram que o AG obteve os mesmos resultados que o algoritmo ótimo para as instâncias pequenas, demonstrando o grande potencial dessa metodologia para a resolução de problemas estocásticos.

Em Soroush e Fredendall (1994), é abordado o problema com custos de antecipação e atraso, onde os tempos de processamento de tarefas são variáveis aleatórias e os prazos das tarefas são distintos e determinísticos. O objetivo dos autores é minimizar o custo total de antecipação esperado mais o custo de atraso. Os autores demonstraram que variações nos tempos de processamento aumentam os custos e afetam as decisões de sequenciamento. São propostas três heurísticas utilizando os limites inferiores e superiores na função de custo esperado para obter candidatos para a sequência ótima. A primeira heurística minimizava o custo do limite inferior. A segunda heurística minimizava o custo do limite superior. Por fim, a terceira heurística utilizava os desvios padrão ponderados dos tempos de processamento para sequenciar os trabalhos.

Na pesquisa de Gascon (1988), é apresentada a heurística *Lookahead* para programar a produção em ambientes com demandas dinâmicas e estocásticas. Essa abordagem fundamenta-se na realização de simulações dos próximos dias de produção, permitindo a tomada de decisões sobre o encerramento ou continuidade da produção em determinados turnos de trabalho. Os resultados dos testes de simulação revelam que, em diversas condições de produção, a heurística proporciona a diminuição dos custos totais, mantendo um alto nível de serviço. Esses resultados destacam a eficácia da abordagem baseada em simulação da heurística na gestão da produção, especialmente em cenários caracterizados por flutuações nas demandas e disponibilidade de recursos, evidenciando sua relevância para a melhoria do desempenho operacional.

A pesquisa conduzida por Sabri *et al.* (2024) aborda o problema de sequenciamento associado à manutenção preventiva, sujeita a falhas aleatórias, com o intuito de minimizar os custos de antecipação e atraso. O principal objetivo é investigar a eficácia de métodos baseados em aprendizado de máquina de tendências em comparação com abordagens de otimização estocástica. Os autores propõem um método que inicialmente resolve o problema como um modelo de programação dinâmica estocástica de forma aproximativa e, em seguida, aplica um modelo de aprendizado por reforço. Este enfoque permite apresentar detalhes sobre a qualidade da solução, tempo de execução e robustez, para analisar o desempenho da sua proposta em comparação com abordagens já existentes na literatura.

O estudo conduzido por Soroush e Amin (2013) aborda um problema em que os tempos de processamento são variáveis aleatórias, com efeitos de aprendizagem dependentes das tarefas. Para resolver este problema, os autores utilizaram o método *branch-and-bound*, que permite minimizar

diversas funções objetivo de forma sequencial. Esses critérios incluem o *makespan*, tempo total de conclusão, atraso total, custo total de espera, tempo total de espera, diferenças absolutas totais nos tempos de conclusão, e o somatório da multa por antecipação, atraso e vencimento comum.

Os estudos apresentados por Soroush (2007) e Soroush (2013) abordam um problema de sequenciamento com datas de vencimento e com pesos fixos (penalidades) atribuídos aos trabalhos atrasados. Em ambos os estudos, o objetivo é encontrar um sequenciamento que minimize o número ponderado esperado de trabalhos atrasados. No estudo de Soroush (2007), apenas os tempos de processamento são considerados variáveis aleatórias, enquanto no estudo de Soroush (2013), são analisados três cenários distintos: um cenário com tempos de processamento e prazos estocásticos, outro com tempos de processamento determinísticos e prazos estocásticos, e um terceiro com tempos de processamento estocásticos e prazos determinísticos. Em ambos os estudos, é proposta uma heurística para abordar o problema, seguida por uma etapa de simulação para avaliar a solução obtida.

Em Leachman e Gascon (1988), os autores estenderam a política básica de sequenciamento para integrá-la ao planejamento tático, devido à natureza das demandas estocásticas. A abordagem desenvolvida é aplicada período por período para tomar decisões sobre quais itens produzir e em que quantidades durante o próximo período. Essas quantidades refletem nos ciclos de produção previstos em cada período de tempo em resposta às diferenças entre os níveis de inventário projetados e reais. Essa abordagem utiliza uma heurística para construir a solução, sendo seguida por uma simulação ao final da busca.

3.2.3 PROBLEMA DE SEQUENCIAMENTO COM CONSIDERAÇÕES AMBIENTAIS E PARÂMETROS ESTOCÁSTICOS

Na Subseção 3.2.3.1 e na Subseção 3.2.3.2, são discutidas a sumarização e as abordagens dos artigos mais relevantes para a revisão do problema de sequenciamento de máquina única com considerações ambientais e parâmetro estocástico.

3.2.3.1 Sumarização e análise dos trabalhos

Nesta subseção, são apresentados 7 dos 8 artigos encontrados na busca, sendo 1 artigo excluído da revisão por não abordar as considerações ambientais na modelagem. Na Tabela 10, cada um dos trabalhos considerados nesta revisão é apresentado.

Tabela 10 – Artigos utilizados para a revisão do PSVMUE

Referência	Título do artigo
Liu (2016)	Mathematical programming formulations for single-machine scheduling problems while considering renewable energy uncertainty
Fu <i>et al.</i> (2019)	Stochastic multi-objective modelling and optimization of an energy-conscious distributed permutation flow shop scheduling problem with the total tardiness constraint
Amiri e Behnamian (2020)	Multi-objective green flowshop scheduling problem under uncertainty: Estimation of distribution algorithm
Wang <i>et al.</i> (2020)	Stochastic optimization for flow-shop scheduling with on-site renewable energy generation using a case in the United States
Marichelvam e Geetha (2021)	A memetic algorithm to solve uncertain energy-efficient flow shop scheduling problems
Wang e Qi (2023)	Scheduling an Energy-Aware Parallel Machine System with Deteriorating and Learning Effects Considering Multiple Optimization Objectives and Stochastic Processing Time
Zheng <i>et al.</i> (2023)	Single machine scheduling with uncertain processing times and carbon emission constraint in the shared manufacturing environment

Fonte: Autor (2024)

Entre os artigos analisados, todos foram publicados em revistas acadêmicas, abrangendo um total de seis periódicos distintos. Mais uma vez, destaca-se a predominância da revista *Journal of cleaner production*, a mesma que recebeu destaque na Subseção 3.2.1. Na Tabela 11 estão listadas todas as revistas abordadas nesta análise.

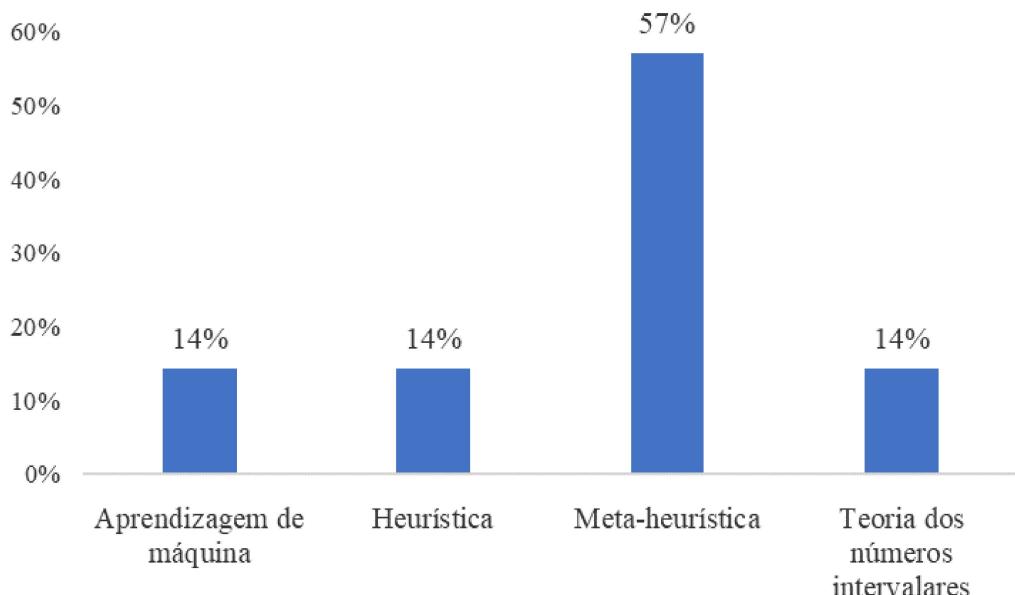
Tabela 11 – Publicações em cada revista para o PSVE

Revista	Quantidade
Journal of Cleaner Production	2
CMES- Computer Modeling in Engineering Sciences	1
Computers & Industrial Engineering	1
International Journal of Advanced Manufacturing Technology	1
International Journal of Production Research	1
Annals of Operations Research	1

Fonte: Elaborado pelo autor (2024)

Outro ponto a ser destacado refere-se aos métodos utilizados para resolver esse tipo de problema. Como já evidenciado nas Subseções 3.2.1 e 3.2.2, a abordagem mais comum é a utilização de métodos heurísticos. Dado que essa temática engloba tanto a estocasticidade (conforme apresentado na Seção 3.2.2) quanto as considerações ambientais (como abordado na Seção 3.2.1), observou-se que os métodos heurísticos também foram os mais utilizados nesse contexto, representando 71% das abordagens encontradas. Isso apenas demonstra que a resolução desse tipo de problema é extremamente complexa, sendo frequentemente classificada como *NP-Hard*. Por essa razão, a grande maioria dos estudos que abordaram essa temática optaram pela utilização de métodos heurísticos. Esses métodos, embora não garantam a obtenção da solução ótima, são capazes de encontrar soluções próximas ao ótimo em um tempo computacionalmente viável, tornando-se uma abordagem prática e eficaz para lidar com a complexidade inerente desses problemas. As demais abordagens podem ser visualizadas na Figura 14.

Figura 14 – Métodos de resolução para o PSVE



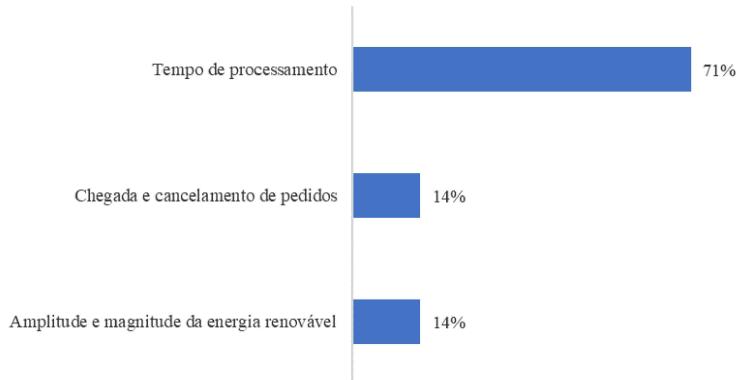
Fonte: Autor (2024)

Fonte: Elaborado pelo autor (2024)

Quanto aos parâmetros estocásticos mais abordados, observamos que os tempos de processamento foram os mais utilizados, representando 71% dos trabalhos analisados, em consonância com o apresentado na Subseção 3.2.2. Essa tendência pode ser explicada pelo fato de que os PSVE são normalmente resolvidos considerando a eficiência energética, que é representada pelo produto do consumo de energia da máquina, o preço da energia e os tempos de processamento das tarefas. Portanto, as variações presentes nos tempos de processamento exercem uma influência direta sobre o

desempenho ambiental analisado. Na Figura 15 pode ser observado os demais parâmetros estocásticos considerados.

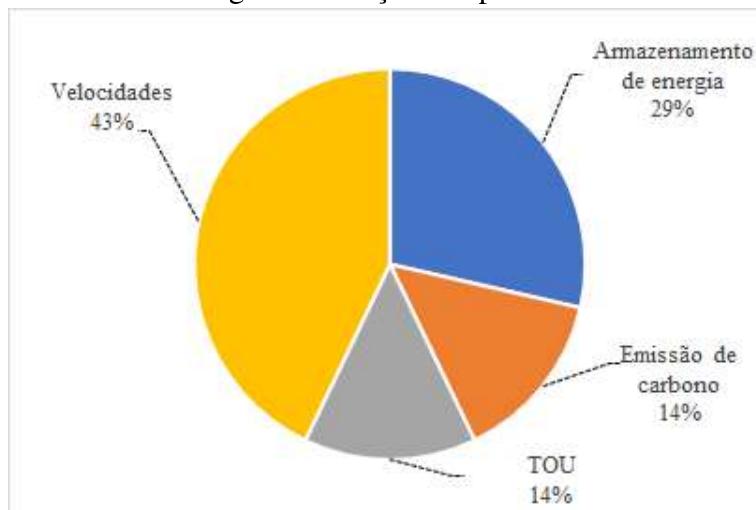
Figura 15 – Percentual de artigos em relação as considerações ambientais para o PSVE



Fonte: Elaborado pelo autor (2024)

Por fim, quanto às considerações ambientais mais utilizadas, observou-se que as velocidades escaláveis foram as mais frequentemente abordadas, representando 43% dos estudos analisados. Surpreendentemente, a política TOU, que foi a mais utilizada na Subseção 3.2.1, foi abordada em apenas 14% dos trabalhos desta pesquisa. Esse ponto destaca uma lacuna significativa nesta área, sugerindo uma oportunidade de desenvolvimento adicional para demonstrar a importância das considerações de parâmetros estocásticos para esse tipo de consideração ambiental. Essa lacuna pode ser explorada para fornecer discussões adicionais sobre como a incerteza nos parâmetros afeta essas estratégias de sequenciamento e, consequentemente, impacta nos objetivos organizacionais relacionados à sustentabilidade e eficiência energética. A Figura 16 demonstra o percentual de todas as considerações.

Figura 16 – Percentual de artigos em relação aos parâmetro estocásticos para o PSVE



Fonte: Elaborado pelo autor (2024)

Por fim, dentre todos os ambientes de manufatura presentes nessa subseção, observa-se que o ambiente de máquina única possui apenas 29% dos trabalhos dedicados a essa temática, sendo o principal ambiente o *flowshop*, com 54% dos trabalhos.

Com isso, destaca-se que o tema abordado nesta subseção representa uma área ainda pouco explorada e que nunca foi resolvida por meio de uma simheurística, o que ressalta a importância das contribuições desta pesquisa na introdução de um novo método para a resolução desse problema. Além disso, é notável que esse tema tem sido objeto de estudo apenas recentemente na literatura, indicando uma tendência crescente de interesse e investigação nessa área. Essa observação enfatiza ainda mais a relevância do presente estudo, que contribui para o avanço do conhecimento em uma área emergente e promissora, fornecendo ideias valiosas e abrindo novas perspectivas de pesquisa.

3.2.3.2 Abordagem dos artigos

Nesta subseção, são discutidos todos os trabalhos relacionados ao PSVE, com ênfase nas abordagens das considerações ambientais, métodos de resolução adotados e funções objetivo analisadas neste contexto.

No estudo conduzido por Liu (2016), a teoria dos números intervalares é empregada para introduzir incerteza relacionada à energia renovável em problemas de sequenciamento de máquina única. A utilização de energias renováveis, como a eólica e a solar, apresenta uma incerteza significativa em relação à disponibilidade, magnitude e intensidade dessas fontes de energia em momentos futuros (i.e., a magnitude se relaciona com a quantidade total de energia disponível na área em potência total, enquanto, a intensidade está mais diretamente ligada à velocidade do vento ou a intensidade solar, que influencia diretamente a quantidade de energia que pode ser gerada). Para abordar essa incerteza, o estudo adota uma abordagem bi-objetivo na otimização do problema, empregando o método Tchebycheff ponderado lexicográfico para obter soluções Pareto-ótimas. Os objetivos considerados são a minimização da emissão de CO_2 e do *makespan*.

Em Fu *et al.* (2019), também houve a abordagem da questão ambiental por meio do sequenciamento com velocidades ajustáveis. No entanto, os autores adotaram uma método diferente ao utilizar a heurística *Brainstorm Optimization*, a qual foi combinada com uma etapa de simulação. Isso foi aplicado para lidar com o problema de *flowshop* permutacional e multiobjetivo, considerando aspectos ambientais e estocásticos. Nessa pesquisa, os objetivos abordados pelos autores foram a minimização do *makespan* e dos custos energéticos. Além disso, o parâmetro estocástico adotado pelos autores foi o tempo de processamento das tarefas.

No estudo de Amiri e Behnamian (2020), também é apresentado um problema de *flowshop*,

e a abordagem adotada para a sua resolução envolve uma das variantes do Algoritmo Genético (AG). Nessa pesquisa, no entanto, um algoritmo de estimativa de distribuição também é aplicado e é considerado um modelo bi-objetivo, buscando a minimização do valor de *makespan* e dos custos energéticos. O custo energético é calculado por meio de ajuste de velocidade. Os tempos de processamento são considerados variáveis aleatórias, sendo modelados com base em uma distribuição normal com média e variância conhecidas.

Já em Gholizadeh *et al.* (2021) os autores realizaram uma adaptação do AG para solucionar um problema de otimização real na programação de um ambiente de fabricação do tipo *flowshop* flexível, inserindo o contexto de um sistema de geração de energia. O objetivo deste estudo é otimizar o sequenciamento das tarefas, minimizando o atraso total. Para aumentar a precisão da modelagem em relação à realidade, os autores incorporaram incertezas nos tempos de processamento.

No estudo de Marichelvam e Geetha (2021), os autores desenvolveram uma extensão do tradicional AG para resolver um problema de *flowshop* real em uma indústria fabricante de componentes automotivos. Ao modelar esse problema, os pesquisadores incorporaram incertezas ao considerar a possibilidade de chegada e cancelamento de pedidos durante o processamento das tarefas. Além disso, o estudo incorporou considerações ambientais na função objetivo da formulação, com o intuito de reduzir o custo energético. Essa abordagem foi realizada multiplicando o *makespan* pelo consumo de energia por unidade de tempo e pelo custo por unidade de consumo de energia, tudo isso dentro de uma política TOU. Como resultado, conseguiram reduzir, em média, o custo energético em 9,86%, contribuindo para a diminuição das emissões de carbono e do impacto ambiental.

Em Wang e Qi (2023), o algoritmo *Multi-Verse Optimizer* (MVO) é empregado para resolver o problema de sequenciamento em máquinas paralelas com tempos de processamento estocásticos, levando em consideração aspectos ambientais, efeitos de deterioração e aprendizado. O modelo adotado pelos autores é multiobjetivo, visando a minimização do *makespan* e do TEC por meio de ajustes na velocidade. A estocacidade é tratada por meio da Simulação Monte Carlo, na qual essa metodologia é utilizada para avaliar o desempenho da solução em diversos cenários.

No estudo conduzido por Zheng *et al.* (2023), os autores têm como objetivo maximizar o lucro total esperado em um problema de sequenciamento de máquina única com tempos de processamento de tarefas incertos, juntamente com restrições de emissão de carbono. Para alcançar esse objetivo, eles empregam dois métodos de aprendizado de máquina não supervisionados: *K-means* e *K-medoids*. Esses métodos são utilizados para lidar com a incerteza nos tempos de processamento das tarefas. O *K-means* agrupa os dados em *clusters*, enquanto o *K-medoids* seleciona *medoids* como representantes dos *clusters*. Ambos os métodos são integrados a uma abordagem de aproximação de

média de amostra. Os resultados obtidos pelos autores demonstraram que essa combinação de técnicas constitui uma estratégia eficaz para resolver o problema de maximização do lucro total esperado no contexto apresentado.

4 METODOLOGIA

Neste capítulo, é apresentada a classificação da pesquisa quanto à sua natureza, abordagem, objetivos, método de pesquisa e as etapas. Ademais, são discutidos os procedimentos computacionais implementados.

4.1 CLASSIFICAÇÃO DA PESQUISA

A classificação da pesquisa quanto à natureza é considerada como básica. Conforme Gil (2019), a pesquisa básica tem como propósito gerar novos conhecimentos com utilidade para o progresso da ciência, sem previsão de aplicação prática.

Da mesma forma, a abordagem adotada é quantitativa, pois se baseia na ideia de quantificação e mensuração dos resultados. De acordo com Richardson (2017), toda pesquisa que presume a quantificação de variáveis, envolvendo a conversão de opiniões e informações em valores numéricos para classificação e análise, é considerada quantitativa. Além disso, no que tange aos objetivos, ela pode ser categorizada como exploratória. Por definição, essa categoria visa preencher lacunas frequentemente encontradas em um estudo (Richardson, 2017). A presente pesquisa busca suprir a lacuna existente nos estudos de simheurística para o PSVMUE.

O método de pesquisa é identificado como simulação, uma vez que, de acordo com Cauchick-Miguel (2018), a simulação faz uso de abordagens computacionais para conduzir representações simuladas de realidades específicas através de modelos matemáticos.

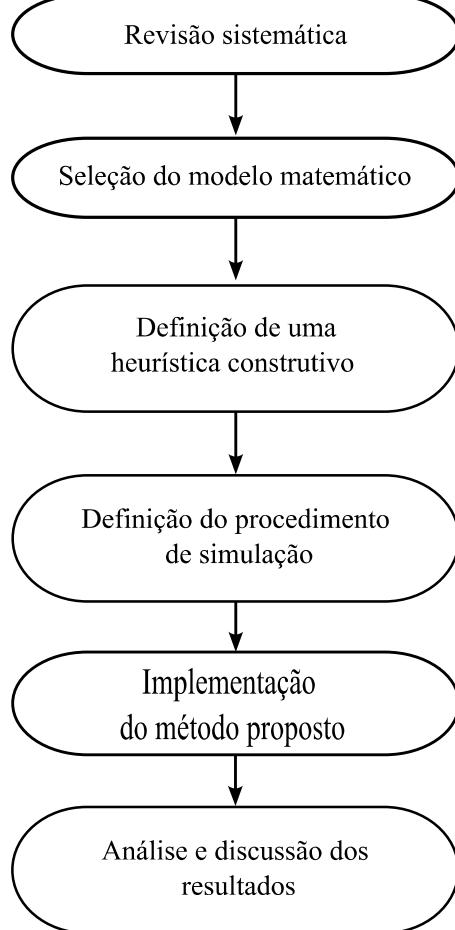
Dessa forma, este estudo pode ser elaborado por meio de etapas, conforme observado na Figura 17. A primeira etapa consiste em uma revisão sistemática relacionada ao PSMUE, PSVMU e ao PSVE. Essas três áreas foram escolhidas devido à carência de estudos sobre o problema específico abordado nesta pesquisa, ou seja, o PSVMUE. A revisão sistemática serviu como uma base sólida para a definição do problema e da abordagem simheurística adotada.

Com base na revisão sistemática, um modelo existente na literatura foi selecionado para descrever o problema a ser otimizado. No entanto, nesta pesquisa, optou-se por utilizar como método de resolução uma heurística construtiva estabelecida na literatura, combinada com um procedimento de simulação, integrando-os em uma meta-heurística para desenvolver o algoritmo simheurístico proposto.

O método proposto foi então implementado e aplicado em diversas instâncias de teste. Nessa fase, buscou-se aplicar diferentes métricas estocásticas e simular cenários variados de incertezas. O objetivo foi avaliar a robustez e eficácia do algoritmo em contextos diversos, explorando a estocasticidade de múltiplas formas e níveis. Essa abordagem permitiu uma análise abrangente da performance

do algoritmo frente às variabilidades e incertezas inerentes ao problema estudado, contribuindo para a compreensão e resolução do PSVMUE de maneira mais eficaz e realista.

Figura 17 – Metodologia da pesquisa



Fonte: Elaborado pelo autor (2024)

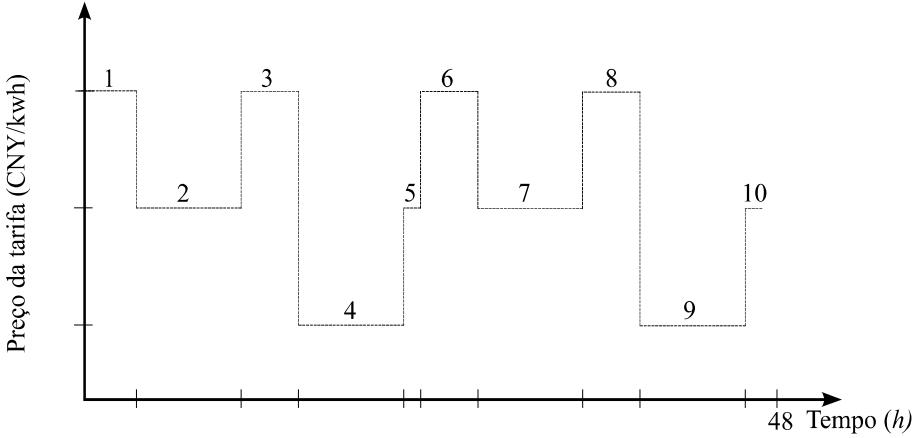
4.2 PROCEDIMENTOS COMPUTACIONAIS

Neste seção, apresenta-se a abordagem simheurística utilizada nesta pesquisa. Na Subseção 4.2.1 são detalhados os procedimentos construtivos. Na Subseção 4.2.2 é descrita a abordagem de simulação empregada para este problema. Na Subseção 4.2.3 é apresentada a meta-heurística selecionada e como ela orienta a heurística construtiva na busca por diferentes soluções. Na Subseção 4.2.4 é apresentada a proposta de simheurística. Por fim, na Subseção 4.2.5 é demonstrado o procedimento meta-heurístico utilizado para buscar a melhor solução determinístico.

4.2.1 Heurística Construtiva

O procedimento construtivo adotado na simheurística é baseado na heurística *Greedy Insertion Heuristic* (GIH) proposta por Zhang *et al.* (2018a). Essa abordagem é inspirada na política de tarifa TOU da China, no qual, cada período de tarifa baixa é seguido por um período de tarifa média e precedido por um período de tarifa alta. Nessa política, há três conjuntos denominados A , B e C , que representam os conjuntos que contêm os períodos de tarifa baixa, média e alta, respectivamente. Os conjunto A , B e C são partições de M , i.e., $A \cup B \cup C = M$, $A \cap B = \emptyset$, $A \cap C = \emptyset$ e $B \cap C = \emptyset$. O tamanho dos períodos e a distribuição das tarifas durante o horizonte de tempo pode ser visualizada na Figura 18, onde, $M = \{1, 2, \dots, 10\}$, $A = \{4, 9\}$, $B = \{2, 5, 7, 10\}$ e $C = \{1, 3, 6, 8\}$.

Figura 18 – Ilustração da distribuição das tarifas no horizonte de tempo



Fonte: Elaborado pelo autor (2024)

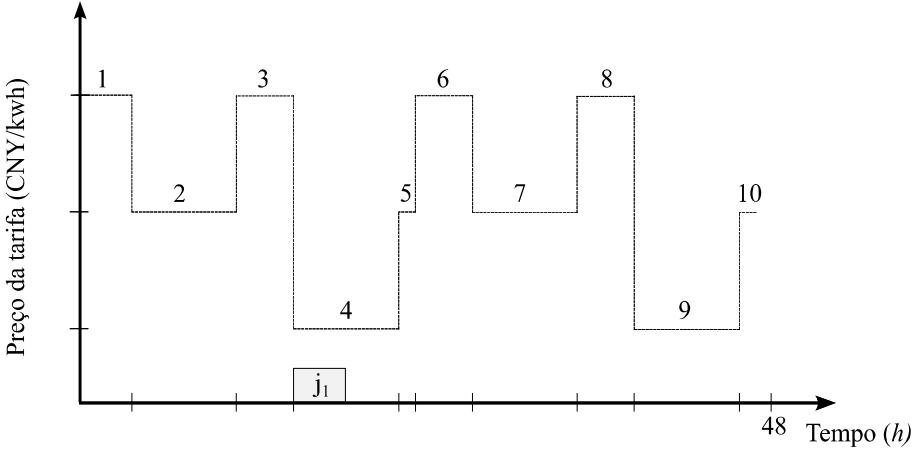
Além disso, temos d_k e X_k , onde $k \in M$, que representam a duração do período k e o total de tempos de processamento já atribuídos no período k , respectivamente. A diferença entre d_k e X_k é definida como o tempo de ociosidade restante do período k , que é representado por I_k , onde $k \in M$. Se $I_k = 0$, o período k está completamente preenchido e sem ociosidade.

A heurística GIH adota o conceito de filtragem em múltiplas camadas, no qual todas as alocações são realizadas considerando as camadas estabelecidas e as condições específicas dentro de cada camada. Nesse método, a heurística inicia ordenando os consumos energéticos de forma não crescente, e com base nessa ordem, as alocações são realizadas, de modo a minimizar o TEC. Além disso, todos os tempos de processamento considerados são menores que a duração do menor período de tarifa alta.

Assim, temos a Camada 1, que engloba as Condições 1 e 2. Nessa camada, uma Tarefa i é alocada para a Camada 1 se $\exists k \in A$, tal que $t_i \leq \max_{k \in A} \{I_k\} + I_{k+1}$, onde $I_k \neq 0$. Isso ocorre porque as tarefas com maior consumo energético são priorizadas para serem alocadas nos períodos com tarifas

mais baixas. Dentro da Camada 1, encontramos a Condição 1, que estabelece que se $\exists k \in A$, tal que $t_i \leq \max_{k \in A} \{I_k\}$, então a tarefa i é completamente processada durante um período de tarifa baixa. Uma ilustração desse processo é fornecida na Figura 19, que demonstra a alocação da Tarefa 1 (j_1) no período 4.

