



APLICAÇÃO DA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS E
PROGRAMAÇÃO PSEUDO-DINÂMICA NA ANÁLISE DE ATRASO DE
OBRAS DE TRANSMISSÃO CONSIDERANDO CONFIABILIDADE

Eduardo Leite Moutinho

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Elétrica, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Carmen Lucia Tancredo Borges

Rio de Janeiro

Maior de 2022

APLICAÇÃO DA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS E
PROGRAMAÇÃO PSEUDO-DINÂMICA NA ANÁLISE DE ATRASO DE
OBRAS DE TRANSMISSÃO CONSIDERANDO CONFIABILIDADE

Eduardo Leite Moutinho

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO
ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE
ENGENHARIA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO
PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU
DE MESTRE EM CIÊNCIAS EM ENGENHARIA ELÉTRICA.

Orientador: Carmen Lucia Tancredo Borges

Aprovada por: Prof^a. Carmen Lucia Tancredo Borges

Eng. Luciano de Souza Moulin

Prof. Djalma Mosqueira Falcão

Prof. Vitor Hugo Ferreira

RIO DE JANEIRO, RJ – BRASIL

MAIO DE 2022

Moutinho, Eduardo Leite

Aplicação da Otimização por Enxame de Partículas e Programação Pseudo-dinâmica na Análise de Atraso de Obras de Transmissão Considerando Confiabilidade/ Eduardo Leite Moutinho. – Rio de Janeiro: UFRJ/COPPE, 2022.

XIV, 106 p.: il.; 29,7cm.

Orientador: Carmen Lucia Tancredo Borges

Dissertação (mestrado) – UFRJ/COPPE/Programa de Engenharia Elétrica, 2022.

Referências Bibliográficas: p. 66 – 73.

1. Planejamento da transmissão. 2. Análise de atrasos. 3. Otimização por enxame de partículas. 4. Programação pseudo-dinâmica. I. Borges, Carmen Lucia Tancredo. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia Elétrica. III. Título.

Agradecimentos

Agradeço a Deus por me guiar até aqui e por dar forças para seguir em frente.

À minha orientadora Carmen e ao amigo de Cepel Luciano pelo direcionamento e pelas valiosas contribuições.

Aos meus pais Zileide e Afonso, e minha irmã Érica pelo apoio.

À minha esposa Kamila pelo carinho e paciência, além do incentivo e bom exemplo de dedicação acadêmica dado diariamente.

Aos amigos Felipe e Nicolas pelas discussões e contribuições durante o desenvolvimento deste trabalho.

Aos amigos Renan, Paula, Lígia, Beatriz, Thiago e Miryam pelo companheirismo diário.

Ao Cepel e à UFRJ pela oportunidade e recursos para a realização deste trabalho.

Às equipes do PLANTAC, NH2, ANAREDE e SAGE-SAR, projetos pelos quais passei durante este período.

Resumo da Dissertação apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

APLICAÇÃO DA OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS E
PROGRAMAÇÃO PSEUDO-DINÂMICA NA ANÁLISE DE ATRASO DE
OBRAS DE TRANSMISSÃO CONSIDERANDO CONFIABILIDADE

Eduardo Leite Moutinho

Maio/2022

Orientador: Carmen Lucia Tancredo Borges

Programa: Engenharia Elétrica

Este trabalho apresenta o desenvolvimento de uma metodologia de busca inteligente de cenários de atraso de obras de transmissão, para a classificação sobre sua criticidade, sem que haja a necessidade de uma execução exaustiva de todos os cenários possíveis.

Para isto, foi escolhido o Método de Otimização por Enxame de Partículas(PSO) e suas variantes. Foi implementada uma junção entre o PSO Pareto-ótimo, que considera múltiplas funções objetivo em sua busca, e o PSO Binário, capaz de buscar soluções em espaços de busca binários. Isto possibilitou a utilização de quatro objetivos de otimização e a característica binária do atraso ou não das obras consideradas. Para considerar a característica plurianual do planejamento da transmissão, foi utilizado um algoritmo pseudo-dinâmico com capacidade de percorrer iterativamente o horizonte de estudos.

Para classificar as obras por sua criticidade, foi desenvolvida uma metodologia de classificação utilizando atributos técnicos obtidos através da execução do fluxo de potência AC, bem como da análise de confiabilidade via Simulação de Monte Carlo.

Abstract of Dissertation presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

APPLICATION OF PARTICLE SWARM OPTIMIZATION AND
PSEUDO-DYNAMIC PROGRAMMING IN THE DELAY ANALYSIS OF
TRANSMISSION PROJECTS CONSIDERING RELIABILITY

Eduardo Leite Moutinho

May/2022

Advisor: Carmen Lucia Tancredo Borges

Department: Electrical Engineering

In this work, a methodology for an intelligent search of transmission projects delay scenarios has been developed, aiming at classifying their criticality, without the need for an exhaustive execution of all possible scenarios.

For this, the Particle Swarm Optimization (PSO) method and its variants were chosen. Namely, a combination of Pareto-optimal PSO and Binary PSO was implemented. The first considers multiple objective functions in its search, and the latter is able to find solutions in binary search spaces. With this combination of methods, it was possible to use four optimization objectives and include the binary characteristic of delays. To consider the multiannual characteristic of transmission planning, a pseudo-dynamic algorithm was used with the ability to go through the horizon of study iteratively.

A classification method was developed to rank the projects according to their criticality, using technical attributes obtained through the execution of the AC power flow, as well as the reliability analysis via Monte Carlo Simulation.

Sumário

Lista de Figuras	x
Lista de Tabelas	xii
1 Introdução	1
1.1 Objetivo	6
1.2 Artigos decorrentes deste trabalho	7
1.3 Estrutura da dissertação	7
2 Revisão Bibliográfica	8
2.1 Métodos para análise de atrasos de obras de transmissão	8
2.2 Planejamento da transmissão em múltiplos estágios	9
2.2.1 Estado da arte em planejamento da transmissão	10
2.3 Programação pseudo-dinâmica	11
2.4 Métodos meta-heurísticos	12
2.4.1 Otimização por Enxame de Partículas	13
3 Metodologia	18
3.1 Abordagem Exaustiva	18
3.2 Simulação das configuração anuais de atraso	21
3.2.1 Análise de Confiabilidade	24
3.2.2 Algoritmo para geração de configurações plurianuais de atraso	25
3.3 Otimização por Enxame de Partículas	26
3.3.1 Versão clássica	26
3.3.2 PSO Binário Pareto-Ótimo	30
3.4 Aplicação do PSO Binário Pareto-ótimo na busca por configurações de atraso	35
3.4.1 Representação das partículas	37
3.4.2 Inicialização da População	38
3.4.3 Funções objetivo	38
3.4.4 Algoritmo para geração de configurações anuais com PSO . . .	39
3.5 Geração das configurações plurianuais de atraso	41

3.6	Programação pseudo-dinâmica	42
3.7	Geração do grupo Pareto de configurações plurianuais	45
3.8	Método para ranqueamento das obras	45
3.8.1	Índices gerais	46
3.8.2	Índices anuais	47
3.9	Implementação computacional	49
4	Estudos de caso e Resultados	50
4.1	Sistema de subtransmissão 40-barras	50
4.1.1	Horizonte de 3 anos	51
4.1.2	Horizonte de 6 anos	53
4.2	IEEE 24-barras RTS	55
4.3	Comparação entre o método NSGA-II e o BP-PSO	60
4.3.1	Caso de estudo	60
4.3.2	Conclusão da comparação dos métodos	63
5	Conclusões	64
	Referências Bibliográficas	66
A	Comparação multi-objetivo	74
B	Exemplo de execução: PSO Binário Mono-objetivo	75
B.1	Inicialização da população	76
B.1.1	Partícula 1	76
B.1.2	Partícula 2	76
B.2	Iteração 1	77
B.2.1	Partícula 1	77
B.2.2	Partícula 2	78
B.3	Iteração 2	79
B.3.1	Partícula 1	79
B.3.2	Partícula 2	80
B.4	Iteração 3	81
B.4.1	Partícula 1	82
B.4.2	Partícula 2	82
B.5	Iteração 4	84
B.5.1	Partícula 1	84
B.5.2	Partícula 2	85
B.6	Iterações seguintes	86

C	Validador BP-PSO	87
C.1	Aplicação do BP-PSO nas funções de teste	90
C.1.1	$f1$ vs. $f2$	91
C.1.2	$f8$ vs. $f2$	92
C.1.3	$f3$ vs. $f2$ vs. $f7$ vs. $g00$	93
D	Exemplo numérico do cálculo dos índices de classificação de obras	95
D.1	Cálculo do Índice de Severidade IS	97
D.2	Cálculo do Índice de Probabilidade	98
D.3	Índices anuais	99
D.3.1	Cálculo do índice de Severidade anual	99
D.3.2	Cálculo da probabilidade anual	100
E	Método alternativo NSGA-II	102
E.1	Conceitos teóricos do método NSGA-II	102
E.1.1	Classificação das não dominadas	104
E.1.2	Classificação por distância de aglomeração	104
E.2	Aplicação do método NSGA-II na classificação dos atrasos de obras .	106
E.2.1	Cruzamentos	106
E.2.2	Inclusão de múltiplas funções objetivo	106
E.2.3	Definição da convergência	106

Lista de Figuras

3.1	Exemplo de número de combinações de atrasos possíveis	20
3.2	Abordagem exaustiva	21
3.3	Análise feita para cada configuração de atraso	23
3.4	Método interno de análise de confiabilidade	25
3.5	Controle dinâmico do coeficiente de inércia w	29
3.6	Caminhada de uma partícula no espaço real	29
3.7	Visão geral do PSO real mono-objetivo	31
3.8	Curva da função <i>sigmóide</i>	32
3.9	Visão geral do PSO Binário Pareto-Ótimo	36
3.10	BP-PSO aplicado na geração de atrasos de obras	41
3.11	Detalhamento dos passos a) <i>backward</i> e b) <i>forward</i>	43
3.12	Alternância entre os passos <i>forward</i> and <i>backward</i>	44
4.1	Sistema de subtransmissão com obras planejadas - Estudo de caso 1 .	51
4.2	IEEE RTS com obras planejadas - Caso 2	57
A.1	Exemplo de Grupo de Pareto	74
B.1	Espaço de buscas do exemplo	76
B.2	Movimentação das partículas na iteração 1	79
B.3	Movimentação das partículas na iteração 2	81
B.4	Movimentação das partículas na iteração 3	83
B.5	Movimentação das partículas na iteração 4	86
C.1	Todas as posições possíveis para $f1(x)$ vs. $f2(x)$	88
C.2	88
C.3	Todas as posições possíveis para $f7(x)$ vs. $f9(x)$	89
C.4	Todas as posições possíveis para $f8(x)$ vs. $f9(x)$	90
C.5	Valores de $f1$ e $f2$ visitados pelos métodos a) exaustivo e b) BP-PSO	91
C.6	9 primeiras iterações das partículas com $f1$ e $f2$	92
C.7	Valores de $f8$ e $f2$ visitados pelos métodos a) exaustivo e b) BP-PSO	92
C.8	$f3$ vs. $f2$ vs. $f7$ vs. $g00$: frentes de Pareto com o método exaustivo .	93

C.9	<i>f3 vs. f2 vs. f7 vs. g00</i> : frentes de Pareto com o método BP-PSO	94
E.1	Método NGSA-II	103
E.2	População inicial	103
E.3	População inicial mais descendentes	103
E.4	Frentes de Pareto identificadas pela classificação das não-dominadas	104
E.5	Identificação dos indivíduos aptos a progredir	105

Lista de Tabelas

3.1	Resultado da Eq. 3.1 variando nA_{max} e nO	19
4.1	Visão geral dos atributos do \mathbb{GP}^* no horizonte de planejamento de 3 anos	51
4.2	Índices de classificação de obras no horizonte de 3 anos	52
4.3	Classificação final das obras - horizonte de 3 anos	52
4.4	Visão geral dos atributos do \mathbb{GP}^* no horizonte de planejamento de 6 anos	54
4.5	Índices de classificação de obras no horizonte de 6 anos	54
4.6	Classificação final das obras - horizonte de 6 anos	54
4.7	Visão geral dos valores de atributos do \mathbb{GP}^* para o caso RTS	56
4.8	Índices de classificação de obras para o caso RTS em 3 anos	58
4.9	Classificação final das obras - caso RTS	58
4.10	Visão geral dos atributos do \mathbb{GP}^* no horizonte de planejamento de 3 anos	60
4.11	Índices de classificação de obras no horizonte de 3 anos	61
4.12	Classificação final das obras - horizonte de 3 anos	61
4.13	Visão geral dos atributos do \mathbb{GP}^* no horizonte de planejamento de 6 anos	62
4.14	Índices de classificação de obras no horizonte de 6 anos	62
4.15	Classificação final das obras - horizonte de 6 anos	62
B.1	Valores da função objetivo em cada localização possível	75
C.1	Funções binárias usadas no validador BP-PSO	87
C.2	Funções binárias encontradas em [66]	90
D.1	Grupo de Pareto com valores anuais	95
D.2	arquivo1 com média dos impactos anuais por obra considerando as configurações de Pareto	96
D.3	Valores plurianuais dos atributos de cada configuração em \mathbb{GP}^*	97
D.4	Valores dos atributos associados a cada obra j	98

D.5	valores máximos de cada atributo	98
D.6	Valores normalizados pelo máximo	98
D.7	Valores de <i>IS</i> no exemplo ilustrativo	99
D.8	Valores de <i>IP</i> no exemplo ilustrativo	99
D.9	Valores anuais máximos de cada atributo	99
D.10	Valores anuais dos atributos normalizados pelo máximo	100
D.11	<i>IS</i> anual para o exemplo numérico	100
D.12	<i>IP</i> anual para o exemplo numérico	101

Lista de Algoritmos

3.1	Atualização da localização pBest da partícula p	30
3.2	Atualização do grupo gBests	30
3.3	Atualização da localização pBest da partícula p	33
3.4	Checagem da dominância com duas funções objetivo	34
3.5	Atualização do grupo gBests	34
3.6	Checagem da dominância considerando os quatro atributos	40

Capítulo 1

Introdução

O principal objetivo do planejamento da transmissão multiestágio é decidir onde, quando e quais reforços devem ser construídos no sistema existente para atender aos critérios de adequação e segurança da rede nos anos futuros.

Estes estudos determinam prazos para a construção destes empreendimentos, mas muitas vezes estes não são cumpridos, devido à imprevisibilidades em suas licitações e construções.

Na atual estrutura regulatória do Sistema Elétrico Brasileiro, concessões de transmissão são feitas através de leilões invertidos, a fim de promover a competitividade e reduzir os custos. Após os empreendimentos serem concluídos, as empresas passam a receber as receitas contratadas subtraídas da parcela variável referente aos descontos por paradas e falhas na transmissão.

Atrasos de obras de transmissão no Brasil

O atraso de obras de transmissão é um problema que atinge diversas instituições do setor elétrico no Brasil, passando por entidades públicas e privadas, no planejamento e na operação do sistema. Com isso, um interesse comum em evitar este problema é firmado, consolidando uma cadeia de medidas a serem tomadas para diminuir os impactos provenientes destes atrasos.

O ONS (Operador Nacional do Sistema) monitora continuamente a operação do sistema elétrico e verifica a necessidade de expansões na Rede Básica de Transmissão para resolver as restrições que porventura apareçam no horizonte de curto prazo. Essas necessidades são incluídas no Plano de Ampliações e Reforços – PAR. Para a definição dessas novas obras de curto prazo, o ONS faz um estudo em um horizonte de até 4 anos à frente, verificando limites e restrições violadas e definindo as necessidades de ampliações.

As obras do PAR definidas pelo ONS são recomendadas à EPE/MME, para que sejam incluídas no plano de expansão de médio prazo, que tem o horizonte de até 6

anos à frente.

O atraso de obras planejadas para o curto prazo pode acarretar violações dos critérios de operação e a necessidade de modificações no planejamento da operação elétrica e energética, a fim de evitar situações de operação insegura do sistema.

Isso também pode levar a uma eficiência abaixo da prevista para a operação energética, devido a modificações nos intercâmbios de energia planejados pela otimização dos despachos de geração.

A EPE (Empresa de Pesquisa Energética) realiza os estudos referentes ao planejamento da expansão da transmissão de médio e longo prazos (6 anos e 15 anos à frente) em ciclos anuais. Tendo os resultados dos estudos de planejamento, o MME (Ministério de Minas e Energia) divulga o plano indicativo de expansão da transmissão que contém a lista de obras e respectivo cronograma de implantação, necessários para o bom desempenho do sistema elétrico de acordo com os critérios de planejamento considerados.

Após os estudos de planejamento, as obras planejadas são oferecidas em leilões de transmissão, quando podem ser arrematadas pelas empresas de transmissão interessadas na construção e operação de linhas de transmissão e subestações da rede básica. Parte dos lotes oferecidos pode deixar de ser arrematado por falta de interesse dos participantes. Consequentemente, as obras dos lotes não arrematados deixam de ser incluídas no sistema elétrico no prazo previsto nos estudos de planejamento da expansão. Soma-se a isso, o atraso de obras que, embora tenham sido arrematadas, tem a sua conclusão atrasada por fatores diversos que serão explanados adiante.

Devido aos casos de indefinições quanto à entrada em operação de obras planejadas, a EPE tem procurado adaptar o plano de expansão dos estudos posteriores, face à não entrada em operação de obras planejadas em estudos anteriores, atuando de maneira corretiva para adequação às novas situações [1].

Depois de arrematar os lotes de transmissão, as empresas vencedoras passam a obedecer aos Contratos de Concessão de Transmissão, quando devem observar o cronograma de implantação e o prazo para término da implantação das linhas de transmissão e subestações da rede básica.

A ANEEL (Agência Nacional de Energia Elétrica) realiza ações de fiscalização e acompanhamento desses empreendimentos já licitados e em fase de implantação, com ferramentas de gestão administrativa dos contratos de concessão. O acompanhamento dos contratos se dá com base na evolução da previsão de conclusão das diversas etapas do cronograma de implantação, podendo culminar em processos corretivos ou até, num último estágio, processos punitivos com aplicação de penalidades pela ANEEL. Mensalmente, são divulgados detalhes das obras e marcos de execução dos empreendimentos em andamento ou concluídos recentemente em [2].

As implantações de obras em andamento são submetidas à avaliação periódica pela ANEEL e um subgrupo de obras classificadas como mais críticas é inserido num acompanhamento diferenciado, que corresponde a uma fiscalização mais detalhada, com reuniões periódicas e visitas nos locais de obras, entre outras medidas. Durante o acompanhamento diferenciado, a ANEEL/SFE (Superintendência de Fiscalização dos Serviços de Eletricidade) utiliza ferramentas de inteligência analítica para estimar o prazo efetivo do término das obras. Por fim, a ANEEL compara essa estimativa com as informações mensais de evolução das obras, enviadas pelas empresas de transmissão responsáveis pelas obras [3].

Um relatório trimestral [4] é então gerado e apresenta os resultados da fiscalização e as constatações da SFE sobre o andamento dos projetos.

A classificação de criticidade das obras para a definição do subgrupo diferenciado é realizada com base nos seguintes atributos :

- Dados de porte (número de módulos);
- Atraso previsto;
- Importância sistêmica:
 - Abrangência na operação do SIN;
 - Não conformidade a ser corrigida;
- Não conformidade a ser corrigida;
- Necessidade de licenciamento ambiental; e
- Potência de geração associada.

No relatório de acompanhamento diferenciado de março de 2019 há aproximadamente 403 empreendimentos de transmissão licitados e em processo de implantação, dos quais 141 (35%) têm previsão de atraso na avaliação da ANEEL. Segundo o relatório, 90 empreendimentos de transmissão estão no subgrupo de acompanhamento diferenciado.

Pelos atributos considerados para a definição do subgrupo diferenciado, as informações utilizadas são de natureza qualitativa. Muitos empreendimentos passam a ter o acompanhamento diferenciado depois do início da construção das obras, quando se passa a constatar algum risco de atraso. Outras obras tem o acompanhamento diferenciado desde o início do cronograma de implantação, por serem estimadas como mais impactantes no SIN. Como exemplo dessas, citam-se linhas de transmissão de interligação entre subsistemas energéticos e linhas de transmissão associadas a grandes empreendimentos de geração, onde há risco de desequilíbrio

entre grandes quantidades de geração previstas para entrarem em operação e a efetiva disponibilidade dos recursos de transmissão associados à geração. Não há uma avaliação técnica detalhada prévia sobre o impacto do atraso das obras no SIN, para além de obras associadas à transmissão de grandes blocos de potência [5].

Atrasos em construções de empreendimentos de engenharia podem ser causados por fatores diversos, tais como mau tempo, falta de comunicação e coordenação entre as partes do projeto, falta de pagamento para contratados, força de trabalho não qualificada, capacidades financeiras fracas dos contratados, planejamento e cronograma de projetos inadequados, gerenciamento e supervisão ineficaz do local por empreiteiros, entre outros [6].

Somado a isso, projetos de transmissão planejados no Brasil podem sofrer com leilões de transmissão vazios, ou seja, falta de interesse por parte de investidores nos leilões; extenso processo de licenciamento ambiental, que deve ser finalizado antes do início da construção do projeto e; problemas financeiros ou falência de empresas de transmissão após vencerem o leilão. Em [1] há diversos exemplos de linhas de transmissão de 230kV e 500kV planejadas, que após três anos do prazo esperado para operação, ainda estava indefinido quando ou se elas estariam disponíveis para operação.

Avaliação de atrasos de obras

A avaliação deste tipo de situação se torna importante, a fim de checar os impactos que tais atrasos causariam em um plano de transmissão, como perda de confiabilidade, aumento de perdas elétricas e violações de limites operacionais. O método proposto neste trabalho considera informações importantes extraídas através de ferramentas de análise da rede como o fluxo de potência AC e o fluxo de potência ótimo, além de análise de confiabilidade probabilística via Simulação Monte Carlo não-sequencial. Desta forma, é possível dar um indicativo de obras que devem receber mais atenção no sentido de cumprimento de prazos, ao gerar prejuízos mais severos em situações de atraso. Além disso, ao aplicar esta análise em planos de expansão diferentes, pode ser feita uma comparação em relação à sua robustez ao lidar com atrasos em suas obras.

Este trabalho aborda a análise do atraso de obras de transmissão, que pode ser entendido como uma extensão do problema de planejamento da expansão, pois trata de combinações de obras, também num horizonte plurianual. Esta análise inclui a análise de confiabilidade probabilística para ranquear reforços planejados passíveis de atraso.

Atualmente no Brasil, a EPE, que é responsável pelos estudos para expansão da rede transmissão, atualiza anualmente o plano de expansão de médio e longo

prazos. Nele são indicados se, quais e quando reforços de transmissão são necessários no sistema para que ele atenda aos critérios técnicos obrigatórios, como o critério determinístico N-1. Este tipo de análise determinística deixa de considerar pontos importantes, como as probabilidades e consequências das falhas de equipamentos no sistema. Pontos estes abordados numa análise de confiabilidade probabilística. Portanto, pode fornecer uma avaliação irreal do sistema, ao passo que, em muitas áreas do sistema o critério N-1 pode ser considerado conservador.

Na referência [7], o problema foi abordado enumerando e simulando cada um dos cenários de atrasos das obras consideradas, combinadas duas-a-duas, num horizonte de estudo plurianual, através de uma busca exaustiva implementada por meio da modificação do PLANTAC [8],[9], software de planejamento da transmissão desenvolvido no Centro de Pesquisas de Energia Elétrica (Cepel). A ideia apresentada em [7] é detalhada na Seção 3.1. Este tipo de abordagem é computacionalmente ineficiente, pois todos os cenários de atrasos para certo grau de combinações são simulados, em cada ano do horizonte. Este gargalo computacional limita o método, pois, como simular todos os arranjos plurianuais de atrasos em obras pode inviabilizar a execução, é fixado um número máximo de atrasos simultâneos por ano (dois atrasos, no caso da referência). Assim, nenhuma combinação de três ou mais obras seria simulada nesta abordagem. Com isso pode-se deixar de considerar cenários críticos de atrasos destas obras.

Há então, a necessidade da implementação de um método para racionalizar a busca e desta forma explorar mais eficientemente o universo de combinações de atrasos possíveis.

Técnicas meta-heurísticas são muito utilizadas na resolução de problemas combinatoriais de sistemas de potência, e há uma gama de opções na escolha das técnicas a serem aplicadas, cada uma com suas especificidades. Uma característica dos métodos meta-heurísticos é a não-garantia de se encontrar a solução ótima, mas podendo promover uma considerável redução no esforço computacional, se bem calibrados. Enquanto a otimização matemática obtém a solução para o problema através da resolução de formulações matemáticas, e os métodos heurísticos obtém a solução explorando o espaço de buscas e direcionando a solução a um ótimo, os métodos meta-heurísticos integram recursos de ambas as abordagens [10].

Dentre as meta-heurísticas mais utilizadas, incluem-se: Algoritmos Genéticos, Estratégias de Evolução, Otimização de Enxame de Partículas, Colônias de Formigas, Busca Tabu, Recozimento Simulado, Sistemas Fuzzy, Evolução Diferencial, entre outras.

Este trabalho propõe-se a aprimorar a abordagem de [7], introduzindo uma busca inteligente pelos cenários de atraso, via método meta-heurístico, a fim de aliviar a carga computacional, e permitir uma busca mais eficiente no grupo de atrasos

possíveis. Outra melhoria é a definição de uma metodologia para o ranqueamento das obras analisadas a partir dos cenários simulados.

O método de otimização por enxame de partículas (PSO) se mostrou bastante adequado para ser aplicado no problema em questão, pois possui vasto histórico de aplicações em problemas relacionados ao setor elétrico, além de possuir boa sinergia com programas baseados em computação paralela.

Neste trabalho, cada cenário de atraso de obras pode ser entendido como uma lista de obras onde cada uma delas será atrasada ou não em dado ano. Esta característica tornou o PSO binário (BPSO) o método mais adequado e que será utilizado por tratar de variáveis binárias. A aplicação consiste em maximizar atributos de corte de carga, perda de confiabilidade e perdas elétricas, a fim de encontrar configurações de atraso de maior impacto no sistema. A minimização do número de obras atrasadas simultaneamente também é considerada, a fim de diminuir a concentração das configurações candidatas em regiões onde mais obras são combinadas simultaneamente. Por considerar múltiplos objetivos não combináveis, o método de busca mais adequado é do tipo Pareto-Ótimo. Assim, será aplicada uma variante do método BPSO que utiliza conceitos de Ótimo de Pareto no ranqueamento das partículas. Esta técnica permite otimização da busca considerando múltiplos objetivos e se mostrou eficiente na aplicação, e será referida neste trabalho como BP-PSO.

1.1 Objetivo

Este trabalho tem como objetivo desenvolver uma ferramenta de análise de atrasos de obras que considere aspectos técnicos da rede, incluindo confiabilidade. Para tanto, foi tomado como base uma ferramenta consolidada de planejamento da transmissão, mas que possuía como gargalo o tempo computacional de suas execuções.

A implementação do método meta-heurístico PSO Binário Pareto-ótimo (BP-PSO) em uma estrutura de algoritmo pseudo-dinâmico foi feita para, através de busca inteligente, reduzir o número de combinações de atrasos a serem executadas, sem gerar prejuízo na classificação destas obras. Assim, este tipo de estudo que é naturalmente custoso computacionalmente, torna-se viável.

Além disso, uma metodologia de ranqueamento de obras foi definida neste trabalho, utilizando os atributos técnicos extraídos dos resultados de cada simulação executada.

1.2 Artigos decorrentes deste trabalho

Ao longo do desenvolvimento desta dissertação, foram publicados dois artigos em congresso, ambos apresentados pelo autor deste trabalho, e um artigo com a metodologia completa foi submetido e atualmente sob análise:

- [7] Moutinho, E. L.; Borges, C. L. T.; Moulin, L. S.; “Reliability Assessment of Transmission Reinforcements Delay in the Brazilian Expansion Planning”. Em: 2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS), 2018
- [11] Moulin, L. S.; Moutinho, E. L.; Borges, C. L. T.; “Metodologia para Avaliação de Atrasos de Obras de Transmissão Elétrica no Sistema Elétrico Brasileiro sob o Enfoque da Confiabilidade”. Em: XXV Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE), 2019
- Artigo submetido e atualmente sob análise: Moutinho, E. L.; Borges, C. L. T.; Moulin, L. S.; “Assessment of Most Critical Projects on a Multi-Stage Transmission Expansion Planning based on Particle Swarm Optimization”.

1.3 Estrutura da dissertação

Além deste capítulo introdutório, esta dissertação apresenta mais quatro capítulos e cinco apêndices.

O Capítulo 2 apresenta uma revisão bibliográfica dos temas relacionados ao desenvolvimento deste trabalho.

O Capítulo 3 apresenta a metodologia proposta neste trabalho, além de detalhar as ferramentas utilizadas.

O Capítulo 4 apresenta os casos teste e os resultados deste trabalho, incluindo análise e interpretações.

O Capítulo 5 apresenta as conclusões deste trabalho, bem como as prospecções de trabalhos futuros.

O Apêndice A introduz conceitos de dominância em comparação multi-objetivos.

O Apêndice B expõe um exemplo prático de uma execução de PSO binário mono-objetivo.

O Apêndice C lista algumas funções binárias utilizadas para testar o método BP-PSO implementado.

O Apêndice D expõe um exemplo numérico do cálculo dos índices de classificação utilizados no ranqueamento das obras.

O Apêndice E traz o método alternativo NSGA-II que teve seu desempenho comparado ao BP-PSO.

Capítulo 2

Revisão Bibliográfica

2.1 Métodos para análise de atrasos de obras de transmissão

A literatura técnica no tema de análise de atrasos de obras não é muito extensa.

Em [6] os autores fazem uma pesquisa bibliográfica com 74 artigos, onde buscam as causas de atrasos de projetos de expansão da transmissão. A maioria dos artigos revisados trazem atrasos de outros tipos de empreendimentos de engenharia, mas com causas gerais e que podem ser considerados em qualquer projeto de transmissão. O foco do artigo é nas causas de atrasos em projetos específicos, mas sem tratar os impactos sistêmicos que os projetos poderiam ocasionar no sistema elétrico.

A referência [12] apresenta um modelo para planejamento da transmissão dinâmico (multi-período) considerando incertezas quanto ao prazo de implementação das obras. Utiliza a programação linear inteira mista e fluxo de potência linearizado. Não foi feita análise de confiabilidade nesta simulação. Como caso teste, utilizou-se o sistema teste IEEE 14 barras, com dados modificados, e um horizonte de planejamento de 4 anos e 3 patamares de carga para cada intervalo de 4 meses. O trabalho mostrou tempos de processamento altos, mesmo para um sistema de teste.

Em [7] é apresentada uma investigação sobre os atrasos de obras de transmissão no Brasil e a avaliação do impacto desses atrasos, considerando a confiabilidade. O artigo contemplou um estudo de caso real, considerando uma parte do Sistema Interligado Nacional (SIN), e utilizou a rede completa representada em seis cenários de carga e geração, num horizonte de oito anos. Além disso, utilizou-se o método AC para análise de fluxo de potência e o método dos pontos interiores durante o fluxo de potência ótimo. A análise de confiabilidade utilizou-se da Simulação Monte Carlo (SMC) não sequencial. Este estudo, ao utilizar de ferramentas complexas e precisas, esbarrou na limitação do alto tempo computacional, devido à forma de seleção das combinações de obras a serem simuladas. O modelo fazia uma enu-

meração das combinações, tornando o tempo dispendioso ao se expandir o número de possibilidades de atrasos a serem simulados.

O problema de análise do atraso de obras possui similaridades com relação ao planejamento da expansão. Ambos os problemas avaliam combinações de obras de expansão, considerando suas construções ou não, num horizonte plurianual. Além disso, ambos devem considerar indicadores e atributos para mensurar os impactos destas obras elétricas. Por ser um tema vastamente abordado na literatura, o problema de planejamento da expansão da transmissão foi bastante importante nas pesquisas, indicando boas práticas e aplicações dos métodos e técnicas aqui utilizados.

2.2 Planejamento da transmissão em múltiplos estágios

O principal objetivo do planejamento da transmissão é decidir onde, quando e quais reforços devem ser construídos no sistema existente para atender aos critérios de continuidade e segurança da rede. Trata-se de um problema naturalmente grande e complexo, e quanto mais detalhes são inseridos na modelagem, através do aumento do número de cenários representados, da diversificação dos índices e parâmetros calculados, e da expansão das opções de reforços, as aplicações se tornam mais completas, porém eleva-se o tempo computacional, podendo tornar a execução inviável.

É chamado de planejamento estático quando o planejador procura os reforços necessários para um único ano do planejamento, ou seja, busca a configuração final da rede sem avaliar quando no horizonte cada obra deverá ser construída. Já o planejamento dinâmico tem como objetivo encontrar um plano de expansão ótimo considerando todos os anos do horizonte. Este tipo de abordagem é mais complexa pois cria um acoplamento temporal entre cada etapa de planejamento. Com isso, restrições de viabilidade devido ao tempo computacional consumido podem aparecer [13].

A referência [14] apresenta uma aplicação do planejamento estático da transmissão, considerando o modelo DC em conjunto com uma técnica heurística. Em [15], é demonstrado um algoritmo de planejamento estático numa estrutura *branch-and-bound*, que aceita não só a modelagem DC, mas também AC, modelo de transportes e configurações híbridas.

Em [13], é proposta uma abordagem dinâmica utilizando otimização por enxame de partículas como forma de diminuir o tempo computacional gasto na execução. A referência [16] utiliza algoritmo genético para reduzir a carga computacional ao executar simulação dinâmica para tratar do problema de planejamento multi-estágio.

Outra forma de se diminuir o tempo gasto na solução de problemas de múltiplos estágios é dividir a abordagem dinâmica em vários subproblemas estáticos, qualificando as chamadas abordagens pseudo-dinâmicas, como exposto na Seção 2.3.

2.2.1 Estado da arte em planejamento da transmissão

Para se checar quais são as técnicas de resolução do problema de planejamento multiestágio atualmente em estudo, artigos de revisão recentes foram consultados.

A revisão [17] de 2010 compila uma série de artigos que utilizam métodos evolucionários na solução de problemas em aplicações de sistemas elétricos de potência. Nesta revisão, doze dos artigos citados utilizaram métodos PSO e dezesseis AG.

As referências [18] e [19] de 2013 citam algumas variantes de algoritmos genéticos, incluindo Non-dominated Sorting Genetic Algorithm (NSGA), e indicou que este tipo de algoritmo é bastante utilizado no planejamento considerando múltiplos objetivos.

O artigo de revisão [20] de 2019 é um excelente compilado de métodos utilizados na expansão da rede de transmissão. Além de trazer diversas referências, esta revisão resumizou as principais características e considerações de cada método.

Artigos que utilizaram Algoritmos Genéticos somaram 19 citações, sendo aplicado em planejamento da transmissão considerando múltiplos objetivos. Os métodos AG destacaram-se por resolver problemas de planejamento de natureza não convexa e inteira mista com alta taxa de convergência no processo iterativo.

Aprimoramentos no AG possibilitaram a solução com menos tempo computacional encontrando boas soluções já nas primeiras iterações. Suas principais desvantagens são o alto custo computacional e um número expressivo de parâmetros de calibração.

Já os artigos que utilizaram métodos derivados do PSO somaram 7 citações, sendo aplicado principalmente em problemas de expansão com múltiplos estágios.

O PSO destacou-se por possuir uma boa taxa de convergência, devido ao rápido fluxo de informações entre os vetores de solução, e por ser capaz de encontrar uma solução melhor do que o algoritmo genético.

A principal desvantagem observada na revisão foi que a diversidade da população diminui muito rapidamente com o passar das iterações, podendo resultar numa cobertura pior do espectro de soluções.

Dentro da família de algoritmos genéticos, observou-se um destaque para o Algoritmo Genético de Classificação Não-dominada II (NSGA-II), do inglês “*Non-dominated Sorting Genetic Algorithm II*”

Por ser um tipo de algoritmo altamente relevante e por ser também baseado em população, foi decidido implementar, além do método BP-PSO, o método NSGA-II.

Os conceitos envolvendo o método NSGA-II são apresentados no Apêndice E, e os resultados da comparação entre o BP-PSO e o NSGA-II estão descritos no Capítulo 4.

2.3 Programação pseudo-dinâmica

Em [21], é apresentado um método pseudo-dinâmico aplicado ao planejamento em múltiplos estágios de redes de distribuição. Nele, ano a ano o problema é abordado como uma expansão do ano anterior.

A abordagem pseudo-dinâmica *forward* (em avanço) consiste em resolver problemas de expansão estática a partir do primeiro, até o último ano em sequência, considerando os reforços calculados em etapas anteriores [22].

Já a abordagem *backward* (em regresso) trata o problema a partir do último ano (por este possuir violações mais severas) e faz o caminho contrário, regredindo nos anos e checando a necessidade das obras nos anos anteriores. Obras adicionais podem então ser necessárias para resolver violações em anos intermediários.

Por iniciar pelo cenário temporal ser mais severo, a abordagem *backward* pode ser considerada mais eficaz que a *forward*. Ao mesclar elementos de ambas as abordagens pode-se obter o método “*backward-forward*”, proposto em [22], com o intuito de produzir um plano mais consistente e econômico. Para isto, a execução é dividida entre passadas em avanço e em regresso alternadamente.

Esta abordagem é composta de passos em avanço e em regresso no tempo, cobrindo apenas algumas alternativas por passada. Desta forma, obtém-se uma convergência uniforme que considera as dependências pluri-aneais das configurações de rede. As informações de cada estágio k são herdadas pelas simulações seguintes (estágio $k + 1$ em passos *forward* ou $k - 1$ em passos *backward*).

Em [23] é utilizado o método *backward-forward*, e considera também ocorrências de falhas de equipamentos durante o planejamento da distribuição.

A referência [24] demonstra a utilização de um método pseudo-dinâmico sendo utilizado no planejamento em múltiplos estágios de sistemas de distribuição, considerando incertezas de geração e demanda. Nela, a cada passo no caminho *forward* ou *backward* é utilizado um algoritmo genético a fim de reduzir ainda mais o tempo computacional.

Como o esforço computacional para resolver o problema multi-estágio associado à análise de atrasos é muito grande, neste trabalho, além de uma abordagem pseudo-dinâmica, foi escolhido aplicar a cada etapa temporal do método, um método meta-heurístico. Assim, a dinâmica temporal adotada em [24] foi escolhida para ser utilizada nesta dissertação, por ter se demonstrado muito eficiente ao acompanhar o método heurístico e assim lidar com o problema com múltiplos estágios de forma

mais ágil e eficaz.

2.4 Métodos meta-heurísticos

Meta-heurística é um princípio de busca ou a estrutura de algoritmo que terá seu comportamento modificado de acordo com o contexto em que for aplicado, e tem como objetivo encontrar boas soluções aproximadas para problemas de otimização [25]. Problemas de otimização combinatória, otimização global, programação estocástica são exemplos de aplicações bem-sucedidas de técnicas meta-heurísticas.

Os métodos meta-heurísticos têm sido largamente aplicados em diversas áreas de sistemas de potência, como: avaliação de estabilidade dinâmica, fluxo de potência ótimo, planejamento da operação, planejamento da expansão da geração, transmissão e distribuição, alocação de reativos, reconfiguração de redes, controle de sistemas de potência, despacho econômico, etc. [26], [27], [17], [28], [29]. A referência [30] traz uma visão geral destas aplicações em sistemas de potência, e indica uma série de referências separadas por aplicação.

A meta-heurística tem vantagens sobre a programação matemática convencional em termos da flexibilidade da função e das restrições de custo. Os algoritmos são capazes de lidar com problemas de programação inteira mista não-linear e a avaliação de soluções globalmente ótimas ou aproximadas [27].

Outra característica é que sua velocidade de convergência depende do ajuste apropriado dos parâmetros associados a cada meta-heurística, tornando uma boa calibragem parte importante de sua implementação. Apesar de ser eficaz na solução de problemas complexos, as técnicas de meta-heurística não garantem a obtenção de um ótimo global, podendo eventualmente ficar presos em ótimos locais ao resolver problemas multimodais [28].

Um segmento dos métodos meta-heurísticos bastante explorado na literatura é o baseado em população. Criada para otimização de objetivo único, tem a capacidade de explorar o espaço de busca de forma inerentemente paralela, resultando numa maior eficiência computacional. A aplicação em problemas multi-objetivo é igualmente difundida, devido à sua facilidade em explorar o espaço de busca concorrentemente [29].

Duas das técnicas meta-heurísticas baseadas em população mais populares são os Algoritmos Evolucionários (Algoritmo Genético e suas variantes) e a Otimização por Enxame de Partículas (*Particle Swarm Optimization*).

2.4.1 Otimização por Enxame de Partículas

A Otimização de Enxame de Partículas (PSO) surgiu em 1995 [31] e é uma técnica de computação evolucionária inspirada no comportamento de grupos de pássaros e peixes quando em movimento coletivo [32].

PSO introduz o conceito de inteligência de enxame, quando os comportamentos coletivos de indivíduos não sofisticados criam padrões funcionais globais coerentes, ao interagir localmente com seu ambiente [33].

Como numa revoada de pássaros, indivíduos num grupo podem trocar de direção, se espalhar, reagrupar, de acordo com a situação mais favorável percebida pelo coletivo, tentando manter certa distância entre cada indivíduo. Assim, experiências positivas individuais podem ser aproveitadas por todo o grupo, e as negativas servirão como alerta a todos sobre certa direção ruim [31].

O método PSO tem sido aplicado em vários tipos de problemas em sistemas de potência. As referências [33] e [32] trazem compilações das aplicações de PSO em diversas áreas da engenharia elétrica, tais como despacho econômico, controle de potência reativa e redução de perdas elétricas, fluxo de potência ótimo, projeto de controladores, confiabilidade, planejamento da expansão da geração e estimação de estados.

Comparando-se com outras técnicas de otimização, o método PSO destaca-se em vários pontos [32]:

- É livre de derivadas, e cálculos computacionalmente custosos.
- Pode ser facilmente integrado a outros métodos, formando ferramentas híbridas.
- Tem a capacidade de escapar dos mínimos locais.
- É fácil de implementar e programar com operações matemáticas e lógicas básicas.
- Não requer uma boa solução inicial para iniciar seu processo de iteração.

Quando comparado com outras meta-heurísticas baseadas em população, como os *Algoritmos Genéticos*, o PSO se destaca em alguns pontos [33]:

- Maior facilidade na implementação, pois possui menos parâmetros para ajuste.
- Boa capacidade de memória, guardando tanto seu melhor valor individual como o melhor de sua vizinhança.

- Boa capacidade de manter a população diversificada, pois todas as partículas evoluem sem serem podadas, incentivando maior exploração e gerando uma população com alta carga de experiências. No AG, a cada iteração os piores indivíduos não participam da composição da próxima geração, podendo gerar uma população muito semelhante.

No que tange à implementação computacional, destaca-se por ter um comportamento bastante adequado para modelagens paralelizadas, onde se tem processos que, apesar de executarem o mesmo código, traçam trajetórias diferentes, assim como animais num grupo, inspiração deste método [31].

Otimização de Enxame de Partículas Binária

Na literatura há uma gama de métodos derivados do PSO tradicional. Tais modificações podem ter sido implementadas apenas para se adequar melhor a um problema específico, ou para resolver limitações do método tradicional e beneficiar um vasto número de aplicações.

Este é o caso do método BPSO, uma versão do método PSO que lida com variáveis binárias, e foi proposto em [34].

Também há uma versão do algoritmo original para trabalhar com variáveis inteiras. Em [35] foram feitos dois experimentos para testar o método PSO em aplicações de programação inteira. No primeiro, a localização da partícula continua a ser calculada com valores reais, mas é truncada a cada iteração para o valor inteiro mais próximo. No segundo experimento, as localizações são truncadas gradativamente durante as iterações, diminuindo as casas decimais.

O método BPSO é utilizado na resolução de vários problemas do setor elétrico. As referências a seguir possuem exemplos de aplicações que obtiveram bons resultados ao utilizar este método de otimização.

As referências [36], [37] e [38], aplicam o método na reconfiguração de sistemas de distribuição, buscando as melhores configurações de trechos ligados ou não, para diversos objetivos, como melhoria no perfil de tensão, nas perdas e na confiabilidade, por exemplo.

De maneira semelhante, a busca pela melhoria da margem de estabilidade de tensão em sistemas de transmissão pelo método BPSO é abordada em [39], através do desligamento ótimo de circuitos de transmissão.

Em [40], [41] e [42], BPSO e suas modificações são aplicados no problema de comissionamento de unidades de geração, trazendo resultados relevantes para este tipo de abordagem.

No cálculo de confiabilidade, o método BPSO foi utilizado para guiar a busca pelos estados de falha [43], levando a uma maior rapidez na convergência na Simulação

de Monte Carlo.

As referências [44], [45] e [46] demonstram a aplicação na programação de gerenciamento de demanda, para encontrar os melhores valores de corte de demanda dentro do horizonte de operação de curto prazo, em casos de implantação dessa tecnologia no contexto de *smart-grids*.

O artigo [47] aplica o BPSO no problema de despacho econômico, minimizando custos de geração.

A referência [48] demonstra o BPSO aplicado na programação de manutenção de geradores.

Em [49], o BPSO é utilizado na busca da melhor localização e de menor custo para instalação de PMUs em subestações de um sistema elétrico.

Devido a sua aplicação satisfatória nos temas acima, neste trabalho o BPSO será utilizado para buscar entre as configurações de atrasos de obras, com o objetivo de encontrar aquelas que causem o maior impacto no sistema.