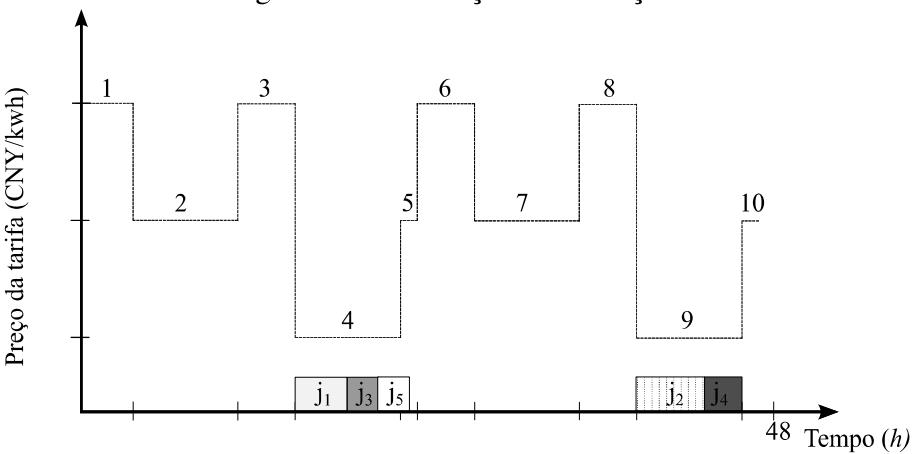
Figura 19 – Ilustração da condição 1



Fonte: Elaborado pelo autor (2024)

Já Condição 2, é o caso contrário da Condição 1 (satisfazendo a condição geral da Camada 1), pois quando não é possível processar completamente uma tarefa durante o período de tarifa baixa e ainda há ociosidade nesse período, a tarefa é processada nos períodos k e $k + 1$. Na Figura 20, é ilustrada a alocação da Tarefa 5 no período 4. Como observado, $t_5 > I_4$, porém $t_5 < I_4 + I_5$, resultando na execução da Tarefa 5 nos períodos 4 e 5.

Figura 20 – Ilustração da condição 2



Fonte: Elaborado pelo autor (2024)

Se não for possível alocar a Tarefa i na Camada 1, ela passa para a Camada 2. Onde é considerado que se $t_i > \max_{k \in A} \{I_k\} + I_{k+1}$ e que $\exists k' \in B$, tal que $t_i \leq \{I_{k'}\}$, então, a tarefa é alocada

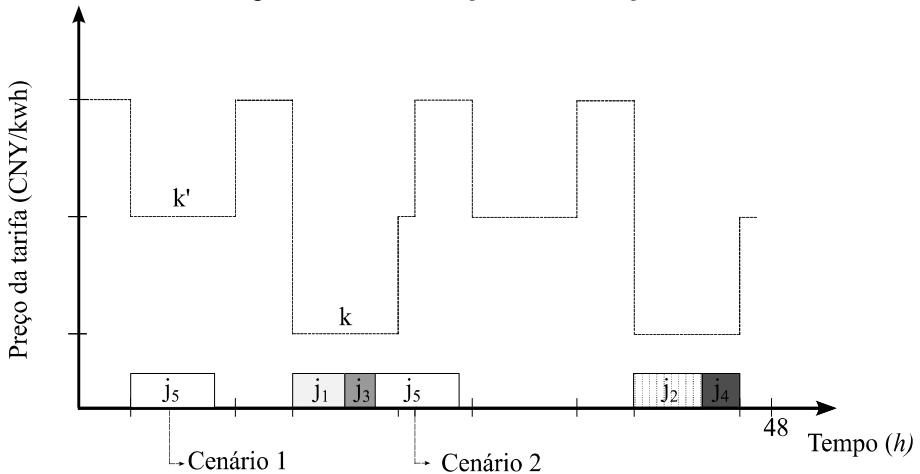
na Condição 3, 4 ou 5. Assim, na Condição 3, se $\max_{k \in A} \{I_k\} > 0$ e $d_{k+2} > 0$, a Tarefa i entra nessa condição. Onde $d_{k+2} > 0$ indica que existem dois períodos depois do período k analisado. Nessa condição são analisados dois cenários para a alocação da Tarefa i . A primeira opção é processar a tarefa em três períodos consecutivos ($k, k+1$ e $k+2$), onde $k \in A, k+1 \in B$ e $k+2 \in C$, gerando o *custo1*. O segundo cenário consiste em processar toda a tarefa em um período de tarifa média, gerando o *custo2*. Diante disso, a posição que apresentar o menor custo, vai ser a posição em que a Tarefa i vai ser alocada.

Teorema 1. Se a Condição 3 estiver satisfeita e $x_{ik} \times (c_B - c_A) < x_{ik+2} \times (c_C - c_B)$, a melhor alocação para a Tarefa i é processá-la durante o período de tarifa média.

Prova 1. $\text{custo1} = p_i \times (x_{ik} \times c_A + x_{ik+1} \times c_B + x_{ik+2} \times c_C)$ e $\text{custo2} = p_i \times t_i \times c_B$. É assumido que $\text{custo1} > \text{custo2}$, isso é, $\text{custo1} - \text{custo2} = p_i \times (x_{ik} \times c_A + x_{ik+1} \times c_B + x_{ik+2} \times c_C) - p_i \times t_i \times c_B > 0$. Desde que $t_i = x_{ik} + x_{ik+1} + x_{ik+2}$, conclui-se que: $x_{ik} \times (c_B - c_A) < x_{ik+2} \times (c_C - c_B)$ (Zhang et al., 2018a).

Dessa maneira, sempre que a inequação apresentada no Teorema 1 for respeitada, a Tarefa i é processada no período de tarifa média. Caso contrário, a Tarefa i é processada em três períodos consecutivos. Na Figura 21, é apresentada uma demonstração das possibilidades dessa condição. Se a melhor alocação para T_5 for o cenário 1, o sequenciamento obtido é j_5, j_1, j_3, j_2 e j_4 . Caso contrário, o sequenciamento obtido é j_1, j_3, j_5, j_2 e j_4 .

Figura 21 – Ilustração da condições 3

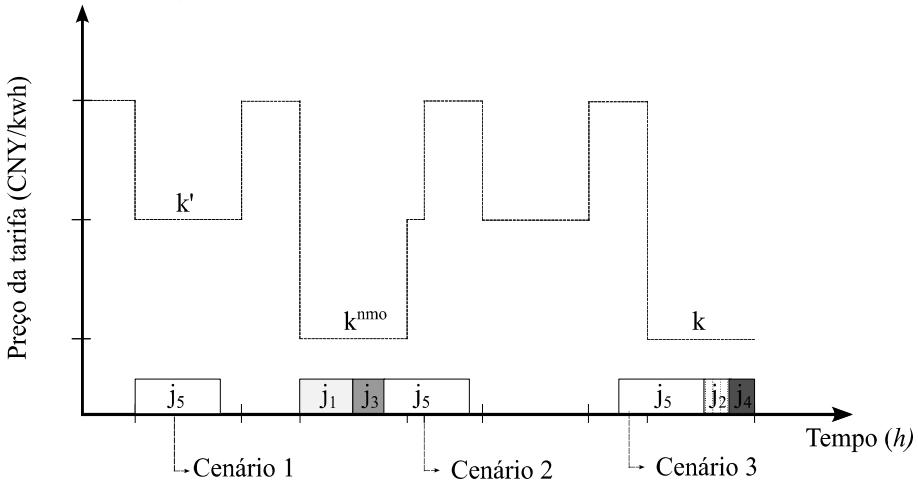


Fonte: Elaborado pelo autor (2024)

Na Condição 4, considera-se que $\max_{k \in A} \{I_k\} > 0$ e $d_{k+2} = 0$. A única diferença entre as Condições 3 e 4 é se $d_{k+2} = 0$ ou não. Isso implica que, na Condição 4, o período k é o último período de tarifa baixa e o período $k+2$ não existe. Nessa etapa, são analisadas duas versões. Na Versão 1,

nem o período $k + 1$ nem o período $k + 2$ existem, e três cenários de alocação são considerados, sendo dois idênticos aos apresentados na Condição 3. O terceiro cenário da Versão 1 é baseado em uma alteração no tempo de início de todas as tarefas que já estavam alocadas no período k . Nesse caso, todas as tarefas são deslocadas para a direita, deixando a ociosidade do período k no início, o que resulta no processamento da tarefa em dois períodos, no período $k - 1$ e no período k . Na Figura 22, é demonstrado um exemplo para ilustrar essa condição, onde k representa o período $\max_{k \in A} \{I_k\}$, k^{nmo} representa outro período de tarifa baixa que não é o de maior ociosidade, e k' representa um período de tarifa média. Assim, se o Cenário 1 for o de menor custo, o sequenciamento obtido será j_5, j_1, j_3, j_2 e j_4 . Se o Cenário 2 for a melhor alocação, o sequenciamento obtido será j_1, j_3, j_5, j_2 e j_4 . Por fim, se for o Cenário 3, o sequenciamento obtido será j_1, j_3, j_5, j_2 e j_4 , o qual é semelhante ao sequenciamento do Cenário 2, mas com j_5, j_2 e j_4 começando em momentos diferentes.

Figura 22 – Ilustração da Versão 1 da condições 4



Fonte: Elaborado pelo autor (2024)

Teorema 2. se a Condição 4 for satisfeita e $d_{k+1} = 0$, o Trabalho i é diretamente inserido seguindo o cenário 3, sem precisar movimentar nenhum trabalho já inserido no período $k - 1$.

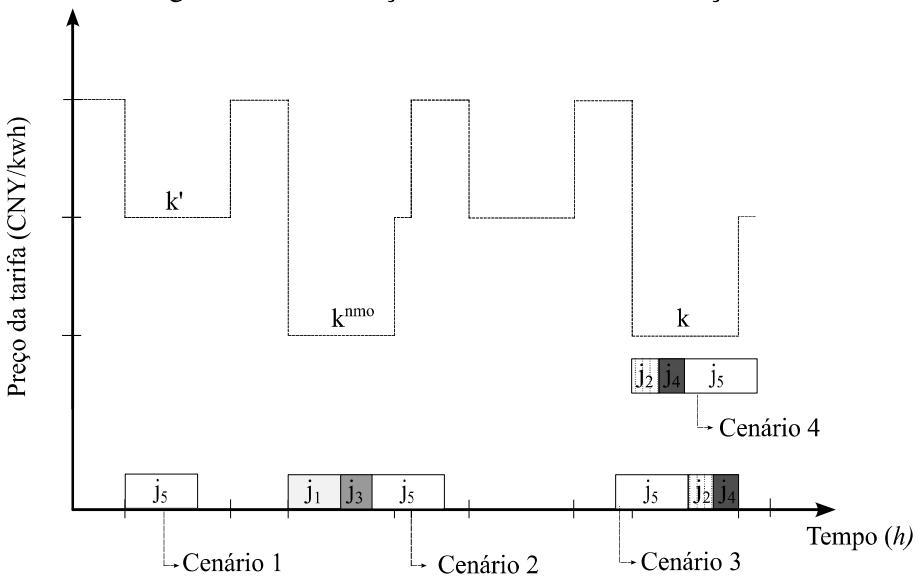
Prova 2. Desde que $\exists k \in A, I_k > 0$, não deve haver nenhum trabalho processado no período $k - 1$. Só é possível que um trabalho $j < i$, seja processado nos períodos $k - 2$ e $k - 1$. Portanto, $x_{j,k-2}$ pode ser o valor do tempo ocioso máximo restante de todos os períodos de tarifa alta antes de inserir o trabalho j . Como $\exists k' \in B, t_i \leq I_{k'} \text{ e } j < i$, isso é compreensível que $t_i \leq I_{k'} \leq x_{jk-2}$. Agora, o trabalho i deve ser inserido, seguindo que $t_i + x_{jk-1} \leq x_{jk-2} + x_{jk-1} = t_j$. Como mencionado anteriormente, os tempos de processamento de todos os trabalhos não devem exceder a duração do período de pico mais curto, ou seja, $t_j \leq d_{k-1}$. Portanto, $t_i + x_{jk-1} \leq d_{k-1}$. Se o trabalho i for processado nos períodos k e $k - 1$, então $x_{ik-1} + x_{jk-1} \leq x_{ik-1} + x_{ik} + x_{jk-1} = t_i + x_{jk-1} \leq d_{k+1}$. Ou seja, $x_{ik-1} + x_{jk-1} \leq d_{k-1}$. Assim,

$d_{k-1} - x_{jk_{-1}} - x_{ik_{-1}} = I_{k-1} \geq 0$. Isso sugere que quando o trabalho i é inserido na Posição 1, o período $k-1$ não pode estar cheio. Portanto, o trabalho i pode ser inserido diretamente na Posição 1 sem mover nenhum trabalho já inserido no período $k-1$. Essa propriedade também se aplica a Versão 2 do Condição 3 (Zhang et al., 2018a).

Dessa forma, os custos de inserção para os três cenários analisados na Versão 1 são os seguintes: custo1 = $p_i \times t_i \times c_B$, custo2 = $p_i \times (x_{ik^{nmo}} \times c_A + x_{ik_{+1}^{nmo}} \times c_B + x_{ik_{+2}^{nmo}} \times c_C)$ e custo3 = $p_i \times (x_{ik} \times c_A + x_{ik_{-1}} \times c_C)$. O cenário que apresentar o menor custo será escolhido para a alocação da tarefa.

Já a Versão 2 da Condição 4 é bastante semelhante a Versão 1, diferenciando somente pela consideração de que $d_{k+1} > 0$ (i.e., o período $k+1$ existe). Gerando mais um cenário possível para a alocação de tarefas quando comparada a Versão 1. Nesse novo cenário considera-se justamente o processamento de tarefas em dois períodos consecutivos, sendo eles o k e $k+1$. Conforme demonstrado na Figura 23, é demonstrado o Cenário 4, que caso essa alocação seja a que possuir o menor custo de eletricidade, o sequenciamento obtido seria T_1, T_3, T_2, T_4 e T_5 .

Figura 23 – Ilustração da Versão 2 da Condições 4



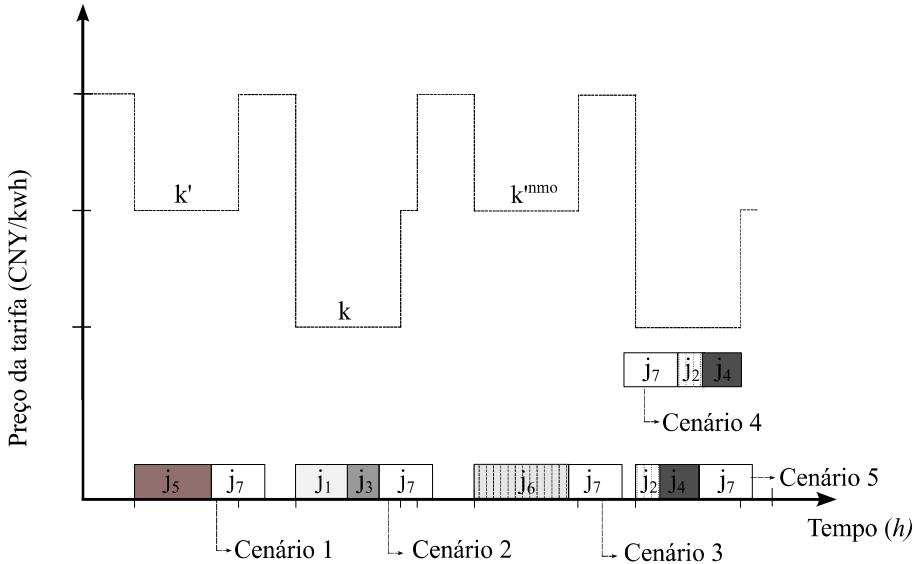
Fonte: Elaborado pelo autor (2024)

Já a Condição 5 é satisfeita quando $\forall k \in A, I_k = 0$. Essa condição representa que todos os períodos de tarifa baixa já estão completamente preenchidos e sem ociosidade. Diante disso, a Tarefa i pode ser diretamente processada em um período de tarifa média.

Por fim, a Camada 3 representa o caso contrário das Camadas 1 e 2. Nessa camada, são incluídas as Condições 6 e 7. Na Condição 6 temos que $t_i > \max_{k' \in B} \{I_{k'}\} > 0$. Se a Condição 6 for satisfeita, isso indica que a tarefa i não pode ser processada completamente em nenhum dos períodos

de tarifa média, nem nos períodos de tarifa baixa. Assim, a Tarefa i só pode ser processada em períodos consecutivos. A Figura 24 mostra todos os cinco cenários possíveis para a inserção de uma tarefa nessa condição, e aquele que apresentar o menor custo será escolhido para processar a Tarefa i .

Figura 24 – Ilustração da Condições 6



Fonte: Elaborado pelo autor (2024)

Já na Condição 7, temos que $\max_{k' \in B} \{I_{k'}\} = 0$. Se a Condição 7 for satisfeita, isso implica que todos períodos de tarifa média estão ocupados e a Tarefa i só pode ser processada nos períodos de tarifa alta.

Dante da explicação de todas as camadas e condições presentes nessa abordagem desenvolvida por Zhang *et al.* (2018a), é apresentado no Algoritmo 3 o pseudocódigo desse método. Em s , são incluídas todas as tarefas juntamente com seus respectivos tempos de início e término. No procedimento Avaliação, é calculado o TEC_{Det} , que representa o valor do TEC do sequenciamento s .

Teorema 3. *O algoritmo heurístico apresentado possui complexidade $O(n^2 m |C|)$.*

Prova 3. Na Linha 1 roda em tempo $O(n \log n)$ para ordenar n tarefas e na Linha 2 requer tempo $O(m)$. Para cada trabalho dado, a Condição 1 roda em tempo $O(|A|)$ no pior caso e a Condição 2 requer tempo $O(1)$. As Condições 3 e 5 ambos exigem $O(|B|)$ operações no pior caso. As Condições 4 e 6 demandam $O(nm)$ para calcular o custo de movimento ao calcular o custo de inserção. A Condição 7 requer $O(nm|C|)$ operações no pior caso. Para resumir, o algoritmo apresentado roda em $O(n^2 m |C|)$ no pior caso (Zhang *et al.*, 2018a).

Algoritmo 3: Greedy Insertion Heuristic (n, m, k, c_k, b_k, N, M)

```

1: Ordenar todos as tarefas em ordem não crescente de suas taxas de consumo de energia
2: Inicializar  $I_k = b_{k+1} - b_k$ , para todo  $1 \leq k \leq m$ 
3: for  $i = 1, \dots, n$  do
4:   if Camada 1 then
5:     if Condição 1 é satisfeita then
6:        $s \leftarrow$  Alocar a Tarefa  $i$  no período com  $\max_{k \in A} \{I_k\}$ .
7:     else if Condição 2 é satisfeita then
8:        $s \leftarrow$  Alocar a Tarefa  $i$  no período com  $\max_{k \in A} \{I_k\}$  e no período  $I_{k+1}$ .
9:     end if
10:    else if Camada 2 then
11:      if Condição 3 é satisfeita then
12:        if Se a inequação do Teorema 1 não for satisfeita then
13:           $s \leftarrow$  A Tarefa  $i$  é alocada nos períodos consecutivos  $k, k+1$  e  $k+2$ .
14:        else
15:           $s \leftarrow$  A Tarefa  $i$  é alocada no período de tarifa média.
16:        end if
17:      else if Condição 4 é satisfeita then
18:        if  $d_{k+1} = 0$  then
19:          Calcular o custo1, custo2 e custo3.
20:           $s \leftarrow$  Inserir a Tarefa  $i$  na posição que gera o menor custo.
21:        else if  $d_{k+2} = 0$  e  $d_{k+1} > 0$  then
22:          Calcular o custo1, custo2, custo3 e custo4.
23:           $s \leftarrow$  Inserir a Tarefa  $i$  na posição que gera o menor custo.
24:        end if
25:      else if Condição 5 é satisfeita then
26:         $s \leftarrow$  Alocar a Tarefa  $i$  no período com  $\max_{k' \in B} \{I'_k\}$ .
27:      end if
28:    else if Camada 3 then
29:      if Condição 6 é satisfeita then
30:        Calcular o custo1, custo2, custo3, custo4 e custo5.
31:         $s \leftarrow$  Inserir a Tarefa  $i$  na posição que gera o menor custo.
32:      else if Condição 7 é satisfeita then
33:         $s \leftarrow$  Alocar a Tarefa  $i$  no período com  $\max_{k'' \in C} \{I''_k\}$ .
34:      end if
35:    end if
36:  end for
37:   $TEC_{Det} \leftarrow$  Avaliação( $s$ )
38:  return  $s, TEC_{Det}$ 
  
```

4.2.2 Etapa da Simulação

A simulação nesse trabalho considerou que a instância determinística é estocasticamente modelada pela substituição do parâmetro t_i (tempos de processamento). Portanto, ao invés de considerar tempos de processamento determinísticos t_i , utilizamos uma variável aleatória \hat{t}_i com $E[\hat{t}_i] = t_i$ e $Var[\hat{t}_i] = \delta \times E[\hat{t}_i]$, onde δ é o parâmetro de variância, utilizado para criar diferentes níveis de incerteza nos

tempos de processamento.

Além disso, foi adotado que os parâmetros estocásticos seguem uma distribuição de probabilidade Lognormal, que de acordo com Juan *et al.* (2011), é mais adequada do que a Normal para modelar tempos não negativos. Os parâmetros dessa distribuição são definidos como μ_d e σ_d , conforme demonstrado em (4.1) e (4.2), respectivamente:

$$\mu_d = \ln(E[\hat{t}_i]) - \frac{1}{2} \ln\left(1 + \frac{\text{Var}[\hat{t}_i]}{E[\hat{t}_i]^2}\right) \quad (4.1)$$

$$\sigma_d = \sqrt{\ln\left(1 + \frac{\text{Var}[\hat{t}_i]}{E[\hat{t}_i]^2}\right)} \quad (4.2)$$

Dante disso, o procedimento de simulação inicia recebendo uma solução s para variar cada tempo de processamento por meio da Simulação Monte Carlo. A abordagem empregada na simulação ajusta dinamicamente o número de replicações necessárias com base no erro do intervalo de confiança. Inicialmente, o número de replicações não é conhecido, porém, assim que o erro calculado (Erro) se torna menor que um determinado limite predefinido (Erro_{limite}), o processo de iteração é finalizado. Além disso, para evitar uma convergência prematura do erro calculado, estabelece-se um número mínimo de replicações (ρ_{min}) que devem ser realizadas pelo algoritmo.

O pseudocódigo do procedimento de simulação é mostrado no Algoritmo 4.

Algoritmo 4: Simulação ($s, \delta, \rho_{min}, \text{Erro}_{limite}, NC$)

```

1:  $A_s \leftarrow \emptyset$ 
2:  $\text{Erro} \leftarrow \infty$ 
3:  $iter = 1$ 
4: while  $Stop = false$  do
5:    $seq' \leftarrow \text{MonteCarlo}(s, \delta)$ 
6:    $TEC* \leftarrow \text{Avaliação}(seq')$ 
7:    $A_s \leftarrow TEC*$ 
8:    $(\mu, \sigma) \leftarrow \text{Estatística}(A_s)$ 
9:    $\text{Erro} \leftarrow \text{IntervaloDeConfiança}(\mu, \sigma, NC, iter)$ 
10:   $\rho \leftarrow \max(\rho_{min}, \lfloor iter \times \frac{\rho_{min}}{100} \rfloor)$ 
11:  if  $\rho \leq iter$  e  $\text{Erro} \leq \text{Erro}_{limite}$  then
12:     $Stop = true$ 
13:  else
14:     $iter \leftarrow iter + 1$ 
15:  end if
16: end while
17:  $TEC_{esperado} \leftarrow A_s$ 
18: return  $TEC_{esperado}$ 
```

O conjunto de TEC observados (na simulação), representado por A_s , é inicializado como vazio, enquanto o erro do conjunto de amostras é definido como infinito, e o número de iteração, $iter$, é

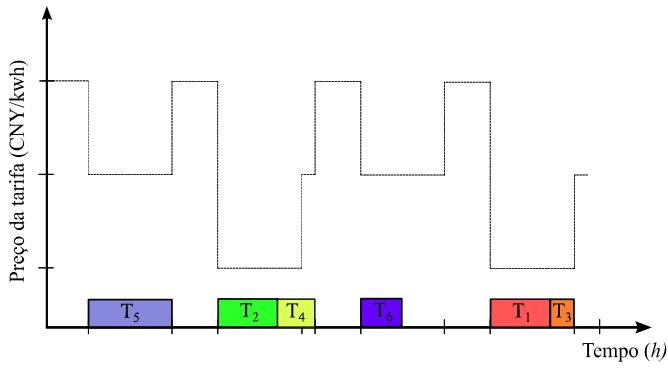
inicializado como 1 (Linhas 1–3). Durante cada replicação, o procedimento MonteCarlo gera valores aleatórios para o parâmetro estocástico (Linha 5), resultando em novos tempos de processamento (\hat{t}_i). Isso resulta em uma nova solução seq' , que mantém a mesma ordem de tarefas do sequenciamento s obtido anteriormente pelo procedimento construtivo, mas com os tempos de processamento atualizados.

De acordo com o novo cronograma definido (seq'), o procedimento Avaliação calcula o novo TEC (TEC^*) da replicação atual (Linha 6). O conjunto A_S é atualizado incluindo o novo valor de observação TEC^* , e a média e o desvio padrão da amostra são calculados pelo procedimento Estatística (Linha 7-8). Em seguida, o procedimento IntervaloDeConfiança calcula o erro do intervalo de confiança, levando em conta o número total de replicação ($iter$), média (μ), desvio (σ) e o nível de confiança desejado (NC) (Linha 9). O processo de simulação é encerrado quando o *Erro* (calculado na Linha 9) é menor que um limite de erro desejado ($Erro_{limite}$), respeitando um número mínimo de replicações ($\rho \leq iter$), conforme explicado na Seção 2.2. Caso contrário, o algoritmo realiza mais uma replicação (Linha 14). Por fim, a partir do conjunto A_s , a métrica estocástica é calculada e salva em $TEC_{Esperado}$ (Linha 17).

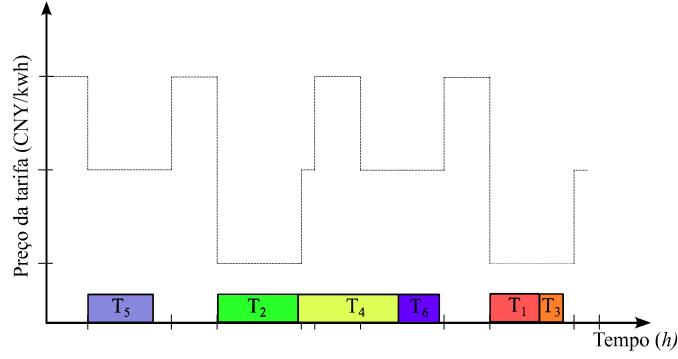
A Figura 25 apresenta um exemplo de uma replicação de simulação com valores estocásticos para os tempos de processamento. O sequenciamento original (s), obtido considerando-se parâmetros determinísticos, é apresentado no cenário a), enquanto a simulação do sequenciamento s é mostrada no cenário b).

Na abordagem utilizada nesta pesquisa, durante a simulação, o tempo de início de cada tarefa é mantido apenas quando há ociosidade entre duas tarefas consecutivas, como no caso de T_5 e T_2 na Figura 25. Mesmo com a geração de um novo tempo de processamento para T_5 durante a simulação, o tempo de término de T_5 ainda é menor que o tempo de início de T_2 , portanto, nenhuma alteração nos tempos de início é realizada. Já nos casos em que a variação dos tempos de processamento acarretam em interseção entre o término de uma tarefa e o início de outra, como T_4 e T_6 , que possuíam ociosidade entre elas, realiza-se um ajuste no início de T_6 para ocorrer logo após o término de T_4 . Por fim, quando as tarefas são processadas de maneira consecutiva, sem ociosidade entre elas no cenário original, como T_1 e T_3 , mas o tempo de término de T_1 na simulação é menor que o tempo de término no cenário original, então o tempo de início de T_3 é antecipado para o novo tempo de conclusão de T_1 . Essa abordagem visa manter a solução da simulação o mais próxima possível da solução obtida na fase construtiva.

Figura 25 – Exemplo da Simulação
a) Sequenciamento original (s)



b) Simulação do sequenciamento s (seq')



Fonte: Elaborado pelo autor (2024)

4.2.3 Meta-heurística

A meta-heurística utilizada foi a SA, a qual é inspirada no processo de resfriamento controlado de materiais, conhecido como recozimento simulado, onde o algoritmo busca por soluções implementando aleatoriedade na busca e evitando ótimos locais ao permitir a aceitação de soluções de desempenho pior, com nível de probabilidade variável ao longo da sua execução. Isso é determinado por uma probabilidade definida por $e^{\frac{-\Delta}{T_i}}$, onde Δ representa a diferença entre o TEC_{Det} da solução candidata e o da melhor solução, e T_i é um parâmetro associado à temperatura. Ao final de cada iteração, a temperatura T_i é reduzida com base em um determinado parâmetro R , onde $T_i = T_i \times R$, e quando a condição $T_i \leq T_f$ é satisfeita, o procedimento é encerrado (Kirkpatrick *et al.*, 1983). Portanto, no início do algoritmo com temperaturas elevadas, há uma maior probabilidade de aceitar soluções piores do que a melhor, permitindo uma diversificação na busca no espaço de soluções.

Foi adotada a metodologia utilizada em Mecler *et al.* (2022) para a definição da temperatura inicial T_i , temperatura final T_f e da constante de resfriamento R , as quais são definidas respectivamente como:

$$T_i = -\frac{0.6 \times TEC_{Det}}{\ln(0.5)} \quad (4.3)$$

$$T_f = -\frac{1 \times 10^{-5} \times TEC_{Det}}{\ln(0.5)} \quad (4.4)$$

$$R = \left(\frac{T_f}{T_i}\right)^{\frac{1}{\eta}} \quad (4.5)$$

Onde, TEC_{Det} representa o valor da função objetivo analisada e η representa o número de iterações do algoritmo. Além do SA, utiliza-se a ideia do parâmetro aleatório-guloso (α) da meta-heurística GRASP, desenvolvido por Feo e Resende (1995). O parâmetro α é empregado dentro da heurística construtiva (apresentada na Seção 4.2.1) para diversificar as soluções geradas e auxiliar na exploração do espaço de soluções. Essa estratégia visa aumentar a variedade de soluções consideradas durante o processo de busca, o que pode ser crucial para encontrar soluções de alta qualidade em problemas complexos.

4.2.4 Simheurística Proposta

A simheurística proposta, denominada SimSA, é apresentada no Algoritmo 5. Esta simheurística baseia-se na heurística construtiva GIH, definida por Zhang *et al.* (2018a) e detalhada na Seção 4.2.1, combinada com estratégias das meta-heurísticas SA e GRASP, conforme apresentada na Seção 4.2.3, desenvolvidas por Kirkpatrick *et al.* (1983) e Feo e Resende (1995), respectivamente. Além disso, inclui etapas de simulação, descrita na Seção 4.2.2. Nove parâmetros devem ser definidos para executar o algoritmo: o número de iterações (η), o indicador aleatório-guloso (α), o nível de variância (δ), o número mínimo de iterações da simulação curta (ρ_C), o número mínimo de iterações da simulação longa (ρ_L), o erro limite para as simulações curtas ($Erro_{LimiteC}$), o erro limite para as simulações longas ($Erro_{LimiteL}$), o nível de confiança para o intervalo (NC) e o comprimento do pool de soluções ($size$). O SimSA pode ser observado no Algoritmo 5.

O método combina a Simulação de Monte Carlo com as meta-heurísticas citadas para identificar boas soluções estocásticas. No algoritmo, são realizadas simulações curtas com um limite de erro ($Erro_{LimiteC}$) mais expressivo, visando gerar apenas um número pequeno de replicações para a simulação, respeitando um número mínimo de iterações (ρ_C) e deixando a parte mais custosa computacionalmente para a busca por soluções da meta-heurística. Assim, sempre que uma solução for melhor tanto no ambiente determinístico quanto no ambiente estocástico do que a melhor solução encontrada até o momento, ela é adicionada ao pool de soluções P . Por fim, após o critério de parada da meta-heurística ser satisfeito, é conduzida uma simulação longa, com um limite de erro menor do que nas simulações curtas ($Erro_{LimiteL} < Erro_{LimiteC}$), mas também considera-se um número mínimo de replicações (ρ_L), onde ρ_L é maior que ρ_C , para permitir um maior número de replicações e obter informações estatísticas mais precisas para todas as soluções do pool P .

Algoritmo 5: SimSA ($\eta, \alpha, \delta, \rho_C, \rho_L, Erro_{LimiteC}, Erro_{LimiteL}, NC, size$)

```

1:  $P \leftarrow \emptyset$ 
2:  $P_{Final} \leftarrow \emptyset$ 
3:  $s, TEC_{Det} \leftarrow \text{Construtiva}(n, m, k, c_k, b_k, N, M)$ 
4:  $TEC_{Esperado} \leftarrow \text{Simulação}(s, \delta, Erro_{LimiteC}, \rho_C, NC)$ 
5:  $P \leftarrow \text{AtualizaçãoPool}(s, TEC_{Det}, TEC_{Esperado})$ 
6: while  $T_i > T_f$  do
7:    $s', TEC'_{Det} \leftarrow \text{Construtiva}(\alpha, n, m, k, c_k, b_k, N, M)$ 
8:   if  $TEC'_{Det} < TEC_{Det}$  then
9:      $TEC'_{Esperado} \leftarrow \text{Simulação}(s', \delta, Erro_{LimiteC}, \rho_C, NC)$ 
10:  else
11:    if Critério do SA é válido then
12:       $TEC'_{Esperado} \leftarrow \text{Simulação}(s', \delta, Erro_{LimiteC}, \rho_C, NC)$ 
13:    end if
14:  end if
15:  if  $TEC'_{Esperado} < TEC_{Esperado}$  then
16:     $s \leftarrow s'$ 
17:     $TEC_{Det} \leftarrow TEC'_{Det}$ 
18:     $TEC_{Esperado} \leftarrow TEC'_{Esperado}$ 
19:     $P \leftarrow \text{AtualizaçãoPool}(s, TEC_{Det}, TEC_{Esperado})$ 
20:    if  $|P| > size$  then
21:       $P \leftarrow \text{RemoverPool}(P)$ 
22:    end if
23:  end if
24:   $T_i \leftarrow T_i \times R$ 
25: end while
26: for  $s$  in  $P$  do
27:    $TEC_{Esperado}^{**} \leftarrow \text{Simulação}(s, Erro_{LimiteL}, \rho_L, NC)$ 
28:    $P_{Final} \leftarrow \text{AtualizaçãoPool}(TEC_{Esperado}^{**})$ 
29: end for
30:  $BestSolution \leftarrow \text{Análise}(P_{Final})$ 
31: return  $BestSolution$ 
  
```

Nessa abordagem simheurística, parte-se do pressuposto de que, em cenários com incerteza baixa e moderada (variância), soluções de alta qualidade para a versão determinista de um problema OC provavelmente também serão soluções de boa qualidade para sua versão estocástica correspondente. Assim, a busca é feita por soluções que sejam boas no ambiente determinístico, e com essas são realizadas as simulações. No entanto, isso não implica que a melhor solução para a versão determinística necessariamente será a melhor solução para a versão estocástica. Para isso, utilizamos a estratégia do SA de aceitar soluções piores no ambiente determinístico para realizar as simulações e testar sua qualidade no ambiente estocástico.

Conforme mencionado na Seção 4.2.2, o parâmetro de variância (δ) pode assumir diferentes níveis de incerteza. Portanto, para cada instância, o problema será resolvido o número de

cenários disponíveis em δ . Os conjuntos P e P_{Final} são inicializados como vazios (Linhas 1-2). No procedimento **Construtiva**, é aplicado o GIH de maneira tradicional, resultando na solução s e em seu respectivo valor no ambiente determinístico TEC_{Det} (Linha 3). Em seguida, essa solução s é submetida ao procedimento de **Simulação** para obter a respectiva métrica estocástica $TEC_{Esperado}$ (Linha 4). Após isso, no procedimento **AtualizaçãoPool**, a solução s e seus respectivos valores no ambiente determinístico e estocástico são adicionados a P (Linha 5).

Na Linha 6, é apresentado o critério de parada do algoritmo, baseado no resfriamento do SA, onde o algoritmo busca por novas soluções enquanto a temperatura T_i não alcançar a temperatura final T_f , ou seja, enquanto $T_i > T_f$. Assim, a cada nova iteração do *loop while* (Linha 6 - 25), uma nova solução candidata s' é criada (Linha 7), onde a alocação de tarefas não vai ser totalmente gulosa igual ao método de Zhang *et al.* (2018a), pois o elemento a ser adicionado a cada iteração é oriundo de uma LCR. Este elemento é escolhido a partir dessa lista, que contém as tarefas com os maiores consumos energéticos. A seleção do elemento é feita de forma aleatória entre as opções disponíveis na LCR. Esse procedimento visa evitar que o algoritmo fique estagnado em ótimos locais, permitindo uma exploração mais ampla do espaço de soluções.

O valor da solução s' (TEC'_{Det}) no ambiente determinístico é então comparado para determinar se é melhor (ou seja, menor) do que o valor da melhor solução encontrada até o momento (TEC_{Det}) (Linha 8). Se a condição for satisfeita, uma simulação curta da solução candidata é realizada para obter inicialmente uma estimativa do seu valor na métrica estocástica (Linha 9). Caso contrário, a solução passa pelo critério de aceitação do SA (Linha 11). Se aceita nesse critério, é realizada uma simulação curta da solução candidata para também obter uma estimativa do seu desempenho no ambiente estocástico (Linha 12). Caso contrário, a solução candidata é descartada. Essa estratégia permite aceitar soluções que são piores que a melhor solução no ambiente determinístico, a fim de testar o desempenho dessas soluções no ambiente estocástico.

Na linha 15, verifica-se o $TEC'_{Esperado}$ da solução candidata é melhor que o melhor valor encontrado até o momento para o ambiente estocástico ($TEC_{Esperado}$). Se a condição for satisfeita, a solução s' e seus valores são atualizados como os melhores (Linhas 16-18), e então são adicionados em P através do procedimento **AtualizaçãoPool** (Linha 19). Caso o tamanho do *Pool* já tenha atingido o seu limite (Linha 20), o procedimento **RemoverPool** remove a solução (s) com a pior métrica estocástica (Linha 21). Após isso, é realizado a atualização (resfriamento) de T_i (Linha 25). Após o procedimento de busca por soluções no *loop while* (Linhas 6-25) parar, o algoritmo realiza uma simulação mais extensa (Linha 27), para cada solução presente em P , com o objetivo de obter uma compreensão mais detalhada do comportamento estocástico de cada sequenciamento. Isso resulta

em um novo conjunto de soluções, o P_{Final} , que contém o novo desempenho estocástico de todas as soluções (Linha 29). Assim, o algoritmo conclui sua execução selecionando, por meio do procedimento **Análise**, a solução com a menor média para a métrica estocástica analisada ou conforme a opção de um decisor (Linha 30). Nesta pesquisa, foi escolhida a solução com a menor média para a métrica estocástica analisada *BestSolution*.

4.2.5 Meta-heurística utilizada

Além do Algoritmo SimSA, foi implementado também um algoritmo denominado GIH-GRASP. Ele incorpora os princípios da meta-heurística GRASP para explorar o espaço de soluções em busca das melhores soluções, empregando a heurística construtiva GIH com o parâmetro α ao longo de múltiplas iterações de η . Esse método busca encontrar a melhor solução determinística para cada instância, com a finalidade de comparar a simulação da melhor solução determinística com a abordagem do SimSA.

Algoritmo 6: GIH-GRASP (α, η)

```

1:  $TEC_{Det} = \infty$ 
2: for  $b = 1, \dots, \eta$  do
3:    $s', TEC'_{Det} \leftarrow \text{Construtiva}(\alpha)$ 
4:   if  $TEC'_{Det} < TEC_{Det}$  then
5:      $s \leftarrow s'$ 
6:      $TEC_{Det} \leftarrow TEC'_{Det}$ 
7:   end if
8: end for
9: return  $s, TEC_{Det}$ 

```

O algoritmo inicia com a declaração de TEC_{Det} como um valor alto (Linha 1). Em seguida, entra em um *loop* de iterações (Linha 2-8), onde a cada nova iteração, o procedimento **Construtiva** utiliza a heurística GIH com o parâmetro α para criar uma nova solução e compara (Linha 4) se o sequenciamento obtido possui um valor melhor na função objetivo analisada (TEC'_{Det}) do que o melhor valor encontrado até então (TEC_{Det}). Se o valor deste novo sequenciamento for melhor, atualiza-se o melhor sequenciamento (Linha 5) e a melhor função objetivo (Linha 6). O algoritmo encerra quando atinge o número de iterações η , retornando assim o melhor sequenciamento encontrado, juntamente com a melhor função objetivo encontrada (Linha 9).

5 RESULTADOS

O algoritmo proposto SimSA foi aplicado com três métricas estocásticas distintas, resultando em três abordagens: o SimSA-Esperado, SimSA-VaR e o SimSA-CVaR, onde as medidas de desempenho estocástica são a média, o VaR e o CVaR dos valores simulados, respectivamente. Além disso, foi implementado o algoritmo GIH-GRASP para resolver o mesmo problema abordado pelo algoritmo SimSA. No entanto, o foco principal desse novo algoritmo é encontrar soluções determinísticas de alta qualidade. A ideia por trás dessa abordagem é utilizar a melhor solução determinística encontrada pelo método e, em seguida, realizar uma simulação longa com essa solução. Isso permite calcular a média, o VaR e o CVaR das simulações, possibilitando assim a comparação de desempenho entre a solução obtida pelo método e as abordagens SimSA-Esperado, SimSA-VaR e SimSA-CVaR.

A principal comparação foi realizada utilizando o GAP entre os valores obtidos pelo GIH-GRASP e as abordagens do SimSA. O GAP, apresentado em 5.1, é calculado individualmente para cada métrica, sendo definido como a diferença entre o valor obtido pelo GIH-GRASP e o valor da abordagem do SimSA, dividida pelo valor do GIH-GRASP.

$$GAP_l = \frac{\text{GIH-GRASP}_l - \text{SimSA}_l}{\text{GIH-GRASP}_l}; \quad (5.1)$$

onde l é a métrica analisada.

Essa métrica percentual indica o desempenho relativo das abordagens do SimSA em comparação ao GIH-GRASP. Um valor positivo do GAP indica que o SimSA teve um desempenho superior, enquanto um valor negativo indica que o GIH-GRASP foi superior.

Para todas as abordagens que utilizam simulação, foi adotado um nível de confiança (NC) de 90%. Além disso, para todas as abordagens do SimSA, foi utilizado um erro ($Erro_{LimiteC}$) de 60% em simulações curtas e um erro ($Erro_{LimiteL}$) de 20% em simulações longas. Para o GIH-GRASP, também foi adotado um erro ($Erro_{LimiteL}$) de 20% em simulações longas.

Estes valores para $Erro_{LimiteC}$ e $Erro_{LimiteL}$ foram escolhidos para permitir um pequeno número de replicações nas simulações curtas, proporcionando uma visão inicial do comportamento da solução no ambiente estocástico. Para as simulações longas, foi selecionado um erro menor para garantir um maior número de replicações e, consequentemente, obter informações mais precisas sobre o desempenho estocástico da solução. Para as abordagens que visam minimizar os valores das métricas VaR e CVaR, adotou-se a minimização do $VaR_{95\%}$ e do $CVaR_{95\%}$. Para todas as abordagens implementadas que incluem a etapa de simulação, foram utilizados cenários δ de 0.1, 0.5 e 2.0. Esses cenários representam ambientes de baixa, média e alta variação, respectivamente. Por fim, o parâmetro

size foi adotado como 3 para todas as abordagens do SimSA. Todos os demais parâmetros utilizados foram calibrados utilizando o pacote IRace, conforme detalhado na Seção 5.2.

Todas os algoritmos foram implementados em linguagem de programação Julia, realizando os experimentos em um computador com processador Intel(R) Core (TM) i5-7200U, equipado com CPU de @ 2.50GHz e 8 GB de memória RAM e sistema operacional Windows.

Na Seção 5.1, são apresentados os conjuntos de instâncias considerados na resolução do problema. Em seguida, na Seção 5.2, são detalhados os procedimentos de calibração adotados para cada uma das abordagens propostas, destacando as características das instâncias de teste, os valores testados pelo pacote e as melhores configurações identificadas durante o processo de calibração. Por fim, na Seção 5.3, são analisados e discutidos os resultados obtidos a partir da comparação entre as abordagens do SimSA e do GIH-GRASP.

5.1 INSTÂNCIAS UTILIZADAS

As instâncias utilizadas na resolução desse problema foram inspiradas no modelo de instância utilizadas em Zhang *et al.* (2018a). No qual, os custos de eletricidade (c_k), início de cada período (b_k) e número de períodos (k) são inspiradas na política TOU aplicada a cidades da China. Foram criados quatro grupos de instâncias, onde cada grupo possui diferentes números de tarefas. O horizonte de tempo considerado para a alocação de tarefas em todas as instâncias é de 48 horas. Os tempos de processamento das tarefas foram definidos de modo que a soma desses tempos corresponda a 75% desse horizonte de tempo disponível. Isso garante que seja sempre possível alocar todas as tarefas dentro do horizonte de tempo. A Tabela 12 demonstra a classificação das instâncias e organização destas quanto ao número de tarefas.

Tabela 12 – Instâncias utilizadas	
Instâncias	Número de tarefas (n)
1 - 25	25
26 - 50	50
51 - 75	75
76 - 100	100

Fonte: Elaborado pelo autor (2024)

Todas as instâncias utilizadas nessa pesquisa estão disponíveis em [https://github.com/ MatheusLB05/psvmuelib](https://github.com/MatheusLB05/psvmuelib).

5.2 CALIBRAÇÃO DOS PARÂMETROS

Com o intuito de otimizar o desempenho dos algoritmos, empregou-se o pacote IRace de López-Ibáñez *et al.* (2016) para calibrar os parâmetros de cada uma das abordagens do SimSA e do GIH-GRASP. A escolha do pacote IRace se baseia em sua capacidade de selecionar as configurações mais promissoras e combiná-las de maneira inteligente, empregando operadores de mutação e *crossover* (baseado na meta-heurística AG), repetindo esse processo iterativamente até atingir um critério de parada predefinido. Ao concluir o processo, o IRace oferece a melhor configuração de parâmetros encontrada para o algoritmo testado, considerando as instâncias de treinamento utilizadas e todas as possibilidades de parâmetros disponibilizadas como entrada (López-Ibáñez *et al.*, 2016). Essa abordagem proporciona uma maneira eficiente e automatizada de aprimorar o desempenho dos algoritmos.

Foram empregadas seis instâncias de teste, distribuídas da seguinte forma: duas com um número reduzido de tarefas, duas com um número médio e duas com um número considerável de tarefas. Essa seleção foi orientada pela intenção de abordar instâncias com características distintas, permitindo uma análise mais abrangente do comportamento dos parâmetros em diversos cenários.

Os parâmetros calibrados foram o número de iterações (η), o indicador aleatório-guloso (α), o número mínimo de iterações para simulações curtas (ρ_C) e o número mínimo de iterações para simulações longas (ρ_L). Essa calibração foi realizada com base em um conjunto de valores categóricos, conforme detalhado na Tabela 13. Além disso, a tabela exibe a classificação dos parâmetros em grupos, as opções de valores testados pela abordagem e os valores obtidos para cada parâmetro em relação às métricas avaliadas.

Tabela 13 – Parâmetros calibrados

Grupo	Parâmetros	Variação	SimSA			GIH-GRASP
			CVaR	VaR	Média	
SA	η	(500:50:1500)	600	800	600	-
GRASP	α	(0.00:0.05:1.00)	0.10	0.10	0.20	0.50
	η	(500:50:1500)	-	-	-	600
Simheurística	ρ_C	(10:5:50)	25	50	50	-
	ρ_L	(500:100:1500)	500	1000	1000	1000

Fonte: Elaborado pelo autor (2024)

5.3 AVALIAÇÃO DOS RESULTADOS

Nesta seção, apresentam-se os resultados da comparação entre os métodos GIH-GRASP e as abordagens do SimSA. Estas comparações estão resumidas na Tabela 14 e serão discutidas ao longo desta seção. Para uma visualização mais detalhada, os resultados específicos de cada instância podem ser encontrados nos Apêndices. No Apêndice A, são apresentados os valores obtidos para o SimSA-Esperado; no Apêndice B, os valores para o SimSA-VaR; e no Apêndice C, os resultados para o SimSA-CVaR.

Para simplificar a organização e a visualização dos resultados sumarizados, foram criadas as seguintes abreviações, que serão utilizadas ao longo da discussão dos resultados.

- TME: TEC Médio Esperado em CNY (Unidade monetária chinesa);
- VaRM_{95%}: VaR Médio em CNY;
- CVaRM_{95%}: CVaR Médio em CNY;
- TCM: Tempo Computacional Médio em segundos (s);
- DPM: Desvio Padrão Médio em CNY;
- MME: Makespan Médio Esperado em horas (h);
- NSCM: Número médio de replicações nas Simulações Curtas Médio (unidade);
- NSLM: Número médio de replicações nas Simulações Longas Médio (unidade);
- GAP: GAP Médio.

Tabela 14 – Resumo dos GIH-GRASP x SimSA

δ	(1) GIH-GRASP		(2) SimSa-Esperado						(1) x (2)
	TME	TCM	TME	TCM	DPM	MME	NSCM	NSLM	GAP
0.1	79188.91	1.99	76264.63	33.90	6328.54	49.60	298	2831	3.70%
0.5	82395.52	38.62	79393.44	292.54	14900.66	52.21	1573	14515	3.66%
2.0	86503.29	515.36	84022.66	2585.25	29217.38	59.32	5441	49931	2.89%
δ	(1) GIH-GRASP		(3) SimSa-VaR						(1) x (3)
	VaRM _{95%}	TCM	VaRM _{95%}	TCM	DPM	MME	NSCM	NSLM	GAP
0.1	91069.16	1.99	87352.26	45.28	6284.85	49.60	269	2783	4.10%
0.5	110948.25	38.62	106802.48	451.58	14861.45	52.21	1502	14402	3.77%
2.0	142459.93	515.36	140507.22	4388.33	29205.66	59.32	5324	49687	1.39%
δ	(1) GIH-GRASP		(4) SimSa-CVaR						(1) x (4)
	CVaRM _{95%}	TCM	CVaRM _{95%}	TCM	DPM	MME	NSCM	NSLM	GAP
0.1	94615.74	1.99	90749.71	40.85	6289.59	49.61	266	2788	4.12%
0.5	121012.14	38.62	117034.45	378.28	14861.52	52.22	1480	14381	3.32%
2.0	164904.24	515.36	162983.30	3062.99	29188.68	59.33	5223	49592	1.18%

Fonte: Elaborado pelo autor (2024)

Nas colunas TME e GAP, é possível observar uma melhora no valor médio encontrado

pelo SimSA-Esperado em comparação ao GIH-GRASP, apresentando ganhos médios de 3.70%, 3.66% e 2.89% para os cenários de 0.1, 0.5 e 2.0, respectivamente. Considerando que a unidade de medida do TME é uma unidade monetária (CNY) e que os valores apresentados correspondem ao sequenciamento com horizonte de tempo de 48 horas (dois dias), esses ganhos tornam-se mais significativos quando escalados para períodos semanais (168 horas), mensais (720 horas) e anuais (8760 horas).

Essa escalabilidade demonstra que mesmo pequenas melhorias percentuais no curto prazo podem resultar em economias significativas a longo prazo. Esses resultados demonstram ainda mais a aplicabilidade do estudo, evidenciando os benefícios tanto para o ambiente organizacional quanto para o meio ambiente. Os ganhos apresentados indicam uma diminuição no consumo de energia (TEC), o que resulta em uma redução do impacto ambiental. Pois, a metodologia emprega a política TOU, onde o sequenciamento é ajustado para aproveitar ao máximo os períodos de tarifa mais baixa para a execução das tarefas, evitando períodos de tarifas mais altas. Esses períodos de tarifa elevada geralmente correspondem a momentos em que as empresas fornecedoras de energia recorrem a fontes secundárias de energia para atender à demanda. Essas fontes secundárias, muitas vezes, são mais poluentes, resultando em maiores emissões de poluentes na atmosfera.

Ao reduzir a demanda nos períodos de tarifas mais altas, o impacto ambiental é diminuído, uma vez que se reduz a necessidade de recorrer a essas fontes secundárias de energia. Assim, a abordagem proposta não apenas otimiza o consumo de energia e reduz os custos operacionais para as organizações, mas também contribui para a sustentabilidade ambiental, promovendo uma menor emissão de poluentes.

Nas colunas VaRM95% e CVaRM95%, os ganhos das abordagens do SimSA foram de 4.10%, 3.77% e 1.39% para o VaRM95%, e 4.12%, 3.32% e 1.18% para o CVaRM95%. A principal vantagem de utilizar essas abordagens é a capacidade de identificar e mitigar riscos extremos que podem ter impactos significativos no sequenciamento.

Além disso, ao incorporar o VaR e o CVaR na análise de desempenho, as organizações podem tomar decisões mais informadas e alinhadas com sua tolerância ao risco. Essas métricas proporcionam uma compreensão dos piores cenários possíveis, ajudando a equilibrar o potencial de ganho com a exposição ao risco. Com uma avaliação clara dos riscos, as organizações podem otimizar a alocação de recursos, priorizando investimentos e estratégias que oferecem o melhor equilíbrio entre retorno e risco.

Uma diferença significativa observada na comparação entre o GIH-GRASP e as abordagens do SimSA está relacionada ao tempo computacional, conforme pode ser visto nas colunas TCM. O tempo computacional apresentado em segundos pelas abordagens SimSA é consideravelmente maior

do que o da abordagem GIH-GRASP. Isso pode ser explicado pelo número de replicações realizadas nas simulações curtas, que não estão presentes na abordagem GIH-GRASP. Com o aumento da variação (δ), o tempo computacional tende a aumentar também, pois o número de simulações curtas necessárias para serem consideradas suficientes pelo método do intervalo de confiança cresce. Isso torna o algoritmo SimSA progressivamente mais lento, uma vez que, para cada solução considerada promissora ou aceita pelo critério do SA, é realizado um número significativo de simulações para testar seu desempenho no ambiente estocástico.

Na coluna DPM, é possível observar que os desvios padrão de todas as abordagens para todos os níveis de variância são expressivos, demonstrando que qualquer variação existente nos processos pode causar um impacto significativo nos valores da função objetivo. Esses valores podem ser explicados pela natureza da heurística construtiva GIH, que busca preencher o máximo possível dos períodos com as tarifas mais baixas, evitando assim deixar esses períodos ociosos. Portanto, quando qualquer variação nos tempos de processamento é aplicada durante a simulação, ocorre um extrapolamento ou uma subutilização desses períodos, resultando em um efeito crítico no valor do TEC.

Pelo fato das abordagens do SimSA não incorporarem nenhuma estratégia que considere as possíveis variações no processo durante a construção da solução, o método acaba se tornando muito sensível às incertezas.

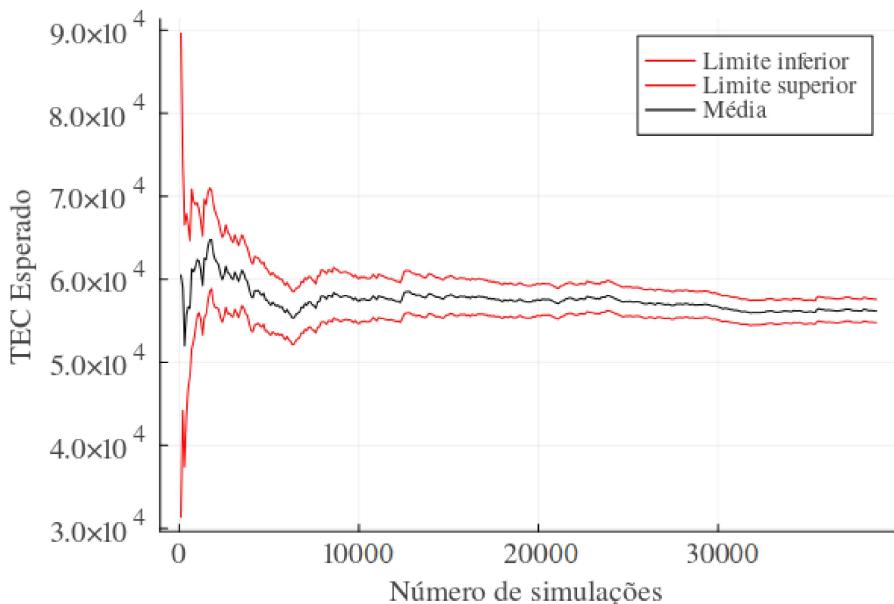
A análise do MMS revela que há uma probabilidade de 95% para que a solução selecionada em cada cenário apresente, em média, valores de tempo de conclusão (*makespan*) de até 49.60, 52.21 e 59.32 para o SimSa-esperado, 49.63, 52.23, 59.19 para o SimSA-VaR, e 49.61, 52.22 e 59.33 para o SimSA-CVaR, nos cenários de variabilidade de 0.1, 0.5 e 2, respectivamente. Isso representa um aumento médio de cerca de 3%, 8% e 22%, respectivamente, em relação ao horizonte de tempo definido para o problema (48 horas). Mesmo em cenários de baixa variabilidade ($\delta = 0.1$), o MMS ultrapassou o horizonte de tempo definido nas instâncias, ressaltando que, em situações reais, a alocação de tarefas visando minimizar o *TEC* por meio da política TOU, pode gerar soluções inviáveis por não respeitarem o limite de horizonte de tempo definidos para o sequenciamento.