Utilização do Ótimo de Pareto em métodos PSO

Em problemas multi-objetivos, pode ser bastante difícil de se definir uma função objetivo e de se criar comparadores entre soluções cujas características consideram parâmetros diferentes. No método PSO por exemplo, onde a cada movimentação das partículas ocorre um ranqueamento para atualizar a melhor localização individual e global, pode ocorrer dificuldade na comparação [50]. Deve então ser definido o procedimento para se lidar com tais situações.

Além disso, procura-se encontrar uma população bem distribuída por toda a região de Pareto, sem guiá-las para determinado objetivo em detrimento do conjunto.

A comparação entre as partículas segue os conceitos de dominância, expostos no apêndice A deste trabalho.

A referência [51] aplica o PSO para despacho ótimo de potência reativa. Um banco de dados com todas as localizações não dominadas já visitadas pelas partículas é mantido e atualizado, e a melhor localização global utilizada por cada partícula é sorteada aleatoriamente neste banco. A atualização da melhor localização individual para a última visitada é feita se houver dominação, ou seja, se a nova for melhor em todos os quesitos de comparação. Porém se ambas forem não-dominadas, a escolha é feita aleatoriamente.

Em [52], onde é proposta uma técnica híbrida para otimização multi-objetivos, a abordagem é bastante parecida no tocante à escolha dos melhores globais e pessoais, porém, na escolha do melhor individual, caso as duas localizações sejam não-dominadas, em vez de se sortear aleatoriamente, checa-se qual delas possui a maioria das dominâncias parciais. Permanecendo o empate, o melhor individual é escolhido aleatoriamente.

Critérios de parada em métodos PSO

Os critérios de parada do método PSO definem quando o algoritmo considera que tempo computacional não compensa o avanço esperado na solução. Testes devem ser feitos para a calibração de tais critérios, a fim de evitar um número elevado de iterações sem melhoria na resposta, no caso de o critério ser muito rígido, e também evitar uma parada prematura do método, no caso de os critérios estarem muito folgados.

O livro [53] expõe 5 critérios de parada gerais para métodos PSO, sem distinção de aplicações:

1. O primeiro e mais simples critério é a consideração de um número máximo de iterações. Sua utilização é importante para garantir que o algoritmo pare, caso os outros critérios não sejam atingidos, porém, a utilização exclusiva deste critério pode acarretar em um gasto computacional desnecessário, e deve ser evitado.
2. O segundo critério fica restrito à aplicações cujo resultado é conhecido. Neste caso, pode-se optar por parar a execução quando a resposta se aproxima da solução final. Tem aplicação quando se deseja comparar o tempo computacional para a convergência de uma nova variante do método, por exemplo. No caso deste trabalho, a resposta do PSO é desconhecida, inviabilizando tal checagem.
3. O terceiro critério consiste em finalizar o método quando não são observadas melhorias na solução para dado número de iterações. No caso de otimização multi-objetivo, representa a estagnação do grupo $gBests$, que compreende a seleção de localizações visitadas que apresentaram melhor desempenho nas funções objetivo. Estes termos são estressados na Seção 3.3. Tendo esta condição satisfeita, indica ao algoritmo que o método está convergido, e que pode parar de procurar por soluções melhores.
4. Pode-se também ser considerada a diminuição das distâncias mútuas entre todas as partículas no espaço de busca. Esta abordagem direta em aplicações de PSO com único objetivo, onde pode-se medir as distâncias entre as partículas e observar a estabilização destas. Porém em problemas multi-objetivo, cujo resultado é uma frente de Pareto, tal distância mínima não pode ser mensurada, pois posições otimizadas podem ficar distantes uma das outras em diferentes dimensões. Foi considerado adaptar este critério para considerar a distância em relação à cada componente do grupo $gBests$, mas isso implicaria num tempo a mais demandado na comparação, além de ser uma abordagem diferente do

critério original, que considera a distância entre as partículas. Outro ponto complicador para a utilização deste critério neste trabalho é o fato de que se trabalha num espaço de buscas binário. O conceito de “distância” pode ter outra interpretação. A distância entre as partículas num espaço binário é sempre zero ou um em dada dimensão d . Sendo assim, foi descartada a utilização deste critério neste trabalho.

5. Outro critério de parada para o PSO é a consideração de uma tolerância mínima na progressão do método, considerando o valor da função objetivo da posição $gBest$. No caso de otimização multi-objetivo, pode-se considerar cada um dos integrantes do grupo $gBests$, onde, se as partículas não visitarem novas posições com diferenças nos atributos acima da tolerância por um número de iterações, o método é considerado convergido.

Nota-se que este critério é mais folgado que o de estagnação do grupo $gBests$, exposto no item 3.

A maioria dos artigos que utilizam o método PSO como ferramenta de solução não detalha os critérios de parada utilizados. Em [51] e [54] o número máximo de iterações é o único critério de parada utilizado. Já em [55], o critério de parada é satisfeito quando todas as partículas atingem suas melhores localizações durante as iterações.

Este trabalho utilizará os critérios 1 e 3 enumerados acima, ou seja, número máximo de iterações e estagnação do grupo $gBests$.

Capítulo 3

Metodologia

Para atingir o objetivo deste trabalho, que é ranquear as obras de transmissão que causariam mais prejuízos ao sistema na consideração de atrasos em suas construções, será utilizado o BP-PSO como método de busca por configurações anuais de atraso. O objetivo de cada execução do BP-PSO não será então encontrar uma única solução ótima, onde se tem o maior impacto, mas, durante o sua busca, contemplar a execução de cenários de atraso que exponham o impacto individual e combinado do atraso das obras de transmissão.

Parte-se de um plano de expansão previamente preparado, no qual serão introduzidas modificações referentes aos cenários de atrasos das obras definidas como planejadas.

Neste trabalho, serão chamadas de *obras*, os projetos de expansão da transmissão em que se deseja analisar os impactos de seus atrasos. Para definir uma obra, é necessário determinar qual ou quais equipamentos a compõe, bem como o ano planejado para sua implementação. Se em dado ano k a obra deixar de ser construída, levando sua entrada em operação para depois da data prevista, esta obra é considerada atrasada nas análises. Para simular que uma obra composta por circuitos elétricos foi adiada, basta recarregar o caso base com a configuração planejada (sem atrasos), onde todos os reforços previstos estão presentes, e em seguida desligar os equipamentos que compõem a obra.

3.1 Abordagem Exaustiva

Todo o desenvolvimento deste trabalho ocorreu a partir de uma versão do programa de planejamento da transmissão PLANTAC [8],[9] adaptada para a avaliação de atrasos de obras [7],[11]. Nesta versão, era executada a simulação de uma lista de possíveis atrasos nas obras, através da alteração das topologias de rede. Esta abordagem será definida como “abordagem exaustiva”.

Tabela 3.1: Resultado da Eq. 3.1 variando nA_{max} e nO

nAt_{max}	$nO = 5$	$nO = 10$	$nO = 15$
0	1	1	1
1	6	11	16
2	16	56	121
3	26	176	576
4	31	386	1941
5	32	638	4944
6		848	9949
7		968	16384
8		1013	22819
9		1023	27824
10		1024	30827
11			32192
12			32647
13			32752
14			32767
15			32768

Nela, para cada ano k no horizonte de estudo, são listadas cada uma das configurações de atraso D_c possíveis. Estas listas anuais de configurações de atraso são montadas a partir da combinação das obras que deveriam estar implementadas no ano k . Estas obras são combinadas considerando um número máximo de atrasos simultâneos (nA_{max}).

A Equação 3.1 expressa o número de combinações possíveis para um ano com nO obras passíveis de atraso, considerando um número máximo de atrasos simultâneos nA_{max} .

$$\sum_{i=0}^{nA_{max}} \frac{nO!}{i! \cdot (nO - i)!} \quad (3.1)$$

Nesta equação, pode-se observar que há dois fatores que contribuem para o aumento do número de combinações a serem simuladas na abordagem exaustiva: nO e nA_{max} . A Tabela 3.1 e o gráfico da Figura 3.1, em escala logarítmica, expõem como o número de combinações possíveis aumenta ao permitir a simulação de um número atrasos simultâneos maior.

Em aplicações da abordagem exaustiva, pode então ser interessante diminuir o número de atrasos simultâneos permitidos, a fim de diminuir o número de configurações a serem simuladas, reduzindo assim o tempo computacional [7, 11]. Ao se reduzir este número, porém, cenários de atrasos importantes, que considerem a interação de determinadas obras sendo atrasadas simultaneamente podem deixar de

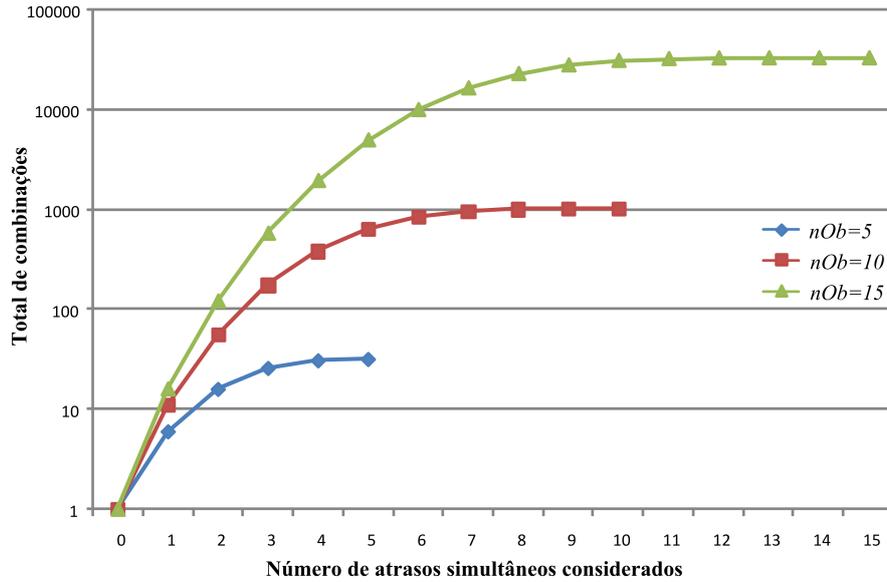


Figura 3.1: Exemplo de número de combinações de atrasos possíveis

serem cobertos.

Em contrapartida, a execução de todos os cenários possíveis de atrasos pode ser considerado um gasto ineficiente de poder computacional, pois haverá um grande número de cenários pouco críticos, agregando pouca ou nenhuma informação à análise.

Essa abordagem foi usada na avaliação dos atrasos de obras em [7] e [11], mas sem uma definição clara da classificação final das obras. Este trabalho, além de definir índices de classificação de obras, propõe também a redução do tempo computacional na execução de atrasos, realizando uma busca inteligente através do método BP-PSO aplicado a um algoritmo pseudo-dinâmico.

A Figura 3.2 expõe a abordagem exaustiva detalhadamente.

Para cada ano k do horizonte de estudos, é gerada uma lista de atrasos a serem simulados considerando nA_{max} , como descrito anteriormente. Começando com a configuração de atraso D_1 , cada configuração da lista é simulada através de ferramentas de análise de redes, considerando todos os cenários operativos modelados. O bloco “Simulação da Configuração de Atraso D_c ” será explorado a seguir, na Seção 3.2. Uma vez simuladas todas as configurações de atraso da lista do primeiro ano, é simulado o segundo ano, e assim sucessivamente até cobrir todo o horizonte de estudo.

Com todas as simulações anuais executadas, o programa pode associá-las para gerar configurações plurianuais de atraso, para avaliar o impacto futuro, e assim ranquear as obras mais críticas ao sistema. Os blocos “Montagem das configurações plurianuais” e “Ranqueamento das Obras” serão mais detalhados nas seções seguintes.

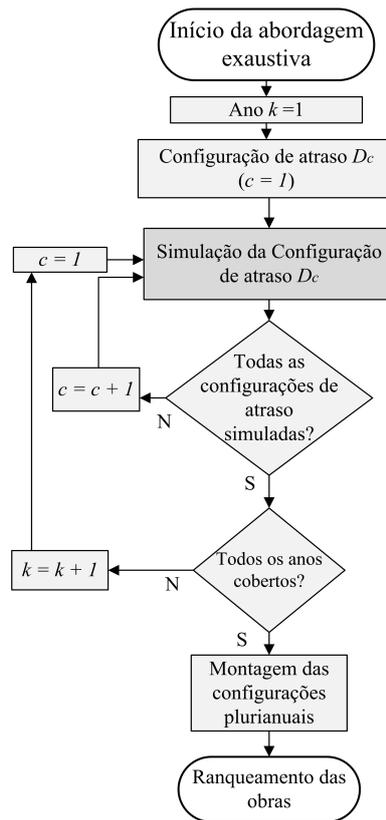


Figura 3.2: Abordagem exaustiva

3.2 Simulação das configuração anuais de atraso

Uma configuração anual de atraso consiste em uma simulação do sistema considerando que as obras estão atrasadas ou não. Na abordagem exaustiva, todas as configurações são executadas sequencialmente. Já no método proposto, as configurações a serem executadas serão ditadas pelo algoritmo de otimização BP-PSO.

Para cada uma destas configurações, serão calculados quatro atributos com o intuito de quantificar o impacto dos atrasos das obras:

- Corte de carga no Caso Base (CCB)
- Número de Obras Atrasadas simultaneamente (NOA)
- Estimativa de Energia Não Suprida (EENS)
- Perdas de Potência Ativa (PPA)

Optou-se por utilizar EENS por ser um importante índice de confiabilidade probabilística. Outros índices de confiabilidade probabilística como por exemplo LOLF ou LOLD poderiam ter sido usados, ou até mesmo um índice determinístico como a aderência ao critério N-1.

O problema é modelado com quatro funções objetivo, uma para cada um dos quatro atributos comparativos. O algoritmo de otimização BP-PSO buscará maximizar os atributos CCB, PPA e EENS, e ao mesmo tempo minimizar o número de obras atrasadas simultaneamente (NOA). Com isso, haverá a priorização da busca por configurações de atraso mais severas, sem que ocorra uma tendência excessiva para regiões onde mais obras são combinadas simultaneamente, regiões estas onde os outros atributos tendem a possuir valores mais elevados.

Neste trabalho, não serão consideradas curvas horárias de carga e geração. Em vez disso, a modelagem do problema aceita cenários operativos inseridos com suas respectivas probabilidades de ocorrência. A discretização com cenários operativos relaciona num mesmo período de tempo, possíveis cenários de carga/geração, e é amplamente utilizada na modelagem de sistemas para estudos de expansão de transmissão no Brasil. Um bom exemplo de cenários utilizados no Brasil se baseia em seis cenários: cargas leve, média e pesada combinada aos perfis hidrológicos seco e úmido para a região Norte, por exemplo.

A Figura 3.3 expõe a sequência de execução empregada na avaliação das configurações de atraso. O atributo NOA pode ser extraído analisando a configuração topológica do sistema a ser simulado, bastando contabilizar o número de obras cujas construções tenham sido atrasadas no ano de estudo em questão.

Para cada cenário operativo s considerado na modelagem, o programa restabelece seu caso base e aplica a alteração na topologia que simule os atrasos de obras, como por exemplo desligando uma ou mais linhas de transmissão. A partir daí, são aplicadas ferramentas de análise de redes em regime permanente para a aquisição dos demais atributos. Através da ferramenta ANAREDE [56], é executado um fluxo de potência AC inicial, para convergir o caso recém alterado. É então checada a ocorrência de violações no sistema. Em caso positivo, entra-se na etapa de Fluxo de Potência Ótimo (FPO), que é responsável por ativar controles na rede para eliminar tais violações. Para tal, é utilizado o software FLUPOT [57]. A função objetivo utilizada no FPO é de mínimo corte de carga, e este valor é armazenado no atributo CCB.

Não havendo corte de carga, ou não havendo violações no fluxo AC, o valor do atributo PPA é armazenado, e é executada a análise de confiabilidade, para se extrair o último atributo, EENS. A análise de confiabilidade é executada pelo software NH2 [58],[59], e traz como resultados diversos índices de confiabilidade, incluindo o atributo EENS. O método utilizado nesta etapa será mais detalhado na Seção 3.2.1. A partir daí, o algoritmo considera o próximo cenário operativo, até que todos sejam cobertos.

Uma vez executados todos os nS cenários operativos de carga/geração os atributos são ponderados pelas probabilidades $Prob(s)$ de ocorrência de cada um destes

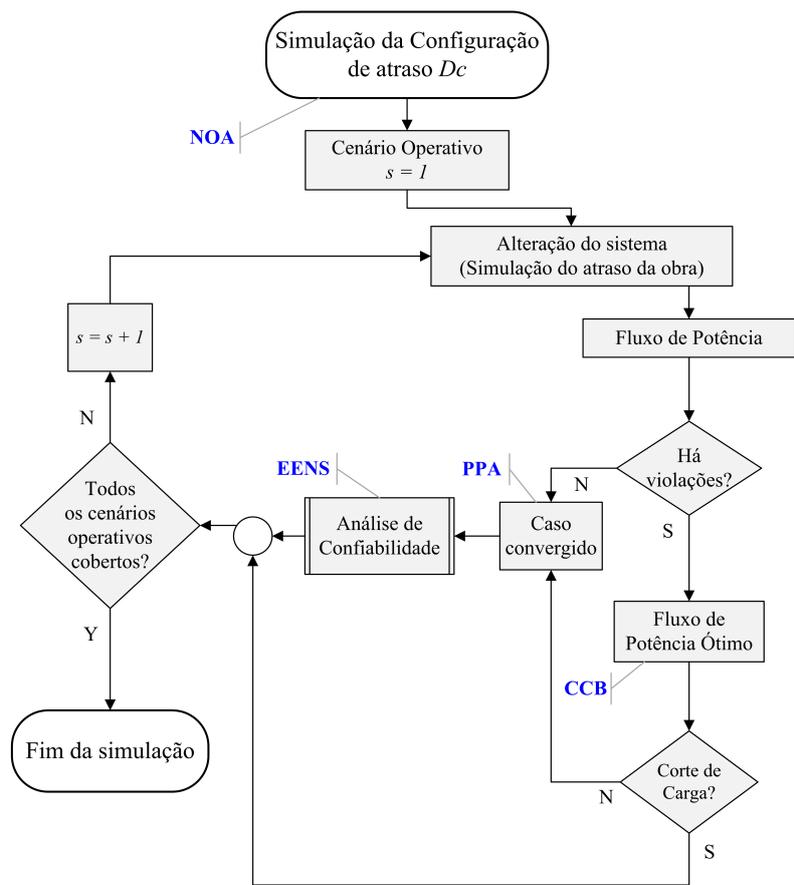


Figura 3.3: Análise feita para cada configuração de atraso

cenários, que é um parâmetro de entrada. É possível então gerar os atributos das configurações anuais de atraso, como mostradas nas Equações (3.2)-(3.5).

$$NOA_c = NOA \quad (3.2)$$

$$CCB_c = \sum_{s=1}^{nS} (Prob(s) \cdot CCB_s) \quad (3.3)$$

$$EENS_c = \sum_{s=1}^{nS} (Prob(s) \cdot EENS_s) \quad (3.4)$$

$$PPA_c = \sum_{s=1}^{nS} (Prob(s) \cdot PPA_s) \quad (3.5)$$

Assim, cada configuração D_c simulada carrega uma carga de informações acumuladas de cada cenário operativo considerado.

3.2.1 Análise de Confiabilidade

Confiabilidade em sistemas elétricos de potência basicamente segue dois caminhos de estudo: segurança e adequação. O estudo de confiabilidade para segurança de sistemas envolve análise dinâmica e caracteriza a robustez do sistema ao se deparar com distúrbios transitórios. A análise de adequação por outro lado avalia estaticamente o comportamento da rede ao ocorrerem contingências.

A análise de confiabilidade probabilística aplicada neste trabalho avaliará o sistema sob o aspecto da adequação, e será feita via Simulação Monte Carlo não-sequencial [60], método este já implementado no programa NH2, e utilizado internamente pelo PLANTAC [9],[8],[7],[11].

Como dados de entrada da análise de confiabilidade probabilística, há os dados estocásticos das linhas de transmissão e transformadores e opcionalmente os dados de geradores para análise da confiabilidade composta. Há também uma série de critérios a serem definidos, como a região de monitoração, a região de cálculo dos índices de confiabilidade, além das regiões de aplicação dos controles do FPO, e de sorteio das contingências pela Simulação de Monte Carlo.

O fluxograma da Figura 3.4, demonstra o método. A cada estado sorteado pela Simulação Monte Carlo não-sequencial, é feita uma análise de fluxo de potência AC na rede modificada. Se o caso convergir sem violações, os índices não são atualizados e um novo sorteio é feito. Caso não convirja, ou haja violações, é executado o fluxo de potência ótimo, com função objetivo de mínimo corte de carga. Se este não convergir, o caso é retirado das estatísticas e contabilizado nesta categoria. Caso convirja sem corte de carga, o *loop* é incrementado e será feito um novo sorteio. Havendo corte de carga, os índices de confiabilidade são atualizados, e se aproximarão mais da sua

convergência. Sendo assim, pode-se dizer que quanto mais próximo de seus limites o sistema estiver, maior a probabilidade de se sortear cenários que exijam corte de carga, e conseqüentemente, mais rapidamente o algoritmo converge. O critério de parada do método consiste em atingir certa tolerância nos índices de confiabilidade calculados ou atingir um número máximo de iterações. Ao final, são obtidos os índices de confiabilidade da Simulação Monte Carlo.

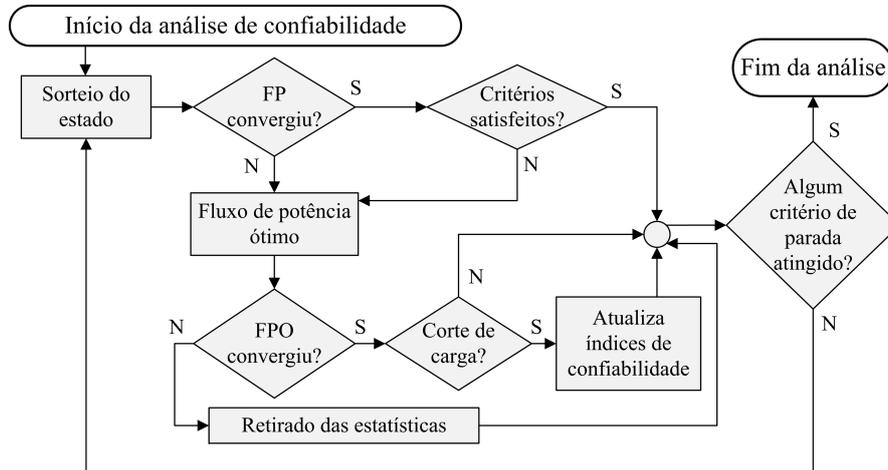


Figura 3.4: Método interno de análise de confiabilidade

3.2.2 Algoritmo para geração de configurações plurianuais de atraso

Após a execução das configurações anuais de atraso para todo o horizonte de simulação, devem-se compor as configurações plurianuais de atrasos de obras, definidas como CP_i .