Em todas as abordagens, é evidente a diferença na quantidade de simulações consideradas suficientes pelo método do erro do intervalo de confiança para cada nível de variação, tanto para as simulações curtas (NSCM) quanto para as simulações longas (NSLM). Essa observação é importante para promover o uso dessa abordagem, pois, de acordo com o nível de variação, o método consegue determinar com maior precisão o número necessário de simulações, evitando a imposição do mesmo número de simulações para todos os níveis de variação. Quando o número de replicações é fixado

igualmente para todos os níveis de variação, podem surgir dois cenários indesejáveis: ou o número de simulações para o cenário de baixa variação é excessivo para compensar o número de replicações necessários nos cenários de média e alta variação, ou os cenários de média e alta variação têm um número insuficiente de simulações para capturar adequadamente a estocasticidade necessária, devido à adoção de um número pequeno de replicações, já que no cenário de baixa variação o número de replicações necessárias é menor.

Na Figura 26, é possível analisar em detalhes o funcionamento do método do erro do intervalo de confiança. A imagem ilustra que, à medida que o número de simulações aumenta, os limites superior e inferior (linhas vermelhas) se aproximam gradualmente, resultando em um intervalo mais estreito. Esse estreitamento do intervalo indica uma maior precisão na estimativa, pois o *Erro* do intervalo de confiança diminui progressivamente.

Figura 26 – Método do *Erro* do intervalo de confiança

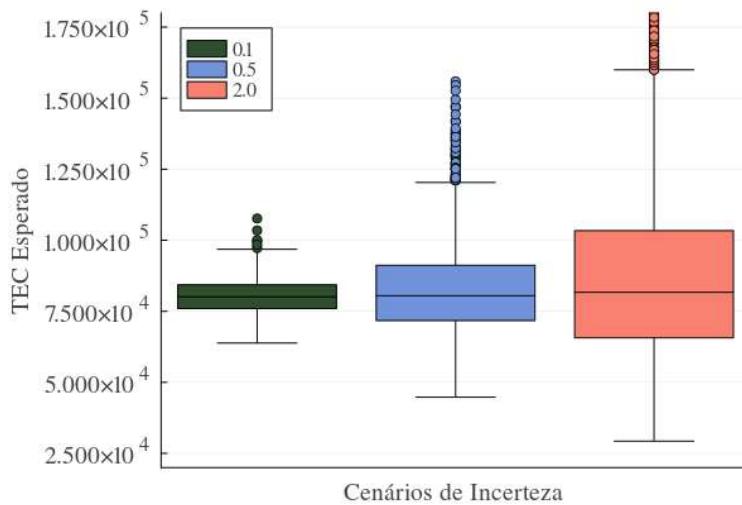


Fonte: Elaborado pelo autor (2024)

Além disso, fica evidente a necessidade de desenvolver processos com menor variabilidade, visando obter resultados e previsões mais assertivas tanto em relação aos custos quanto aos tempos de conclusão das tarefas. A análise revela que para todos os cenários, as métricas são consideravelmente impactadas. Conforme pode ser observado na Figura 27.

Na Figura 27, utiliza-se o exemplo da Instância 1 para ilustrar os resultados obtidos pelo SimSA-Esperado para o TEC Esperado nos cenários de incertezas 0.1, 0.5 e 2.0. Os valores observados são de 79.781,97, 82.323,53 e 87.204,15, respectivamente. Nota-se um aumento nos resultados conforme a incerteza cresce. No entanto, o aspecto mais alarmante é a variação significativa

Figura 27 – Boxplot da instância 1 para os resultados do SimSA-Esperado



Fonte: Elaborado pelo autor (2024)

apresentada nos boxplots, principalmente para os cenários 0.5 e 2.0 de incerteza. Esse padrão se repete para todas as demais instâncias e métricas.

Por fim, para todas as abordagens estudadas, constatou-se que realizar uma simulação longa na melhor solução determinística encontrada (GIH-GRASP) não resulta em uma performance tão eficiente quanto uma abordagem que já considera a estocasticidade durante a busca por soluções (SimSA). Isso ocorre porque a melhor solução determinística pode não ser robusta o suficiente para lidar com as variabilidades e incertezas inerentes ao ambiente de produção. Essa observação evidencia que a melhor solução determinística nem sempre será a melhor solução estocástica. Quando a variabilidade e a incerteza são fatores significativos, abordagens que incorporam a estocasticidade no processo de otimização tendem a gerar soluções mais resilientes e adaptáveis às condições reais de operação.

5.4 TESTE DE WILCOXON PARA GIH-GRASP X ABORDAGENS DO SIMSA

Para comparar estatisticamente os resultados obtidos pelo GIH-GRASP com as abordagens do SimSA, foi aplicado o teste de Wilcoxon para amostras pareadas, com um nível de significância de 0.05. Este teste foi escolhido por ser adequado para comparar duas amostras dependentes, ou seja, as mesmas amostras avaliadas por métodos diferentes. Foram realizadas as seguintes comparações: GIH-GRASP x SimSA-Esperado, GIH-GRASP x SimSA-VaR e GIH-GRASP x SimSA-CVaR.

O teste de Wilcoxon para amostras pareadas verifica se há uma diferença significativa nas medianas das amostras emparelhadas. As hipóteses formuladas para o teste bilateral foram as seguintes:

$$\begin{cases} H_0 : M_d = 0 \\ H_1 : M_d \neq 0 \end{cases} \quad (5.2)$$

Caso o valor-p do teste seja maior que 0,05, não rejeitamos a hipótese nula. Isso indica que não há evidência estatística suficiente para afirmar que existe uma diferença significativa entre os métodos comparados. Em outras palavras, os desempenhos dos métodos GIH-GRASP e SimSA são estatisticamente similares para a comparação específica realizada.

Por outro lado, se o valor-p do teste for menor ou igual a 0,05, rejeitamos a hipótese nula. Isso sugere que há uma diferença significativa entre os métodos comparados. Ou seja, o desempenho do GIH-GRASP é estatisticamente diferente do desempenho do SimSA para a comparação específica, indicando que um dos métodos pode ser superior ao outro em termos da mediana das diferenças observadas.

Os resultados obtidos para o valor-p foram de 9,82E-76 para as três abordagens comparadas (GIH-GRASP x SimSA-Esperado, GIH-GRASP x SimSA-VaR e GIH-GRASP x SimSA-CVaR). Esse valor extremamente pequeno demonstra que há uma diferença significativa entre o GIH-GRASP e as abordagens do SimSA.

6 CONCLUSÕES

Esta dissertação abordou o problema de sequenciamento de máquina única com consideração ambiental sob incerteza nos tempos de processamento (PSVMUE), buscando minimizar o TEC por meio da aplicação de uma política TOU. Esta variante ainda não foi amplamente explorada no contexto de sequenciamento de produção. No entanto, devido às exigências sustentáveis atuais impostas pelos governos e à necessidade de preservação do planeta, esse tema está se tornando cada vez mais relevante. Além disso, a busca por modelos mais realistas tem aumentado o interesse no estudo de problemas de OC com parâmetros estocásticos, tornando-se um tópico ativo em diversas pesquisas.

Para enfrentar esse desafio, foi proposto um algoritmo simheurístico denominado SimSA, que integra as estratégias das meta-heurísticas SA e GRASP. O SimSA utiliza um parâmetro aleatório-guloso na construção da solução e adota o critério de aceitação de soluções piores do que a melhor solução encontrada até o momento, permitindo a realização de simulações nessas soluções.

Os testes do algoritmo foram realizados em instâncias com diferentes características, variados cenários de incerteza e três métricas estocásticas. Os resultados demonstraram que o SimSA apresentou um bom desempenho estocástico em comparação com a simulação da melhor solução determinística, para todas as três métricas utilizadas, evidenciando que a melhor solução determinística não necessariamente seja a melhor solução estocástica. Isso destaca a relevância e a importância das simheurísticas. No entanto, um desafio significativo identificado foi o alto tempo computacional requerido pelo método, tornando-se bastante custoso ao lidar com instâncias do PSVMUE com um elevado índice de incerteza.

Essa pesquisa representa um avanço significativo ao incentivar o desenvolvimento de novos estudos voltados para a integração das preocupações ambientais e de risco/incerteza no processo de sequenciamento de produção. Ao fornecer uma abordagem eficiente, ela capacita as organizações a lidar com essas complexidades de maneira mais eficaz.

Destaca-se, a importância de adotar o SimSA em conjunto com diferentes métricas estocásticas. Cada uma dessas métricas desempenha um papel crucial ao avaliar aspectos específicos da aleatoriedade do processo. Isso amplia significativamente as opções disponíveis para os tomadores de decisão, permitindo uma análise mais abrangente das soluções propostas. Por exemplo, a métrica SimSA-Esperado oferece uma perspectiva da solução com base na média das simulações, enquanto o SimSA-VaR se concentra na minimização associado a solução com o menor risco entre os piores casos e o SimSA-CVaR com a solução com o menor risco médio entre os piores casos. Essa variedade de

abordagens permite que as organizações selezionem a estratégia mais adequada às suas necessidades específicas, fortalecendo assim sua capacidade de enfrentar desafios complexos de forma mais eficaz e sustentável.

Outro ponto a ser destacado é a importância de minimizar a variabilidade dos dados. Nos testes realizados, foi possível observar que em todos os cenários apresentaram um impacto significativo nas métricas de desempenho. Quando os dados são mais estáveis, é possível obter sequenciamentos com menor variabilidade, o que, por sua vez, reduz os riscos associados à produção. A estabilidade dos dados também contribui para uma maior eficiência operacional, pois processos mais previsíveis permitem uma melhor alocação de recursos. Além disso, a confiabilidade da tomada de decisão é aprimorada, uma vez que previsões mais precisas e consistentes facilitam a escolha das melhores estratégias e soluções. Em resumo, a redução da variabilidade dos dados não só melhora o desempenho operacional, mas também fortalece a capacidade das organizações de se adaptarem e competirem em um mercado cada vez mais exigente e volátil.

A heurística construtiva GIH se baseia em um método aplicável apenas a instâncias que seguem uma estrutura específica de demanda de energia. Neste padrão, cada período de tarifa baixa é seguido por um período de tarifa média e precedido por um período de tarifa alta. Esta heurística foi originalmente concebida com base na demanda de energia observada na China. No entanto, é possível adaptar essa heurística para se adequar a diferentes distribuições de energia ao longo do dia. Isso sugere uma área de melhoria para futuras pesquisas, buscando desenvolver modelos mais flexíveis e adaptáveis que possam lidar com uma variedade mais ampla de cenários de demanda de energia.

Para futuras pesquisas, é essencial realizar uma análise detalhada e testes adicionais para determinar o ponto de convergência dos algoritmos utilizados. Isso permitirá avaliar se o número de iterações atual é excessivo e, se necessário, ajustar esse valor para otimizar a eficiência do algoritmo, evitando execuções prolongadas sem a obtenção de soluções melhores. Além disso, pretende-se implementar o modelo matemático de Zhang *et al.* (2018a) para resolver o problema de maneira exata e, a partir dessa solução, realizar simulações em diferentes cenários para testar a qualidade da solução no ambiente estocástico. Também se sugere o desenvolvimento de um algoritmo simheurístico multi-objetivo que considere a redução dos objetivos *Makespan* e TEC, juntamente com uma análise detalhada dos gargalos computacionais, com o objetivo de aprimorar a eficiência do algoritmo proposto.

Esta dissertação oferece contribuições significativas nos aspectos sociais, econômicos e ambientais:

- **Aspectos Sociais:** A implementação da política TOU promove uma consciência coletiva sobre o uso responsável dos recursos energéticos. Ao incentivar o sequenciamento da produção para

períodos de menor demanda, a sociedade como um todo se beneficia, pois reduz a pressão sobre a infraestrutura energética, mitigando assim os riscos de sobrecarga e interrupções no fornecimento. Além disso, ao encorajar horários alternativos de produção, cria-se espaço para uma maior flexibilidade no emprego, facilitando a conciliação entre trabalho e vida pessoal para os trabalhadores. Por fim, ao demonstrar um compromisso com a responsabilidade social corporativa, a pesquisa responde às expectativas crescentes da sociedade e dos consumidores por práticas empresariais sustentáveis e éticas.

- **Aspectos Econômicos:** A política TOU desempenha um papel crucial na otimização dos custos de produção e no aumento da eficiência dos recursos. Ao direcionar a produção para momentos de tarifas mais baixas, as empresas podem reduzir significativamente seus gastos com energia, aumentando sua competitividade no mercado. Além disso, ao incentivar a adoção de tecnologias mais eficientes e práticas de gestão de energia, a política TOU estimula a inovação e promove um desenvolvimento econômico sustentável a longo prazo. Essa otimização econômica não apenas beneficia as empresas individualmente, mas também contribui para um mercado mais eficiente e competitivo.
- **Aspectos Ambientais:** A política TOU desempenha um papel fundamental na redução da pegada de carbono e na promoção da sustentabilidade. Ao desencorajar a produção durante os períodos de pico de demanda, reduz-se a necessidade de recorrer a fontes de energia mais poluentes, como usinas termelétricas movidas a carvão. Isso contribui para a preservação dos recursos naturais e para a mitigação das mudanças climáticas. A adoção de práticas energéticas mais limpas e eficientes promove um ambiente mais saudável e sustentável, beneficiando não apenas a geração atual, mas também as futuras.

Além disso, a contribuição da revisão sistemática é destacada por sua importância na contextualização da pesquisa dentro do cenário atual e na identificação de lacunas de conhecimento. Esse processo demonstra um compromisso com a rigorosidade metodológica e com a construção sobre o conhecimento existente na área, fortalecendo a validade e a relevância dos resultados obtidos.

REFERÊNCIAS

- ABEDI, M.; CHIONG, R.; NOMAN, N.; ZHANG, R. A hybrid particle swarm optimisation approach for energy-efficient single machine scheduling with cumulative deterioration and multiple maintenances. In: IEEE. **2017 IEEE Symposium Series on Computational Intelligence (SSCI)**. [S. l.], 2017. p. 1–8.
- AGHELINEJAD, M.; OUAZENE, Y.; YALAOUI, A. Complexity analysis of energy-efficient single machine scheduling problems. **Operations Research Perspectives**, Elsevier, v. 6, p. 100105, 2019.
- AGHELINEJAD, M. M.; OUAZENE, Y.; YALAOUI, A. Single-machine scheduling problem with total energy consumption costs minimization. **IFAC-PapersOnLine**, Elsevier, v. 52, n. 13, p. 409–414, 2019.
- AMIRI, M. F.; BEHNAMIAN, J. Multi-objective green flowshop scheduling problem under uncertainty: Estimation of distribution algorithm. **Journal of Cleaner Production**, Elsevier, v. 251, p. 119734, 2020.
- AN, Y.; LI, C.; CHEN, X.; LI, Y.; ZHAO, Z.; CAO, H. An optimal energy-efficient scheduling with processing speed selection and due date constraint in a single-machine environment. **Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture**, SAGE Publications Sage UK: London, England, 2022.
- ARENALES, M.; ARMENTANO, V.; MORABITO, R.; YANASSE, H. **Pesquisa Operacional**. Rio de Janeiro: Elsevier, 2015. ISBN 978-85-352-5193-7.
- ASADPOUR, M.; HODAEI, Z.; AZAMI, M.; KEHTARI, E.; VESAL, N. A green model for identical parallel machines scheduling problem considering tardy jobs and job splitting property. **Sustainable Operations and Computers**, v. 3, p. 149–155, 2022. ISSN 2666-4127. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2666412722000034>.
- BALANÇO ENERGÉTICO NACIONAL . **Empresa de Pesquisa Energética**. Rio de Janeiro: EPE: [S. n.], 2023. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2023>. Acesso em: 27 jul. 2023.
- BANKS, J. **Discrete event system simulation**. [S. l.]: Pearson Education India, 2005.
- BEKTUR, G. A hybrid heuristic solution based on simulated annealing algorithm for energy efficient single machine scheduling problem with sequence dependent setup times. *Gazi Üniversitesi*, 2021.
- BITTENCOURT, M. L.; OLIVEIRA, C. M. R. de; KRAMER, R.; LINS, I. D. Simheurística para programação de máquina única com tempos de setup dependente da sequência e estocásticos. In: **Anais do LV Simpósio Brasileiro de Pesquisa Operacional**. São José dos Campos - SP: [S. n.], 2023.
- BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. **ACM computing surveys (CSUR)**, Acm New York, NY, USA, v. 35, n. 3, p. 268–308, 2003.
- BOLD, M.; GOERIGK, M. Investigating the recoverable robust single machine scheduling problem under interval uncertainty. **Discrete Applied Mathematics**, Elsevier, v. 313, p. 99–114, 2022.
- BRUCKER, P.; KNUST, S. **Complex scheduling, second edition**. [S. l.: s. n.], 2012. 1-340 p. ISBN 978-3-642-23928-1.

BUECHLER, T.; PAGEL, F.; PETITJEAN, T.; DRAZ, M.; ALBAYRAK, S. Optimal energy supply scheduling for a single household: Integrating machine learning for power forecasting. In: IEEE. **2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)**. [S. l.], 2019. p. 1–5.

BUSSADORI, H. S. Fontes de energia e impactos na sociedade contemporânea. **Revista Resgates**, v. 9, p. 105–120, 2019.

CASTANEDA, J.; GHORBANI, E.; AMMOURIOVA, M.; PANADERO, J.; JUAN, A. A. Optimizing transport logistics under uncertainty with simheuristics: Concepts, review and trends. **Logistics**, MDPI, v. 6, n. 3, p. 42, 2022.

CAUCHICK-MIGUEL, P. A. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 3. ed. Rio de Janeiro: Elsevier, 2018.

CHANG, Z.; SONG, S.; ZHANG, Y.; DING, J.-Y.; ZHANG, R.; CHIONG, R. Distributionally robust single machine scheduling with risk aversion. **European Journal of Operational Research**, v. 256, n. 1, p. 261–274, 2016. ISSN 0377-2217.

CHE, A.; LV, K.; LEVNER, E.; KATS, V. Energy consumption minimization for single machine scheduling with bounded maximum tardiness. In: IEEE. **2015 IEEE 12th international conference on networking, sensing and control**. [S. l.], 2015. p. 146–150.

CHE, A.; WU, X.; PENG, J.; YAN, P. Energy-efficient bi-objective single-machine scheduling with power-down mechanism. **Computers & Operations Research**, v. 85, p. 172–183, 2017. ISSN 0305-0548. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0305054817300953>.

CHE, A.; ZENG, Y.; LYU, K. An efficient greedy insertion heuristic for energy-conscious single machine scheduling problem under time-of-use electricity tariffs. **Journal of Cleaner Production**, Elsevier, v. 129, p. 565–577, 2016.

CHEN, L.; WANG, J.; XU, X. An energy-efficient single machine scheduling problem with machine reliability constraints. **Computers & Industrial Engineering**, Elsevier, v. 137, p. 106072, 2019.

CHEN, S.-H.; LIOU, Y.-C.; CHEN, Y.-H.; WANG, K.-C. Order acceptance and scheduling problem with carbon emission reduction and electricity tariffs on a single machine. **Sustainability**, MDPI, v. 11, n. 19, p. 5432, 2019.

CHENG, J.; CHU, F.; CHU, C.; XIA, W. Bi-objective optimization of single-machine batch scheduling under time-of-use electricity prices. **RAIRO-Operations Research-Recherche Opérationnelle**, v. 50, n. 4-5, p. 715–732, 2016.

CHENG, J.; CHU, F.; LIU, M.; XIA, W. Single-machine batch scheduling under time-of-use tariffs: New mixed-integer programming approaches. In: IEEE. **2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)**. [S. l.], 2016. p. 003498–003503.

CHENG, J.; CHU, F.; LIU, M.; WU, P.; XIA, W. Bi-criteria single-machine batch scheduling with machine on/off switching under time-of-use tariffs. **Computers & Industrial Engineering**, Elsevier, v. 112, p. 721–734, 2017.

CHENG, J.; CHU, F.; LIU, M.; WU, P.; XIA, W. Bi-criteria single-machine batch scheduling with machine on/off switching under time-of-use tariffs. **Computers & Industrial Engineering**, Elsevier, v. 112, p. 721–734, 2017.

- CHENG, J.; CHU, F.; XIA, W.; DING, J.; LING, X. Bi-objective optimization for single-machine batch scheduling considering energy cost. In: IEEE. **2014 international conference on control, decision and information technologies (CoDIT)**. [S. l.], 2014. p. 236–241.
- CHOI, Y.-C. Dispatching rule-based scheduling algorithms in a single machine with sequence-dependent setup times and energy requirements. **Procedia CIRP**, Elsevier, v. 41, p. 135–140, 2016.
- CORREA, H. L.; CORREA, C. A. **Administração de Produção e Operações: Manufatura e Serviços: uma Abordagem Estratégica**. 4. ed. São Paulo: Atlas, 2017. ISBN 978-8597012385.
- DANIELS, R. L.; CARRILLO, J. E. β -robust scheduling for single-machine systems with uncertain processing times. **IIE transactions**, Springer, v. 29, n. 11, p. 977–985, 1997.
- DONTHU, N.; KUMAR, S.; MUKHERJEE, D.; PANDEY, N.; LIM, W. M. How to conduct a bibliometric analysis: An overview and guidelines. **Journal of Business Research**, v. 133, p. 285–296, 2021. ISSN 0148-2963. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0148296321003155>.
- ERTEM, M.; OZCELIK, F.; SARAç, T. Single machine scheduling problem with stochastic sequence-dependent setup times. **International Journal of Production Research**, Taylor & Francis, v. 57, n. 10, p. 3273–3289, 2019.
- ESQUIROL, P.; LOPEZ, P. Basic concepts and methods in production scheduling. In: _____. **Production Scheduling**. John Wiley & Sons, Ltd, 2013. ISBN 9780470611050. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/9780470611050.ch2>.
- FANG, K.; UHAN, N. A.; ZHAO, F.; SUTHERLAND, J. W. Scheduling on a single machine under time-of-use electricity tariffs. **Annals of Operations Research**, Springer, v. 238, n. 1, p. 199–227, 2016.
- FAY, N.; GLAZEBROOK, K. D. On a “no arrivals” heuristic for single machine stochastic scheduling. **Operations research**, INFORMS, v. 40, n. 1, p. 168–177, 1992.
- FEÓ, T. A.; RESENDE, M. G. Greedy randomized adaptive search procedures. **Journal of global optimization**, Springer, v. 6, p. 109–133, 1995.
- FILIPPI, C.; GUASTAROBA, G.; SPERANZA, M. G. Conditional value-at-risk beyond finance: a survey. **International Transactions in Operational Research**, Wiley Online Library, v. 27, n. 3, p. 1277–1319, 2020.
- FU, Y.; TIAN, G.; FATHOLLAHI-FARD, A. M.; AHMADI, A.; ZHANG, C. Stochastic multi-objective modelling and optimization of an energy-conscious distributed permutation flow shop scheduling problem with the total tardiness constraint. **Journal of cleaner production**, Elsevier, v. 226, p. 515–525, 2019.
- FUCHIGAMI, H. Y. Material didático, versão 8.0, **Introdução ao sequenciamento da produção**. 2021.
- GASCON, A. The lookahead heuristic for multi-item single machine production scheduling with dynamic, stochastic demands. **INFOR: Information Systems and Operational Research**, Taylor & Francis, v. 26, n. 2, p. 114–126, 1988.

GASCON, A.; LEACHMAN, R. C.; LEFRANÇOIS, P. Multi-item, single-machine scheduling problem with stochastic demands: a comparison of heuristics. **THE INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH**, Taylor & Francis, v. 32, n. 3, p. 583–596, 1994.

GENDREAU, J.-Y. P. M. **Handbook of Metaheuristics**. 3. ed. [S. l.]: Springer, 2010. ISBN 978-3-319-91086-4.

GHOLIZADEH, H.; FAZLOLLAHTABAR, H.; FATHOLLAHI-FARD, A. M.; DULEGNETS, M. A. Preventive maintenance for the flexible flowshop scheduling under uncertainty: A waste-to-energy system. **Environmental Science and Pollution Research**, Springer, p. 1–20, 2021.

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. São Paulo: Editora Atlas, 2019. ISBN 978-8597020571.

GOLDBARG, M. C.; GOLDBARG, E. G.; LUNA, H. P. L. **Otimização combinatória e meta-heurísticas: algoritmos e aplicações**. 1. ed. Rio de Janeiro: Elsevier, 2016.

GONZALEZ-NEIRA, E. M.; FERONE, D.; HATAMI, S.; JUAN, A. A. A biased-randomized simheuristic for the distributed assembly permutation flowshop problem with stochastic processing times. **Simulation Modelling Practice and Theory**, v. 79, p. 23–36, 2017.

GONZALEZ-NEIRA, E. M.; MONTOYA-TORRES, J. R. A simheuristic for bi-objective stochastic permutation flow shop scheduling problem. **Journal of Project Management**, v. 4, p. 57–80, 2019.

GONZALEZ-NEIRA, E. M.; MONTOYA-TORRES, J. R.; JIMENEZ, J.-F. A multicriteria simheuristic approach for solving a stochastic permutation flow shop scheduling problem. **Algorithms**, v. 14, n. 7, 2021.

GRAHAM, R.; LAWLER, E.; LENSTRA, J.; KAN, A. Optimization and approximation in deterministic sequencing and scheduling: a survey. In: HAMMER, P.; JOHNSON, E.; KORTE, B. (Ed.). **Discrete Optimization II**. Elsevier, 1979, (Annals of Discrete Mathematics, v. 5). p. 287–326. Disponível em: <https://www.sciencedirect.com/science/article/pii/S016750600870356X>.

GUIMARANS, D.; DOMINGUEZ, O.; PANADERO, J.; JUAN, A. A. A simheuristic approach for the two-dimensional vehicle routing problem with stochastic travel times. **Simulation Modelling Practice and Theory**, v. 89, p. 1–14, 2018. ISSN 1569-190X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1569190X18301254>.

HALIM, N. N. A.; SHARIFF, S. S. R.; ZAHARI, S. M. Single-machine integrated production preventive maintenance scheduling: A simheuristic approach. **MATEMATIKA: Malaysian Journal of Industrial and Applied Mathematics**, p. 113–126, 2020.

HECKMANN, I.; COMES, T.; NICKEL, S. A critical review on supply chain risk—definition, measure and modeling. **Omega**, Elsevier, v. 52, p. 119–132, 2015.

HOAD, K.; ROBINSON, S.; DAVIES, R. Automating des output analysis: How many replications to run. In: **2007 Winter Simulation Conference**. [S. l.: s. n.], 2007. p. 505–512.

JANG, W. Dynamic scheduling of stochastic jobs on a single machine. **European Journal of Operational Research**, Elsevier, v. 138, n. 3, p. 518–530, 2002.

JIA, J.; LU, C.; YIN, L. Energy saving in single-machine scheduling management: An improved multi-objective model based on discrete artificial bee colony algorithm. **Symmetry**, MDPI, v. 14, n. 3, p. 561, 2022.

JIANG, Q.; LIAO, X.; ZHANG, R.; LIN, Q. Energy-saving production scheduling in a single-machine manufacturing system by improved particle swarm optimization. **Mathematical Problems in Engineering**, Hindawi Limited, v. 2020, p. 1–16, 2020.

JUAN, A.; FAULIN, J.; GRASMAN, S.; RIERA, D.; MARULL, J.; MENDEZ, C. Using safety stocks and simulation to solve the vehicle routing problem with stochastic demands. **Transportation Research Part C: Emerging Technologies**, Elsevier, v. 19, n. 5, p. 751–765, 2011.

JUAN, A. A.; FAULIN, J.; GRASMAN, S. E.; RABE, M.; FIGUEIRA, G. A review of simheuristics: Extending metaheuristics to deal with stochastic combinatorial optimization problems. **Operations Research Perspectives**, v. 2, p. 62–72, 2015.

JUAN, A. A.; KELTON, W. D.; CURRIE, C. S.; FAULIN, J. Simheuristics applications: Dealing with uncertainty in logistics, transportation, and other supply chain areas. In: **2018 Winter Simulation Conference (WSC)**. [S. l.: s. n.], 2018. p. 3048–3059.

KATHAN, D.; KWOK, J.; LEE, M.; MEDEARIS, L.; SPORBORG, P.; TITA, M.; WIGHT, D. Assessment of demand response and advanced metering: staff report. **relatório técnico, Federal Energy Regulatory Commission**, 2011.

KEENAN, P.; PANADERO, J.; JUAN, A. A.; MARTÍ, R.; MCGARRAGHY, S. A strategic oscillation simheuristic for the time capacitated arc routing problem with stochastic demands. **Computers & Operations Research**, v. 133, p. 105377, 2021.

KIM, H.-J.; KIM, E.-S.; LEE, J.-H.; TANG, L.; YANG, Y. Single-machine scheduling with energy generation and storage systems. **International Journal of Production Research**, Taylor & Francis, v. 60, n. 23, p. 7033–7052, 2022.

KIRKPATRICK, S.; JR, C. D. G.; VECCHI, M. P. Optimization by simulated annealing. **science**, American association for the advancement of science, v. 220, n. 4598, p. 671–680, 1983.

KISIALA, J. **Conditional Value-at-Risk: Theory and Applications**. Dissertação (Master in Operations Research) – The University of Edinburgh, Edinburgh, 2015.