As configurações anuais são combinadas ano a ano, sendo cheçadas todas as possíveis associações entre elas. Apesar de envolver um grande número de possibilidades, esta etapa não é consideravelmente custosa computacionalmente, se comparada com a simulação das configurações anuais de atraso.

Para que as associações sejam aceitas e compoñham o resultado, algumas restrições básicas de dependência são adotadas:

- Uma obra adiada em dado ano k , pode ser adiada novamente ou construída no ano seguinte $k + 1$.
- Uma obra já construída em k não pode ser adiada em $k + 1$, e deverá estar presente na configuração de $k + 1$ associada.

Assim, é gerado um grande grupo de configurações plurianuais de atraso cuja criticidade pode ser avaliada através do cálculo de seus atributos.

Os atributos associados a cada configuração plurianual CP são calculados pela média entre cada um dos nA anos do horizonte, e são definidos nas Equações (3.6)-(3.9).

$$CCB_{CP} = \frac{1}{nA} \sum_{k=1}^{nA} CCB_{CP,k} \quad (3.6)$$

$$NOA_{CP} = \frac{1}{nA} \sum_{k=1}^{nA} NOA_{CP,k} \quad (3.7)$$

$$EENS_{CP} = \frac{1}{nA} \sum_{k=1}^{nA} EENS_{CP,k} \quad (3.8)$$

$$PPA_{CP} = \frac{1}{nA} \sum_{k=1}^{nA} PPA_{CP,k} \quad (3.9)$$

Foi criada a definição de uma configuração plurianual base, que representa o cenário onde nenhuma obra é atrasada. Para ele, foi dado o nome de *Plano Inicial*, e tem como utilidade, ser base de comparação com os cenários de atraso que aparecerão.

3.3 Otimização por Enxame de Partículas

O PSO (otimização por enxame de partículas) é um método de otimização baseado em população, que apesar de poderoso, possui implementação e considerações simples.

O método possui diversas variantes. A modelagem feita neste trabalho, exigiu uma destas variantes, o PSO Binário Pareto-ótimo. Antes de explorar as especificidades desta variação, e a aplicação na metodologia, por simplicidade será introduzida a variante clássica, definida num espaço real e mono-objetivo.

3.3.1 Versão clássica

Esta Seção tem o objetivo de introduzir os termos utilizados no método PSO num espaço de buscas real bidimensional, considerando uma única função objetivo.

O método PSO se baseia num modelo de 2 equações, relacionadas à localização e à velocidade das partículas que fazem parte de uma população de soluções candidatas.

Em conjunto, a localização e a velocidade caracterizam a movimentação de cada partícula, em cada uma das dimensões do problema. Através da atualização das localizações das partículas a cada iteração, a população se dirige naturalmente para a solução ótima do problema ou para uma solução próxima da ótima.

Cada partícula da população tem à sua disposição dados obtidos por suas decisões durante a caminhada, e também dados provenientes da experiência coletiva de sua vizinhança.

A cada iteração m do algoritmo, as localizações x e as velocidades v das partículas são ajustadas de maneira estocástica, considerando a melhor localização em que a partícula já esteve (melhor individual ou $pBest$) e também a melhor localização em que o grupo como um todo já esteve (melhor global ou $gBest$).

Numa otimização por enxame de partículas com único objetivo, a determinação de $pBest$ e $gBest$ a partir das localizações visitadas se baseia na comparação dos valores da função objetivo aplicada nas localizações.

Na primeira iteração ($m = 1$), as localizações das partículas são determinadas através de um inicializador (gerador da população inicial), geralmente sorteadas aleatoriamente entre todo o espaço de buscas. Para estas localizações iniciais, é calculada para cada partícula o valor da função objetivo $f1$, o qual indicará quão boa é a localização, se ao objetivo buscado for maximizar ou minimizar $f1$. Ao final da primeira iteração, a velocidade da partícula p vale zero, pois ela ainda não se movimentou.

$$\mathbf{v}_p^1 = 0 \quad (3.10)$$

Neste ponto, devido a falta de experiência da população, a melhor localização visitada por cada partícula p , \mathbf{pBest}_p^m é a localização que acabou de ser visitada: $\mathbf{pBest}_p^1 = \mathbf{x}_p^1$. A localização \mathbf{gBest}^m porém pode ser determinada comparando todas as localizações visitadas na iteração $m = 1$. No caso de o objetivo ser maximizar $f1$, a que apresentar maior valor de função objetivo, é nomeada \mathbf{gBest}^m .

Em otimizações mono-objetivo, apenas uma localização é nomeada \mathbf{gBest}^m , e a mesma será utilizada por todas as partículas p :

$$\mathbf{gBest}_p^m = \mathbf{gBest}^m \quad (3.11)$$

A partir da segunda iteração $m = 2$, a velocidade da partícula pode ser calculada através da Equação 3.12:

$$\mathbf{v}_p^m = w \cdot \mathbf{v}_p^{m-1} + \varphi_1 \cdot \mathbf{r1} \cdot (\mathbf{pBest}_p^{m-1} - \mathbf{x}_p^{m-1}) + \varphi_2 \cdot \mathbf{r2} \cdot (\mathbf{gBest}_p^{m-1} - \mathbf{x}_p^{m-1}) \quad (3.12)$$

Nota-se que a velocidade possui três parcelas distintas e independentes:

- A primeira ($w \cdot \mathbf{v}_p^{m-1}$), considera o valor da velocidade na iteração anterior, e pode ser nomeada uma “inércia” ou “hábito”.
- A segunda ($\varphi_1 \cdot \mathbf{r1} \cdot (\mathbf{pBest}_p^{m-1} - \mathbf{x}_p^{m-1})$), considera a distância da localização

atual da partícula com a localização **pBest** da iteração anterior, caracterizando uma “memória”, ou “autoconhecimento”.

- A última parcela ($\varphi_2 \cdot \mathbf{r2} \cdot (\mathbf{gBest}_p^{m-1} - \mathbf{x}_p^{m-1})$) pondera o “conhecimento coletivo”, ou “cooperação” do grupo, considerar a distância entre a partícula e o **gBest** da iteração anterior.

Os pesos dados a estas parcelas influencia na decisão de movimentação das partículas. As parcelas de memória e cooperação possuem uma componente fixa, calibrada de acordo com a proposta de cada algoritmo, e outra aleatória, representando a mudança na importância de cada parcela para cada partícula.

Os coeficientes de aceleração φ_1 e φ_2 , juntamente com os vetores aleatórios **r1** e **r2**, controlam a influência estocástica dos componentes cognitivos e sociais presentes na velocidade das partículas. A calibração dos coeficientes φ_1 e φ_2 deve ser feita para se manter um bom balanço entre as componentes de memória e cooperação, e a maioria das aplicações usa $\varphi_1 = \varphi_2$ [53].

Já o coeficiente de inércia w possui características singulares. Valores grandes de w promovem a exploração, aumentando a diversidade. Valores pequenos por sua vez promovem exploração local, porém valores muito baixos de w elimina a habilidade de exploração do enxame.

Assim, pode ser feito um controle dinâmico do valor de w , iniciando com valores altos, favorecendo a exploração, e reduzindo com o tempo, beneficiando a exploração [51]. Uma forma de obter este comportamento é definido na Equação 3.13.

$$w(m) = w_{max} - \frac{w_{max} - w_{min}}{m_{max}} m \quad (3.13)$$

Onde w_{max} representa o valor máximo, que será utilizado na primeira iteração. Já w_{min} representa o valor mínimo a ser utilizado na última iteração (m_{max}), caso o método não atinja outro critério de parada antes.

Graficamente, a equação 3.13 pode ser representada como na Figura 3.5.

Uma vez definida a velocidade de cada partícula na iteração m , pode-se calcular o valor da localização. No espaço real, a localização pode ser definida como o incremento da velocidade na localização anterior, resultando na Equação 3.14.

$$\mathbf{x}_p^m = \mathbf{x}_p^{m-1} + \mathbf{v}_p^m \quad (3.14)$$

Associando as Equações 3.12 e 3.14, é possível obter-se a Figura 3.6, uma interpretação gráfica de como uma partícula considera as parcelas de inércia, memória e cooperação para se movimentar no espaço real de duas dimensões.

A cada iteração m , após serem encontradas as novas velocidades e localizações de cada partícula, devem-se atualizar as localizações **pBest** _{p} ^{m} de cada partícula p ,

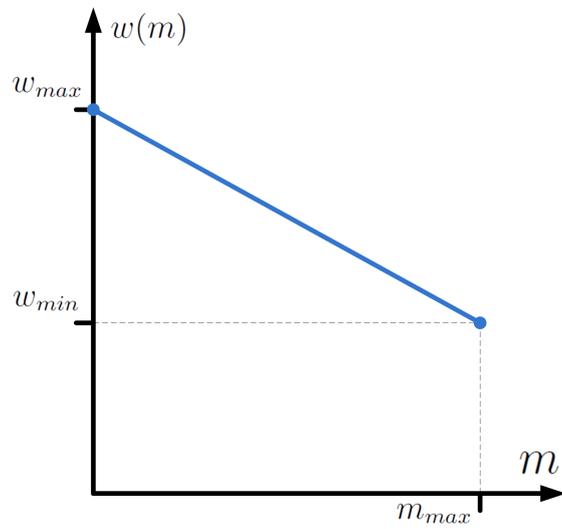


Figura 3.5: Controle dinâmico do coeficiente de inércia w

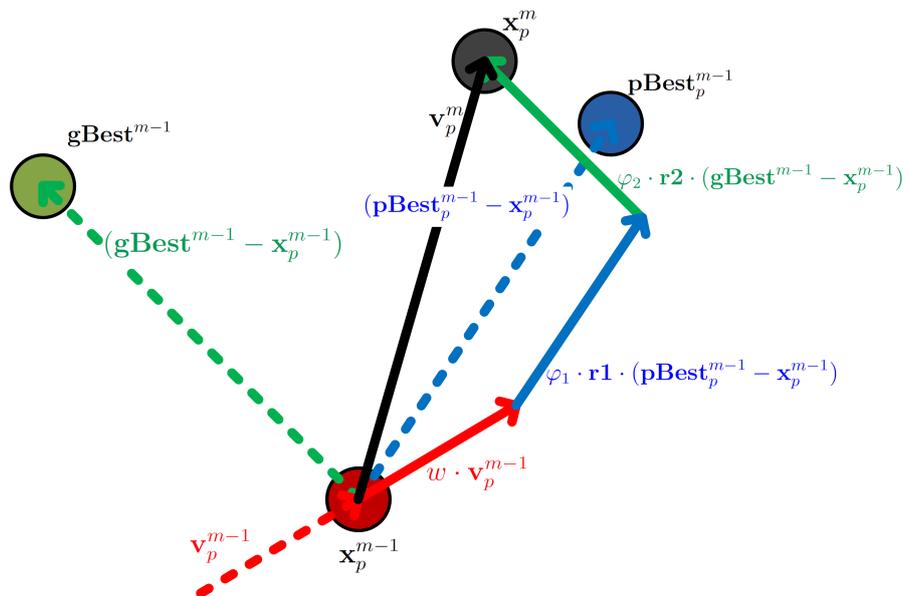


Figura 3.6: Caminhada de uma partícula no espaço real

bem como a localização \mathbf{gBest}^m da população. Neste caso, uma otimização de único objetivo, basta calcular os valores da função para a localização atual ($f1(\mathbf{x}_p^m)$) e comparar com os valores da função na localização $pBest_p$ atual.

Se o problema a se resolver busca maximizar $f1$, \mathbf{pBest}_p^m pode ser atualizada como segue:

```

1 SE ( $f1(\mathbf{x}_p^m) > f1(\mathbf{pBest}_p^{m-1})$ ) ENTÃO // xp melhor que xPB
2    $\mathbf{pBest}_p^m = \mathbf{x}_p^m$ 
3 SENÃO // xp pior ou igual a xPB
4    $\mathbf{pBest}_p^m = \mathbf{pBest}_p^{m-1}$ 
5 FIM SE

```

Algoritmo 3.1: Atualização da localização $pBest$ da partícula p

A atualização de \mathbf{gBest} é feita comparando a localização da iteração anterior, com as atuais localizações de cada partícula p :

```

1  $\mathbf{gBest}^m = \mathbf{gBest}^{m-1}$ 
2 FAÇA PARA_CADA p EM populacao
3   SE ( $f1(\mathbf{x}_p^m) > f1(\mathbf{gBest}^m)$ ) ENTÃO // localização de p melhor
4     que atual gBest
5      $\mathbf{gBest}^m = \mathbf{x}_p^m$ 
6 FIM SE
7 FIM FAÇA

```

Algoritmo 3.2: Atualização do grupo $gBest$ s

A visão geral do PSO clássico está expressa no fluxograma da Figura 3.7.

3.3.2 PSO Binário Pareto-Ótimo

Uma vez introduzidos os conceitos de Otimização por enxame de Partículas num espaço real bidimensional e com único objetivo, alterações no método podem ser feitas para que sua utilização seja mais adequada no problema de atrasos de obras multi-objetivos.

Alterações para utilização do PSO num espaço binário

O método BPSO (PSO Binário) [34] trabalha num espaço multidimensional binário, ou seja, em cada dimensão do problema, a partícula pode estar na posição “0” ou “1”.

Apesar de a posição ser binária, a velocidade da partícula continua sendo uma variável real n-dimensional, respeitando a equação 3.12 introduzida anteriormente:

$$\mathbf{v}_p^m = w \cdot \mathbf{v}_p^{m-1} + \varphi_1 \cdot \mathbf{r1} \cdot (\mathbf{pBest}_p^{m-1} - \mathbf{x}_p^{m-1}) + \varphi_2 \cdot \mathbf{r2} \cdot (\mathbf{gBest}_p^{m-1} - \mathbf{x}_p^{m-1}) \quad (3.12)$$

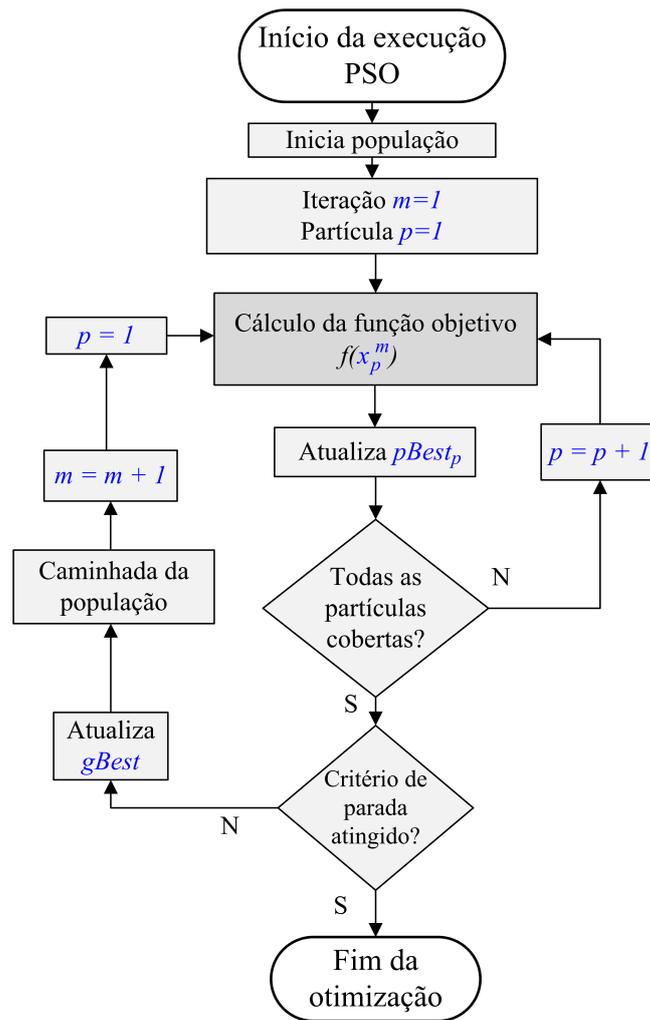


Figura 3.7: Visão geral do PSO real mono-objetivo

A localização porém, é atualizada de forma diferente, a fim de se obter valores binários de localização a partir de valores reais de velocidade. Diferentemente da forma utilizada na Equação 3.14, em dada iteração m não é possível se expressar a equação de localização das partículas em forma do vetor \mathbf{x}_p , contemplando todas as dimensões. Em vez disso, é feita uma análise em cada dimensão d do vetor \mathbf{v}_p como detalhado nas Equações 3.15:

$$\begin{array}{ll} \text{se} & rSig < \mathcal{S}(v_{i,d}^m) \implies x_{i,d}^m = 1 \\ \text{senão} & \implies x_{i,d}^m = 0 \end{array} \quad (3.15)$$

onde: $rSig$ é um número real pseudo-aleatório sorteado entre $[0, 1]$, e \mathcal{S} define a função *sigmóide*, detalhada na Equação 3.16 e no gráfico da Figura 3.8.

$$\mathcal{S}(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (3.16)$$

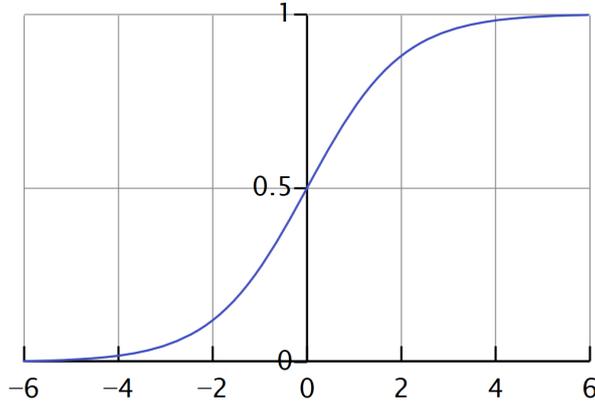


Figura 3.8: Curva da função *sigmóide*

Neste ponto, ainda está sendo considerado uma aplicação mono-objetivo, portanto a atualização das localizações **pBest** e **gBest** seguem os padrões do PSO clássico, sendo atualizados ao fim de cada iteração seguindo os Algoritmos 3.1 e 3.2.

Nota-se que ao se aplicar o valor da velocidade da partícula na função *sigmóide* e comparar com o número aleatório $rSig$ para determinação do estado binário da localização, $\mathcal{S}(v_{i,d}^m)$ representa a probabilidade de a localização da partícula p se fixar no valor 1 na dimensão d .

Quanto maior a velocidade da partícula, mais $\mathcal{S}(v_{i,d}^m)$ se aproxima de 1, diminuindo a probabilidade de $x_{i,d}^m$ se fixar em zero.

Como os pesos φ e \mathbf{r} são positivos, a velocidade tende a aumentar, diminuir ou se manter com a variação de $(\mathbf{pBest}_p - \mathbf{x}_p^{m-1})$ e $(\mathbf{gBest}_p - \mathbf{x}_p^{m-1})$. Estes termos por sua vez podem assumir três valores somente: -1 , 0 ou 1 , que refletem em diminuição, manutenção ou aumento da velocidade, respectivamente:

- Quando $\mathbf{x}_p^{m-1} = 0$ e $\mathbf{gBest}_p = 1$ ou $\mathbf{pBest}_p = 1$, a velocidade aumenta, $\mathcal{S}(v_{i,d}^m)$ se aproxima de 1 e a probabilidade de $x_{i,d}^m$ se fixar em 1 aumenta.
- Quando $\mathbf{x}_p^{m-1} = 1$ e $\mathbf{gBest}_p = 0$ ou $\mathbf{pBest}_p = 0$, a velocidade diminui, $\mathcal{S}(v_{i,d}^m)$ se aproxima de 0 e a probabilidade de $x_{i,d}^m$ se fixar em 0 aumenta.
- Quando \mathbf{x}_p^{m-1} já é igual a \mathbf{gBest}_p e \mathbf{pBest}_p , a velocidade se mantém e o estado binário de $x_{i,d}^m$ tende a se manter.

O Apêndice B traz um exemplo numérico e visual de uma execução do método PSO Binário Mono-objetivo.

Alterações para utilização do PSO com múltiplos objetivos

Este trabalho faz consideração de múltiplos objetivos na otimização por Enxame de Partículas através dos conceitos de ótimo de Pareto [51]. Para tanto, algumas alterações devem ser feitas no método, com relação ao apresentado na Seção anterior, que lidava com apenas uma função objetivo. As operações que envolvem comparações entre posições alcançadas pelas partículas, tal como a atualização de **pBest** e **gBest** passam a considerar os conceitos de dominância.

Assim, diferentemente de no caso clássico demonstrado na Seção 3.3.1, as localizações **pBest** e **gBest** não são obtidas comparando apenas f_1 , como nos Algoritmos (3.1) e (3.2). São utilizados os conceitos de Pareto-ótimo para considerar todas as funções objetivo utilizadas.

Os conceitos de dominância são utilizados na etapa de classificação dos melhores individuais e globais e assim verifica-se multi-objetivamente as localizações dominantes que guiarão a população.

A atualização de **pBest**_p considerando múltiplos objetivos é alterada:

```

1  SE (pBestpm-1 > xpm)  ENTÃO // xp Domina xPB
2    pBestpm = pBestpm-1
3  SENÃO
4    SE (xpm > pBestpm-1)  ENTÃO // xp Dominado pelo xPB
5      pBestpm = xpm
6    SENÃO
7      pBestpm = aleat[pBestpm-1, xpm]
8  FIM SE
9  FIM SE

```

Algoritmo 3.3: Atualização da localização **pBest** da partícula p

onde m é um número inteiro que expressa a iteração atual do método de otimização, e o operador “>” expressa dominância, como exposto no Apêndice A.

O Algoritmo 3.4 ilustra a checagem da dominância entre duas localizações(\mathbf{x}_1 e \mathbf{x}_2), considerando duas funções objetivo(f_1 e f_2).

```

1 // inicialização
2 x1_domina_algo = falso
3 x2_domina_algo = falso
4 qualDomina = 0
5
6 SE (f1(x1)>f1(x2) OU f2(x1)>f2(x2)) ENTÃO
7   x1_domina_algo = verdadeiro
8 FIM SE
9
10 SE (f1(x2)>f1(x1) OU f2(x2)>f2(x1)) ENTÃO
11   x2_domina_algo = verdadeiro
12 FIM SE
13
14 SE(x1_domina_algo E x2_domina_algo) ENTÃO
15   qualDomina = 0 // empate
16 SENÃO
17   SE(x1_domina_algo) ENTÃO
18     qualDomina = 1 // x1 domina
19   SENÃO
20     qualDomina = 2 // x2 domina
21 FIM SE
22 FIM SE

```

Algoritmo 3.4: Checagem da dominância com duas funções objetivo

Ou seja, se a localização **pBest** da iteração anterior domina a localização atual, **pBest** não se altera. No caso de a localização atual dominar a até então **pBest**, ela a substituirá no cálculo da próxima iteração. Porém, se não houver dominação estrita entre elas, é realizado um sorteio aleatório entre as duas para se escolher a nova localização **pBest**.

No caso da localização **gBest**, o conceito é diferente, pois a filosofia do PSO Pareto-ótimo não classifica apenas uma localização como a melhor global. Em vez disso, é definido um grupo **gBests** (ou grupo de localizações de Pareto), atualizado a cada iteração, depois que todas as partículas já tenham caminhado. Checa-se a dominância entre a localização de cada partícula p da população (\mathbf{x}_p^m) com as localizações já incluídas no grupo *gBests*. Assim, permanecem apenas as localizações não dominadas.

O Algoritmo 3.5 detalha como é feita esta checagem.

```

1 xpDominante = falso

```

```

2 xpDominado = falso
3 FAÇA PARA_CADA xgB EM gBests
4   quemDomina = checaDominancia(xp, xgB)
5   SE(quemDomina == 1) ENTÃO // Domina xgB
6     adicionaNoGrupo(xp)
7     retiraDoGrupo(xgB)
8     xpDominante = verdadeiro
9   SENÃO
10    SE(quemDomina == 2) ENTÃO // Dominado pelo xgB
11      xpDominado = verdadeiro
12    FIM SE
13  FIM SE
14 FIM FAÇA
15 // Se no final não dominar nem for dominado por nenhum xgB
16 SE(xpDominado == falso E xpDominante == falso) ENTÃO
17   adicionaNoGrupo(xp)
18 FIM SE

```

Algoritmo 3.5: Atualização do grupo $gBests$

Na linha 4 do algoritmo acima, a checagem de dominância é feita pelo algoritmo 3.4.

O número de localizações salvas no grupo-Pareto pode então variar a cada iteração do BP-PSO.

O grupo-Pareto de localizações, ou grupo ***gBests***, representa então os atrasos de obras que ao serem avaliados por um viés multi-objetivo, são classificados como não dominados, como definido no Apêndice A.

Assim, ao aplicar a Equação (3.12), a localização $gBest_p$ utilizada é escolhida através de um sorteio aleatório entre o grupo ***gBests***.

A visão geral do BP-PSO está expressa no fluxograma da Figura 3.9.

Para validação do método BP-PSO, foi necessário encontrar funções binárias simples, cujos pontos de máximo fossem diferentes umas das outras, para que combinadas, pudessem se tornar um problema binário e multi-objetivos. O Apêndice C expõe funções elaboradas para este fim.

3.4 Aplicação do PSO Binário Pareto-ótimo na busca por configurações de atraso

A aplicação do método BP-PSO se dá na seleção das configurações de atraso anuais a serem simuladas, com o intuito de redução no tempo computacional, e priorizando aquelas que trazem maior impacto ao sistema. Cada uma destas configurações anuais

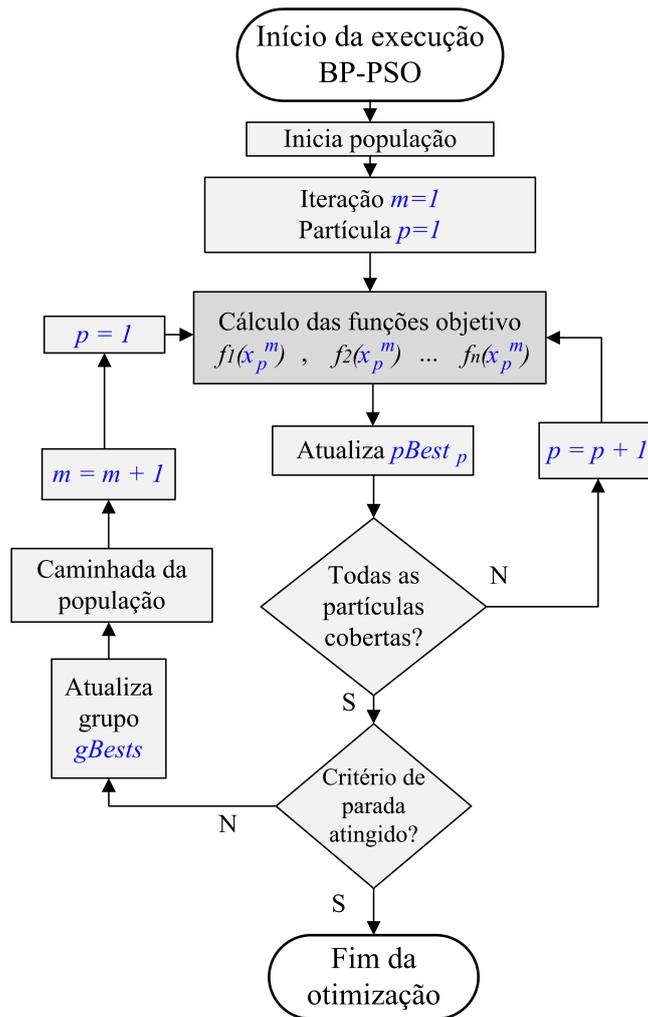


Figura 3.9: Visão geral do PSO Binário Pareto-Ótimo

é modelada como uma localização no espaço de buscas do BP-PSO. Assim, uma partícula que caminha por este espaço de buscas percorre uma série de localizações, cada uma sendo uma configuração de atrasos anual possível naquele ano.

Sendo assim, é realizada uma série de execuções BP-PSO no mesmo estudo, e com resultados independentes, que só serão combinados nas etapas finais (Seção 3.2.2).

Para cada localização visitada pela população de partículas, são calculados os atributos durante a análise da configuração de atrasos, como exposto no início deste capítulo (Figura 3.3). A representação das partículas é detalhada na Seção 3.4.1.

A modelagem escolhida para o problema é tal que a dimensão do espaço de buscas é o número de obras consideradas nO . Com isso, as localizações das partículas são vetores binários de tamanho nO , onde cada posição indica se a obra está atrasada ou não, caracterizando as próprias configurações de atraso. Esta modelagem permite que o método, enquanto percorre o espaço de busca, simule as configurações e avalie sua criticidade pelas funções objetivo, priorizando configurações com as obras cujo atraso traz maior prejuízo ao sistema. Os atributos introduzidos na Seção 3.2, são utilizados para quantificar a criticidade das configurações, através das funções objetivo, qualificando o problema como multi-objetivo.

3.4.1 Representação das partículas

Cada partícula p possui um vetor binário de tamanho nO (número de obras), descrito pela variável de localização \mathbf{x}_p que representa a configuração de atraso simulada. A velocidade da partícula é armazenada pelo vetor real \mathbf{v}_p , que também possui dimensão nO .

O PSO binário fará a busca inteligente por configurações de atraso num espaço de buscas binário de nO dimensões.

Cada partícula da população armazena ainda sua melhor localização já visitada, através do vetor binário \mathbf{pBest}_p .

Cada bit j do vetor binário \mathbf{x}_p indica se cada uma das obras planejadas para estar em operação, encontra-se ou não no sistema para dado ano k :

$\mathbf{x}_p[j] = 1$: a obra j foi adiada nesta localização

$\mathbf{x}_p[j] = 0$: a obra j não foi adiada nesta localização

A equação 3.17 ilustra a posição de uma partícula genérico num ano k para um estudo onde considerou-se atrasos em nO obras.

$$\mathbf{x}_p^k = [j_1, j_2, j_3, \dots, j_{nO}] \quad (3.17)$$

Para cada localização visitada pelas partículas durante o processo, deverá ser feita a análise descrita no início do Capítulo 3 (Figura 3.3).

3.4.2 Inicialização da População

Os métodos PSO e suas variantes são baseados numa população de partículas que caminham pelo espaço de soluções até o final do algoritmo. A posição onde cada partícula nasce, é definida durante a inicialização das mesmas.

No início do algoritmo, espera-se uma população diversificada e dispersa no espaço de soluções. Assim, as partículas são alocadas em posições escolhidas aleatoriamente entre todas as configurações de atrasos possíveis naquele ano, ignorando configurações que atrasem obras com entrada prevista para anos posteriores.

Uma vez inicializadas as partículas, o método BP-PSO é executado.

Para as execuções BP-PSO seguintes, a inicialização das partículas é feita considerando a experiência dos grupos de partículas das execuções anteriores.

A cada ano, haverá então uma nova execução BP-PSO, com partículas novas, ou seja velocidades e melhores individuais e globais reiniciados. Porém, suas posições iniciais conterão uma carga de informação herdada das execuções anteriores.

A Seção 3.6 detalhará estes pontos.

3.4.3 Funções objetivo

O propósito das funções objetivo em métodos de otimização é estabelecer matematicamente a meta de otimização. Procura-se montar uma única função objetivo, que contemple todos os atributos que se deseja minimizar/maximizar. Porém, muitas vezes, além de possuírem ordens de grandeza diferentes, os atributos geram impactos de natureza distintas, ou até mesmo conflitantes, necessitando serem mantidos e analisados separados.

Neste trabalho, devem-se encontrar as obras cujos atrasos causam maior prejuízo ao sistema, considerando os quatro atributos básicos expostos no início deste Capítulo.

Tem-se então quatro funções objetivo diferentes:

- Maximização do Corte de Carga no caso Base: $max(CCB)$
- Maximização da Estimativa de Energia Não Suprida: $max(EENS)$
- Maximização das Perdas de Potência Ativa: $max(PPA)$
- Minimização do Número de Obras Atrasadas: $min(NO A)$

O Número de Obras Atrasadas é o único atributo onde se busca a minimização, valorizando configurações com menos obras atrasadas simultaneamente.

Como os atributos são independentes, e com ordens de grandeza diferentes, será utilizada a abordagem de Ótimos de Pareto na escolha dos melhores partículas a cada iteração, como exposto na Seção 3.3.2.

A maximização/minimização dos quatro atributos se dá pelo direcionamento das partículas ao longo da execução do BP-PSO, e uma vez que cada partícula avalia corretamente se dada localização é melhor que a outra, o algoritmo caminha naturalmente. Assim, a correta nomeação das melhores localizações individuais e globais, etapas inerentes aos métodos de enxame de partículas, garante o direcionamento correto da população, multi-objetivamente.

3.4.4 Algoritmo para geração de configurações anuais com PSO

Na aplicação do BP-PSO, cada posição do vetor binário de localização \mathbf{x} representa uma obra de transmissão, com o *bit* valendo 1 se a obra está atrasada naquela configuração, e valendo 0 caso contrário. Assim, no espaço de buscas, o número de obras é o número de dimensões onde a partícula fará sua caminhada.

Na primeira execução BP-PSO, a população é inicializada aleatoriamente, e nas seguintes, a inicialização é feita considerando resultados anteriores. Cada partícula tem nO_k variáveis binárias, onde nO_k é o número de obras de transmissão planejadas para estar em operação no ano k .

Após a geração da população inicial do ano seguinte, como descrito na Seção 3.4.2, o procedimento é repetido ano a ano, até a convergência do método proposto.

Procedimento a cada iteração

A cada iteração, o algoritmo executa a caminhada de cada uma das partículas. Através das equações de velocidade e localização, é determinada para cada partícula qual a configuração de atraso será executada na iteração. A partir daí é feita a simulação da configuração de atraso de acordo com o explicado na Seção 3.2 e na Figura 3.3. Após todas as configurações serem cobertas, são atualizadas as melhores localizações **pBest** e também o grupo **gBests**, para serem utilizados na iteração seguinte.

Velocidade: A velocidade da partícula p durante a iteração m é representada por um vetor de números reais \mathbf{v}_p^m de nO posições, com cada posição representando a velocidade em cada dimensão. A equação 3.12 exposta anteriormente é utilizada.

Foram feitos testes de convergência e os pesos das parcelas de “memória” e “cooperação” foram fixados nos seguintes valores: $\varphi_1 = \varphi_2 = 2$. Para a parcela de “inércia”, será utilizado o peso dinâmico descrito na Equação 3.13, com os valores $w_{max} = 0,9$ e $w_{min} = 0,4$. O número máximo de iterações do método BP-PSO foi fixado em $m_{max} = 25$.

Localização: A localização de cada partícula p da população é calculada como demonstrado na Equação (3.15). Ao final da caminhada da partícula, a localização encontrada representará uma configuração de atraso que deverá ser simulada.

Atualização das melhores localizações: Para atualizar as melhores localizações, são utilizados os conceitos descritos em 3.3.2. A dominância entre duas localizações \mathbf{x}_1 e \mathbf{x}_2 é checada analisando os quatro atributos. O Algoritmo 3.6 demonstra como é feita esta comparação.

```

1 // inicialização
2 x1_domina_algo = falso
3 x2_domina_algo = falso
4 qualDomina = 0
5
6 SE ( ccb(x1)>ccb(x2) OU noa(x1)<noa(x2) OU
      eens(x1)>eens(x2) OU ppa(x1)>ppa(x2)) ENTÃO
7   x1_domina_algo = verdadeiro
8 FIM SE
9
10 SE ( ccb(x2)>ccb(x1) OU noa(x2)<noa(x1) OU
      eens(x2)>eens(x1) OU ppa(x2)>ppa(x1)) ENTÃO
11   x2_domina_algo = verdadeiro
12 FIM SE
13
14 SE(x1_domina_algo E x2_domina_algo) ENTÃO
15   qualDomina = 0 // empate
16 SENÃO
17   SE(x1_domina_algo) ENTÃO
18     qualDomina = 1 // x1 domina
19   SENÃO
20     qualDomina = 2 // x2 domina
21 FIM SE
22 FIM SE

```

Algoritmo 3.6: Checagem da dominância considerando os quatro atributos

Nota-se nas linhas 6 e 10 que somente o atributo de número de obras atrasadas (NOA) possui o comparador invertido, pois é o único em que busca-se minimizar. Os quatro atributos são expressos como funções que recebem a localização \mathbf{x}_1 e \mathbf{x}_2 , mas são extraídos durante a simulação das configuração de atraso (Seção 3.2).

A visão geral do BP-PSO aplicado na geração de atrasos de obras está expressa no fluxograma da Figura 3.10.

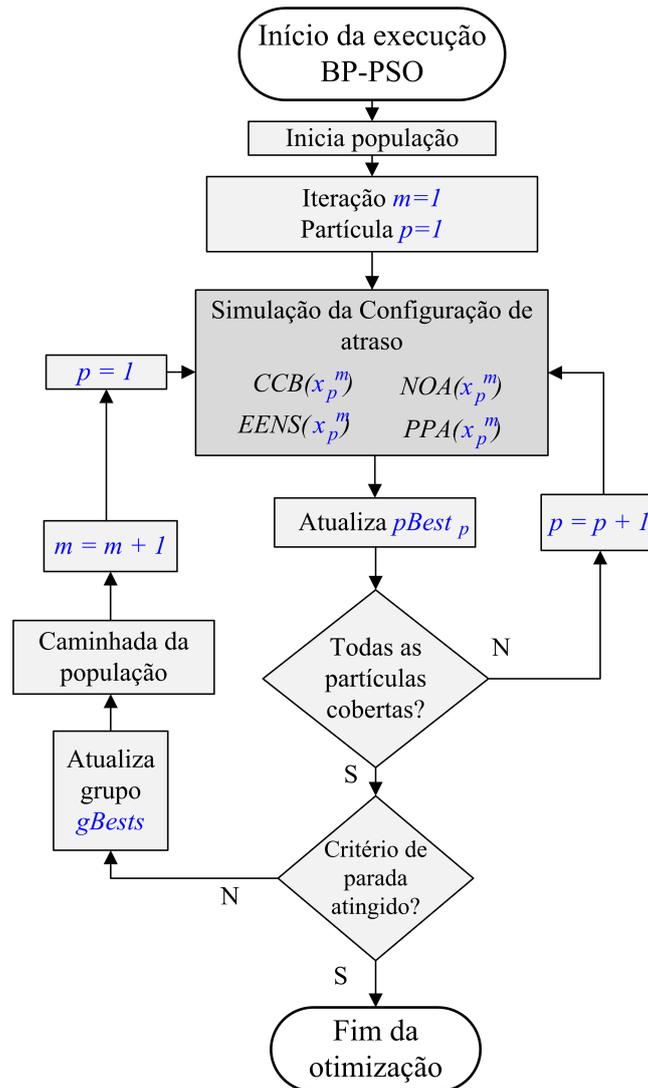


Figura 3.10: BP-PSO aplicado na geração de atrasos de obras

3.5 Geração das configurações plurianuais de atraso

Assim como na abordagem exaustiva, ao possuir configurações anuais de atraso, é possível associá-las para a montagem das configurações plurianuais de atraso. Ao

utilizar o método BP-PSO, porém, não haverá à disposição do algoritmo todas as configurações de atraso de todos os anos do horizonte, mas sim uma fração delas. Como o objetivo dos BP-PSO executados é guiar a busca por combinações que resultem em prejuízos mais severos ao sistema, a associação das configurações anuais será feita de forma simples, compondo todos os cenários plurianuais possíveis com as alternativas anuais já encontradas durante o processo.

As premissas descritas em 3.2.2 são consideradas, a fim de se respeitar a limitações de associações que envolvem o atraso ou construção das obras.

3.6 Programação pseudo-dinâmica

Neste trabalho, será adotado um algoritmo pseudo-dinâmico *forward-backward* para lidar com a característica multiestágio do problema de atrasos de obras de transmissão. Para tanto, foi implementada uma movimentação temporal, como visto na Seção 2.3.

O algoritmo pseudo-dinâmico escolhido é caracterizado por executar passos em avanço (*forward*) e em regresso (*backward*) sequencialmente, e ao final de cada passo, checar a convergência.

O algoritmo pseudo-dinâmico poderia ser iniciado tanto no primeiro ano, dando início a um passo *forward*, quanto no último ano, começando pelo passo *backward*. Neste trabalho, optou-se por começar do último ano, $k = nA$.

A população de partículas é inicializada aleatoriamente, conforme explicado na Seção 3.4.2, através de um sorteio onde todas as configurações anuais de atraso participam. O resultado do BP-PSO é o conjunto $gBests GB_{B_1, nA}$, ou seja, melhores globais de configurações anuais de atraso para o ano nA a partir do passo *backward* B_1 .

O algoritmo pseudo-dinâmico dispara então um novo BP-PSO, desta vez para o ano $nA - 1$. A inicialização das partículas desta execução leva em consideração a solução estática do ano nA , $GB_{B_1, nA}$.

Se o grupo de Pareto do ano nA for maior que o tamanho da população que se pretende inicializar, é feito um sorteio entre as localizações do grupo. Porém, se $GB_{B_1, nA}$ possuir menos localizações que o número de partículas da população, todas entram, e para completar são sorteadas outras localizações dentre todas as possíveis. Cada uma das localizações que alimentará a população inicial do ano $nA - 1$ é avaliada quanto a sua validade no ano em questão, de modo que, se possuir atrasadas obras previstas para anos à frente, são descartadas e sorteadas outras para substituir.

O passo *backward* prossegue executando o algoritmo estático BP-PSO dos anos $k = nA - 1$ até $k = 1$, o que resulta nos conjuntos $gBests$ de configurações de atraso

anuais $GB_{B_1, nA}, GB_{B_1, nA-1}, \dots, GB_{B_1, 1}$.

Em seguida, as configurações de atraso executadas são combinadas para gerar todas as configurações plurianuais de atraso possíveis, e as não dominadas são identificadas por meio das funções objetivo (1) - (4). O Grupo de Pareto do passo B_1 (\mathbb{GP}_{B_1}) é então composto por estas configurações não dominadas. O algoritmo geral para um passo *backward* é ilustrado na Figura 3.11 -a).

O passo *forward* F_1 começa no ano $k = 1$, tomando a solução estática do caminho reverso B_1 como sua solução estática inicial $GB_{F_1, 1} = GB_{B_1, 1}$. Em seguida, ele executa o algoritmo BP-PSO para o ano $k = 2$ e usa $GB_{F_1, 1}$ para inicializar a população da mesma maneira que no passo *backward*. O passo *forward* prossegue executando o algoritmo estático BP-PSO do ano $k = 2$ a $k = nA$, que resulta nos melhores conjuntos globais de configurações de atraso $GB_{F_1, 1} = GB_{B_1, 1}, GB_{F_1, 2}, \dots, GB_{F_1, nA}$.

as configurações executadas são combinadas gerando configurações plurianuais de atraso, que serão comparadas para encontrar o Conjunto Pareto de configurações plurianuais do passo $F_1, (\mathbb{GP}_{F_1})$. O algoritmo geral para um caminho de avanço é ilustrado na Figura 3.11b).

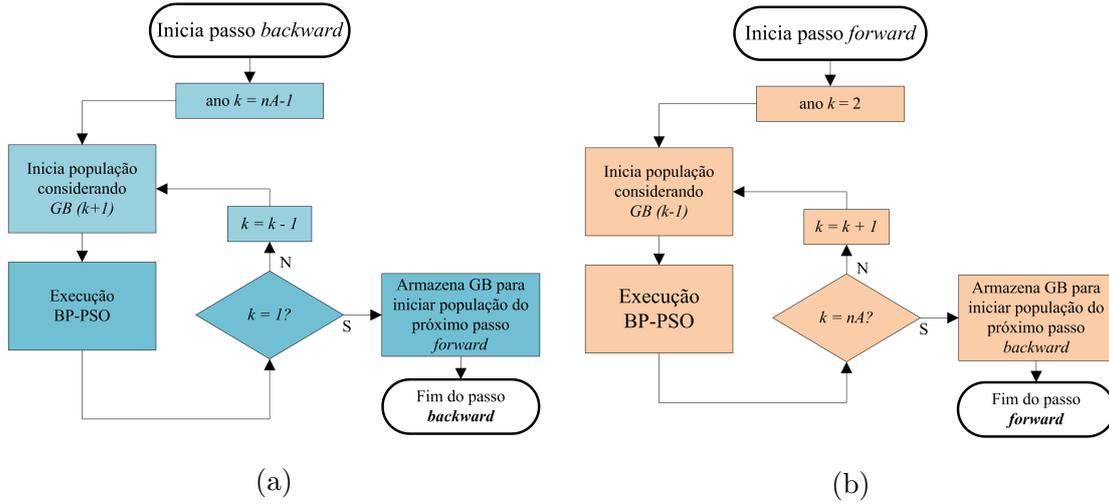


Figura 3.11: Detalhamento dos passos a) *backward* e b) *forward*

O algoritmo pseudo-dinâmico para quando o número máximo de iterações for atingido, ou quando há estabilidade no Grupos Pareto $\mathbb{GP}_{B_{n-1}}, \mathbb{GP}_{F_{n-1}}, \mathbb{GP}_{B_n}, \mathbb{GP}_{F_n}, \dots$, ou seja, estes permanecem inalterados por um número específico passos.

A execução alternada e o relacionamento lógico entre os passos *forward* e *backward* são ilustrados na Figura 3.12 para os dois primeiros caminhos de retrocesso e avanço, B_1, F_1, B_2, F_2 . Os passos *backward* são destacados na cor azul e os passos *forward* são marcados na cor laranja.