KIZYS, R.; DOERING, J.; JUAN, A. A.; POLAT, O.; CALVET, L.; PANADERO, J. A simheuristic algorithm for the portfolio optimization problem with random returns and noisy covariances. **Computers & Operations Research**, v. 139, p. 105631, 2022.

LAW, A. M.; MCCOMAS, M. G. **Secrets of successful simulation studies**. [S. l.], 1991.

LEACHMAN, R. C.; GASCON, A. A heuristic scheduling policy for multi-item, single-machine production systems with time-varying, stochastic demands. **Management Science**, INFORMS, v. 34, n. 3, p. 377–390, 1988.

LEE, S.; CHUNG, B. D.; JEON, H. W.; CHANG, J. A dynamic control approach for energy-efficient production scheduling on a single machine under time-varying electricity pricing. **Journal of Cleaner Production**, Elsevier, v. 165, p. 552–563, 2017.

LI, M.; WANG, G.-G. A review of green shop scheduling problem. **Information Sciences**, v. 589, p. 478–496, 2022. ISSN 0020-0255. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0020025521013438>.

LI, Q.; WANG, B. A stable scheduling for single machine under uncertainty. In: IEEE. **2009 IEEE International Conference on Automation and Logistics**. [S. l.], 2009. p. 526–531.

- LIAO, X.; ZHANG, R.; CHIONG, R. Multi-objective optimization of single machine scheduling with energy consumption constraints. In: IEEE. **2017 IEEE Symposium Series on Computational Intelligence (SSCI)**. [S. l.], 2017. p. 1–8.
- LIU, C.-H. Mathematical programming formulations for single-machine scheduling problems while considering renewable energy uncertainty. **International Journal of Production Research**, Taylor & Francis, v. 54, n. 4, p. 1122–1133, 2016.
- LIU, G.-S.; ZHANG, B.-X.; YANG, H.-D.; CHEN, X.; HUANG, G. Q. *et al.* A branch-and-bound algorithm for minimizing the energy consumption in the pfs problem. **Mathematical problems in engineering**, Hindawi, v. 2013, 2013.
- LIU, Y.; LIAO, X.; ZHANG, R. An enhanced mopsa algorithm for energy-efficient single-machine production scheduling. **Sustainability**, MDPI, v. 11, n. 19, p. 5381, 2019.
- LÓPEZ-IBÁÑEZ, M.; DUBOIS-LACOSTE, J.; CÁCERES, L. P.; BIRATTARI, M.; STÜTZLE, T. The irace package: Iterated racing for automatic algorithm configuration. **Operations Research Perspectives**, Elsevier, v. 3, p. 43–58, 2016.
- LU, C.-C.; LIN, S.-W.; YING, K.-C. Minimizing worst-case regret of makespan on a single machine with uncertain processing and setup times. **Applied Soft Computing**, v. 23, p. 144–151, 2014.
- LU, C.-C.; YING, K.-C.; LIN, S.-W. Robust single machine scheduling for minimizing total flow time in the presence of uncertain processing times. **Computers & Industrial Engineering**, Elsevier, v. 74, p. 102–110, 2014.
- MANSOURI, S. A.; AKTAS, E.; BESIKCI, U. Green scheduling of a two-machine flowshop: Trade-off between makespan and energy consumption. **European Journal of Operational Research**, v. 248, n. 3, p. 772–788, 2016. ISSN 0377-2217. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0377221715008206>.
- MARICHELVAM, M. K.; GEETHA, M. A memetic algorithm to solve uncertain energy-efficient flow shop scheduling problems. **The International Journal of Advanced Manufacturing Technology**, Springer, v. 115, n. 1-2, p. 515–530, 2021.
- MARQUES, J. A. de S. **Heurísticas de Pesquisa Local Para Problemas de Máquina Única**. Dissertação (Mestrado em Engenharia Electrotécnica e de Computadores) – Instituto Politecnico do Porto, Porto, 2015.
- MATELJAK, Ž.; MIHANOVIĆ, D. Operational planning level of development in production enterprises in the machine building industry and its impact on the effectiveness of production. **Economic research-Ekonomska istraživanja**, Taylor and Francis Group i Sveučilište Jurja Dobrile u Puli, Fakultet . . ., v. 29, n. 1, p. 325–342, 2016.
- MECLER, D.; ABU-MARRUL, V.; MARTINELLI, R.; HOFF, A. **Iterated Greedy Algorithms for a Complex Parallel Machine Scheduling Problem**. 2021.
- MECLER, D.; ABU-MARRUL, V.; MARTINELLI, R.; HOFF, A. Iterated greedy algorithms for a complex parallel machine scheduling problem. **European Journal of Operational Research**, Elsevier, v. 300, n. 2, p. 545–560, 2022.
- MOREIRA, D. **Administração da produção e operações**. 2. ed. São Paulo: Saraiva Uni, 2008. ISBN 978-8502180413.

- OSMAN, I. H.; KELLY, J. P. Meta-heuristics theory and applications. **Journal of the Operational Research Society**, Taylor & Francis, v. 48, n. 6, p. 657–657, 1996.
- ÖZTOP, H.; TASGETIREN, M. F.; KANDILLER, L.; ELIIYI, D. T.; GAO, L. Ensemble of metaheuristics for energy-efficient hybrid flowshops: Makespan versus total energy consumption. **Swarm and Evolutionary Computation**, Elsevier, v. 54, p. 100660, 2020.
- PACHECO, J.; PORRAS, S.; CASADO, S.; BARUQUE, B. Variable neighborhood search with memory for a single-machine scheduling problem with periodic maintenance and sequence-dependent set-up times. **Knowledge-Based Systems**, Elsevier, v. 145, p. 236–249, 2018.
- PEREIRA, D. F.; OLIVEIRA, J. F.; CARRAVILLA, M. A. Tactical sales and operations planning: A holistic framework and a literature review of decision-making models. **International Journal of Production Economics**, Elsevier, v. 228, p. 107695, 2020.
- PINEDO, M. L. **Scheduling: Theory, Algorithms, and Systems**. 5. ed. Springer New York Dordrecht Heidelberg London: Springer Publishing Company, Incorporated, 2022. ISBN 978-1-4614-1986-0.
- QIAO, D.; WANG, Y.; PEI, J.; BAI, W.; WEN, X. Research on green single machine scheduling based on improved ant colony algorithm. **Measurement and Control**, SAGE Publications Sage UK: London, England, v. 55, n. 1-2, p. 35–48, 2022.
- QUAN, O. Y.; XU, H. Y. The review of the single machine scheduling problem and its solving methods. **Applied Mechanics and Materials**, Trans Tech Publ, v. 411, p. 2081–2084, 2013.
- RABE, M.; DEININGER, M.; JUAN, A. Speeding up computational times in simheuristics combining genetic algorithms with discrete-event simulation. **Simulation Modelling Practice and Theory**, v. 103, p. 102089, 2020.
- RICHARDSON, R. J. **Pesquisa social: Métodos e técnicas**. São Paulo: Editora Atlas, 2017. ISBN 978-8597013832.
- ROBINSON, S. **Simulation: the practice of model development and use**. [S. l.]: Bloomsbury Publishing, 2004.
- ROCKAFELLAR, R. T.; URYASEV, S. Optimization of conditional value-at-risk. **Journal of risk**, Citeseer, v. 2, p. 21–42, 2000.
- ROSHANI, A.; PAOLUCCI, M.; GIGLIO, D.; DEMARTINI, M.; TONELLI, F.; DULEBENETS, M. A. The capacitated lot-sizing and energy efficient single machine scheduling problem with sequence dependent setup times and costs in a closed-loop supply chain network. **Annals of operations research**, Springer, v. 321, n. 1, p. 469–505, 2023.
- RUBAIEE, S.; CINAR, S.; YILDIRIM, M. B. An energy-aware multiobjective optimization framework to minimize total tardiness and energy cost on a single-machine nonpreemptive scheduling. **IEEE Transactions on Engineering Management**, IEEE, v. 66, n. 4, p. 699–714, 2018.
- RUBAIEE, S.; YILDIRIM, M. B. An energy-aware multiobjective ant colony algorithm to minimize total completion time and energy cost on a single-machine preemptive scheduling. **Computers & Industrial Engineering**, Elsevier, v. 127, p. 240–252, 2019.
- SABERI-ALIABAD, H.; REISI-NAFCHI, M.; MOSLEHI, G. Energy-efficient scheduling in an unrelated parallel-machine environment under time-of-use electricity tariffs. **Journal of Cleaner Production**, v. 249, p. 119393, 2020. ISSN 0959-6526. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652619342635>.

SABRI, A.; ALLAOUI, H.; SOUSSI, O. Reinforcement learning and stochastic dynamic programming for jointly scheduling jobs and preventive maintenance on a single machine to minimise earliness-tardiness. **International Journal of Production Research**, Taylor & Francis, v. 62, n. 3, p. 705–719, 2024.

SALAMA, M.; SRINIVAS, S. Adaptive neighborhood simulated annealing for sustainability-oriented single machine scheduling with deterioration effect. **Applied Soft Computing**, Elsevier, v. 110, p. 107632, 2021.

SCHORN, D. S.; MÖNCH, L. Learning dispatching rules for energy-aware scheduling of jobs on a single batch processing machine. In: IEEE. **2022 Winter Simulation Conference (WSC)**. [S. l.], 2022. p. 3360–3371.

SEWARD, L. E.; DOANE, D. P. **Estatística Aplicada à Administração e Economia-4**. [S. l.]: AMGH editora, 2014.

SHROUF, F.; ORDIERES-MERÉ, J.; GARCÍA-SÁNCHEZ, A.; ORTEGA-MIER, M. Optimizing the production scheduling of a single machine to minimize total energy consumption costs. **Journal of Cleaner Production**, Elsevier, v. 67, p. 197–207, 2014.

SLACK, N.; BRANDON-JONES, A.; JOHNSTON, R. **Administração de Produção e Operações: Manufatura e Serviços: uma Abordagem Estratégica**. 8. ed. São Paulo: Atlas, 2018. ISBN 978-8597014075.

SOROUSH, H. Scheduling stochastic jobs on a single machine to minimize weighted number of tardy jobs. **Kuwait Journal of Science**, v. 40, n. 1, 2013.

SOROUSH, H.; AMIN, F. Scheduling in stochastic bicriteria single machine systems with job-dependent learning effects. **Kuwait Journal of Science**, v. 40, n. 2, 2013.

SOROUSH, H.; FREDENDALL, L. The stochastic single machine scheduling problem with earliness and tardiness costs. **European Journal of Operational Research**, Elsevier, v. 77, n. 2, p. 287–302, 1994.

SOROUSH, H. M. Minimizing the weighted number of early and tardy jobs in a stochastic single machine scheduling problem. **European Journal of Operational Research**, Elsevier, v. 181, n. 1, p. 266–287, 2007.

SOUZA, M. J. F. **Inteligência Computacional para Otimização: metaheurísticas**. Universidade Federal de Ouro Preto, Ouro Preto, Minas Gerais: [S. n.], 2022. Disponível em: <http://www.decom.ufop.br/prof/marcone/Disciplinas/InteligenciaComputacional/InteligenciaComputacional.pdf>.

STREET, A. On the conditional value-at-risk probability-dependent utility function. **Theory and Decision**, Springer, v. 68, p. 49–68, 2010.

SZMEREKOVSKY, J. G. Single machine scheduling under market uncertainty. **European journal of operational research**, Elsevier, v. 177, n. 1, p. 163–175, 2007.

TALBI, E.-G. **Metaheuristics: From Design to Implementation**. New Jersey: John Wiley & Sons, 2009. ISBN 978-0-470-27858-1.

TARAKÇI, E.; ZAIM, A. H.; ÖZTAŞ, O. Energy-based scheduling optimization to minimize the total energy consumption and the total tardiness in a single machine manufacturing system with the sequence-dependent setup times. **Politeknik Dergisi**, Gazi University, v. 27, n. 1, p. 169–183, 2022.

THOMOPOULOS, N. T. **Essentials of Monte Carlo simulation: Statistical methods for building simulation models.** [S. l.]: Springer, 2014.

TIAN, Z.; ZHENG, L. Single machine parallel-batch scheduling under time-of-use electricity prices: New formulations and optimisation approaches. **European Journal of Operational Research**, Elsevier, v. 312, n. 2, p. 512–524, 2024.

TSAO, Y.-C.; THANH, V.-V.; HWANG, F.-J. Energy-efficient single-machine scheduling problem with controllable job processing times under differential electricity pricing. **Resources, Conservation and Recycling**, Elsevier, v. 161, p. 104902, 2020.

TUBINO, D. F. **Planejamento e controle da produção: teoria e prática**. 3. ed. São Paulo: Editora Atlas, 2022. ISBN 978-85-224-4845-6. 1.

VIEIRA, N. H. **Abordagens simheurísticas para o problema de flow shop permutacional multiobjetivo**. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Ouro Preto, Ouro Preto, 2022.

WANG, J.; QIAN, M.; HU, L.; LI, S.; CHANG, Q. Energy saving scheduling of a single machine system based on bi-objective particle swarm optimization. In: IEEE. **2019 IEEE 15th International Conference on Automation Science and Engineering (CASE)**. [S. l.], 2019. p. 585–589.

WANG, L.; QI, Y. Scheduling an energy-aware parallel machine system with deteriorating and learning effects considering multiple optimization objectives and stochastic processing time. **CMES-Computer Modeling in Engineering & Sciences**, TECH SCIENCE PRESS 871 CORONADO CENTER DR, SUITE 200, HENDERSON, NV 89052 USA, v. 135, n. 1, p. 325–339, 2023.

WANG, S.; LIU, M.; CHU, F.; CHU, C. Bi-objective optimization of a single machine batch scheduling problem with energy cost consideration. **Journal of cleaner production**, Elsevier, v. 137, p. 1205–1215, 2016.

WANG, S.; MASON, S. J.; GANGAMMANAVAR, H. Stochastic optimization for flow-shop scheduling with on-site renewable energy generation using a case in the united states. **Computers & Industrial Engineering**, Elsevier, v. 149, p. 106812, 2020.

WANG, Y.; LI, L. Time-of-use based electricity demand response for sustainable manufacturing systems. **Energy**, Elsevier, v. 63, p. 233–244, 2013.

WANG, Y.-J.; WANG, G.-G.; TIAN, F.-M.; GONG, D.-W.; PEDRYCZ, W. Solving energy-efficient fuzzy hybrid flow-shop scheduling problem at a variable machine speed using an extended nsga-ii. **Engineering Applications of Artificial Intelligence**, v. 121, p. 105977, 2023. ISSN 0952-1976. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197623001616>.

WOOLSON, R. F. Wilcoxon signed-rank test. **Wiley encyclopedia of clinical trials**, Wiley Online Library, p. 1–3, 2007.

WU, P.; CHENG, J.; CHU, F. Large-scale energy-conscious bi-objective single-machine batch scheduling under time-of-use electricity tariffs via effective iterative heuristics. **Annals of Operations Research**, Springer, v. 296, n. 1, p. 471–494, 2021.

WU, P.; LI, N.; CHENG, J.; CHU, C. Energy-efficient single-machine scheduling with release dates under time-of-use electricity tariffs. **Journal of Cleaner Production**, v. 393, p. 136228, 2023. ISSN 0959-6526. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652623003864>.

- WU, X.; SUN, Y. A green scheduling algorithm for flexible job shop with energy-saving measures. **Journal of cleaner production**, Elsevier, v. 172, p. 3249–3264, 2018.
- XAVIER, A. d. S. **Sequenciamento preemptivo e designação de tarefas em máquina paralelas uniformes com técnicas de fluxo em redes**. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Pernambuco, Recife, 2020.
- YAN, J.; LI, L.; ZHAO, F.; ZHANG, F.; ZHAO, Q. A multi-level optimization approach for energy-efficient flexible flow shop scheduling. **Journal of Cleaner Production**, Elsevier, v. 137, p. 1543–1552, 2016.
- YANG, A.; QIAN, B.; HU, R.; WANG, L.; LI, S.-H. Single-machine green scheduling problem of multi-speed machine. In: SPRINGER. **Intelligent Computing Theories and Application: 15th International Conference, ICIC 2019, Nanchang, China, August 3–6, 2019, Proceedings, Part II 15**. [S. l.], 2019. p. 669–677.
- YIN, Y.; LIU, M.; CHENG, T.; WU, C.-C.; CHENG, S.-R. Four single-machine scheduling problems involving due date determination decisions. **Information Sciences**, Elsevier, v. 251, p. 164–181, 2013.
- YUE, F.; SONG, S.; JIA, P.; WU, G.; ZHAO, H. Robust single machine scheduling problem with uncertain job due dates for industrial mass production. **Journal of Systems Engineering and Electronics**, BIAI, v. 31, n. 2, p. 350–358, 2020.
- YUE, F.; SONG, S.; ZHANG, Y.; GUPTA, J. N.; CHIONG, R. Robust single machine scheduling with uncertain release times for minimising the maximum waiting time. **International Journal of Production Research**, Taylor & Francis, v. 56, n. 16, p. 5576–5592, 2018.
- ZHANG, B.; PAN, Q.-k.; GAO, L.; LI, X.-y.; MENG, L.-l.; PENG, K.-k. A multiobjective evolutionary algorithm based on decomposition for hybrid flowshop green scheduling problem. **Computers & Industrial Engineering**, Elsevier, v. 136, p. 325–344, 2019.
- ZHANG, B.; PAN, Q. ke; GAO, L.; LI, X. yu; MENG, L. lei; PENG, K. kun. A multiobjective evolutionary algorithm based on decomposition for hybrid flowshop green scheduling problem. **Computers & Industrial Engineering**, v. 136, p. 325–344, 2019. ISSN 0360-8352. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360835219304280>.
- ZHANG, H.; FANG, Y.; PAN, R.; GE, C. A new greedy insertion heuristic algorithm with a multi-stage filtering mechanism for energy-efficient single machine scheduling problems. **Algorithms**, MDPI, v. 11, n. 2, p. 18, 2018.
- ZHANG, H.-L.; QIAN, B.; SUN, Z.-X.; HU, R.; LIU, B.; GUO, N. Single-machine green scheduling to minimize total flow time and carbon emission. In: SPRINGER. **Intelligent Computing Theories and Application: 14th International Conference, ICIC 2018, Wuhan, China, August 15–18, 2018, Proceedings, Part I 14**. [S. l.], 2018. p. 670–678.
- ZHANG, S.; CHE, A.; WU, X.; CHU, C. Improved mixed-integer linear programming model and heuristics for bi-objective single-machine batch scheduling with energy cost consideration. **Engineering optimization**, Taylor & Francis, v. 50, n. 8, p. 1380–1394, 2018.
- ZHAO, C.; TANG, H. Due-window assignment for a single machine scheduling with both deterioration and positional effects. **Asia-Pacific Journal of Operational Research**, World Scientific, v. 32, n. 03, p. 1550014, 2015.

ZHENG, F.; WANG, Z.; XU, Y.; LIU, M. Single machine scheduling with uncertain processing times and carbon emission constraint in the shared manufacturing environment. **Annals of Operations Research**, Springer, p. 1–31, 2023.

ZHOU, S.; JIN, M.; DU, N. Energy-efficient scheduling of a single batch processing machine with dynamic job arrival times. **Energy**, Elsevier, v. 209, p. 118420, 2020.

APÊNDICE A – COMPARAÇÃO ENTRE SIMSA-ESPERADO X GIH-GRASP

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	
1	0.1	85075.00	4.38	79781.95	29.05	6499.20	49.59	313	2727	6.22%
1	0.5	87876.23	25.15	82323.53	236.82	15003.88	52.16	1487	13640	6.32%
1	2.0	90909.70	335.74	87204.15	2131.41	29607.57	59.44	5122	47333	4.08%
2	0.1	71646.14	1.31	67095.25	8.16	5540.67	49.56	343	2802	6.35%
2	0.5	74896.81	33.39	69713.40	96.79	13090.31	52.30	1620	14479	6.92%
2	2.0	79353.93	437.92	74285.60	1157.50	26582.04	59.55	5824	52577	6.39%
3	0.1	78278.95	1.25	73017.03	6.31	5881.83	49.65	284	2667	6.72%
3	0.5	81642.26	29.48	75939.27	74.24	14163.32	52.23	1634	14284	6.99%
3	2.0	86125.29	510.47	81264.16	840.65	28704.11	59.71	5534	51229	5.64%
4	0.1	86435.31	1.33	79290.19	6.49	6783.88	49.56	350	3007	8.27%
4	0.5	89762.39	31.69	82413.76	72.24	15388.11	52.12	1530	14317	8.19%
4	2.0	93610.74	376.79	87679.49	781.44	30676.48	59.24	5482	50263	6.34%
5	0.1	80609.94	1.27	79094.82	21.05	6735.63	49.62	268	2980	1.88%
5	0.5	83666.30	26.47	81781.28	222.09	15206.60	52.18	1582	14198	2.25%
5	2.0	88044.21	384.51	86628.62	2777.70	29394.06	59.42	5147	47274	1.61%
6	0.1	76702.84	1.33	74671.74	13.06	6273.95	49.67	290	2900	2.65%
6	0.5	80042.20	27.97	77512.82	169.39	14486.44	52.19	1512	14343	3.16%
6	2.0	84614.37	489.32	82192.40	2787.54	28175.24	59.44	5382	48250	2.86%
7	0.1	83835.83	1.28	81658.81	21.46	6710.97	49.48	304	2775	2.60%
7	0.5	86174.41	26.03	84946.42	189.76	15418.47	52.09	1458	13530	1.43%
7	2.0	90369.68	462.73	89057.67	2230.63	29650.66	59.18	5033	45516	1.45%
8	0.1	82383.61	1.79	81218.03	13.07	6424.06	49.61	242	2571	1.41%
8	0.5	85942.31	33.66	84209.16	163.13	15865.32	52.10	1727	14576	2.02%
8	2.0	90690.65	527.43	89303.53	1818.45	31130.58	59.45	5520	49896	1.53%
9	0.1	91506.24	1.13	84454.83	5.82	7214.88	49.53	324	2999	7.71%
9	0.5	95325.57	23.97	87866.45	74.86	16648.54	52.16	1553	14744	7.82%
9	2.0	99808.97	340.99	93225.62	742.56	32147.50	59.33	5513	48827	6.60%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
10	0.1	79185.27	1.38	74266.15	6.44	5914.68	49.54	248	2607	6.21%
10	0.5	82519.93	29.07	77624.21	74.12	14374.20	52.09	1600	14081	5.93%
10	2.0	86779.81	414.92	82499.22	865.18	28751.74	59.37	5474	49872	4.93%
11	0.1	83951.78	1.34	82042.23	12.82	7013.25	49.53	356	3003	2.27%
11	0.5	87418.41	34.28	85091.07	216.07	15999.39	52.09	1514	14519	2.66%
11	2.0	92011.76	458.57	90037.66	1785.89	30931.51	59.43	5401	48461	2.15%
12	0.1	83373.30	1.66	80991.54	15.37	6742.71	49.58	321	2849	2.86%
12	0.5	86623.58	36.68	84226.10	141.00	15991.13	52.09	1590	14803	2.77%
12	2.0	90779.16	531.78	89294.13	1892.36	31090.68	59.35	5526	49779	1.64%
13	0.1	69799.95	1.72	68159.11	14.47	5314.95	49.44	292	2499	2.35%
13	0.5	72604.95	44.61	71160.14	124.10	13105.24	52.17	1496	13928	1.99%
13	2.0	76894.44	562.65	76073.95	2405.90	26689.61	59.42	5667	50541	1.07%
14	0.1	48661.62	3.42	46341.19	7.35	3779.50	49.60	304	2733	4.77%
14	0.5	51798.24	101.53	48865.83	120.99	10167.75	52.26	2066	17780	5.66%
14	2.0	56661.30	1125.34	53891.68	1669.44	22268.63	59.63	7717	70108	4.89%
15	0.1	71155.82	1.51	69892.95	9.34	5565.78	49.71	271	2607	1.77%
15	0.5	74353.46	32.73	72830.52	213.28	14042.54	52.24	1541	15266	2.05%
15	2.0	78701.73	580.76	77423.02	2898.85	27674.91	59.53	5735	52464	1.62%
16	0.1	59223.39	1.43	56560.36	6.70	4684.61	49.35	317	2818	4.50%
16	0.5	62301.90	43.22	59238.25	90.85	11787.19	51.93	1809	16258	4.92%
16	2.0	67173.41	764.99	64178.30	1156.66	24456.93	59.28	6782	59629	4.46%
17	0.1	78841.89	1.36	78324.79	14.94	6095.54	49.65	289	2489	0.66%
17	0.5	82530.50	31.21	81124.16	172.80	15128.50	52.21	1499	14282	1.70%
17	2.0	86990.07	435.40	85688.77	2934.04	29868.55	59.74	5607	49891	1.50%
18	0.1	71244.79	1.17	68867.89	9.57	5466.63	49.55	317	2589	3.34%
18	0.5	74130.99	26.84	72084.39	118.47	13372.55	51.95	1650	14133	2.76%
18	2.0	78750.93	513.09	78371.91	3050.73	27751.85	59.37	5677	51487	0.48%
19	0.1	77484.08	1.54	75783.25	18.53	6254.85	49.60	321	2799	2.20%
19	0.5	80879.79	34.74	78801.84	242.11	14710.59	52.12	1614	14312	2.57%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)	
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP	
19	2.0	85453.73	555.37	84078.81	1937.89	29292.50	59.57	5399	49839	1.61%	
20	0.1	91939.27	1.68	87949.15	15.96	7150.27	49.64	320	2717	4.34%	
20	0.5	94965.77	29.38	91078.77	211.83	16601.63	52.30	1291	13645	4.09%	
20	2.0	99172.24	384.59	95807.26	2032.25	31842.43	59.57	4854	45358	3.39%	
21	0.1	89107.83	1.60	87736.40	21.32	7023.04	49.47	296	2634	1.54%	
21	0.5	92350.13	36.18	91081.78	227.94	16891.81	52.30	1488	14124	1.37%	
21	2.0	96758.25	394.09	95679.72	2725.31	32446.21	59.41	4982	47220	1.11%	
22	0.1	46689.77	2.06	44502.17	7.33	3929.73	49.27	381	3203	4.69%	
22	0.5	49389.01	59.96	46776.59	107.01	9921.28	51.71	2125	18474	5.29%	
22	2.0	53674.37	982.24	51213.78	1449.81	21069.60	58.84	8186	69497	4.58%	
23	0.1	75606.56	1.33	70868.39	5.89	5717.50	49.49	304	2674	6.27%	
23	0.5	78565.82	31.52	73714.09	70.15	13829.75	52.21	1512	14455	6.18%	
23	2.0	82551.73	517.43	78217.09	796.34	27113.71	59.58	5706	49341	5.25%	
24	0.1	83921.10	0.94	78862.94	6.70	6516.36	49.57	305	2806	6.03%	
24	0.5	87254.29	25.23	82086.32	80.96	15627.60	52.24	1653	14884	5.92%	
24	2.0	91523.82	457.87	87173.74	866.44	30525.75	59.33	5659	50350	4.75%	
25	0.1	86570.61	1.89	84455.42	14.21	6999.35	49.59	341	2822	2.44%	
25	0.5	90238.64	37.90	87453.08	181.91	15936.17	52.14	1466	13636	3.09%	
25	2.0	94806.31	417.59	91988.55	1729.37	30846.20	59.12	5189	46171	2.97%	
26	0.1	72750.49	1.66	70157.29	29.20	5974.76	49.64	327	2981	3.56%	
26	0.5	75660.62	37.78	73290.15	216.76	13672.62	52.34	1692	14292	3.13%	
26	2.0	79631.72	525.06	77579.51	3265.15	26871.82	59.45	5056	49264	2.58%	
27	0.1	76886.56	2.14	73941.59	19.14	6215.18	49.69	308	2903	3.83%	
27	0.5	80185.07	45.16	76974.70	326.02	14818.22	52.20	1655	15218	4.00%	
27	2.0	84734.13	544.86	81580.13	3218.48	28930.02	59.40	5555	51636	3.72%	
28	0.1	87528.22	1.97	85167.80	28.32	7423.04	49.69	314	3121	2.70%	
28	0.5	91348.32	45.12	88831.77	239.61	16893.67	52.17	1590	14853	2.75%	
28	2.0	95880.25	487.13	93830.50	2140.42	32346.38	59.37	5202	48798	2.14%	
29	0.1	67733.51	2.42	65439.94	22.30	5184.57	49.55	274	2579	3.39%	