Verificou-se que o algoritmo pseudo-dinâmico tem melhor desempenho se em um caminho reverso B_n , o conjunto Global Best $GB_{B_n, k-1}$ for inicializado pelas soluções

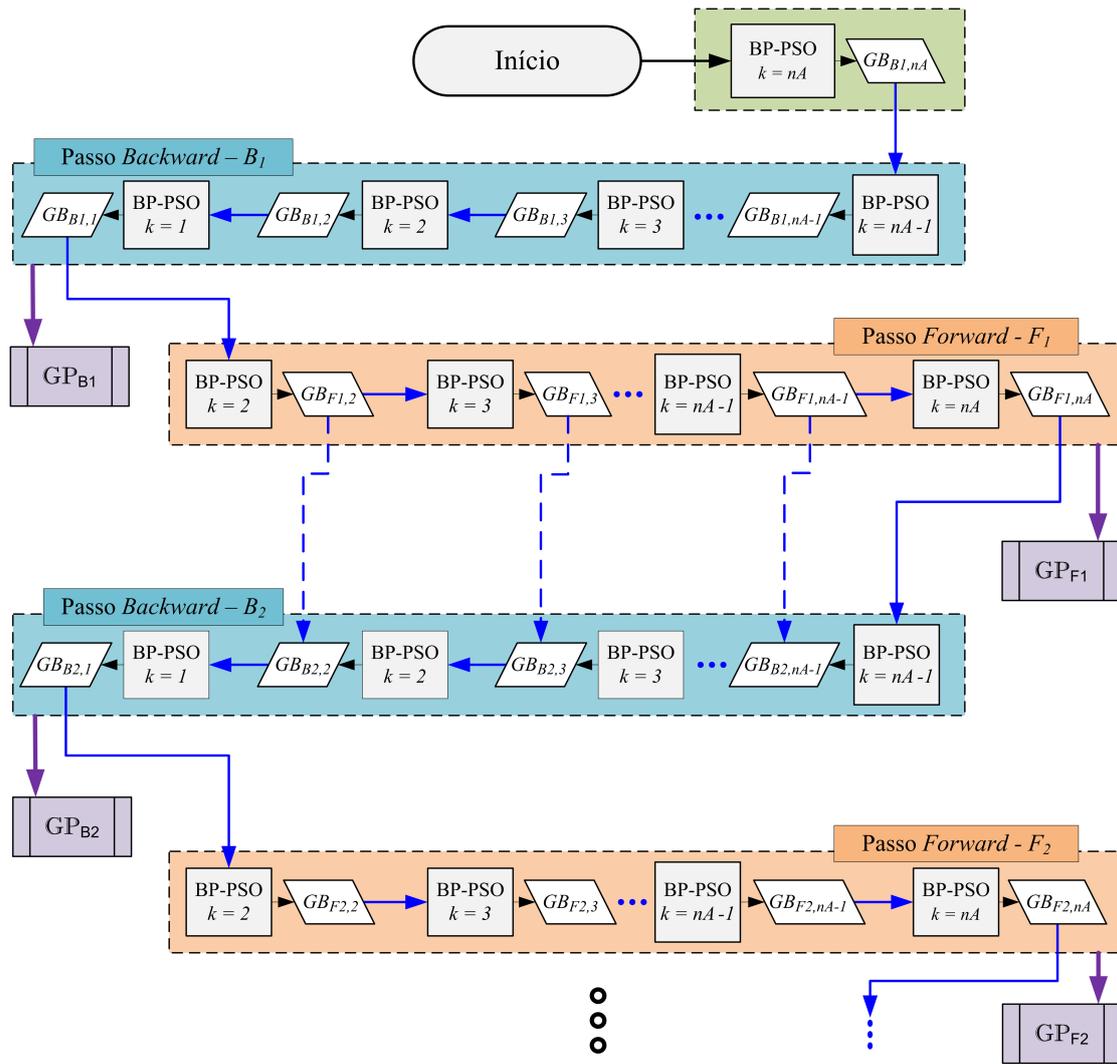


Figura 3.12: Alternância entre os passos *forward* and *backward*

não dominadas de ambos $GB_{B_n,k}$ e $GB_{F_{n-1},k-1}$. Este procedimento é considerado a partir de B_2 e é indicado pelas setas de linha pontilhada na Figura 3.12.

No final de cada passo, todas as configurações plurianuais de atraso geradas são analisadas e o conjunto de Pareto é criado. Em seguida, a convergência é verificada, e caso ocorra, \mathbb{GP}^* é definido.

3.7 Geração do grupo Pareto de configurações plurianuais

Durante toda a execução, as rodadas de otimização por enxame de partículas buscam as configurações anuais de atraso mais críticas, e o algoritmo pseudo-dinâmico fica responsável por ordenar as execuções de modo a alimentar estas rodadas BP-PSO com informações anuais.

Ao final de cada passo, todas as configurações plurianuais de atrasos geradas são analisadas e é montado o grupo Pareto (\mathbb{GP}^*), considerando os conceitos de dominância descritos anteriormente, aplicados nas funções objetivo abaixo. Estes atributos comparados são obtidos com as Equações (3.6) a (3.9).

$$\begin{cases} \max & f1 = mCCB_i \\ \min & f2 = mNOA_i \\ \max & f3 = mEENS_i \\ \max & f4 = mPPA_i \end{cases} \quad (3.18)$$

Checa-se então a convergência deste grupo comparando com os grupos gerados nos passos anteriores do algoritmo Pseudo-dinâmico.

3.8 Método para ranqueamento das obras

Quando a convergência ocorre, tem-se a composição do Grupo de Pareto das configurações plurianuais de atraso. Este grupo, porém, não possui todas as configurações como na abordagem exaustiva, mas sim uma parcela destas, que espera-se representar o grupo total de configurações não dominadas possíveis.

Cada item presente nesta frente de Pareto, por ser não dominado em relação aos outros, pode ser entendido como “igualmente crítico”, impossibilitando uma classificação direta de quais obras possui o atraso mais crítico.

Para gerar uma classificação das obras com relação à criticidade de seus atrasos no horizonte de estudos, foram desenvolvidos dois índices, com interpretações diferentes, mas que podem indicar ao gerente de acompanhamento de obras quais obras

devem receber maior atenção para serem priorizadas.

Ambos os índices partem do grupo de configurações anuais de Pareto, de tamanho $|\mathbb{GP}^*|$ para compor os resultados para cada obra j , considerada no estudo.

3.8.1 Índices gerais

Os índices propostos consideram todo o horizonte do estudo e são chamados de “índices gerais”. As consequências dos atrasos nas obras foram avaliadas como um problema de otimização em múltiplos estágios e, portanto, as obras são ranqueadas considerando as soluções plurianuais, e não soluções isoladas a partir dos anos.

Para calcular esses índices, os grupos \mathbb{A}_j são montados, sendo compostos de todas as configurações plurianuais do Conjunto de Pareto, onde a obra j foi atrasada pelo menos uma vez.

Índice geral de severidade

Este índice tem como objetivo quantificar a severidade dos atrasos. Para isto, considera os mesmos quatro atributos utilizados na otimização e na geração do grupo de Pareto.

Primeiramente, é calculada a média dos valores plurianuais dos atributos nas configurações do grupo \mathbb{A}_j :

$$CCB_j = \frac{1}{|\mathbb{A}_j|} \sum_{CP \in \mathbb{A}_j} CCB_{CP} \quad (3.19)$$

$$NOA_j = \frac{1}{|\mathbb{A}_j|} \sum_{CP \in \mathbb{A}_j} NOA_{CP} \quad (3.20)$$

$$EENS_j = \frac{1}{|\mathbb{A}_j|} \sum_{CP \in \mathbb{A}_j} EENS_{CP} \quad (3.21)$$

$$PPA_j = \frac{1}{|\mathbb{A}_j|} \sum_{CP \in \mathbb{A}_j} PPA_{CP} \quad (3.22)$$

onde $|\mathbb{A}_j|$ é a cardinalidade, ou contagem de elementos no grupo \mathbb{A}_j .

Por se tratarem de atributos com ordens de grandeza diferentes, é necessária a aplicação de normalização entre os valores. O valor do atributo normalizado associado a cada obra pode então ser obtido dividindo as médias dos impactos pelos máximos valores dos atributos associados às obras:

$$C\hat{B}B_j = \frac{CCB_j}{\max\{CCB_j\}} \quad (3.23)$$

$$N\hat{O}A_j = \frac{NOA_j}{\max\{NOA_j\}} \quad (3.24)$$

$$E\hat{E}NS_j = \frac{EENS_j}{\max\{EENS_j\}} \quad (3.25)$$

$$P\hat{P}A_j = \frac{PPA_j}{\max\{PPA_j\}} \quad (3.26)$$

Assim, pode-se calcular o índice de severidade, através de uma soma de parcelas dos valores normalizados dos atributos para cada obra j em cada ano k . A ponderação de todas as parcelas foi definida como unitária, mas diferentes pesos poderiam ser utilizados. É importante destacar que, como o método busca a minimização do atributo NOA , este entra na soma das parcelas com valor negativo:

$$IS_j = C\hat{B}B_j - N\hat{O}A_j + E\hat{E}NS_j + P\hat{P}A_j \quad (3.27)$$

Índice geral de probabilidade

O segundo índice utilizado avalia a quantidade de configurações plurianuais da frente de Pareto em que a obra avaliada é atrasada. Assim, o índice indica a probabilidade de as configurações plurianuais mais críticas conterem a obra atrasada.

Esta probabilidade é calculada através da contagem de configurações da frente de Pareto onde cada obra j foi atrasada em pelo menos um ano (que é o número de elementos em \mathbb{A}_j), dividido pelo número de configurações presentes na frente de Pareto $|\mathbb{GP}^*|$:

$$IP_j = \frac{|\mathbb{A}_j|}{|\mathbb{GP}^*|} \quad (3.28)$$

3.8.2 Índices anuais

Para fins de comparação, os índices anteriores podem ser calculados anualmente. Como será mostrado nos resultados, eles podem não levar ao mesmo ranking de obras, pois não estão levando em consideração os impactos dos atrasos no final de todo o horizonte de planejamento.

Para o cálculo dos índices anuais, para cada obra j analisada no ano k , um grupo $\mathbb{A}_{j,k}$ é montado, sendo composto pelas configurações plurianuais do grupo de Pareto que contém j atrasada em k .

Índice anual de severidade

Para cada ano k , é calculado para cada um dos quatro atributos o impacto médio do atraso da obra j

$$CCB_{j,k} = \frac{1}{|\mathbb{A}_{j,k}|} \sum_{CP \in \mathbb{A}_{j,k}} CCB_{CP,k} \quad (3.29)$$

$$NOA_{j,k} = \frac{1}{|\mathbb{A}_{j,k}|} \sum_{CP \in \mathbb{A}_{j,k}} NOA_{CP,k} \quad (3.30)$$

$$EENS_{j,k} = \frac{1}{|\mathbb{A}_{j,k}|} \sum_{CP \in \mathbb{A}_{j,k}} EENS_{CP,k} \quad (3.31)$$

$$PPA_{j,k} = \frac{1}{|\mathbb{A}_{j,k}|} \sum_{CP \in \mathbb{A}_{j,k}} PPA_{CP,k} \quad (3.32)$$

Os valores de cada atributo são então normalizados considerando seus respectivos valores máximos.

$$C\hat{B}B_{j,k} = \frac{CCB_{j,k}}{\max\{CCB_{j,k}\}} \quad (3.33)$$

$$N\hat{O}A_{j,k} = \frac{NOA_{j,k}}{\max\{NOA_{j,k}\}} \quad (3.34)$$

$$E\hat{E}NS_{j,k} = \frac{EENS_{j,k}}{\max\{EENS_{j,k}\}} \quad (3.35)$$

$$P\hat{P}A_{j,k} = \frac{PPA_{j,k}}{\max\{PPA_{j,k}\}} \quad (3.36)$$

Pode-se então calcular o índice de severidade, através de uma soma de parcelas dos valores normalizados dos atributos para cada obra j em cada ano k .

$$IS_{j,k} = C\hat{B}B_{j,k} - N\hat{O}A_{j,k} + E\hat{E}NS_{j,k} + P\hat{P}A_{j,k} \quad (3.37)$$

Índice anual de probabilidade

Para o cálculo anual do índice de probabilidade, é feita para cada ano k , a contagem de configurações da frente de Pareto onde cada obra j foi atrasada ($|\mathbb{A}_{j,k}|$), dividindo pelo número de configurações presentes na frente de Pareto:

$$IP_{jk} = \frac{|\mathbb{A}_{j,k}|}{|\mathbb{GP}^*|} \quad (3.38)$$

Interpretação conjunta dos índices Severidade e probabilidade são dois tipos diferentes de índices, e consideram conceitos diferentes em seus cálculos. Portanto, pode ocorrer de indicarem ranqueamentos diferentes para prioridades das obras, cabendo ao usuário, na situação de ter que decidir entre duas obras por exemplo, quais os riscos envolvidos em considerar um índice em detrimento do outro. Ao considerar a medida de probabilidade como fator decisório, o decisor prefere evitar o atraso que leva à maior chance de acontecer alguma severidade no sistema, ou seja, a construção da obra classificada como mais crítica pelo índice de probabilidade, reduz em maior quantidade os cenários de atrasos críticos da frente de Pareto.

Se o decisor optar por usar a medida de severidade como fator decisório, ele prefere evitar o atraso que leve aos cenários de maior severidade, mesmo que com menor probabilidade de acontecer.

Além disso, em casos deste tipo, o decisor deve analisar se os valores dos índices estão muito parecidos, indicando “empates técnicos” entre obras.

Vale ressaltar que, por ser uma otimização plurianual, considerando as interações entre os anos durante as análises, este trabalho tem como objetivo analisar o impacto dos atrasos no horizonte de estudos como um todo. Assim, a utilização dos índices anuais deve se feita com cautela, pois não representa os mesmos resultados obtidos com uma análise estática. Nos estudos do Capítulo 4, pode-se observar a ocorrência de diferenças entre a análise anual e a geral.

O Apêndice D traz um exemplo numérico do cálculo dos índices de classificação de obras expostos nesta Seção.

3.9 Implementação computacional

A implementação do método proposto foi toda feita na linguagem Fortran, e estruturada seguindo os conceitos de programação orientada a objetos já adotados no programa original. Além disso, o código foi paralelizado via *Message Passing Interface* (MPI) [61], com o intuito de agilizar a execução em máquinas *multicore* e também *clusters*, nas plataformas *Windows* e *Linux*.

Esta paralelização, porém, é uma versão inicial, baseada na paralelização síncrona implementada na versão exaustiva do programa, assim, não foi explorada e desenvolvida em sua totalidade. Para melhorar esta paralelização mais eficiente, seria interessante aplicar conceitos de paralelização assíncrona, tópico este planejado para trabalhos futuros.

Capítulo 4

Estudos de caso e Resultados

Dois sistemas de teste são usados para avaliar o desempenho do método proposto: um sistema de subtransmissão de 40 barras [62] e o sistema teste de 24 barras IEEE RTS [63], com seis e três estágios de planejamento, respectivamente. Para validar os resultados obtidos pelo método proposto, também foi executada uma abordagem exaustiva, na qual todas as possíveis configurações anuais de atraso são enumeradas e depois combinadas para gerar todas as configurações possíveis de atraso de vários anos, como explicado na Seção 3.1. Esta análise além de comparar o desempenho, também detalha a interpretação dos índices obtidos. Adicionalmente, a Seção 4.3 expõe a comparação de desempenho dos métodos BP-PSO e NSGA-II com relação à abordagem exaustiva.

4.1 Sistema de subtransmissão 40-barras

Um plano de expansão real de curto prazo de um subsistema elétrico da região nordeste do Brasil [62] foi usado para testar o método proposto. A expansão contém seis obras planejadas e seus atrasos serão avaliados. Todas as obras são linhas de 69kV e estão planejadas para implementação nos primeiros três anos do horizonte de planejamento: três delas planejadas para o primeiro ano, uma para o segundo e mais duas para o terceiro ano, conforme destacado na Figura 4.1. Este subsistema está conectado ao sistema de transmissão de 230kV através de dois pontos de alimentação, modelados neste estudo como injeções de potência.

Foram considerados três cenários operativos, representando o sistema com carga leve, média e pesada. Para demonstrar as diferenças nos resultados ao se considerar diferentes horizontes de estudo, a análise de atrasos será realizada considerando os horizontes de planejamento de 3 e 6 anos. Em ambos os horizontes do estudo, foram utilizadas 5 partículas, bem como 25 iterações máximas nas otimizações do BP-PSO e também 25 caminhos máximos no algoritmo pseudo-dinâmico.

Tabela 4.2: Índices de classificação de obras no horizonte de 3 anos

		Exaustivo				Método Proposto			
		Ano 1	Ano 2	Ano 3	Geral	Ano 1	Ano 2	Ano 3	Geral
Índice de severidade	<i>Ob1</i>	1,22	1,08	1,53	1,11	1,24	1,09	1,55	1,11
	<i>Ob2</i>	1,02	0,97	1,01	0,85	1,03	0,98	1,03	0,85
	<i>Ob3</i>	0,98	0,92	1,07	0,83	0,99	0,92	1,07	0,82
	<i>Ob4</i>	0	1,09	1,63	1,31	0	1,10	1,64	1,30
	<i>Ob5</i>	0	0	2,13	1,99	0	0	2,13	1,98
	<i>Ob6</i>	0	0	1,90	1,79	0	0	1,90	1,79
Índice de probabilidade	<i>Ob1</i>	0,77	0,66	0,42	0,77	0,76	0,65	0,41	0,76
	<i>Ob2</i>	0,44	0,30	0,11	0,44	0,43	0,29	0,10	0,43
	<i>Ob3</i>	0,44	0,34	0,08	0,44	0,43	0,33	0,08	0,43
	<i>Ob4</i>	0	0,88	0,61	0,88	0	0,87	0,60	0,87
	<i>Ob5</i>	0	0	0,66	0,66	0	0	0,67	0,67
	<i>Ob6</i>	0	0	0,72	0,72	0	0	0,70	0,70

Observa-se que os índices de severidade e probabilidade das obras obtidos pelo método proposto são praticamente iguais aos da abordagem exaustiva, mostrando sua precisão tanto na análise anual quanto na análise geral. O método proposto alcançou a mesma classificação final das obras, conforme mostrado na Tabela 4.3.

Tabela 4.3: Classificação final das obras - horizonte de 3 anos

		Índice de Severidade				Índice de Probabilidade			
		Exaustivo		BP-PSO		Exaustivo		BP-PSO	
1 ^a	<i>Ob5</i>	1,99	<i>Ob5</i>	1,98	1 ^a	<i>Ob4</i>	0,88	<i>Ob4</i>	0,87
2 ^a	<i>Ob6</i>	1,79	<i>Ob6</i>	1,79	2 ^a	<i>Ob1</i>	0,77	<i>Ob1</i>	0,76
3 ^a	<i>Ob4</i>	1,31	<i>Ob4</i>	1,30	3 ^a	<i>Ob6</i>	0,72	<i>Ob6</i>	0,70
4 ^a	<i>Ob1</i>	1,11	<i>Ob1</i>	1,11	4 ^a	<i>Ob5</i>	0,66	<i>Ob5</i>	0,67
5 ^a	<i>Ob2</i>	0,85	<i>Ob2</i>	0,85	5 ^a	<i>Ob2</i>	0,44	<i>Ob2</i>	0,43
6 ^a	<i>Ob3</i>	0,83	<i>Ob3</i>	0,82	6 ^a	<i>Ob3</i>	0,44	<i>Ob3</i>	0,43

Análise do índice de severidade Ao analisar o resultado geral, nota-se que as obras *Ob5* e *Ob6* (planejadas para o último ano) são classificadas como as mais críticas, respectivamente na primeira e na segunda posições mais críticas. A classificação geral feita pelo método proposto foi a mesma obtida pela abordagem exaustiva. Ao analisar os índices anuais, as obras *Ob5* e *Ob6* também tiveram severidades mais altas no terceiro ano do que as outras obras. Portanto, nesse caso, os índices anuais levam à mesma ordem de prioridade que o indicador geral.

Análise do índice de probabilidade No caso do índice de probabilidade, o método proposto também obteve os mesmos resultados que a abordagem exaustiva. *Ob4* aparece como o mais crítico nesse critério, seguido por *Ob1* e *Ob6*. Assim como no índice de severidade, o índice de probabilidade anual apresentou valores mais altos para as obras planejadas para serem construídas no ano analisado.

Interpretação dos índices associados Como as classificações resultantes foram diferentes para o índice de severidade e o índice de probabilidade, uma análise detalhada deve ser feita sobre quais informações são mais importantes para o decisor. Se uma decisão deve ser tomada entre as obras *Ob1*, *Ob2*, *Ob3* e *Ob4*, a decisão é direta, pois em ambos os índices foi indicado que a prioridade de *Ob4* é maior que *Ob1*, *Ob2* e *Ob3*, nessa ordem.

No entanto, ao envolver *Ob5* e *Ob6*, algumas considerações devem ser feitas. Se é mais importante evitar atrasos que levem a uma maior severidade no sistema, mesmo com menos chances de acontecer, o decisor considerará a classificação de severidade e, portanto, *Ob5* tem maior prioridade. Se, no entanto, é mais importante evitar atrasos para os quais há uma chance maior de um cenário crítico, o decisor escolherá considerar a classificação de probabilidade e, portanto, *Ob6* tem maior prioridade.

Eficiência computacional Em termos de eficiência computacional, o tempo gasto no método proposto é um pouco menor, 4min 59s em comparação com 5min 55s da abordagem exaustiva, uma redução de 16%. A redução no número de configurações de atraso anuais simuladas foi de 13% (76 *vs.* 88). Nesse caso, os dois primeiros anos têm um pequeno número de combinações possíveis de atrasos a serem avaliados, enquanto o terceiro ano possui uma quantidade maior, pois pode avaliar o atraso de todas as seis obras e suas combinações. Portanto, a pequena redução no tempo de processamento se deve ao fato de o espaço de pesquisa ser muito pequeno nos anos 1 e 2. No ano 3, o método proposto é mais eficiente. Porém, neste caso de poucas obras consideradas, o ganho de desempenho do terceiro ano ao usar o método proposto é ofuscado pelos anos iniciais.

4.1.2 Horizonte de 6 anos

A Tabela 4.4 mostra uma visão geral dos valores ótimos dos atributos obtidos para o horizonte de 6 anos. Os valores calculados pelas duas abordagens são muito semelhantes, confirmando a precisão do método proposto. Nesse caso, o número de configurações de atraso plurianuais presentes no Grupo de Pareto é 51% do número exaustivo. O impacto negativo dos atrasos nas obras no horizonte de 6 anos é ainda pior do que no caso anterior. Com o mesmo número médio de obras atrasadas, a média do corte de carga aumentou para 7 MW e a EENS é 71% mais alto, em média, e pode atingir o triplo do valor do plano original.

A Tabela 4.5 apresenta os índices de classificação das obras obtidos pela abordagem exaustiva e pelo método proposto ao considerar um horizonte de planejamento de 6 anos.