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
29	0.5	70610.62	51.82	68258.25	238.81	13072.69	52.26	1562	15063	3.33%
29	2.0	74608.73	582.10	72669.69	2566.30	25577.24	59.40	5345	50866	2.60%
30	0.1	86233.44	1.35	83995.29	39.11	6814.59	49.55	280	2705	2.60%
30	0.5	89730.84	29.27	87342.08	282.65	16130.46	52.21	1467	14006	2.66%
30	2.0	93544.14	474.24	92073.72	1915.17	31136.14	59.48	5061	46956	1.57%
31	0.1	80752.61	1.64	78210.80	26.75	6599.52	49.73	330	2926	3.15%
31	0.5	84041.26	31.85	81203.01	207.46	15175.17	52.17	1578	14342	3.38%
31	2.0	87363.10	496.01	85467.01	2633.82	29040.25	59.28	5056	47406	2.17%
32	0.1	77752.93	2.14	74698.21	31.70	6109.84	49.57	257	2750	3.93%
32	0.5	81351.58	33.00	78063.81	313.88	14516.79	52.28	1506	14201	4.04%
32	2.0	85163.25	431.48	82852.93	1601.50	28863.81	59.54	5372	49833	2.71%
33	0.1	81583.86	1.62	79036.62	27.70	6657.60	49.67	312	2916	3.12%
33	0.5	84590.18	33.08	82280.49	294.30	15534.18	52.19	1619	14637	2.73%
33	2.0	89006.11	511.84	87335.57	2208.70	30423.32	59.47	5307	49826	1.88%
34	0.1	83806.83	2.44	80827.58	23.04	6797.28	49.67	252	2907	3.55%
34	0.5	86499.07	47.96	83950.13	306.62	15562.69	52.15	1500	14112	2.95%
34	2.0	90359.48	468.10	88133.29	2554.98	29830.27	59.45	4973	47041	2.46%
35	0.1	72622.22	2.87	69139.14	15.32	5864.03	49.60	317	2956	4.80%
35	0.5	75558.52	46.71	72154.28	329.96	13981.49	52.16	1610	15419	4.51%
35	2.0	79632.71	531.44	76782.17	1880.38	27280.34	59.26	5704	51834	3.58%
36	0.1	88026.28	1.62	85198.54	17.64	7192.75	49.63	320	2928	3.21%
36	0.5	91573.56	31.84	88123.14	195.82	16227.37	52.22	1605	13925	3.77%
36	2.0	95414.25	411.78	92810.23	2110.72	31668.74	59.22	5145	47809	2.73%
37	0.1	86870.04	1.52	83718.51	28.38	7134.07	49.53	299	2983	3.63%
37	0.5	90396.67	29.10	87255.88	310.15	16227.59	52.21	1447	14203	3.47%
37	2.0	94432.97	458.63	92063.99	2719.16	31261.30	59.42	4909	47344	2.51%
38	0.1	78018.41	1.51	76025.85	18.08	6494.63	49.66	294	2999	2.55%
38	0.5	81123.61	32.89	79093.15	260.92	14995.18	52.20	1589	14760	2.50%
38	2.0	85615.11	531.77	83954.01	3455.40	29332.58	59.35	5640	50125	1.94%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
39	0.1	85781.29	2.17	83150.37	18.44	6875.90	49.62	295	2809	3.07%
39	0.5	89571.40	50.23	86637.89	300.69	16309.75	52.26	1570	14553	3.28%
39	2.0	93586.52	498.80	91361.26	2227.90	31330.50	59.27	5066	48288	2.38%
40	0.1	74843.11	1.95	72075.26	28.80	5843.55	49.55	282	2701	3.70%
40	0.5	77922.09	39.11	75045.40	339.23	13946.47	52.20	1536	14183	3.69%
40	2.0	82048.50	488.78	79781.21	2724.40	27824.34	59.32	5497	49943	2.76%
41	0.1	87515.08	2.06	83783.71	32.20	7278.77	49.52	308	3101	4.26%
41	0.5	90988.65	36.49	87393.63	260.57	16217.78	52.16	1480	14142	3.95%
41	2.0	95017.14	535.81	92411.71	1555.07	32009.79	59.45	5371	49266	2.74%
42	0.1	82510.17	1.47	80340.41	27.85	7030.44	49.65	321	3147	2.63%
42	0.5	86085.51	40.64	83886.43	267.42	16148.87	52.21	1696	15219	2.55%
42	2.0	91007.56	574.21	88724.21	2829.60	31015.33	59.13	5548	50176	2.51%
43	0.1	83767.36	1.70	82233.99	30.77	6675.47	49.62	315	2707	1.83%
43	0.5	87543.74	37.25	85682.68	295.37	15851.28	52.11	1494	14054	2.13%
43	2.0	92452.06	523.53	90707.77	1594.43	31619.49	59.34	5465	49894	1.89%
44	0.1	74703.09	2.14	72705.65	40.54	5930.85	49.58	244	2734	2.67%
44	0.5	77937.72	44.35	75845.47	286.87	14267.71	52.19	1650	14533	2.68%
44	2.0	82646.68	595.55	80932.09	3415.29	28557.78	59.31	5754	51125	2.07%
45	0.1	91323.35	1.72	88461.41	32.76	7450.10	49.58	302	2915	3.13%
45	0.5	94368.82	45.69	92055.17	311.77	17077.67	52.33	1524	14134	2.45%
45	2.0	98644.92	464.39	96778.75	2122.30	32619.45	59.28	5134	46647	1.89%
46	0.1	74883.87	1.62	72443.82	29.93	6293.88	49.64	372	3101	3.26%
46	0.5	78565.39	36.61	75472.25	403.26	14379.57	52.20	1515	14907	3.94%
46	2.0	82759.37	500.52	80237.50	2779.44	28304.07	59.24	6004	51094	3.05%
47	0.1	81058.48	1.73	78005.21	26.57	6333.12	49.61	243	2709	3.77%
47	0.5	84528.47	35.95	81066.95	328.22	14791.36	52.20	1530	13672	4.10%
47	2.0	87989.70	534.81	85606.54	2994.79	29360.59	59.34	5411	48300	2.71%
48	0.1	73708.20	2.31	70473.54	35.54	5758.00	49.60	341	2743	4.39%
48	0.5	77000.86	56.88	73541.15	180.82	13915.80	52.18	1629	14704	4.49%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)	
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP	
48	2.0	81261.36	635.61	78241.79	2790.52	28104.43	59.48	5724	52979	3.72%	
49	0.1	81594.92	1.70	78862.71	31.59	6571.49	49.61	310	2853	3.35%	
49	0.5	84660.86	33.76	82302.62	235.12	15408.32	52.23	1565	14393	2.79%	
49	2.0	88871.99	440.86	87020.76	2561.51	30194.23	59.44	5436	49436	2.08%	
50	0.1	82731.44	1.78	79620.40	22.05	6655.06	49.60	296	2870	3.76%	
50	0.5	85312.44	30.75	82723.54	286.97	15169.31	52.12	1476	13809	3.03%	
50	2.0	88700.45	456.29	86903.11	1826.85	29461.32	59.39	5020	47192	2.03%	
51	0.1	83567.97	2.39	80809.24	52.65	6492.49	49.58	229	2652	3.30%	
51	0.5	86841.42	48.39	84006.57	310.75	15419.08	52.26	1472	13835	3.26%	
51	2.0	91261.37	486.85	88255.89	3002.15	30525.75	59.24	5305	49122	3.29%	
52	0.1	74328.16	1.68	71330.03	45.48	6141.79	49.60	320	3046	4.03%	
52	0.5	76874.97	32.38	74558.50	419.87	14404.85	52.31	1705	15329	3.01%	
52	2.0	81468.91	494.60	79249.43	4288.84	28499.37	59.16	5802	53102	2.72%	
53	0.1	76269.34	1.80	73644.28	55.80	6103.92	49.68	319	2823	3.44%	
53	0.5	78733.85	32.33	76640.10	474.83	14235.76	52.19	1616	14168	2.66%	
53	2.0	83136.95	553.82	81182.80	3072.36	28408.44	59.47	5547	50280	2.35%	
54	0.1	79007.69	1.80	76619.34	52.69	6358.15	49.71	323	2829	3.02%	
54	0.5	82406.43	30.77	79589.62	417.35	14702.63	52.23	1572	14014	3.42%	
54	2.0	86344.17	409.47	84018.77	2994.78	28842.06	59.18	5175	48388	2.69%	
55	0.1	79855.09	1.77	77817.04	55.69	6277.57	49.49	283	2675	2.55%	
55	0.5	82792.05	31.99	81081.01	455.46	15132.27	52.25	1490	14304	2.07%	
55	2.0	87301.52	499.25	85316.44	2587.01	29326.81	58.98	5140	48517	2.27%	
56	0.1	81276.10	1.86	78373.84	44.70	6504.99	49.66	268	2830	3.57%	
56	0.5	84070.79	32.03	81571.03	308.26	15252.25	52.23	1664	14357	2.97%	
56	2.0	87866.76	421.38	86276.78	2763.82	29823.10	59.38	5191	49063	1.81%	
57	0.1	79297.19	1.74	75861.79	34.83	6387.86	49.71	330	2914	4.33%	
57	0.5	82599.18	31.09	78883.80	363.70	14875.48	52.16	1551	14603	4.50%	
57	2.0	86141.56	513.30	83177.30	3564.88	28722.46	59.18	5561	48962	3.44%	
58	0.1	74673.56	2.43	71901.81	28.44	5835.66	49.64	310	2707	3.71%	

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
58	0.5	77586.95	35.10	74833.33	259.95	13697.62	52.19	1541	13758	3.55%
58	2.0	81263.98	495.49	78758.56	2299.51	26679.04	59.18	5133	47117	3.08%
59	0.1	86184.15	2.48	82798.94	34.29	7017.38	49.52	296	2952	3.93%
59	0.5	89100.28	43.80	86312.12	273.54	15927.37	52.25	1517	13984	3.13%
59	2.0	93291.98	457.91	90764.12	2478.82	30956.94	59.20	5307	47767	2.71%
60	0.1	75064.34	1.62	72385.42	46.51	6069.12	49.58	356	2888	3.57%
60	0.5	77975.38	34.00	75148.54	357.71	14050.52	52.20	1504	14356	3.63%
60	2.0	81660.54	463.10	79488.06	3281.61	27639.62	59.37	5326	49646	2.66%
61	0.1	71457.15	1.71	69055.98	45.23	5734.76	49.64	331	2834	3.36%
61	0.5	74716.82	33.69	71956.81	365.68	13655.19	52.27	1692	14789	3.69%
61	2.0	78790.68	588.02	76332.18	3956.92	27030.44	59.27	5619	51489	3.12%
62	0.1	81585.59	2.95	78566.84	29.76	6692.27	49.66	323	2981	3.70%
62	0.5	85576.37	52.52	81790.02	465.13	15560.35	52.30	1580	14864	4.42%
62	2.0	89289.78	577.88	86644.71	2572.62	30465.72	59.44	5534	50766	2.96%
63	0.1	83990.82	1.70	80318.20	48.49	6622.81	49.56	300	2794	4.37%
63	0.5	87290.37	47.76	83436.71	316.24	15668.19	52.33	1494	14481	4.41%
63	2.0	91113.38	496.86	87936.71	3056.88	30468.19	59.29	5148	49293	3.49%
64	0.1	80039.71	2.53	77469.79	28.59	6359.46	49.56	275	2769	3.21%
64	0.5	83029.64	46.76	80636.86	216.88	14971.63	52.17	1552	14157	2.88%
64	2.0	87148.88	532.33	85354.17	3083.86	29295.64	59.23	5105	48371	2.06%
65	0.1	73740.95	2.10	71051.63	48.41	5770.75	49.63	270	2711	3.65%
65	0.5	76384.15	43.33	73832.53	264.57	13730.13	52.32	1420	14201	3.34%
65	2.0	80067.13	529.95	77920.41	2063.05	27045.75	59.41	5298	49468	2.68%
66	0.1	82387.58	3.59	78873.02	34.95	6365.34	49.63	295	2676	4.27%
66	0.5	85612.35	39.73	82177.89	308.99	15239.24	52.28	1531	14122	4.01%
66	2.0	89560.67	561.90	86747.80	2090.08	29705.07	59.27	5492	48148	3.14%
67	0.1	79333.80	2.22	76249.95	43.13	6431.00	49.61	293	2923	3.89%
67	0.5	82349.93	43.43	79498.67	296.89	14905.83	52.26	1616	14437	3.46%
67	2.0	86316.21	541.64	83843.44	2396.19	28864.99	59.32	5369	48667	2.86%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	
68	0.1	76517.21	1.67	74177.58	36.67	6208.87	49.72	271	2878	3.06%
68	0.5	79421.48	35.07	77174.99	260.36	14509.73	52.23	1630	14516	2.83%
68	2.0	83668.58	453.75	81442.22	2935.46	28255.78	59.27	5288	49426	2.66%
69	0.1	79386.59	2.04	76088.63	56.55	6288.91	49.64	313	2807	4.15%
69	0.5	82708.95	40.36	79177.96	273.77	15102.85	52.31	1651	14941	4.27%
69	2.0	86560.21	583.50	83780.60	2857.09	29203.96	59.14	5438	49892	3.21%
70	0.1	77743.47	2.67	75713.85	55.42	6191.00	49.52	273	2748	2.61%
70	0.5	80985.55	48.73	79243.87	477.32	15122.56	52.28	1622	14955	2.15%
70	2.0	85234.40	586.87	83781.85	2837.15	29127.76	59.26	5381	49630	1.70%
71	0.1	79294.29	1.92	77090.27	29.32	6283.85	49.62	213	2730	2.78%
71	0.5	82733.61	46.81	80089.89	326.00	14766.50	52.18	1495	13960	3.20%
71	2.0	86799.88	539.95	84566.57	3284.53	29069.21	59.41	5170	48517	2.57%
72	0.1	85447.57	1.85	83110.63	31.81	6715.96	49.65	285	2684	2.73%
72	0.5	89135.49	36.02	86787.91	316.47	15980.49	52.17	1562	13923	2.63%
72	2.0	93411.96	535.61	91737.18	2997.83	31613.50	59.31	5479	48763	1.79%
73	0.1	77728.79	2.48	74939.05	41.72	6256.07	49.54	289	2863	3.59%
73	0.5	80794.00	48.50	78145.66	485.66	14701.68	52.21	1489	14534	3.28%
73	2.0	85001.30	561.23	82638.46	2857.16	28921.47	59.17	5470	50293	2.78%
74	0.1	86750.28	2.09	83003.37	36.39	6953.47	49.71	330	2883	4.32%
74	0.5	89994.29	33.27	86393.15	349.57	16290.42	52.22	1608	14601	4.00%
74	2.0	94192.75	437.28	91233.89	1406.82	31638.02	59.52	5369	49378	3.14%
75	0.1	71255.48	1.87	68376.53	36.08	5864.60	49.70	274	3022	4.04%
75	0.5	73915.16	39.51	71194.83	278.00	13677.64	52.06	1505	15157	3.68%
75	2.0	77829.39	643.07	75822.86	3202.02	27045.87	59.32	5856	52243	2.58%
76	0.1	75347.80	2.47	72117.29	28.07	5912.70	49.65	290	2762	4.29%
76	0.5	78525.43	47.77	75301.53	445.76	14359.34	52.38	1633	14932	4.11%
76	2.0	82834.54	537.31	79634.19	2393.31	28441.10	59.04	5345	52375	3.86%
77	0.1	77091.63	1.92	74363.90	50.97	6287.33	49.67	259	2938	3.54%
77	0.5	80304.89	37.01	77281.76	450.55	14354.50	52.14	1617	14167	3.76%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
77	2.0	83863.96	492.27	81573.79	3657.34	28153.54	59.31	5121	48909	2.73%
78	0.1	77269.07	3.35	73946.69	52.03	6147.03	49.66	245	2839	4.30%
78	0.5	80213.93	48.26	76921.23	251.91	14308.19	52.29	1563	14209	4.10%
78	2.0	84444.83	578.84	81193.21	3011.84	28257.15	59.01	5262	49733	3.85%
79	0.1	81047.16	2.37	77788.74	69.25	6329.92	49.63	292	2722	4.02%
79	0.5	84485.88	50.64	80928.63	304.19	15031.22	52.20	1608	14166	4.21%
79	2.0	88272.87	569.30	85045.77	3238.96	29403.24	59.20	5340	49081	3.66%
80	0.1	86893.08	3.11	83572.02	68.06	6944.30	49.61	279	2837	3.82%
80	0.5	90131.93	44.88	87012.59	358.62	16264.79	52.31	1487	14349	3.46%
80	2.0	93851.68	451.35	91399.64	3141.46	31236.37	59.27	4939	47958	2.61%
81	0.1	78356.70	1.86	75844.98	66.23	6268.96	49.59	277	2807	3.21%
81	0.5	81739.60	36.15	78803.39	337.46	14677.10	52.25	1508	14245	3.59%
81	2.0	85586.03	522.21	83275.54	2592.67	28973.80	59.40	5306	49705	2.70%
82	0.1	78754.09	2.85	75454.18	48.40	6204.06	49.63	237	2778	4.19%
82	0.5	81858.06	52.45	78480.73	376.94	14640.44	52.30	1606	14291	4.13%
82	2.0	85541.51	558.79	82712.57	3850.26	28984.75	59.40	5490	50422	3.31%
83	0.1	81217.76	1.84	78000.19	64.72	6401.14	49.61	329	2767	3.96%
83	0.5	84265.95	31.83	81117.13	476.07	15070.41	52.29	1538	14174	3.74%
83	2.0	87967.62	510.44	85653.30	2973.57	29456.91	59.10	5548	48564	2.63%
84	0.1	82121.40	2.04	79248.22	36.84	6672.19	49.60	259	2913	3.50%
84	0.5	85934.43	35.46	82727.94	278.94	15691.99	52.32	1579	14775	3.73%
84	2.0	89843.42	445.85	87326.77	3175.45	30377.77	59.06	5503	49688	2.80%
85	0.1	83140.49	1.83	79739.09	60.11	6700.18	49.69	365	2902	4.09%
85	0.5	86266.92	31.75	82863.14	505.32	15560.07	52.20	1512	14480	3.95%
85	2.0	89722.45	436.43	87391.84	3508.28	29977.12	59.38	5056	48313	2.60%
86	0.1	73795.21	3.03	70341.36	43.55	5862.12	49.64	302	2853	4.68%
86	0.5	77123.04	58.79	73537.04	483.99	14217.17	52.37	1550	15349	4.65%
86	2.0	81474.65	623.95	78228.62	3011.71	28403.43	59.20	5755	54130	3.98%
87	0.1	84384.08	1.88	80928.86	60.00	6776.94	49.62	249	2881	4.09%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
87	0.5	87698.13	32.16	84312.21	415.31	15719.27	52.27	1474	14274	3.86%
87	2.0	91437.92	431.33	89012.29	2637.53	30408.87	59.17	5205	47921	2.65%
88	0.1	81225.51	1.87	78138.24	59.53	6513.82	49.64	328	2855	3.80%
88	0.5	84628.82	32.57	81681.93	440.73	15633.66	52.41	1555	15044	3.48%
88	2.0	88800.28	517.56	86139.11	2849.65	29989.86	59.07	5305	49771	3.00%
89	0.1	82466.06	2.65	79577.13	70.44	6542.60	49.60	294	2777	3.50%
89	0.5	85587.25	35.84	82704.92	402.49	15475.46	52.26	1589	14378	3.37%
89	2.0	89903.27	523.80	87446.68	3017.67	30210.13	59.29	5285	49006	2.73%
90	0.1	79220.68	2.10	76504.35	45.73	6310.49	49.62	304	2796	3.43%
90	0.5	82383.56	34.95	80002.56	410.70	15147.06	52.25	1522	14720	2.89%
90	2.0	86349.97	514.07	84396.30	3577.46	29223.32	59.15	5653	49231	2.26%
91	0.1	74379.10	1.64	71421.71	56.44	5880.54	49.56	279	2785	3.98%
91	0.5	77256.83	33.54	74374.77	337.78	14108.31	52.23	1686	14777	3.73%
91	2.0	81362.65	499.53	78785.83	3748.95	27822.03	59.11	5757	51206	3.17%
92	0.1	76973.84	2.87	74155.88	40.05	6306.60	49.63	292	2973	3.66%
92	0.5	80258.46	35.55	77134.17	340.14	14487.74	52.18	1546	14487	3.89%
92	2.0	83860.59	587.10	81535.02	3704.01	28195.12	59.36	5189	49101	2.77%
93	0.1	80162.74	2.53	77447.29	66.00	6428.86	49.63	269	2832	3.39%
93	0.5	83476.24	50.33	80699.32	318.23	15220.49	52.31	1504	14608	3.33%
93	2.0	87438.59	543.07	85184.61	2556.61	29785.44	59.09	5206	50201	2.58%
94	0.1	79923.51	2.25	77115.83	53.00	6443.25	49.61	263	2869	3.51%
94	0.5	83316.59	39.06	80341.54	312.60	15117.45	52.18	1531	14539	3.57%
94	2.0	87306.03	512.90	85069.54	3618.97	30019.55	59.28	5414	51132	2.56%
95	0.1	76696.31	2.58	73172.15	31.97	6177.86	49.68	359	2929	4.59%
95	0.5	79542.83	34.93	76149.36	493.22	14261.83	52.24	1467	14404	4.27%
95	2.0	83098.73	489.92	80335.14	2754.46	27823.27	59.14	5310	49253	3.33%
96	0.1	75661.15	1.86	72878.13	40.81	5890.30	49.65	243	2684	3.68%
96	0.5	79198.38	38.94	75918.45	436.45	14317.51	52.18	1566	14606	4.14%
96	2.0	83162.19	515.23	80142.94	3149.68	27954.65	59.34	5384	49959	3.63%

Continua na página seguinte

Tabela 15 – Resultado do SimSA-Esperado x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(2) SimSA-Esperado						(1) x (2)
		TEC _E	Tempo	TEC _E	Tempo	Desvio	M _E	Nsc	Nsl	GAP
97	0.1	82851.51	1.96	79854.34	69.89	6661.54	49.59	316	2859	3.62%
97	0.5	86275.35	35.13	83136.60	470.26	15594.14	52.10	1611	14448	3.64%
97	2.0	90055.69	494.08	87510.46	2081.02	29947.35	58.94	5230	48088	2.83%
98	0.1	76145.89	2.13	72707.93	49.64	6089.49	49.64	278	2882	4.51%
98	0.5	79138.05	36.68	75675.78	476.98	14373.30	52.22	1651	14814	4.37%
98	2.0	83209.70	618.18	80156.98	3774.62	28296.73	59.27	5781	51170	3.67%
99	0.1	86126.16	3.32	83139.77	38.34	7080.67	49.68	309	2980	3.47%
99	0.5	89309.99	52.34	86422.28	344.11	16169.71	52.34	1688	14375	3.23%
99	2.0	93356.88	500.69	90986.89	3900.98	31400.20	59.27	5294	48903	2.54%
100	0.1	83240.66	1.74	79777.72	71.01	6700.36	49.59	341	2899	4.16%
100	0.5	86592.62	31.85	83235.29	430.31	15633.85	52.29	1492	14487	3.88%
100	2.0	90277.35	430.50	87559.28	3511.01	30169.20	59.29	5023	48747	3.01%

APÊNDICE B – COMPARAÇÃO ENTRE SIMSA-VAR X GIH-GRASP

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
1	0.1	97512.17	4.38	91087.42	43.49	6401.71	49.63	256	2651	6.59%
1	0.5	115019.43	25.15	109969.27	398.77	14944.40	52.20	1474	13294	4.39%
1	2.0	145171.99	335.74	144038.59	4554.86	29533.37	59.59	5062	46948	0.78%
2	0.1	82317.83	1.31	76820.79	21.14	5519.43	49.59	285	2786	6.68%
2	0.5	101949.61	33.39	93704.10	191.83	13137.06	52.23	1605	14570	8.09%
2	2.0	131241.57	437.92	128755.06	4744.23	26833.50	59.32	5249	50367	1.89%
3	0.1	89914.07	1.25	87245.83	37.71	6063.15	49.52	259	2600	2.97%
3	0.5	110333.73	29.48	102381.28	140.01	14378.28	52.26	1565	14720	7.21%
3	2.0	143573.21	510.47	136883.25	1618.74	28571.49	59.51	5467	51123	4.66%
4	0.1	98508.61	1.33	90458.28	8.61	6562.41	49.61	344	2828	8.17%
4	0.5	117890.25	31.69	110415.64	125.32	15484.73	52.10	1620	14442	6.34%
4	2.0	151177.38	376.79	147233.77	4543.84	30642.31	59.54	5508	50249	2.61%
5	0.1	92502.73	1.27	90180.06	26.49	6463.40	49.58	276	2746	2.51%
5	0.5	111921.55	26.47	109576.18	353.51	14986.51	52.16	1418	13752	2.10%
5	2.0	143606.00	384.51	143321.14	5136.59	29265.86	59.19	5051	46827	0.20%
6	0.1	88637.22	1.33	85491.74	28.92	6009.71	49.52	255	2641	3.55%
6	0.5	107261.46	27.97	104094.49	209.85	14179.18	52.14	1419	13522	2.95%
6	2.0	139968.66	489.32	136440.49	5860.80	28197.50	59.36	5235	48261	2.52%
7	0.1	96132.98	1.28	93328.86	16.98	6807.94	49.53	291	2841	2.92%
7	0.5	114673.86	26.03	113102.00	390.28	15476.37	52.29	1453	13669	1.37%
7	2.0	147168.75	462.73	146587.90	4196.49	29575.63	59.61	4804	44767	0.39%
8	0.1	93532.20	1.79	92252.51	14.84	6333.78	49.49	252	2507	1.37%
8	0.5	116039.23	33.66	113247.59	287.23	15613.12	52.19	1437	14042	2.41%
8	2.0	150035.68	527.43	149285.65	4611.70	30884.24	59.39	5189	48588	0.50%
9	0.1	104509.29	1.13	97527.68	9.44	7307.91	49.55	316	3061	6.68%
9	0.5	125626.55	23.97	118111.66	126.24	16589.42	52.17	1476	14645	5.98%
9	2.0	160712.41	340.99	155760.53	3095.94	32099.68	59.39	5488	48484	3.08%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
10	0.1	90975.22	1.38	85546.10	24.59	6054.93	49.68	327	2691	5.97%
10	0.5	111337.67	29.07	106421.70	312.03	14567.02	52.13	1385	13691	4.42%
10	2.0	142506.65	414.92	138293.79	1536.69	28708.35	59.27	5397	49729	2.96%
11	0.1	95577.51	1.34	94135.92	21.39	6754.31	49.63	264	2761	1.51%
11	0.5	115941.05	34.28	114561.71	365.52	16159.90	52.24	1490	14762	1.19%
11	2.0	150330.94	458.57	149957.72	4910.07	30978.83	59.49	5306	48637	0.25%
12	0.1	96853.23	1.66	93234.49	14.13	6581.97	49.30	252	2668	3.74%
12	0.5	117148.42	36.68	112763.65	234.07	15680.67	52.23	1452	14323	3.74%
12	2.0	149450.24	531.78	148064.58	3339.30	30637.42	59.23	5451	47920	0.93%
13	0.1	80250.81	1.72	78592.12	14.78	5522.16	49.57	271	2642	2.07%
13	0.5	97960.74	44.61	96443.79	252.49	13193.52	52.24	1429	13770	1.55%
13	2.0	128136.97	562.65	127827.46	5686.35	26826.51	59.35	5459	51152	0.24%
14	0.1	57394.11	3.42	53373.14	8.91	3804.69	49.56	328	2776	7.01%
14	0.5	74514.35	101.53	69641.59	439.72	10367.93	52.33	1802	17381	6.54%
14	2.0	102380.75	1125.34	99661.34	6870.13	22446.37	59.81	7257	67603	2.66%
15	0.1	82442.46	1.51	79863.83	28.66	5718.26	49.54	237	2738	3.13%
15	0.5	100719.53	32.73	97670.91	142.16	13254.60	52.15	1510	13553	3.03%
15	2.0	131776.56	580.76	130541.35	3426.30	26969.42	59.51	5265	49106	0.94%
16	0.1	67983.09	1.43	64914.54	12.07	4658.10	49.33	347	2788	4.51%
16	0.5	86733.17	43.22	81842.68	334.14	12001.48	51.93	1892	16779	5.64%
16	2.0	116516.58	764.99	112285.30	1979.08	24447.69	59.41	6609	59679	3.63%
17	0.1	91025.44	1.36	89026.98	32.45	6228.01	49.54	233	2597	2.20%
17	0.5	111827.77	31.21	108289.11	272.01	15075.83	52.13	1500	14239	3.16%
17	2.0	144270.68	435.40	143085.88	3877.80	29417.43	59.40	5095	47747	0.82%
18	0.1	81728.87	1.17	80565.38	25.47	5727.56	49.50	239	2711	1.42%
18	0.5	99873.66	26.84	96756.78	462.49	13364.59	52.05	1560	14195	3.12%
18	2.0	131930.90	513.09	131741.01	5958.20	27469.83	59.25	5557	50785	0.14%
19	0.1	89790.18	1.54	86722.57	33.51	6181.09	49.60	290	2727	3.42%
19	0.5	110623.53	34.74	105934.86	289.21	14719.67	52.11	1565	14270	4.24%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
19	2.0	142480.87	555.37	141187.93	5516.01	29188.77	59.44	5245	49079	0.91%
20	0.1	104862.66	1.68	100624.54	48.13	7191.19	49.63	278	2742	4.04%
20	0.5	124261.40	29.38	121585.83	507.42	16725.31	52.26	1326	13837	2.15%
20	2.0	158012.53	384.59	156261.29	3286.28	31812.86	59.65	4883	45511	1.11%
21	0.1	101879.64	1.60	100623.83	12.92	7218.84	49.87	242	2771	1.23%
21	0.5	122427.44	36.18	122089.14	253.99	16818.42	52.15	1404	13961	0.28%
21	2.0	157637.14	394.09	156915.21	4601.05	31881.95	59.23	4748	45053	0.46%
22	0.1	54859.76	2.06	51567.78	9.33	3930.84	49.19	354	3190	6.00%
22	0.5	69764.10	59.96	65427.69	196.04	9958.50	51.66	2110	18577	6.22%
22	2.0	96330.58	982.24	93236.24	7037.91	21192.38	58.94	7742	70090	3.21%
23	0.1	86798.61	1.33	80966.91	16.68	5726.07	49.52	305	2680	6.72%
23	0.5	105541.21	31.52	98482.42	181.45	13661.41	52.24	1548	14136	6.69%
23	2.0	135974.27	517.43	134732.74	4674.83	27860.65	59.56	5270	48615	0.91%
24	0.1	94885.65	0.94	90653.39	11.15	6641.96	49.61	286	2898	4.46%
24	0.5	115725.07	25.23	110145.12	160.50	15433.81	52.23	1604	14515	4.82%
24	2.0	149703.70	457.87	149527.08	4316.44	30902.83	59.24	5138	48191	0.12%
25	0.1	99370.09	1.89	96728.84	19.13	7004.97	49.62	270	2812	2.66%
25	0.5	120599.03	37.90	116788.09	316.15	15994.56	52.28	1412	13571	3.16%
25	2.0	152791.09	417.59	152402.38	4330.16	31000.94	59.50	4949	46030	0.25%
26	0.1	83889.49	1.66	80718.43	38.22	5842.42	49.64	246	2839	3.78%
26	0.5	101720.92	37.78	98628.52	282.40	13627.87	52.19	1482	14187	3.04%
26	2.0	131542.95	525.06	129067.60	3813.26	26751.44	59.32	5102	48926	1.88%
27	0.1	88343.81	2.14	84783.79	24.52	6234.33	49.62	269	2932	4.03%
27	0.5	107969.37	45.16	103585.33	516.94	14427.37	52.25	1493	14386	4.06%
27	2.0	140275.63	544.86	137335.06	4875.29	28712.58	59.36	5484	51000	2.10%
28	0.1	100369.65	1.97	97882.56	39.20	7302.38	49.68	256	3019	2.48%
28	0.5	122434.27	45.12	119487.60	382.50	16747.12	52.10	1550	14558	2.41%
28	2.0	156686.82	487.13	155715.24	4430.78	32137.39	59.38	5230	48301	0.62%
29	0.1	78329.28	2.42	74859.33	18.43	5344.67	49.63	275	2748	4.43%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
29	0.5	95117.74	51.82	91509.73	439.43	12668.81	52.23	1487	14196	3.79%
29	2.0	124782.05	582.10	121738.28	5313.61	25372.67	59.34	5545	50192	2.44%
30	0.1	98399.13	1.35	95783.43	53.77	6977.46	49.64	295	2832	2.66%
30	0.5	120181.34	29.27	117328.84	513.51	16225.80	52.16	1461	14155	2.37%
30	2.0	152186.55	474.24	151242.51	4158.29	31022.36	59.28	5220	46904	0.62%
31	0.1	92660.17	1.64	89273.72	45.22	6430.73	49.61	311	2794	3.65%
31	0.5	112615.90	31.85	109098.45	447.92	15090.97	52.14	1426	14150	3.12%
31	2.0	143326.17	496.01	140701.05	4292.99	29005.22	59.19	5012	47279	1.83%
32	0.1	89528.96	2.14	85669.20	45.24	6210.15	49.60	246	2814	4.31%
32	0.5	109405.71	33.00	105158.35	538.14	14492.58	52.25	1511	14119	3.88%
32	2.0	139883.23	431.48	138173.34	4699.55	28686.23	59.39	5351	49371	1.22%
33	0.1	93933.92	1.62	91060.36	41.39	6668.30	49.60	273	2908	3.06%
33	0.5	114036.51	33.08	110368.17	575.06	15507.29	52.22	1444	14601	3.22%
33	2.0	147962.97	511.84	146733.32	5456.38	30559.01	59.13	5386	50540	0.83%
34	0.1	96688.12	2.44	92479.08	52.81	6753.99	49.52	280	2862	4.35%
34	0.5	115757.57	47.96	111965.21	406.18	15541.74	52.18	1414	14144	3.28%
34	2.0	147085.68	468.10	145340.73	3577.64	29810.08	59.33	5098	46942	1.19%
35	0.1	84080.89	2.87	79177.49	40.31	5596.26	49.62	223	2669	5.83%
35	0.5	101303.73	46.71	97550.98	630.74	13548.56	52.28	1471	14372	3.70%
35	2.0	132111.82	531.44	130114.43	6438.40	27358.79	59.19	5775	52126	1.51%
36	0.1	100840.80	1.62	97899.71	24.99	7145.46	49.65	230	2894	2.92%
36	0.5	122533.82	31.84	118752.73	506.27	16454.09	52.25	1499	14211	3.09%
36	2.0	154942.60	411.78	153701.73	4046.72	31353.73	59.59	4906	46323	0.80%
37	0.1	99659.12	1.52	95605.10	46.03	6638.43	49.60	272	2560	4.07%
37	0.5	120555.31	29.10	117213.69	476.38	16206.84	52.11	1379	14184	2.77%
37	2.0	152940.23	458.63	152727.65	4921.20	31578.59	59.54	5117	48142	0.14%
38	0.1	89442.43	1.51	87423.41	40.86	6438.59	49.55	239	2941	2.26%
38	0.5	109348.34	32.89	106809.16	483.42	15006.76	52.19	1475	14721	2.32%
38	2.0	141745.38	531.77	140920.73	3581.48	29513.70	59.56	5485	50560	0.58%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
39	0.1	98819.60	2.17	95186.18	36.87	6868.18	49.62	244	2797	3.68%
39	0.5	121182.43	50.23	116127.33	415.58	15989.41	52.14	1490	13951	4.17%
39	2.0	153255.72	498.80	151572.17	5310.00	31294.54	59.42	5087	47944	1.10%
40	0.1	86700.75	1.95	82344.29	47.59	5824.79	49.66	275	2685	5.02%
40	0.5	105580.65	39.11	100781.02	395.54	13948.27	52.24	1467	14205	4.55%
40	2.0	136248.65	488.78	134224.89	4303.60	27891.80	59.54	5357	50146	1.49%
41	0.1	101165.21	2.06	95845.15	33.66	6929.66	49.62	270	2817	5.26%
41	0.5	123352.51	36.49	117275.64	329.00	16336.70	52.32	1472	14360	4.93%
41	2.0	156287.82	535.81	153981.15	5677.35	31788.94	59.26	5248	48206	1.48%
42	0.1	94740.13	1.47	92435.10	32.61	6932.74	49.57	290	3041	2.43%
42	0.5	116008.26	40.64	112949.75	355.81	16026.34	52.19	1594	14987	2.64%
42	2.0	151303.17	574.21	148708.03	4409.67	31174.76	59.28	5690	50434	1.72%
43	0.1	96863.24	1.70	93757.88	39.90	6542.84	49.60	240	2588	3.21%
43	0.5	118758.65	37.25	114884.42	493.98	15896.33	52.30	1428	14112	3.26%
43	2.0	153861.29	523.53	151948.59	3003.57	31248.61	59.43	5149	48414	1.24%
44	0.1	85410.63	2.14	83167.11	24.92	6054.02	49.62	241	2852	2.63%
44	0.5	105430.89	44.35	102874.04	497.70	14444.68	52.24	1562	14878	2.43%
44	2.0	137486.57	595.55	136048.58	4592.69	28576.52	59.30	5446	51330	1.05%
45	0.1	105424.83	1.72	101120.15	28.65	7285.88	49.54	226	2786	4.08%
45	0.5	126553.62	45.69	122924.11	289.02	16888.92	52.22	1417	13879	2.87%
45	2.0	160439.15	464.39	159496.71	5168.56	32715.38	59.37	5116	46755	0.59%
46	0.1	86104.12	1.62	83198.47	37.29	6098.62	49.63	264	2914	3.37%
46	0.5	106219.18	36.61	101090.94	356.77	14169.55	52.09	1559	14511	4.83%
46	2.0	136775.87	500.52	135549.44	3508.95	28352.75	59.44	5535	51286	0.90%
47	0.1	93368.67	1.73	88998.53	20.72	6321.10	49.60	264	2697	4.68%
47	0.5	113520.43	35.95	108805.09	508.12	14783.69	52.26	1414	13418	4.15%
47	2.0	143693.27	534.81	142760.02	3062.25	29460.04	59.38	4915	48525	0.65%
48	0.1	84701.76	2.31	80438.84	37.99	5620.44	49.56	251	2619	5.03%
48	0.5	104484.34	56.88	98558.95	533.24	13678.98	52.23	1574	14285	5.67%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
48	2.0	136365.91	635.61	131950.25	4793.02	27680.69	59.30	5676	51524	3.24%
49	0.1	94062.67	1.70	90823.66	33.91	6776.14	49.60	285	3013	3.44%
49	0.5	113476.88	33.76	110700.82	386.68	15389.69	52.19	1423	14293	2.45%
49	2.0	146347.03	440.86	145552.99	3685.66	30179.20	59.63	5349	49302	0.54%
50	0.1	96041.19	1.78	91485.38	42.12	6724.46	49.63	261	2929	4.74%
50	0.5	114564.28	30.75	110881.73	452.72	15341.63	52.14	1336	14067	3.21%
50	2.0	145129.67	456.29	143299.57	3695.94	29280.94	59.14	5016	46763	1.26%
51	0.1	95777.30	2.39	91725.94	64.05	6430.64	49.66	280	2614	4.23%
51	0.5	117010.86	48.39	112562.11	350.95	15548.87	52.10	1536	14079	3.80%
51	2.0	150109.88	486.85	147843.12	4750.65	30654.98	59.34	5046	49092	1.51%
52	0.1	85196.33	1.68	81868.14	81.64	5962.80	49.51	224	2876	3.91%
52	0.5	104011.53	32.38	100835.16	458.09	14320.18	52.29	1482	15206	3.05%
52	2.0	136044.37	494.60	135421.52	5545.30	28741.16	59.31	5880	53607	0.46%
53	0.1	88071.90	1.80	84160.94	62.48	6015.47	49.57	217	2731	4.44%
53	0.5	106246.44	32.33	103305.16	553.72	14312.25	52.28	1488	14275	2.77%
53	2.0	138831.24	553.82	136352.02	3564.82	28455.15	59.45	5310	50241	1.79%
54	0.1	90924.96	1.80	87703.33	73.65	6454.77	49.68	269	2923	3.54%
54	0.5	110960.76	30.77	106815.54	484.38	14817.14	52.26	1431	14214	3.74%
54	2.0	141199.59	409.47	139687.20	4411.61	29030.64	59.37	5304	49045	1.07%
55	0.1	92037.34	1.77	88497.30	39.85	6211.99	49.62	278	2622	3.85%
55	0.5	111327.62	31.99	109215.51	526.65	15214.62	52.21	1449	14491	1.90%
55	2.0	144794.29	499.25	142432.23	2700.79	29673.78	59.30	5319	49261	1.63%
56	0.1	93942.41	1.86	89710.53	15.73	6614.42	49.58	299	2936	4.50%
56	0.5	113199.75	32.03	110448.31	588.98	15518.39	52.33	1702	14853	2.43%
56	2.0	144777.84	421.38	144597.34	3354.96	30129.63	59.16	5118	48617	0.12%
57	0.1	91383.66	1.74	86975.50	53.35	6330.85	49.66	293	2854	4.82%
57	0.5	110916.64	31.09	105834.56	378.94	14771.10	52.17	1393	14454	4.58%
57	2.0	141563.68	513.30	139094.42	3765.97	28993.52	59.34	5112	49724	1.74%
58	0.1	85490.44	2.43	82424.55	46.16	5928.11	49.59	282	2780	3.59%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
58	0.5	103420.91	35.10	99742.32	570.26	13641.16	52.09	1495	13721	3.56%
58	2.0	132591.59	495.49	130527.87	2929.54	26842.50	59.20	4713	47670	1.56%
59	0.1	99091.13	2.48	94677.89	64.07	6865.14	49.56	288	2814	4.45%
59	0.5	120964.23	43.80	115535.66	543.60	15913.48	52.17	1460	13969	4.49%
59	2.0	151855.79	457.91	150629.02	2958.93	31016.89	59.32	5044	47573	0.81%
60	0.1	85948.90	1.62	82647.13	61.51	5969.43	49.61	242	2801	3.84%
60	0.5	105365.20	34.00	101225.87	490.74	14150.44	52.29	1461	14415	3.93%
60	2.0	133976.55	463.10	132787.23	3257.65	27863.68	59.38	5518	50400	0.89%
61	0.1	81969.86	1.71	79146.42	71.25	5670.93	49.65	287	2771	3.44%
61	0.5	100834.22	33.69	97086.15	466.90	13579.82	52.20	1572	14678	3.72%
61	2.0	131235.46	588.02	129048.23	4043.94	27286.78	59.30	5358	52474	1.67%
62	0.1	94129.13	2.95	89935.99	57.95	6431.47	49.57	252	2765	4.45%
62	0.5	115731.44	52.52	110408.12	471.43	15545.53	52.31	1502	14782	4.60%
62	2.0	147384.72	577.88	145734.38	3259.18	30390.17	59.37	5235	50343	1.12%
63	0.1	96133.86	1.70	92044.89	65.59	6657.76	49.64	228	2821	4.25%
63	0.5	116976.75	47.76	112277.93	576.76	15560.23	52.27	1575	14247	4.02%
63	2.0	148375.65	496.86	145517.59	3580.08	29775.45	59.18	5245	47335	1.93%
64	0.1	91720.43	2.53	88239.12	58.12	6304.18	49.55	206	2732	3.80%
64	0.5	111539.34	46.76	108545.24	475.59	15038.03	52.28	1455	14221	2.68%
64	2.0	142611.78	532.33	141482.33	3551.47	29253.71	59.35	5195	48268	0.79%
65	0.1	84716.18	2.10	80931.53	45.83	5706.51	49.57	275	2645	4.47%
65	0.5	102233.77	43.33	98897.39	372.58	13585.59	52.20	1426	13955	3.26%
65	2.0	131607.61	529.95	129678.00	2842.53	26869.32	59.33	5251	48791	1.47%
66	0.1	95308.98	3.59	89867.35	47.33	6408.30	49.61	255	2725	5.71%
66	0.5	115507.29	39.73	110029.75	599.76	15019.80	52.31	1415	13743	4.74%
66	2.0	147556.52	561.90	144109.95	4889.19	30363.50	59.27	5327	50182	2.34%
67	0.1	91675.84	2.22	87331.31	66.82	6488.19	49.56	271	2968	4.74%
67	0.5	111506.08	43.43	106843.60	643.07	14772.99	52.24	1473	14165	4.18%
67	2.0	142496.32	541.64	139738.47	3456.29	28860.09	59.43	5171	48419	1.94%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
68	0.1	87903.39	1.67	84779.44	44.33	6001.80	49.64	296	2685	3.55%
68	0.5	107843.57	35.07	103268.72	365.16	14399.16	52.29	1426	14292	4.24%
68	2.0	137757.32	453.75	136397.10	4387.73	28345.77	59.41	5377	49630	0.99%
69	0.1	92072.25	2.04	86893.34	54.70	6328.72	49.62	246	2847	5.62%
69	0.5	111568.46	40.36	106691.55	527.83	14969.34	52.21	1444	14631	4.37%
69	2.0	142081.49	583.50	141429.00	3570.77	29597.75	59.24	5234	50875	0.46%
70	0.1	89453.10	2.67	86739.75	36.01	6275.41	49.63	275	2803	3.03%
70	0.5	108914.03	48.73	107261.04	696.71	15098.69	52.30	1590	14909	1.52%
70	2.0	141506.52	586.87	140656.29	6116.14	29233.96	59.09	5304	50065	0.60%
71	0.1	91680.84	1.92	87928.47	36.66	6258.94	49.61	271	2708	4.09%
71	0.5	112432.29	46.81	107083.47	488.27	14748.41	52.20	1439	13959	4.76%
71	2.0	142650.89	539.95	140314.90	5039.16	29128.14	59.20	5109	48886	1.64%
72	0.1	98566.74	1.85	94881.30	32.13	6801.59	49.65	267	2745	3.74%
72	0.5	120827.11	36.02	116271.07	494.65	16087.14	52.27	1500	14099	3.77%
72	2.0	155103.04	535.61	152322.53	5397.93	31486.70	59.14	5206	48623	1.79%
73	0.1	88838.56	2.48	85954.01	117.31	6274.85	49.62	273	2891	3.25%
73	0.5	108237.41	48.50	105467.23	913.54	14768.07	52.23	1477	14736	2.56%
73	2.0	140772.74	561.23	138285.80	6262.33	28990.21	59.30	5461	50685	1.77%
74	0.1	100556.51	2.09	94910.32	29.15	6834.08	49.66	269	2787	5.61%
74	0.5	120930.01	33.27	116612.88	372.70	16252.04	52.24	1474	14475	3.57%
74	2.0	154426.42	437.28	151378.62	4177.48	31354.47	59.40	5178	48716	1.97%
75	0.1	81612.19	1.87	78222.38	44.85	5677.90	49.62	240	2846	4.15%
75	0.5	100171.68	39.51	96446.99	352.69	13742.96	52.30	1556	15283	3.72%
75	2.0	130832.22	643.07	128260.39	7259.65	27184.11	59.37	5526	52993	1.97%
76	0.1	85836.59	2.47	82430.61	102.56	5767.62	49.68	270	2617	3.97%
76	0.5	105528.67	47.77	101400.72	656.27	14156.16	52.29	1528	14511	3.91%
76	2.0	136884.22	537.31	134147.88	4312.88	28279.26	59.29	5380	51619	2.00%
77	0.1	88325.25	1.92	85844.52	67.82	6315.42	49.67	291	2955	2.81%
77	0.5	107956.17	37.01	104172.68	409.12	14436.52	52.31	1505	14250	3.50%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
77	2.0	138396.29	492.27	135581.41	5966.84	28297.46	59.04	5528	49532	2.03%
78	0.1	88679.42	3.35	84418.09	59.48	5994.30	49.59	282	2685	4.81%
78	0.5	108540.92	48.26	102874.53	523.86	14234.30	52.23	1377	14005	5.22%
78	2.0	138857.41	578.84	135813.46	4601.89	28208.07	59.26	5301	49589	2.19%
79	0.1	93378.15	2.37	88313.82	87.09	6179.16	49.60	308	2610	5.42%
79	0.5	114565.35	50.64	108234.06	598.48	14902.12	52.19	1604	13980	5.53%
79	2.0	144255.05	569.30	141254.44	5028.48	29362.29	59.28	5165	48891	2.08%
80	0.1	99945.21	3.11	95311.67	99.21	6746.77	49.65	222	2685	4.64%
80	0.5	120889.82	44.88	116496.14	494.66	16131.58	52.24	1526	14214	3.63%
80	2.0	152639.76	451.35	150469.55	4504.99	30953.18	59.19	5259	47291	1.42%
81	0.1	89771.41	1.86	86957.33	52.31	6351.15	49.61	253	2883	3.13%
81	0.5	110108.16	36.15	106317.10	563.17	14808.30	52.26	1441	14422	3.44%
81	2.0	140894.78	522.21	139149.26	4662.80	28973.83	59.31	5296	49359	1.24%
82	0.1	90592.25	2.85	86010.57	57.33	6169.36	49.64	271	2751	5.06%
82	0.5	109995.61	52.45	105287.17	444.47	14489.48	52.24	1447	14014	4.28%
82	2.0	140548.81	558.79	137982.63	5004.76	28829.02	59.35	5140	49649	1.83%
83	0.1	92547.29	1.84	89418.49	69.58	6441.71	49.65	322	2784	3.38%
83	0.5	112519.78	31.83	109671.13	639.61	15179.80	52.17	1455	14349	2.53%
83	2.0	144207.40	510.44	142672.38	4148.95	29628.90	59.09	5251	48933	1.06%
84	0.1	94614.99	2.04	90993.67	45.67	6483.22	49.66	288	2738	3.83%
84	0.5	116487.30	35.46	111537.27	363.81	15739.51	52.29	1570	14834	4.25%
84	2.0	147410.67	445.85	145152.27	3593.24	30275.14	59.03	5215	49293	1.53%
85	0.1	95576.56	1.83	91467.05	72.10	6746.75	49.68	270	2941	4.30%
85	0.5	116067.68	31.75	111010.61	686.62	15421.78	52.14	1566	14223	4.36%
85	2.0	146136.47	436.43	144832.80	3499.18	29758.64	59.15	4902	47973	0.89%
86	0.1	84740.56	3.03	80543.93	67.47	5790.65	49.55	264	2777	4.95%
86	0.5	105603.72	58.79	99742.85	650.70	14238.72	52.24	1660	15308	5.55%
86	2.0	136143.40	623.95	133500.97	4296.95	28639.14	59.30	5712	54594	1.94%
87	0.1	97160.14	1.88	93076.82	41.83	6792.19	49.67	283	2894	4.20%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
87	0.5	117655.66	32.16	113404.88	674.65	15702.50	52.22	1435	14266	3.61%
87	2.0	149696.86	431.33	147937.86	4402.56	30447.27	59.43	5170	48109	1.18%
88	0.1	93398.25	1.87	89579.55	73.42	6323.70	49.59	263	2666	4.09%
88	0.5	114240.21	32.57	110400.53	584.61	15412.18	52.24	1525	14701	3.36%
88	2.0	145693.05	517.56	144363.07	4173.80	30220.99	59.21	5278	50606	0.91%
89	0.1	95557.95	2.65	91112.12	58.90	6658.22	49.54	291	2883	4.65%
89	0.5	115146.24	35.84	111972.52	475.47	15717.83	52.25	1504	14729	2.76%
89	2.0	147034.96	523.80	145620.24	5870.85	30185.34	59.21	5443	48942	0.96%
90	0.1	91292.71	2.10	87529.27	52.83	6301.35	49.58	258	2791	4.12%
90	0.5	111045.94	34.95	107264.01	727.72	14866.57	52.22	1477	14231	3.41%
90	2.0	142103.23	514.07	140487.88	2972.85	29013.79	59.20	5417	48316	1.14%
91	0.1	85163.97	1.64	81243.75	60.27	5770.28	49.55	369	2696	4.60%
91	0.5	104116.25	33.54	100454.95	489.00	14203.84	52.21	1588	15053	3.52%
91	2.0	135034.97	499.53	132262.52	4868.35	27655.62	59.15	5458	50770	2.05%
92	0.1	88770.62	2.87	84972.70	50.30	6117.78	49.58	254	2790	4.28%
92	0.5	108605.55	35.55	103924.98	386.69	14575.91	52.08	1473	14668	4.31%
92	2.0	137641.83	587.10	135870.20	3769.73	28401.94	59.24	5410	49899	1.29%
93	0.1	91845.15	2.53	88742.11	85.59	6407.79	49.63	257	2804	3.38%
93	0.5	112442.19	50.33	109109.89	468.44	15302.45	52.32	1442	14732	2.96%
93	2.0	143438.01	543.07	141095.92	5001.10	29260.04	59.11	5044	48761	1.63%
94	0.1	92171.82	2.25	88609.07	69.31	6293.87	49.70	221	2711	3.87%
94	0.5	112532.26	39.06	108343.77	430.47	15220.29	52.19	1595	14679	3.72%
94	2.0	143869.15	512.90	141828.40	4302.20	29443.59	59.13	5373	49241	1.42%
95	0.1	88285.87	2.58	83593.79	45.71	5789.27	49.67	227	2539	5.31%
95	0.5	107097.35	34.93	102262.53	511.01	14195.32	52.34	1529	14296	4.51%
95	2.0	136460.24	489.92	134680.04	3519.59	28119.83	59.19	5436	49887	1.30%
96	0.1	86803.58	1.86	83188.42	68.25	5905.78	49.71	233	2691	4.16%
96	0.5	107382.97	38.94	101925.21	657.79	14151.58	52.23	1500	14308	5.08%
96	2.0	137255.65	515.23	133833.78	5393.71	28045.14	59.00	5358	50327	2.49%

Continua na página seguinte

Tabela 16 – Resultado do SimSA-VaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(3) SimSA-VaR						(1) x (3)
		VaR _{95%}	Tempo(s)	VaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
97	0.1	95462.36	1.96	91205.89	83.51	6626.29	49.63	265	2844	4.46%
97	0.5	116461.26	35.13	111526.61	671.69	15578.05	52.41	1549	14370	4.24%
97	2.0	146863.12	494.08	145094.95	3716.28	30211.82	59.09	5256	48762	1.20%
98	0.1	88002.49	2.13	83079.69	60.27	6011.30	49.68	260	2806	5.59%
98	0.5	106993.81	36.68	102500.40	648.99	14349.01	52.25	1504	14672	4.20%
98	2.0	137297.06	618.18	135211.33	6931.51	28401.76	59.23	5438	51628	1.52%
99	0.1	99650.80	3.32	94788.76	61.69	6870.22	49.61	254	2829	4.88%
99	0.5	120292.48	52.34	115589.36	613.89	15991.38	52.27	1484	14092	3.91%
99	2.0	152778.63	500.69	150027.98	4287.23	30961.21	59.07	4817	47540	1.80%
100	0.1	95326.96	1.74	91647.75	96.54	6749.76	49.65	340	2931	3.86%
100	0.5	116045.45	31.85	111354.61	867.65	15558.25	52.23	1414	14387	4.04%
100	2.0	146756.57	430.50	145493.00	4401.51	30618.74	59.45	5109	49916	0.86%