O método proposto também alcançou a mesma classificação final das obras para

Tabela 4.4: Visão geral dos atributos do \mathbb{GP}^* no horizonte de planejamento de 6 anos

	Exaustivo ($ \mathbb{GP}^* = 1494$)				Método Proposto ($ \mathbb{GP}^* = 765$)			
	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)
Plano Inicial	0	0	1,67	58,35	0	0	1,67	58,35
Média	2,75	7,07	2,13	100,51	2,44	7,44	2,11	94,29
Desvio Padrão	0,89	4,62	0,13	30,92	0,81	4,63	0,12	29,14
Valor máximo	5,17	19,11	2,44	187,68	4,67	16,57	2,30	171,49
Valor mínimo	0,17	0,00	1,70	58,36	0,17	0,00	1,70	58,47

Tabela 4.5: Índices de classificação de obras no horizonte de 6 anos

		Exaustivo							Método Proposto						
		Ano 1	Ano 2	Ano 3	Ano 4	Ano 5	Ano 6	Geral	Ano 1	Ano 2	Ano 3	Ano 4	Ano 5	Ano 6	Geral
Índice de severidade	<i>Ob1</i>	1,17	1,06	1,83	0,68	1,38	1,03	0,44	1,23	1,11	2,05	0,70	1,24	0,80	0,43
	<i>Ob2</i>	0,94	0,99	1,72	0,54	1,84	1,80	0,49	1,02	1,00	1,70	0,68	1,79	1,62	0,49
	<i>Ob3</i>	0,99	0,98	1,66	0,71	1,84	1,21	0,45	0,98	0,97	1,80	0,68	2,11	0,87	0,43
	<i>Ob4</i>	0	1,08	1,84	0,80	1,65	1,14	0,64	0	1,12	2,11	0,82	1,72	1,15	0,70
	<i>Ob5</i>	0	0	2,06	1,68	2,06	1,93	2,00	0	0	2,35	1,88	1,88	2,13	2,06
	<i>Ob6</i>	0	0	1,99	1,21	1,78	1,50	1,35	0	0	2,25	1,35	1,69	1,38	1,39
Índice de probabilidade	<i>Ob1</i>	0,85	0,79	0,68	0,56	0,41	0,32	0,85	0,84	0,77	0,57	0,44	0,30	0,22	0,84
	<i>Ob2</i>	0,52	0,44	0,24	0,21	0,17	0,11	0,52	0,50	0,42	0,27	0,25	0,16	0,11	0,50
	<i>Ob3</i>	0,63	0,58	0,43	0,31	0,25	0,15	0,63	0,51	0,40	0,10	0,02	0,02	0,02	0,51
	<i>Ob4</i>	0	0,93	0,75	0,63	0,54	0,43	0,93	0	0,95	0,85	0,63	0,51	0,36	0,95
	<i>Ob5</i>	0	0	0,89	0,73	0,56	0,31	0,89	0	0	0,87	0,71	0,52	0,24	0,87
	<i>Ob6</i>	0	0	0,94	0,86	0,74	0,53	0,94	0	0	0,96	0,88	0,74	0,47	0,96

o planejamento de 6 anos, conforme mostrado na Tabela 4.6,

Tabela 4.6: Classificação final das obras - horizonte de 6 anos

Índice de Severidade				Índice de Probabilidade					
Exaustivo		BP-PSO		Exaustivo		BP-PSO			
1ª	<i>Ob5</i>	2,00	<i>Ob5</i>	2,06	1ª	<i>Ob6</i>	0,94	<i>Ob6</i>	0,96
2ª	<i>Ob6</i>	1,35	<i>Ob6</i>	1,39	2ª	<i>Ob4</i>	0,93	<i>Ob4</i>	0,95
3ª	<i>Ob4</i>	0,64	<i>Ob4</i>	0,70	3ª	<i>Ob5</i>	0,89	<i>Ob5</i>	0,87
4ª	<i>Ob2</i>	0,49	<i>Ob2</i>	0,49	4ª	<i>Ob1</i>	0,85	<i>Ob1</i>	0,84
5ª	<i>Ob3</i>	0,45	<i>Ob3</i>	0,43	5ª	<i>Ob3</i>	0,63	<i>Ob3</i>	0,51
6ª	<i>Ob1</i>	0,44	<i>Ob1</i>	0,43	6ª	<i>Ob2</i>	0,52	<i>Ob2</i>	0,50

Análise do índice de severidade O resultado geral mostra um índice muito maior para as obras *Ob5* e *Ob6*, como ocorreu no horizonte de três anos. Ao analisar os índices anuais, percebe-se que a diferença de *Ob5* e *Ob6* em relação às demais obras aumenta ainda mais no ano 4. No entanto, a decisão baseada em índices anuais pode levar a erros, como pode ser observado nas obras *Ob4* e *Ob3*. A partir do quinto ano, *Ob4* tem índices mais baixos que o *Ob3*, mas, considerando o horizonte geral de planejamento, o *Ob4* se destaca como a terceira obra mais crítica, somente atrás de *Ob5* e *Ob6*.

Análise do índice de probabilidade *Ob6* e *Ob4* são classificados como as obras mais críticas nesse critério, seguidas por *Ob5* e *Ob1*. Percebe-se que nos anos 3, 4 e 5, os índices anuais indicam *Ob4* como menos crítico que *Ob5*, enquanto no ano 6 a ordem é invertida. Este é outro exemplo de que, utilizar resultados de métodos plurianuais numa avaliação anual estática pode levar a uma interpretação equivocada.

Interpretação dos índices associados Novamente, caberá ao decisor escolher quais obras priorizar, tendo em mãos as classificações de severidade e probabilidade, mostradas na Tabela 4.6. De acordo com o critério de severidade, *Ob5* é considerada mais crítica que *Ob6* e *Ob4*, ao contrário do que indica o índice de probabilidade. Os critérios de decisão devem levar em consideração se é preferível priorizar obras cujo atraso leva a cenários mais graves ou priorizar obras cujo atraso indica maior probabilidade de cenários críticos.

Comparando os resultados para os dois horizontes, existem diferenças nas classificações da obra. No estudo de 6 anos, a classificação final aponta que *Ob2* deve ser priorizada em relação a *Ob3* e *Ob1*, considerando o índice de severidade. *Ob1* tem baixa prioridade, o que indica que seu atraso gera menos impacto em estudos de médio prazo do que no estudo de curto prazo.

Essas diferenças nos índices se devem ao fato de que em um estudo mais curto, como o estudo de três anos, as consequências de atrasos mais longos na construção não são cobertas. Nesse sentido, é importante que o gerente de obras ou a equipe de planejamento considere os atrasos típicos de obras naquela região ou empresa analisada, para realizar o estudo dentro de um horizonte temporal compatível.

Eficiência computacional Em termos de eficiência computacional, a redução no tempo computacional utilizando o método proposto atingiu 35% no estudo de 6 anos, passando de 17min 31s para 11min 13s, enquanto o número de atrasos simulados foi reduzido em 37% em relação ao abordagem exaustiva (280 *vs* 176). Essa diferença de 2% se deve a gastos intrínsecos do método proposto. Observa-se também que a perda de desempenho nos anos iniciais descritos na análise de três anos foi bem menos evidente no estudo com maior horizonte de estudo, e a redução no tempo computacional aumentou de 16% para 35%.

4.2 IEEE 24-barras RTS

O Sistema de Teste de Confiabilidade IEEE (RTS) [63] é o segundo sistema usado para testar e avaliar o método proposto. Para tanto, foi procurada uma referência que tratasse o caso como um problema de expansão de múltiplos estágios. Em [64],

foram propostas 14 obras como uma expansão do RTS, distribuídos em um horizonte de três anos, onde a carga e a geração possuem valores 3,00, 3,05 e 3,10 vezes o do sistema de teste de confiabilidade original do IEEE. No entanto, a referência utilizou de fluxo de potência CC sem perdas, impossibilitando a obtenção direta desses fatores de carga neste estudo.

Assim, a carga foi reduzida até que a convergência do fluxo de potência fosse alcançada ao simular contingências para cada projeto. Usando ferramentas de fluxo de potência ótimo, o valor de 1,82 vezes a carga original do sistema foi encontrado no primeiro estágio. Foi definido um aumento de carga de 6% entre os anos, resultando em 1,93 e 2,05 vezes a carga original do caso RTS, no segundo e no terceiro estágio, respectivamente.

A Figura 4.2 mostra as catorze obras e os estágios em que elas estão planejadas para serem implementadas.

A Tabela 4.7 mostra uma visão geral dos valores médios dos atributos para o sistema RTS, em que o número de configurações plurianuais de atraso no Grupo Pareto é 90% do número obtido pela abordagem exaustiva. O impacto dos atrasos das obras no sistema pode ser considerado severo. Com um número médio de quase 5 obras atrasadas, o corte de carga médio é de 1,8GW podendo atingir a carga total do sistema. Isso ocorre porque em situações em que o fluxo de potência ótimo não converge, é entendido como uma configuração muito crítica e inviável, e toda a carga do sistema é considerada cortada. As perdas são 26% mais altas, em média, atingindo quase o dobro no pior cenário. A EENS é 61% mais alta, em média, podendo atingir o dobro do valor encontrado no plano de expansão original.

Tabela 4.7: Visão geral dos valores de atributos do \mathbb{GP}^* para o caso RTS

	Exaustivo ($ \mathbb{GP}^* = 1712$)				Método Proposto ($ \mathbb{GP}^* = 1546$)			
	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)
Plano Inicial	0	0	80,42	153974,01	0	0	80,42	153974,01
Média	4,93	1836,53	107,80	248643,89	4,80	1827,81	107,33	248422,70
Desvio Padrão	1,93	1393,14	11,63	42916,66	1,91	1389,80	11,62	42919,89
Valor máximo	11,33	5519,90	154,67	321123,62	11,33	5519,90	154,67	321123,62
Valor mínimo	0,33	0,00	81,37	154874,65	0,33	0,00	81,37	154874,65

A Tabela 4.8 mostra os índices de classificação das obras obtidos pela abordagem exaustiva e pelo método proposto, nos mesmos padrões da Tabela 4.2. Pode-se observar que os índices de severidade e probabilidade das obras calculados pelo método proposto são muito semelhantes à abordagem exaustiva.

Quando há circuitos paralelos planejados para serem implementados no mesmo ano (como *Ob6* + *Ob7* e *Ob8* + *Ob9*), seus índices são idênticos, pois o impacto de cada uma dessas obras é igual quando atrasado. Entretanto, ao analisar *Ob8* + *Ob9*

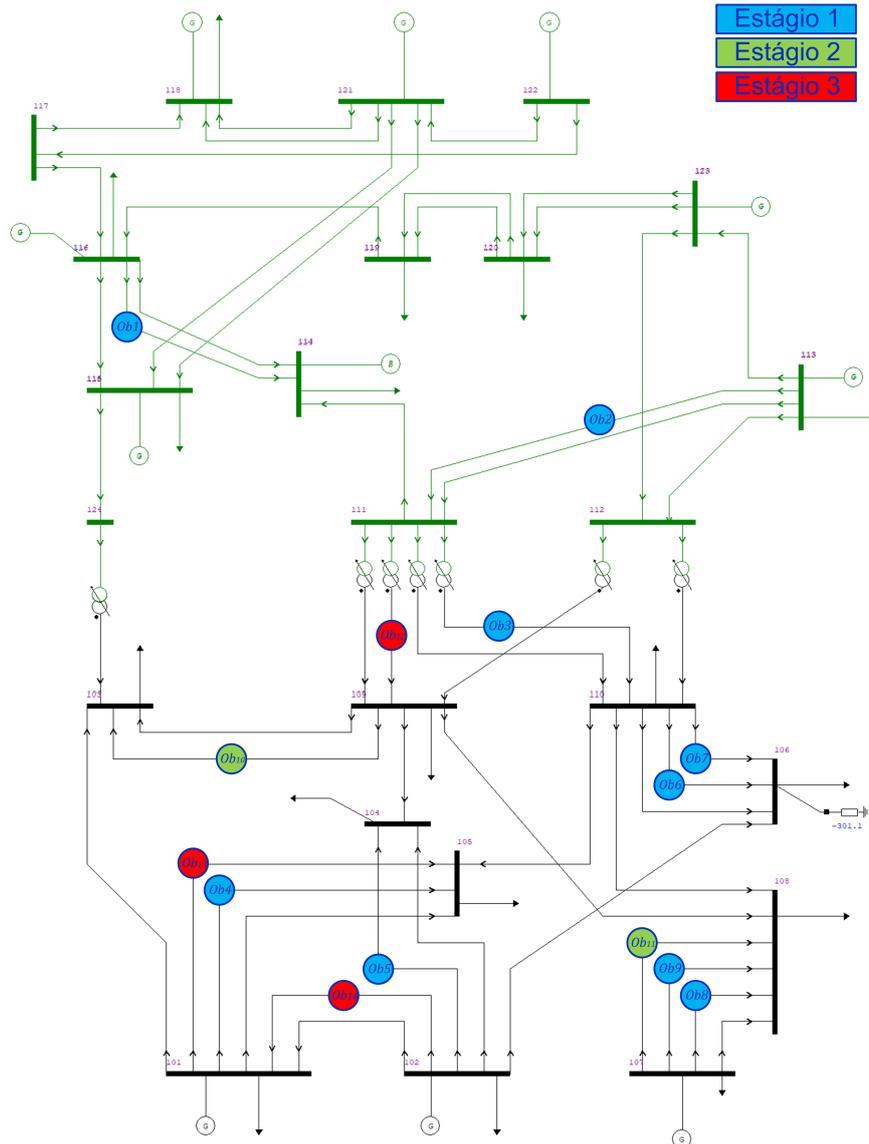


Figura 4.2: IEEE RTS com obras planejadas - Caso 2

e *Ob11*, apesar de serem circuitos paralelos, uma vez que *Ob11* deve ser construído um ano após *Ob8 + Ob9*, o número de ocorrências de *Ob11* nas configurações pluri-
 rianuais do conjunto Pareto é diferente, alterando tanto sua severidade e os índices
 de probabilidade, e levando a uma posição de classificação diferente em comparação
 com *Ob8* e *Ob9*.

A Tabela 4.9 mostra a classificação final das obras considerando os dois índices
 propostos. O método proposto obteve os mesmos resultados que o método exaustivo
 na classificação de ambos os índices.

Análise do índice de severidade Considerando o índice geral, as obras paralelas
Ob8 + Ob9, seguidos pelas obras *Ob6 + Ob7*, são as mais críticas. Na quinta

Tabela 4.8: Índices de classificação de obras para o caso RTS em 3 anos

		Exaustivo				Método Proposto			
		Ano 1	Ano 2	Ano 3	Geral	Ano 1	Ano 2	Ano 3	Geral
Índice de severidade	<i>Ob1</i>	1,834	1,624	1,457	1,673	1,839	1,625	1,493	1,665
	<i>Ob2</i>	1,872	1,334	1,614	1,706	1,880	1,343	1,633	1,697
	<i>Ob3</i>	1,830	1,279	1,373	1,725	1,836	1,286	1,397	1,713
	<i>Ob4</i>	1,855	1,805	1,617	1,658	1,863	1,819	1,701	1,647
	<i>Ob5</i>	1,782	1,739	1,253	1,622	1,781	1,754	1,283	1,609
	<i>Ob6</i>	1,967	1,757	1,553	1,737	1,975	1,757	1,578	1,725
	<i>Ob7</i>	1,967	1,757	1,553	1,737	1,975	1,755	1,578	1,725
	<i>Ob8</i>	2,016	1,801	1,447	1,748	2,029	1,808	1,477	1,737
	<i>Ob9</i>	2,016	1,801	1,447	1,748	2,029	1,808	1,477	1,737
	<i>Ob10</i>	0	1,611	1,451	1,671	0	1,610	1,476	1,664
	<i>Ob11</i>	0	1,761	1,438	1,714	0	1,768	1,465	1,705
	<i>Ob12</i>	0	0	1,481	1,660	0	0	1,508	1,655
	<i>Ob13</i>	0	0	1,299	1,646	0	0	1,335	1,616
	<i>Ob14</i>	0	0	1,437	1,684	0	0	1,469	1,675
Índice de probabilidade	<i>Ob1</i>	0,717	0,442	0,259	0,717	0,696	0,428	0,254	0,696
	<i>Ob2</i>	0,876	0,258	0,016	0,876	0,867	0,250	0,018	0,867
	<i>Ob3</i>	0,522	0,192	0,009	0,522	0,506	0,181	0,010	0,506
	<i>Ob4</i>	0,447	0,159	0,009	0,447	0,417	0,144	0,009	0,417
	<i>Ob5</i>	0,370	0,187	0,086	0,370	0,335	0,162	0,067	0,335
	<i>Ob6</i>	0,844	0,617	0,492	0,844	0,842	0,612	0,491	0,842
	<i>Ob7</i>	0,844	0,617	0,492	0,844	0,842	0,612	0,491	0,842
	<i>Ob8</i>	0,848	0,603	0,269	0,848	0,846	0,588	0,245	0,846
	<i>Ob9</i>	0,848	0,603	0,269	0,848	0,846	0,588	0,245	0,846
	<i>Ob10</i>	0	0,651	0,465	0,651	0	0,635	0,443	0,635
	<i>Ob11</i>	0	0,700	0,317	0,700	0	0,683	0,283	0,683
	<i>Ob12</i>	0	0	0,470	0,470	0	0	0,448	0,448
	<i>Ob13</i>	0	0	0,043	0,043	0	0	0,040	0,040
	<i>Ob14</i>	0	0	0,252	0,252	0	0	0,254	0,254

Tabela 4.9: Classificação final das obras - caso RTS

		Índice de Severidade		Índice de Probabilidade					
		Exaustivo	BP-PSO	Exaustivo		BP-PSO			
1 ^a	<i>Ob8</i>	1,748	<i>Ob8</i>	1,737	1 ^a	<i>Ob2</i>	0,876	<i>Ob2</i>	0,867
2 ^a	<i>Ob9</i>	1,748	<i>Ob9</i>	1,737	2 ^a	<i>Ob8</i>	0,848	<i>Ob8</i>	0,846
3 ^a	<i>Ob6</i>	1,737	<i>Ob6</i>	1,725	3 ^a	<i>Ob9</i>	0,848	<i>Ob9</i>	0,846
4 ^a	<i>Ob7</i>	1,737	<i>Ob7</i>	1,725	4 ^a	<i>Ob6</i>	0,844	<i>Ob6</i>	0,842
5 ^a	<i>Ob3</i>	1,725	<i>Ob3</i>	1,713	5 ^a	<i>Ob7</i>	0,844	<i>Ob7</i>	0,842
6 ^a	<i>Ob11</i>	1,714	<i>Ob11</i>	1,705	6 ^a	<i>Ob1</i>	0,717	<i>Ob1</i>	0,696
7 ^a	<i>Ob2</i>	1,706	<i>Ob2</i>	1,697	7 ^a	<i>Ob11</i>	0,700	<i>Ob11</i>	0,683
8 ^a	<i>Ob14</i>	1,684	<i>Ob14</i>	1,675	8 ^a	<i>Ob10</i>	0,651	<i>Ob10</i>	0,635
9 ^a	<i>Ob1</i>	1,673	<i>Ob1</i>	1,665	9 ^a	<i>Ob3</i>	0,522	<i>Ob3</i>	0,506
10 ^a	<i>Ob10</i>	1,671	<i>Ob10</i>	1,664	10 ^a	<i>Ob12</i>	0,470	<i>Ob12</i>	0,448
11 ^a	<i>Ob12</i>	1,660	<i>Ob12</i>	1,655	11 ^a	<i>Ob4</i>	0,447	<i>Ob4</i>	0,417
12 ^a	<i>Ob4</i>	1,658	<i>Ob4</i>	1,647	12 ^a	<i>Ob5</i>	0,370	<i>Ob5</i>	0,335
13 ^a	<i>Ob13</i>	1,646	<i>Ob13</i>	1,616	13 ^a	<i>Ob14</i>	0,252	<i>Ob14</i>	0,254
14 ^a	<i>Ob5</i>	1,622	<i>Ob5</i>	1,609	14 ^a	<i>Ob13</i>	0,043	<i>Ob13</i>	0,040

posição, *Ob3* aparece, seguida por *Ob11* e *Ob2*.

Se o índice anual fosse usado na decisão de qual obra priorizar no segundo e no terceiro anos, no entanto, *Ob4* teria sido classificada como a mais crítico, enquanto a classificação geral mostra que, em uma avaliação plurianual, o atraso de *Ob4* leva a um dos impactos menos relevantes. Este é outro exemplo do erro causado pelo

uso de índices anuais para tomar a decisão.

Análise do índice de probabilidade A obra *Ob2* aparece como a obra mais crítica ao considerar o índice de probabilidade. Isso indica que *Ob2* é a obra cujo atraso está mais frequentemente associado à ocorrência de configurações críticas. É seguido por $Ob8 + Ob9$ e $Ob6 + Ob7$, que são as obras mais críticas quando se considera o índice de severidade.

A análise dos índices anuais mostra um caso interessante no terceiro ano, em que *Ob13* tem uma probabilidade mais alta que *Ob3* e *Ob4*, enquanto os índices gerais mostram que *Ob13* é a obra menos crítica sob o critério de probabilidade. Novamente, os índices anuais não são bons indicadores das obras a serem priorizados quando a análise é focada no horizonte de planejamento, considerando as relações inter-anuais.

Interpretação dos índices associados O gerente de obras pode decidir quais obras devem receber maior atenção para garantir sua construção na data planejada com base na Tabela 4.9.

Consultando os dois índices, fica claro que algumas obras são mais críticas que outras, pois apresentam valores mais altos nos dois índices, como *Ob7* em relação a *Ob5*. No entanto, quando o decisor precisa escolher entre *Ob8* e *Ob2* para priorizar, por exemplo, caberia a ele analisar qual é a melhor decisão a ser tomada. Se for mais importante evitar o atraso que leva a uma maior chance de alguma severidade no sistema, o decisor usará a classificação de probabilidade e escolherá priorizar *Ob2*. Porém, se for considerado mais importante evitar o atraso que leva a maior severidade, mesmo que seja menos provável, *Ob8* deve ser escolhida, de acordo com o índice de severidade.

Eficiência computacional Nesse caso, devido ao maior número de obras, o tempo exaustivo de simulação da abordagem se tornou inviável do ponto de vista prático. Foram necessárias 10 horas e 35 minutos para que as 18944 configurações de atraso fossem executadas em 12 threads de um computador Intel Core i7 de 3,2 GHz. O método proposto, por outro lado, analisou 55% do número total de combinações possíveis das 14 obras (10413 de um total de 18944 combinações anuais) e obteve a mesma priorização final de obras. Para espaços de busca ainda maiores, a eficiência do método proposto tende a crescer ainda mais.

4.3 Comparação entre o método NSGA-II e o BP-PSO

Como mencionado anteriormente, além do método proposto BP-PSO, foi implementado também o método NSGA-II para ser utilizado como otimizador a ser chamado durante o algoritmo pseudo-dinâmico.

Apesar de ambos os algoritmos serem meta-heurísticas baseadas em população, eles se diferem bastante em suas metodologias. Nesta Seção, serão comparados os resultados obtidos ao aplicar os métodos NSGA-II e do BP-PSO no problema de atrasos de obras.