APÊNDICE C – COMPARAÇÃO ENTRE SIMSA-CVAR X GIH-GRASP

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
1	0.1	101092.95	4.38	94588.42	37.59	6403.54	49.55	249	2614	6.43%
1	0.5	123090.52	25.15	119870.38	196.35	14965.01	52.31	1383	13439	2.62%
1	2.0	165618.60	335.74	165447.37	2436.66	29719.11	59.43	5151	47691	0.10%
2	0.1	85581.17	1.31	80343.98	19.74	5641.02	49.66	303	2893	6.12%
2	0.5	111366.19	33.39	104668.68	252.18	13190.70	52.21	1402	13861	6.01%
2	2.0	149977.92	437.92	147695.31	2734.24	26854.50	59.39	5343	51170	1.52%
3	0.1	93401.65	1.25	87062.37	9.36	5971.41	49.76	295	2745	6.79%
3	0.5	120348.77	29.48	111641.11	211.96	14089.87	52.14	1658	14176	7.24%
3	2.0	164524.09	510.47	157767.10	2280.30	28718.57	59.53	5824	51428	4.11%
4	0.1	102067.90	1.33	94673.21	8.82	6757.20	49.55	301	2982	7.24%
4	0.5	128087.78	31.69	124666.23	334.51	15455.92	52.11	1351	13477	2.67%
4	2.0	173288.70	376.79	172245.72	2964.96	31050.44	59.48	5075	47869	0.60%
5	0.1	96088.38	1.27	94172.59	21.73	6659.74	49.62	277	2925	1.99%
5	0.5	121813.02	26.47	119473.19	205.08	15243.73	52.20	1421	14296	1.92%
5	2.0	164556.06	384.51	164422.76	2184.25	29564.32	59.33	5075	47949	0.08%
6	0.1	91630.39	1.33	88259.73	20.86	5897.87	49.63	268	2544	3.68%
6	0.5	116890.98	27.97	112583.67	246.50	14162.57	52.27	1404	13687	3.68%
6	2.0	160268.83	489.32	157092.60	3068.89	28422.64	59.49	5229	48953	1.98%
7	0.1	99426.51	1.28	97129.88	27.30	6763.81	49.63	222	2783	2.31%
7	0.5	124490.19	26.03	122865.80	184.70	15446.85	52.14	1377	13592	1.30%
7	2.0	167353.97	462.73	166665.63	2286.54	29558.13	59.39	4880	45082	0.41%
8	0.1	97220.60	1.79	95607.63	14.62	6409.75	49.42	281	2553	1.66%
8	0.5	125999.32	33.66	123961.30	237.24	15891.16	52.17	1546	14635	1.62%
8	2.0	171663.52	527.43	169795.16	3070.70	31075.67	59.46	5635	49632	1.09%
9	0.1	108218.37	1.13	100656.44	13.85	7161.97	49.57	342	2958	6.99%
9	0.5	136166.57	23.97	129164.52	280.56	16490.64	52.07	1671	14460	5.14%
9	2.0	182761.34	340.99	177637.45	2266.17	32127.22	59.26	5553	48828	2.80%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
10	0.1	94528.03	1.38	88592.25	15.04	6150.86	49.62	305	2796	6.28%
10	0.5	120774.10	29.07	113934.20	172.83	14418.18	52.23	1515	14256	5.66%
10	2.0	163673.28	414.92	161247.71	2386.03	28737.80	59.80	5047	46766	1.48%
11	0.1	99221.79	1.34	98078.38	28.06	6778.40	49.48	239	2755	1.15%
11	0.5	125747.15	34.28	124673.28	202.84	15942.77	52.11	1507	14240	0.85%
11	2.0	172136.82	458.57	171763.68	2441.04	30926.80	59.31	5015	48313	0.22%
12	0.1	100665.63	1.66	97170.87	21.77	6801.61	49.65	262	2843	3.47%
12	0.5	126707.98	36.68	123468.69	310.03	15883.24	51.97	1472	14650	2.56%
12	2.0	171436.03	531.78	171290.25	2339.92	31006.34	59.18	5339	49312	0.09%
13	0.1	83127.27	1.72	81038.85	15.46	5363.67	49.52	227	2493	2.51%
13	0.5	106927.73	44.61	104658.60	167.44	13251.59	52.14	1566	14221	2.12%
13	2.0	146994.77	562.65	146876.73	2418.09	26566.29	59.68	5107	49489	0.08%
14	0.1	60333.76	3.42	55578.10	11.69	3814.87	49.62	314	2780	7.88%
14	0.5	82580.15	101.53	78130.64	297.20	10422.03	52.26	1766	17641	5.39%
14	2.0	120444.42	1125.34	116225.47	3703.62	22142.02	59.75	7670	69383	3.50%
15	0.1	85764.04	1.51	82555.65	14.51	5600.30	49.70	235	2645	3.74%
15	0.5	109537.24	32.73	107187.77	268.24	13938.07	52.21	1644	14987	2.14%
15	2.0	151239.71	580.76	150095.32	2161.73	27190.94	59.24	5493	50292	0.76%
16	0.1	71313.56	1.43	67597.35	9.56	4738.13	49.38	318	2877	5.21%
16	0.5	96307.14	43.22	91274.75	323.03	11802.33	52.03	1508	15253	5.23%
16	2.0	135061.56	764.99	131116.26	1436.75	24399.43	59.24	6326	59489	2.92%
17	0.1	94740.38	1.36	92511.74	17.81	6173.97	49.62	256	2554	2.35%
17	0.5	122198.41	31.21	118809.44	273.08	14945.43	52.12	1372	13896	2.77%
17	2.0	164722.64	435.40	163145.19	1902.45	29310.30	59.23	5194	47443	0.96%
18	0.1	84505.55	1.17	81885.20	11.47	5567.99	49.62	263	2681	3.10%
18	0.5	107983.32	26.84	106531.90	360.52	13406.83	52.13	1592	14163	1.34%
18	2.0	152027.40	513.09	151302.01	2675.69	27670.64	59.30	5335	51560	0.48%
19	0.1	93215.14	1.54	89852.66	21.48	6351.90	49.63	232	2890	3.61%
19	0.5	120342.09	34.74	114913.11	218.69	14546.36	52.11	1441	13895	4.51%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
19	2.0	162988.02	555.37	161895.14	3178.16	29407.52	59.50	5457	50273	0.67%
20	0.1	108476.24	1.68	104363.90	29.07	7371.16	49.59	288	2879	3.79%
20	0.5	134124.46	29.38	131863.76	173.39	16725.98	52.25	1463	13860	1.69%
20	2.0	179763.21	384.59	177839.85	2452.40	31913.86	59.89	4759	45628	1.07%
21	0.1	105338.20	1.60	104128.55	18.24	7131.38	49.53	270	2691	1.15%
21	0.5	133392.82	36.18	132646.84	233.14	16597.88	52.18	1358	13596	0.56%
21	2.0	179781.21	394.09	179314.17	1605.22	31822.09	59.66	4771	44315	0.26%
22	0.1	57355.46	2.06	54115.80	11.87	4064.65	49.21	354	3433	5.65%
22	0.5	77966.42	59.96	72699.41	155.05	9943.02	51.78	2043	18543	6.76%
22	2.0	113629.08	982.24	112129.96	4476.35	21479.52	59.63	7097	68671	1.32%
23	0.1	89784.66	1.33	84019.85	9.21	5662.09	49.59	307	2625	6.42%
23	0.5	115162.52	31.52	108669.29	108.35	13765.81	52.23	1429	14358	5.64%
23	2.0	155001.09	517.43	150390.95	2858.20	27104.39	59.48	5503	49675	2.97%
24	0.1	98516.47	0.94	96540.69	25.67	6576.66	49.58	259	2636	2.01%
24	0.5	125862.07	25.23	120703.91	179.85	15479.32	52.27	1571	14536	4.10%
24	2.0	171190.67	457.87	170478.20	2566.74	30789.15	59.36	5295	48349	0.42%
25	0.1	103548.09	1.89	99936.31	16.77	6853.27	49.63	261	2692	3.49%
25	0.5	130354.79	37.90	127466.20	222.03	16095.87	52.11	1403	13794	2.22%
25	2.0	173124.33	417.59	171752.11	2206.52	30626.37	59.33	4979	45225	0.79%
26	0.1	87271.94	1.66	83946.50	23.93	5907.69	49.68	255	2891	3.81%
26	0.5	111592.87	37.78	107325.91	311.99	13660.90	52.24	1454	14292	3.82%
26	2.0	151361.13	525.06	149707.05	2624.00	26804.59	59.30	5202	49011	1.09%
27	0.1	92175.42	2.14	88361.36	34.98	6279.02	49.62	288	2960	4.14%
27	0.5	117900.73	45.16	113592.09	400.98	14459.04	52.14	1507	14476	3.65%
27	2.0	161850.10	544.86	159319.80	3021.58	28944.27	59.29	5432	51381	1.56%
28	0.1	104201.99	1.97	102047.93	40.84	7206.82	49.61	301	2916	2.07%
28	0.5	134020.17	45.12	130356.79	282.92	16699.90	52.21	1516	14456	2.73%
28	2.0	179205.75	487.13	178682.74	2904.01	32029.76	59.28	4997	47990	0.29%
29	0.1	81388.30	2.42	77561.27	21.88	5360.37	49.52	287	2767	4.70%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
29	0.5	104400.08	51.82	101127.36	393.86	12882.67	52.15	1509	14592	3.13%
29	2.0	143946.95	582.10	141753.17	2567.91	25547.08	59.41	5237	50750	1.52%
30	0.1	101944.68	1.35	99705.94	32.67	6986.82	49.60	210	2846	2.20%
30	0.5	130996.77	29.27	127038.57	297.10	16017.88	52.18	1407	13802	3.02%
30	2.0	175049.24	474.24	174116.40	2698.84	31030.47	59.31	4936	46756	0.53%
31	0.1	96595.12	1.64	93191.15	33.46	6500.87	49.57	251	2828	3.52%
31	0.5	122746.51	31.85	118971.14	335.27	15114.12	52.19	1499	14247	3.08%
31	2.0	165246.12	496.01	163211.51	2818.96	29098.76	59.24	4863	47295	1.23%
32	0.1	92747.28	2.14	88992.71	29.70	6117.51	49.60	218	2733	4.05%
32	0.5	119347.46	33.00	115029.51	424.81	14531.45	52.24	1377	14120	3.62%
32	2.0	161313.24	431.48	159912.06	2602.22	28622.22	59.32	5142	49069	0.87%
33	0.1	97593.69	1.62	94233.69	37.76	6552.40	49.66	293	2821	3.44%
33	0.5	124475.74	33.08	121616.27	373.82	15552.69	52.12	1485	14643	2.30%
33	2.0	170456.06	511.84	169752.22	2435.05	30640.91	59.38	5433	50675	0.41%
34	0.1	100163.95	2.44	96284.63	35.98	6767.60	49.67	274	2872	3.87%
34	0.5	126008.88	47.96	122028.28	278.69	15328.72	52.16	1408	13731	3.16%
34	2.0	168333.96	468.10	167605.26	2477.73	29852.32	59.31	5079	47026	0.43%
35	0.1	88001.50	2.87	81823.96	40.09	5587.36	49.63	243	2678	7.02%
35	0.5	110577.41	46.71	106846.42	460.62	13617.44	52.22	1719	14617	3.37%
35	2.0	153295.21	531.44	152016.85	3376.02	27431.71	59.40	5430	52104	0.83%
36	0.1	104792.73	1.62	101326.85	38.98	7106.40	49.58	297	2860	3.31%
36	0.5	133217.47	31.84	128698.51	324.90	16244.54	52.21	1462	13830	3.39%
36	2.0	178667.59	411.78	177052.61	2556.40	31585.76	59.39	4897	47052	0.90%
37	0.1	103093.68	1.52	99729.17	44.63	6936.09	49.59	285	2800	3.26%
37	0.5	131220.35	29.10	127565.71	360.40	16067.32	52.26	1383	13822	2.79%
37	2.0	176741.45	458.63	175663.07	2509.67	31431.86	59.43	4896	47804	0.61%
38	0.1	92753.21	1.51	90717.89	32.79	6337.72	49.64	250	2860	2.19%
38	0.5	119503.69	32.89	117198.13	344.95	15120.34	52.24	1497	14972	1.93%
38	2.0	164219.76	531.77	163533.06	3032.10	29466.41	59.46	5294	50321	0.42%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
39	0.1	102870.84	2.17	98606.81	42.46	6940.54	49.61	206	2872	4.15%
39	0.5	131755.05	50.23	127177.87	345.52	16346.69	52.12	1481	14607	3.47%
39	2.0	175238.71	498.80	174770.18	3251.08	31253.45	59.31	5096	47718	0.27%
40	0.1	90220.87	1.95	85567.56	34.84	5912.87	49.55	253	2765	5.16%
40	0.5	115762.19	39.11	110813.67	351.99	14101.62	52.25	1485	14485	4.27%
40	2.0	157041.91	488.78	155221.06	3222.13	27848.84	59.25	5280	50194	1.16%
41	0.1	105368.96	2.06	99665.31	21.41	6846.07	49.65	267	2734	5.41%
41	0.5	133711.50	36.49	128554.44	330.03	16250.97	52.22	1451	14188	3.86%
41	2.0	178600.69	535.81	178480.19	2113.86	32257.14	59.59	5100	49527	0.07%
42	0.1	97783.06	1.47	96237.56	38.69	7034.42	49.58	303	3147	1.58%
42	0.5	127689.48	40.64	124896.82	281.98	16206.91	52.33	1564	15372	2.19%
42	2.0	174584.70	574.21	171607.90	3198.32	31155.95	59.23	5424	50524	1.71%
43	0.1	100502.10	1.70	97574.24	28.26	6587.85	49.61	251	2629	2.91%
43	0.5	129529.13	37.25	125594.62	316.63	15741.93	52.27	1400	13797	3.04%
43	2.0	177797.24	523.53	175994.00	3109.73	31392.73	59.31	4972	48714	1.01%
44	0.1	88885.88	2.14	86079.46	35.34	5820.92	49.57	244	2646	3.16%
44	0.5	115211.99	44.35	112487.89	357.83	14446.63	52.15	1504	14878	2.36%
44	2.0	159297.50	595.55	159180.58	3780.38	28761.78	59.41	5235	51710	0.07%
45	0.1	109123.10	1.72	105336.06	33.20	7367.97	49.65	273	2846	3.47%
45	0.5	136705.22	45.69	134630.23	355.53	16926.44	52.23	1392	13857	1.52%
45	2.0	184354.41	464.39	183832.77	2435.76	32699.70	59.46	4829	46700	0.28%
46	0.1	89723.36	1.62	86978.97	30.19	6126.73	49.58	261	2914	3.06%
46	0.5	116602.99	36.61	111361.18	482.70	14320.25	52.15	1584	14722	4.50%
46	2.0	158348.75	500.52	156103.15	2632.45	28163.72	59.48	5399	50778	1.42%
47	0.1	96995.79	1.73	92800.21	43.58	6470.21	49.68	260	2815	4.33%
47	0.5	123860.81	35.95	118623.35	322.09	15057.36	52.22	1465	14146	4.23%
47	2.0	165711.15	534.81	164314.45	2613.45	29412.89	59.55	5149	48175	0.84%
48	0.1	87554.98	2.31	83399.89	32.25	5612.64	49.64	260	2600	4.75%
48	0.5	115058.88	56.88	108298.76	405.76	13797.95	52.22	1550	14528	5.88%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR							(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP	
48	2.0	157477.94	635.61	154046.07	3029.99	27916.92	59.44	5533	52413	2.18%	
49	0.1	97179.17	1.70	94043.48	33.13	6598.24	49.63	291	2867	3.23%	
49	0.5	124410.57	33.76	120735.07	425.62	15379.03	52.18	1529	14416	2.95%	
49	2.0	168832.61	440.86	167577.32	3140.05	30006.03	59.47	5250	48850	0.74%	
50	0.1	99509.84	1.78	94815.30	44.02	6711.85	49.56	274	2902	4.72%	
50	0.5	124054.43	30.75	121178.51	358.51	15422.89	52.25	1450	14255	2.32%	
50	2.0	167362.28	456.29	165363.65	2218.00	29461.23	59.35	4940	47023	1.19%	
51	0.1	99786.22	2.39	95528.49	54.15	6577.04	49.71	267	2727	4.27%	
51	0.5	127125.15	48.39	122857.09	358.63	15456.02	52.19	1478	13907	3.36%	
51	2.0	173869.50	486.85	171942.81	3488.38	30579.66	59.30	4989	48823	1.11%	
52	0.1	88547.24	1.68	85041.32	46.08	5978.89	49.61	291	2879	3.96%	
52	0.5	113801.17	32.38	110731.85	400.76	14226.92	52.18	1510	14941	2.70%	
52	2.0	158556.59	494.60	156904.39	3588.81	28337.96	59.35	5548	52200	1.04%	
53	0.1	91063.28	1.80	87536.83	63.49	6097.57	49.64	258	2821	3.87%	
53	0.5	116331.12	32.33	114126.63	465.59	14570.47	52.32	1489	14720	1.90%	
53	2.0	161791.73	553.82	158539.79	4003.90	28288.10	59.31	5176	49932	2.01%	
54	0.1	94644.40	1.80	91067.62	41.58	6345.23	49.61	276	2840	3.78%	
54	0.5	121012.27	30.77	116449.59	404.48	14727.56	52.32	1364	14020	3.77%	
54	2.0	164128.22	409.47	162697.94	3223.12	28903.38	59.32	5026	48436	0.87%	
55	0.1	96043.74	1.77	92480.35	36.47	6319.78	49.66	269	2716	3.71%	
55	0.5	121830.42	31.99	119705.48	524.93	15276.45	52.27	1484	14622	1.74%	
55	2.0	168426.51	499.25	166579.48	3370.24	29657.63	59.33	5010	49251	1.10%	
56	0.1	97572.27	1.86	93244.75	50.60	6434.10	49.66	240	2759	4.44%	
56	0.5	123058.81	32.03	119789.17	505.64	15070.08	52.24	1443	14051	2.66%	
56	2.0	167206.23	421.38	166783.12	3968.70	29786.82	59.23	5064	48996	0.25%	
57	0.1	94658.39	1.74	90021.22	50.09	6269.34	49.68	273	2803	4.90%	
57	0.5	120610.05	31.09	115860.80	405.23	14633.18	52.24	1409	14093	3.94%	
57	2.0	163888.06	513.30	161488.72	3318.83	29023.23	59.30	5094	49646	1.46%	
58	0.1	89124.84	2.43	85306.51	55.56	5872.93	49.62	232	2729	4.28%	

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
58	0.5	112462.48	35.10	109465.70	358.79	13778.50	52.21	1389	14001	2.66%
58	2.0	154524.01	495.49	151895.22	3497.66	26829.43	59.28	4950	47765	1.70%
59	0.1	103292.74	2.48	99083.06	37.38	6949.51	49.62	268	2869	4.08%
59	0.5	131437.93	43.80	126520.48	374.32	15986.25	52.31	1479	14128	3.74%
59	2.0	174886.53	457.91	174030.49	2812.03	30867.16	59.22	4793	47601	0.49%
60	0.1	89470.36	1.62	85901.99	50.66	6024.07	49.68	246	2839	3.99%
60	0.5	115069.84	34.00	110976.98	401.68	14164.22	52.27	1473	14571	3.56%
60	2.0	156484.79	463.10	154640.50	3361.95	27525.83	59.24	5185	49357	1.18%
61	0.1	85454.64	1.71	81617.10	46.77	5637.14	49.64	277	2748	4.49%
61	0.5	110682.91	33.69	106508.51	504.06	13554.36	52.16	1480	14604	3.77%
61	2.0	153794.77	588.02	151485.48	4127.87	27314.80	59.38	5474	52450	1.50%
62	0.1	98043.76	2.95	93666.76	43.06	6588.80	49.59	228	2896	4.46%
62	0.5	126611.13	52.52	121710.09	499.23	15535.95	52.28	1506	14687	3.87%
62	2.0	170680.30	577.88	168807.54	3425.56	30053.14	59.26	5255	48886	1.10%
63	0.1	99654.79	1.70	95380.50	61.41	6653.31	49.56	281	2828	4.29%
63	0.5	127206.33	47.76	122922.34	435.59	15638.12	52.23	1437	14411	3.37%
63	2.0	171773.82	496.86	169936.26	2991.82	30328.19	59.42	5107	48695	1.07%
64	0.1	95192.80	2.53	91630.99	43.44	6245.52	49.56	261	2662	3.74%
64	0.5	121489.05	46.76	118712.54	521.27	15028.87	52.23	1365	14145	2.29%
64	2.0	165778.54	532.33	164981.16	3287.22	29258.73	59.30	4906	48458	0.48%
65	0.1	88449.87	2.10	84377.86	42.38	5888.35	49.67	245	2818	4.60%
65	0.5	111781.23	43.33	108435.65	332.33	13545.21	52.28	1520	13860	2.99%
65	2.0	153492.54	529.95	151762.41	3106.54	26887.40	59.42	4982	48797	1.13%
66	0.1	99139.78	3.59	94395.60	48.68	6656.85	49.65	249	2930	4.79%
66	0.5	125445.38	39.73	120163.27	431.17	15035.70	52.21	1401	13753	4.21%
66	2.0	171234.46	561.90	167559.32	3073.07	29703.67	59.23	4970	48259	2.15%
67	0.1	95309.49	2.22	90890.75	52.25	6267.40	49.60	259	2773	4.64%
67	0.5	121823.39	43.43	116587.76	529.26	14678.55	52.18	1446	14004	4.30%
67	2.0	163963.06	541.64	162088.61	3697.17	28865.96	59.57	5069	48543	1.14%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
68	0.1	90951.95	1.67	88350.49	55.75	6111.48	49.64	229	2772	2.86%
68	0.5	117119.23	35.07	114052.40	494.18	14471.54	52.27	1416	14349	2.62%
68	2.0	159715.16	453.75	158443.57	3105.40	28204.48	59.30	5135	49083	0.80%
69	0.1	95848.24	2.04	90623.66	45.25	6335.07	49.64	307	2853	5.45%
69	0.5	121743.31	40.36	116640.84	557.43	14945.21	52.27	1424	14579	4.19%
69	2.0	165797.38	583.50	163544.69	3550.09	29183.18	59.41	5183	49807	1.36%
70	0.1	93115.78	2.67	90541.61	44.74	6251.09	49.57	266	2775	2.76%
70	0.5	119513.16	48.73	116510.01	346.53	14833.59	52.26	1518	14453	2.51%
70	2.0	164554.35	586.87	163783.01	3692.59	29308.13	59.31	5084	50110	0.47%
71	0.1	94998.23	1.92	91403.53	33.97	6293.79	49.62	269	2751	3.78%
71	0.5	122874.49	46.81	117441.24	489.23	14761.25	52.24	1331	13919	4.42%
71	2.0	166301.52	539.95	163401.93	3386.37	29028.68	59.30	4951	48289	1.74%
72	0.1	102689.48	1.85	99052.51	53.66	6901.86	49.65	254	2816	3.54%
72	0.5	131467.95	36.02	128666.63	441.81	16320.82	52.22	1467	14547	2.13%
72	2.0	180146.63	535.61	176594.89	3084.05	31393.75	59.16	5307	47982	1.97%
73	0.1	92310.97	2.48	89558.60	35.55	6249.61	49.64	318	2859	2.98%
73	0.5	118250.19	48.50	115715.13	558.46	14870.71	52.25	1479	14869	2.14%
73	2.0	164152.22	561.23	162515.84	3853.10	29124.60	59.25	5300	50901	1.00%
74	0.1	103887.58	2.09	98153.86	61.12	6818.21	49.62	277	2762	5.52%
74	0.5	130680.15	33.27	127125.26	445.71	16108.09	52.28	1373	14265	2.72%
74	2.0	178092.66	437.28	174460.28	3691.46	30834.80	59.06	5565	47116	2.04%
75	0.1	85170.56	1.87	81104.59	42.57	5600.47	49.69	271	2754	4.77%
75	0.5	109854.39	39.51	105982.51	344.18	13563.43	52.35	1489	14888	3.52%
75	2.0	152417.64	643.07	150697.72	4055.03	27027.07	59.37	5381	52276	1.13%
76	0.1	89490.31	2.47	85582.57	61.14	5841.18	49.71	251	2683	4.37%
76	0.5	115115.37	47.77	111391.35	646.35	14095.29	52.15	1379	14387	3.24%
76	2.0	160742.88	537.31	158104.40	3100.21	28308.63	59.21	5360	51829	1.64%
77	0.1	91727.64	1.92	88614.22	78.94	6221.75	49.65	220	2865	3.39%
77	0.5	118719.43	37.01	114497.47	592.42	14461.07	52.33	1489	14279	3.56%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR							(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP	
77	2.0	161257.83	492.27	158199.33	3852.74	27884.88	59.18	5040	48040	1.90%	
78	0.1	91840.60	3.35	87956.74	57.88	6019.45	49.58	225	2715	4.23%	
78	0.5	118364.34	48.26	113610.77	344.79	14303.01	52.25	1424	14210	4.02%	
78	2.0	163202.21	578.84	159199.98	4001.94	28069.01	59.15	5217	49190	2.45%	
79	0.1	97488.66	2.37	92216.28	75.42	6417.19	49.67	299	2791	5.41%	
79	0.5	124138.49	50.64	118638.78	510.56	14953.09	52.18	1447	14061	4.43%	
79	2.0	168983.95	569.30	164684.23	2705.19	29207.67	59.36	5117	48366	2.54%	
80	0.1	103928.85	3.11	99190.91	61.01	6796.46	49.64	270	2724	4.56%	
80	0.5	131548.82	44.88	127112.58	489.79	16014.42	52.22	1411	13897	3.37%	
80	2.0	179180.18	451.35	175785.91	2645.01	30982.02	59.36	5053	47159	1.89%	
81	0.1	93368.65	1.86	89967.01	77.22	5884.39	49.63	218	2434	3.64%	
81	0.5	120404.53	36.15	116495.52	436.45	14711.74	52.23	1424	14197	3.25%	
81	2.0	164585.67	522.21	162112.59	3214.86	28557.94	59.05	5038	47575	1.50%	
82	0.1	94035.82	2.85	89441.26	71.68	6209.01	49.63	230	2780	4.89%	
82	0.5	120472.14	52.45	115869.00	437.38	14654.42	52.34	1345	14324	3.82%	
82	2.0	163952.77	558.79	161408.36	2668.14	28621.68	59.34	5206	49325	1.55%	
83	0.1	95868.62	1.84	92567.08	49.87	6327.04	49.57	295	2688	3.44%	
83	0.5	122946.93	31.83	119985.16	378.97	15177.10	52.32	1415	14298	2.41%	
83	2.0	168672.10	510.44	168530.24	3938.29	29994.96	59.32	5137	50022	0.08%	
84	0.1	98356.39	2.04	94638.65	39.49	6459.50	49.58	258	2725	3.78%	
84	0.5	127848.72	35.46	122171.67	493.18	15533.14	52.21	1478	14470	4.44%	
84	2.0	172981.04	445.85	170895.51	3052.59	30690.38	59.14	5165	50631	1.21%	
85	0.1	98717.62	1.83	94735.78	54.49	6596.28	49.60	276	2823	4.03%	
85	0.5	126181.09	31.75	122238.91	607.20	15511.55	52.30	1550	14322	3.12%	
85	2.0	170143.93	436.43	168136.99	2734.82	29723.86	59.22	5097	47505	1.18%	
86	0.1	88763.64	3.03	84360.28	63.27	5841.14	49.61	283	2829	4.96%	
86	0.5	116215.50	58.79	110130.06	599.35	14197.35	52.20	1512	15225	5.24%	
86	2.0	159917.12	623.95	157068.96	3386.81	28378.27	59.09	5630	53880	1.78%	
87	0.1	101282.13	1.88	96261.50	48.67	6665.81	49.60	311	2788	4.96%	

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	
87	0.5	128242.21	32.16	124647.72	498.84	15712.76	52.24	1417	14210	2.80%
87	2.0	175028.53	431.33	172576.17	3503.26	30717.11	59.23	5032	48850	1.40%
88	0.1	97249.70	1.87	92524.59	55.33	6381.89	49.60	276	2752	4.86%
88	0.5	124677.00	32.57	121285.71	602.87	15475.46	52.36	1469	14801	2.72%
88	2.0	171302.35	517.56	169876.52	3684.98	30376.70	59.12	5350	50708	0.83%
89	0.1	99751.99	2.65	95024.99	73.16	6566.41	49.66	271	2796	4.74%
89	0.5	126093.10	35.84	122029.12	468.89	15543.68	52.30	1634	14439	3.22%
89	2.0	170958.05	523.80	169780.97	3015.43	30119.09	59.32	4977	48693	0.69%
90	0.1	94924.25	2.10	90779.03	44.79	6189.11	49.65	232	2668	4.37%
90	0.5	121672.08	34.95	117704.30	395.95	14794.91	52.33	1613	13943	3.26%
90	2.0	165423.95	514.07	164146.56	2827.55	29095.57	59.25	4993	48831	0.77%
91	0.1	88287.20	1.64	85017.38	73.87	5845.01	49.74	264	2748	3.70%
91	0.5	114292.86	33.54	110456.09	650.09	14064.73	52.28	1561	14697	3.36%
91	2.0	159195.26	499.53	155328.21	4598.68	27686.58	59.19	5311	50683	2.43%
92	0.1	92368.96	2.87	88195.94	46.27	6179.41	49.65	260	2843	4.52%
92	0.5	118184.32	35.55	114104.36	406.43	14407.71	52.27	1475	14299	3.45%
92	2.0	161467.02	587.10	159426.18	2270.51	28282.33	59.18	5004	49581	1.26%
93	0.1	95387.45	2.53	91636.21	54.24	6296.14	49.65	248	2723	3.93%
93	0.5	122685.81	50.33	118755.03	349.02	14993.88	52.26	1465	14174	3.20%
93	2.0	167670.32	543.07	165879.90	3555.60	29507.69	58.99	5316	49226	1.07%
94	0.1	95658.31	2.25	92065.00	54.59	6414.14	49.66	259	2834	3.76%
94	0.5	123924.95	39.06	119739.82	335.44	15270.47	52.26	1454	14708	3.38%
94	2.0	167249.24	512.90	166246.02	3700.66	29504.12	59.14	5191	49292	0.60%
95	0.1	91713.92	2.58	87395.99	51.62	6190.88	49.65	242	2951	4.71%
95	0.5	116957.59	34.93	112808.44	390.69	14356.18	52.37	1411	14567	3.55%
95	2.0	161310.45	489.92	158157.79	4217.23	27969.60	59.22	5112	49454	1.95%
96	0.1	90408.47	1.86	86481.60	83.64	5901.31	49.65	252	2701	4.34%
96	0.5	118021.98	38.94	112675.83	339.78	14326.03	52.29	1527	14532	4.53%
96	2.0	159304.35	515.23	157194.52	4266.57	27882.02	59.03	5141	49661	1.32%

Continua na página seguinte

Tabela 17 – Resultado do SimSA-CVaR x GIH-GRASP (Continuação)

Inst	δ	(1) GIH-GRASP		(4) SimSA-CVaR						(1) x (4)
		CVaR _{95%}	Tempo(s)	CVaR _{95%}	Tempo(s)	Desvio	M _E	Nsc	Nsl	GAP
97	0.1	99030.43	1.96	94786.61	75.96	6530.89	49.54	276	2750	4.29%
97	0.5	126675.62	35.13	123032.15	377.90	15636.00	52.22	1548	14503	2.88%
97	2.0	173052.14	494.08	170369.59	3427.69	30190.62	59.37	5026	48541	1.55%
98	0.1	91480.24	2.13	86479.57	84.48	6032.63	49.62	305	2830	5.47%
98	0.5	116393.03	36.68	112675.92	576.53	14302.90	52.31	1528	14617	3.19%
98	2.0	162218.93	618.18	158685.46	3904.46	28366.27	59.29	5191	51099	2.18%
99	0.1	103388.10	3.32	98499.87	52.98	6928.77	49.65	238	2860	4.73%
99	0.5	131373.25	52.34	127152.63	415.99	15993.65	52.22	1452	14058	3.21%
99	2.0	178019.25	500.69	176378.00	3644.61	31220.30	59.25	4958	48360	0.92%
100	0.1	99031.44	1.74	95103.27	82.05	6511.11	49.68	255	2718	3.97%
100	0.5	126200.80	31.85	122304.55	613.23	15483.70	52.20	1476	14228	3.09%
100	2.0	171385.95	430.50	170143.25	3149.28	30214.59	59.05	5013	48787	0.73%