4.3.1 Caso de estudo

Para os testes comparativos, será utilizado o caso de subtransmissão 40-barras da Seção 4.1, executando com 3 e 6 anos.

Foram feitos testes com o método NSGA-II para calibrar os parâmetros de forma satisfatória. O número máximo de iterações foi fixado em 25 e a convergência foi considerada ao obter-se a estabilidade da Frente de Pareto das configurações plurianuais.

Sistema 40-barras com 3 anos

Por se tratar de um número limitado de configurações ao se considerar apenas os três primeiros anos, a população foi criada com cinco indivíduos.

A Tabela 4.10 traz a visão geral dos valores ótimos dos atributos obtidos para o horizonte de 3 anos. Observa-se uma diferença significativa do método NSGA-II em relação à abordagem de execução exaustiva.

Tabela 4.10: Visão geral dos atributos do \mathbb{GP}^* no horizonte de planejamento de 3 anos

	Exaustivo ($ \mathbb{GP}^* = 64$)				BP-PSO ($ \mathbb{GP}^* = 63$)				NSGA-II ($ \mathbb{GP}^* = 24$)			
	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)
Plano Inicial	0	0	1,49	61,18	0	0	1,49	61,18	0	0	1,49	61,18
Média	2,17	4,23	1,89	108,42	2,14	4,29	1,89	107,63	2,17	1,45	1,82	117,12
Desvio Padrão	0,87	4,23	0,16	26,81	0,84	4,23	0,16	26,36	1,08	3,24	0,17	27,56
Valor máximo	4,00	9,93	2,14	157,60	3,67	9,93	2,14	157,60	4,00	8,60	2,03	157,60
Valor mínimo	0,33	0,00	1,56	68,55	0,33	0,00	1,56	68,55	0,33	0	1,51	72,03

A Tabela 4.11 apresenta a comparação entre os métodos NSGA-II e o BP-PSO baseados na abordagem de execução exaustiva.

Tabela 4.11: Índices de classificação de obras no horizonte de 3 anos

		Exaustivo				BP-PSO				NSGA-II			
		Ano 1	Ano 2	Ano 3	Geral	Ano 1	Ano 2	Ano 3	Geral	Ano 1	Ano 2	Ano 3	Geral
Índice de severidade	<i>Ob1</i>	1,22	1,08	1,53	1,11	1,24	1,09	1,55	1,11	1,18	1,04	1,36	1,23
	<i>Ob2</i>	1,02	0,97	1,01	0,85	1,03	0,98	1,03	0,85	1,01	0,99	1,12	1,08
	<i>Ob3</i>	0,98	0,92	1,07	0,83	0,99	0,92	1,07	0,82	0,94	0,86	1,94	1,35
	<i>Ob4</i>	0	1,09	1,63	1,31	0	1,10	1,64	1,30	0	1,06	1,03	1,18
	<i>Ob5</i>	0	0	2,13	1,99	0	0	2,13	1,98	0	0	1,82	1,99
	<i>Ob6</i>	0	0	1,90	1,79	0	0	1,90	1,79	0	0	1,30	1,42
Índice de probabilidade	<i>Ob1</i>	0,77	0,66	0,42	0,77	0,76	0,65	0,41	0,76	0,71	0,63	0,46	0,71
	<i>Ob2</i>	0,44	0,30	0,11	0,44	0,43	0,29	0,10	0,43	0,50	0,46	0,29	0,50
	<i>Ob3</i>	0,44	0,34	0,08	0,44	0,43	0,33	0,08	0,43	0,46	0,38	0,21	0,46
	<i>Ob4</i>	0	0,88	0,61	0,88	0	0,87	0,60	0,87	0	0,79	0,50	0,79
	<i>Ob5</i>	0	0	0,66	0,66	0	0	0,67	0,67	0	0	0,25	0,25
	<i>Ob6</i>	0	0	0,72	0,72	0	0	0,70	0,70	0	0	0,63	0,63

Observa-se que os índices de severidade e probabilidade das obras obtidos por ambos os métodos são muito próximos, fato comprovado ao analisar o ranqueamento das obras, exposto na Tabela 4.12.

Tabela 4.12: Classificação final das obras - horizonte de 3 anos

	Índice de Severidade						Índice de Probabilidade						
	Exaustivo	BP-PSO	NSGA-II	Exaustivo	BP-PSO	NSGA-II	Exaustivo	BP-PSO	NSGA-II	Exaustivo	BP-PSO	NSGA-II	
1 ^a	<i>Ob5</i>	1,99	<i>Ob5</i>	1,98	<i>Ob5</i>	1,99	1 ^a	<i>Ob4</i>	0,88	<i>Ob4</i>	0,87	<i>Ob4</i>	0,79
2 ^a	<i>Ob6</i>	1,79	<i>Ob6</i>	1,79	<i>Ob6</i>	1,42	2 ^a	<i>Ob1</i>	0,77	<i>Ob1</i>	0,76	<i>Ob1</i>	0,71
3 ^a	<i>Ob4</i>	1,31	<i>Ob4</i>	1,30	<i>Ob3</i>	1,35	3 ^a	<i>Ob6</i>	0,72	<i>Ob6</i>	0,70	<i>Ob6</i>	0,63
4 ^a	<i>Ob1</i>	1,11	<i>Ob1</i>	1,11	<i>Ob1</i>	1,23	4 ^a	<i>Ob5</i>	0,66	<i>Ob5</i>	0,67	<i>Ob2</i>	0,50
5 ^a	<i>Ob2</i>	0,85	<i>Ob2</i>	0,85	<i>Ob4</i>	1,18	5 ^a	<i>Ob2</i>	0,44	<i>Ob2</i>	0,43	<i>Ob5</i>	0,46
6 ^a	<i>Ob3</i>	0,83	<i>Ob3</i>	0,82	<i>Ob2</i>	1,08	6 ^a	<i>Ob3</i>	0,44	<i>Ob3</i>	0,43	<i>Ob3</i>	0,25

O método BP-PSO conseguiu ordenar a ordem das obras mais críticas por ambos os índices comparativos. O método NSGA-II também foi bem, alternando apenas as obras menos críticas em ambos os indicadores de severidade e probabilidade.

Eficiência computacional A redução no número de configurações de atraso anuais simuladas foi de 88 para 76 para o método BP-PSO, em comparação à abordagem exaustiva, redução equivalente a 13%. Já o método NSGA-II convergiu com 43 configurações simuladas. Esta grande redução equivale a 51%, e seria considerado um excelente resultado, se o método tivesse encontrado corretamente o ranqueamento de todas as obras.

Sistema 40-barras com 6 anos

Como a simulação com 6 anos apresenta uma quantidade grande de combinações nos anos finais, a população nesta execução foi aumentada para vinte e cinco indivíduos.

A Tabela 4.13 mostra a visão geral dos atributos obtidos para o horizonte de 6 anos. Observa-se que a diferença entre o método NSGA-II e o BP-PSO foi mais discreta.

Tabela 4.13: Visão geral dos atributos do GP* no horizonte de planejamento de 6 anos

	Exaustivo ($ \text{GP}^* = 1494$)				BP-PSO ($ \text{GP}^* = 765$)				NSGA-II ($ \text{GP}^* = 246$)			
	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)	<i>NOA</i>	<i>CCB</i> (MW)	<i>PPA</i> (MW)	<i>EENS</i> (MWh)
Plano Inicial	0	0	1,67	58,35	0	0	1,67	58,35	0	0	1,67	58,35
Média	2,75	7,07	2,13	100,51	2,44	7,44	2,11	94,29	2,69	6,29	1,93	89,16
Desvio Padrão	0,89	4,62	0,13	30,92	0,81	4,63	0,12	29,14	0,84	4,68	0,13	23,05
Valor máximo	5,17	19,11	2,44	187,68	4,67	16,57	2,30	171,49	4,17	17,03	2,16	150,55
Valor mínimo	0,17	0,00	1,70	58,36	0,17	0,00	1,70	58,47	0,17	0	1,68	58,61

A Tabela 4.14 apresenta, agora considerando 6 anos, a comparação entre os métodos NSGA-II e o BP-PSO com relação à abordagem de execução exaustiva.

Tabela 4.14: Índices de classificação de obras no horizonte de 6 anos

	Exaustivo								BP-PSO								NSGA-II							
	Ano 1	Ano 2	Ano 3	Ano 4	Ano 5	Ano 6	Geral	Ano 1	Ano 2	Ano 3	Ano 4	Ano 5	Ano 6	Geral	Ano 1	Ano 2	Ano 3	Ano 4	Ano 5	Ano 6	Geral			
Índice de severidade	<i>Ob1</i>	1,17	1,06	1,83	0,68	1,38	1,03	0,44	1,23	1,11	2,05	0,70	1,24	0,80	0,43	0,95	0,97	1,73	0,25	1,38	0,80	1,106		
	<i>Ob2</i>	0,94	0,99	1,72	0,54	1,84	1,80	0,49	1,02	1,00	1,70	0,68	1,79	1,62	0,49	0,90	0,92	1,90	0,73	1,64	1,31	1,27		
	<i>Ob3</i>	0,99	0,98	1,66	0,71	1,84	1,21	0,45	0,98	0,97	1,80	0,68	2,11	0,87	0,47	0,96	0,91	1,73	0,57	1,46	0,67	1,14		
	<i>Ob4</i>	0	1,08	1,84	0,80	1,65	1,14	0,64	0	1,12	2,11	0,82	1,72	1,15	0,70	0	0,93	1,38	0,06	1,13	0,73	1,05		
	<i>Ob5</i>	0	0	2,06	1,68	2,06	1,93	2,00	0	0	2,35	1,88	1,88	2,13	2,06	0	0	1,75	0,81	1,70	1,43	1,50		
	<i>Ob6</i>	0	0	1,99	1,21	1,78	1,50	1,35	0	0	2,25	1,35	1,69	1,38	1,39	0	0	1,81	0,69	1,71	2,43	1,72		
Índice de probabilidade	<i>Ob1</i>	0,85	0,79	0,68	0,56	0,41	0,32	0,85	0,84	0,77	0,57	0,44	0,30	0,22	0,84	0,80	0,72	0,60	0,43	0,31	0,16	0,80		
	<i>Ob2</i>	0,52	0,44	0,24	0,21	0,17	0,11	0,52	0,50	0,42	0,27	0,25	0,16	0,11	0,50	0,76	0,75	0,66	0,61	0,38	0,12	0,76		
	<i>Ob3</i>	0,63	0,58	0,43	0,31	0,25	0,15	0,63	0,51	0,40	0,10	0,02	0,02	0,02	0,51	0,91	0,88	0,85	0,80	0,44	0,22	0,91		
	<i>Ob4</i>	0	0,93	0,75	0,63	0,54	0,43	0,93	0	0,95	0,85	0,63	0,51	0,36	0,95	0	0,80	0,28	0,14	0,11	0,04	0,81		
	<i>Ob5</i>	0	0	0,89	0,73	0,56	0,31	0,89	0	0	0,87	0,71	0,52	0,24	0,87	0	0	0,82	0,64	0,44	0,30	0,82		
	<i>Ob6</i>	0	0	0,94	0,86	0,74	0,53	0,94	0	0	0,96	0,88	0,74	0,47	0,96	0	0	0,90	0,63	0,46	0,15	0,90		

Desta vez, pôde-se observar que os índices de severidade e probabilidade se tornaram mais discrepantes. Na Tabela 4.15, que compara os ranqueamentos obtidos, nota-se que o método BP-PSO obteve o mesmo ordenamento que a abordagem exaustiva, indicando a correta busca pelos cenários de simulação. Já o método NSGA-II falhou, obtendo um ordenamento insatisfatório até em ambos os indicadores de Severidade e Probabilidade.

Tabela 4.15: Classificação final das obras - horizonte de 6 anos

	Índice de Severidade						Índice de Probabilidade						
	Exaustivo	BP-PSO	NSGA-II	Exaustivo	BP-PSO	NSGA-II							
1 ^a	<i>Ob5</i>	2,00	<i>Ob5</i>	2,06	<i>Ob6</i>	1,72	1 ^a	<i>Ob6</i>	0,94	<i>Ob6</i>	0,96	<i>Ob3</i>	0,91
2 ^a	<i>Ob6</i>	1,35	<i>Ob6</i>	1,39	<i>Ob5</i>	1,50	2 ^a	<i>Ob4</i>	0,93	<i>Ob4</i>	0,95	<i>Ob6</i>	0,90
3 ^a	<i>Ob4</i>	0,64	<i>Ob4</i>	0,70	<i>Ob2</i>	1,27	3 ^a	<i>Ob5</i>	0,89	<i>Ob5</i>	0,87	<i>Ob5</i>	0,82
4 ^a	<i>Ob2</i>	0,49	<i>Ob2</i>	0,49	<i>Ob3</i>	1,14	4 ^a	<i>Ob1</i>	0,85	<i>Ob1</i>	0,84	<i>Ob4</i>	0,81
5 ^a	<i>Ob3</i>	0,45	<i>Ob3</i>	0,43	<i>Ob1</i>	1,11	5 ^a	<i>Ob3</i>	0,63	<i>Ob3</i>	0,51	<i>Ob1</i>	0,80
6 ^a	<i>Ob1</i>	0,44	<i>Ob1</i>	0,43	<i>Ob4</i>	1,05	6 ^a	<i>Ob2</i>	0,52	<i>Ob2</i>	0,50	<i>Ob2</i>	0,76

Eficiência computacional A redução no número de configurações de atraso anuais simuladas pelo BP-PSO foi 280 para 176, representando uma redução de 35%. Já o método NSGA-II executou somente 118 configurações anuais, ou 57%. Esta grande redução não representa um mérito do método NSGA-II, pois os resultados obtidos foram insatisfatórios.

4.3.2 Conclusão da comparação dos métodos

As comparações feitas nesta Seção evidenciaram que a aplicação do método proposto BP-PSO neste tipo de problema é a mais indicada. O método NSGA-II não conseguiu obter Índices de Severidade e Probabilidade satisfatórios pois estagnou durante as buscas por configurações de atraso críticas. Já o método BP-PSO conseguiu obter índices muito próximos da abordagem Exaustiva, acertando o ranqueamento em ambos os horizontes de simulação.

Capítulo 5

Conclusões

Este trabalho apresentou uma metodologia para identificar e classificar as obras mais críticas de reforço de sistemas elétricos, considerando possíveis atrasos em suas construções. Ele usa o método de PSO Binário Pareto-ótimo (BP-PSO) para realizar buscas inteligentes pelas configurações anuais de atraso, unidas pelo algoritmo pseudo-dinâmico para realizar uma análise em múltiplos estágios. Por se tratar de um método meta-heurístico, ele não garante a solução exata, mas uma aproximação focada nas soluções mais críticas, com a vantagem de reduzir o número de simulações feitas, e conseqüentemente, o tempo de processamento.

A aplicação do método BP-PSO mostrou-se bastante adequada ao problema tratado, ao contrário do Algoritmo Genético de Classificação Não-dominada II (NSGA-II). Este último método forneceu resultados insatisfatórios, pois, embora tivesse menor tempo de execução, o ranqueamento fornecido foi consideravelmente diferente do método exaustivo. A complexa calibração dos parâmetros do NSGA-II pode ter contribuído para este resultado. Este também é um fator a favor do BP-PSO, que possui fácil implementação e calibração, e conseguiu entregar os resultados esperados de classificação de atrasos de obras.

Considerando-se um horizonte de atrasos curto e com poucas obras, o método proposto apresentou pouco ganho computacional. No entanto, o real gargalo da abordagem exaustiva é observado quando o número de combinações aumenta, e neste caso, a eficiência do método proposto também aumenta, tornando-se bastante atrativo.

Os casos simulados mostram que o esforço computacional economizado é significativo, atingindo redução de até 45% do número de configurações simuladas, e foi obtida a classificação correta das obras mais críticas cujo atraso produzirá impactos no sistema elétrico. Além do ganho computacional decorrente da utilização do método proposto neste trabalho, a melhoria da paralelização dele pode reduzir ainda mais o tempo de execução das simulações.

Como trabalho futuro, é considerada a atualização das bibliotecas do programa

de análise de contingências e de fluxo de potência ótimo, para viabilizar a solução de sistemas de grande porte.

Referências Bibliográficas

- [1] COLAÇO, E. T. M., SZRAJB, M. W. H., DOS ANJOS, A. D. F., et al. “Reforços Conjunturais Propostos ao CMSE para Aliviar o Atraso de Obras Da Transmissão”. In: *XXIV Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE)*, 2017.
- [2] SFE. *Relatório de Monitoramento de Empreendimentos de Transmissão*. Relatório técnico, ANEEL, 2019.
- [3] ANEEL. “Entenda a Expansão da Transmissão”. jun. 2019. Disponível em: http://www.aneel.gov.br/expansao-da-transmissao/-/asset_publisher/2ggRKcvhuMaw/content/entenda-a-expansao-da-transmissao/656808?inheritRedirect=false&redirect=http%3A%2F%2Fwww.aneel.gov.br.
- [4] ANEEL. *Relatório Trimestral de Acompanhamento Diferenciado dos Empreendimentos de Transmissão-ANEEL*. Relatório técnico, Agência Nacional de Energia Elétrica, 2018. Disponível em: <http://www.aneel.gov.br/documents/656808/0/Relat%C3%B3rio+Trimestral+de+Acompanhamento+Diferenciado+dos+Empreendimentos+de+Transmiss%C3%A3o/46a5edc5-c67c-48fe-b7dc-abeaa023402c>.
- [5] ANEEL. “Gestão de contratos de concessão e Fiscalização da Transmissão”. jun. 2019. Disponível em: <http://www.mme.gov.br/documents/10584/24937082/2+-+Gest%C3%A3o+de+contratos+e+fiscaliza%C3%A7%C3%A3o+-+ANEEL+-+7-7-2017.pdf/a1b15c27-e016-487f-955a-c6fff02c1c40;jsessionid=49ECB7E34CBD7EFD1E5D57BE5757F511.srv155>.
- [6] PALL, G. K., BRIDGE, A. J., SKITMORE, M., et al. “Comprehensive review of delays in power transmission projects”, *IET Generation, Transmission Distribution*, v. 10, n. 14, pp. 3393–3404, 2016. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2016.0376.

- [7] MOUTINHO, E. L., BORGES, C. L. T., MOULIN, L. S. “Reliability Assessment of Transmission Reinforcements Delay in the Brazilian Expansion Planning”. In: *2018 IEEE International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, pp. 1–6, June 2018. doi: 10.1109/PMAPS.2018.8440402.
- [8] C. G. MELO, A., R. P. BARROS, J., REI, A., et al. “An attempt to construct a bridge between deterministic and probabilistic approaches in transmission expansion planning - the plantac model”, *41st International Conference on Large High Voltage Electric Systems 2006, CIGRE 2006*, 01 2006.
- [9] *Manual de Metodologia - PLANTAC, v3.2.0*. CEPEL, Rio de Janeiro, Brazil, 2017.
- [10] NIHARIKA, VERMA, S., MUKHERJEE, V. “Transmission Expansion Planning: A Review”. In: *2016 International Conference on Energy Efficient Technologies for Sustainability (ICEETS)*, pp. 350–355, April 2016. doi: 10.1109/ICEETS.2016.7583779.
- [11] MOULIN, L. S., MOUTINHO, E. L., BORGES, C. L. T. “Metodologia para Avaliação de Atrasos de Obras de Transmissão Elétrica no Sistema Elétrico Brasileiro sob o Enfoque da Confiabilidade”. In: *XXV Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE)*, 2019.
- [12] DE SÁ FERREIRA, R. *Improvements to Transmission Expansion Planning and Implementation: Treating Uncertainty in Commercial Operation Dates and Increasing Auction Efficiency*. Tese de Doutorado, Universidade Federal do Rio de Janeiro, 2018.
- [13] YU, Q., GUO, J., DUAN, X. “Dynamic multi-stage transmission network expansion planning”. In: *2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, pp. 635–640, April 2008. doi: 10.1109/DRPT.2008.4523483.
- [14] ROMERO, R., ROCHA, C., MANTOVANI, J. R. S., et al. “Constructive Heuristic Algorithm for the DC Model in Network Transmission Expansion Planning”, *IEE Proceedings - Generation, Transmission and Distribution*, v. 152, n. 2, pp. 277–282, March 2005. ISSN: 1350-2360. doi: 10.1049/ip-gtd:20041196.
- [15] ROMERO, R., ASADA, E. N., CARRENO, E., et al. “Constructive heuristic algorithm in branch-and-bound structure applied to transmission network

- expansion planning”, *IET Generation, Transmission Distribution*, v. 1, n. 2, pp. 318–323, March 2007. ISSN: 1751-8687. doi: 10.1049/iet-gtd:20060239.
- [16] ESCOBAR, A. H., GALLEGO, R. A., ROMERO, R. “Multistage and Coordinated Planning of the Expansion of Transmission Systems”, *IEEE Transactions on Power Systems*, v. 19, n. 2, pp. 735–744, May 2004. ISSN: 0885-8950. doi: 10.1109/TPWRS.2004.825920.
- [17] PINDORIYA, N. M., SINGH, S. N., LEE, K. Y. “A comprehensive survey on multi-objective evolutionary optimization in power system applications”. In: *IEEE PES General Meeting*, pp. 1–8, July 2010. doi: 10.1109/PES.2010.5589511.
- [18] HEMMATI, R., HOOSHMAND, R.-A., KHODABAKHSHIAN, A. “State-of-the-art of transmission expansion planning: Comprehensive review”, *Renewable and Sustainable Energy Reviews*, v. 23, pp. 312 – 319, 2013. ISSN: 1364-0321. doi: <https://doi.org/10.1016/j.rser.2013.03.015>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1364032113001743>.
- [19] HEMMATI, R., HOOSHMAND, R. A., KHODABAKHSHIAN, A. “Comprehensive Review of Generation and Transmission Expansion Planning”, *IET Generation, Transmission Distribution*, v. 7, n. 9, pp. 955–964, Sept 2013. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2013.0031.
- [20] GIDEON UDE, N., YSKANDAR, H., CONETH GRAHAM, R. “A Comprehensive State-of-the-Art Survey on the Transmission Network Expansion Planning Optimization Algorithms”, *IEEE Access*, v. 7, pp. 123158–123181, 2019.
- [21] RAMIREZ-ROSADO, I. J., GONEN, T. “Pseudodynamic planning for expansion of power distribution systems”, *IEEE Transactions on Power Systems*, v. 6, n. 1, pp. 245–254, Feb 1991. ISSN: 0885-8950. doi: 10.1109/59.131069.
- [22] BINATO, S., OLIVEIRA, G. C. “A heuristic procedure to cope with multi-year transmission expansion planning”. In: *IEEE/KTH Stockholm Power Tech. Conf.*, pp. 1–6, jun. 1995.
- [23] KUWABARA, H., NARA, K. “Multi-year and multi-state distribution systems expansion planning by multi-stage branch exchange”, *IEEE Transactions*

on *Power Delivery*, v. 12, n. 1, pp. 457–463, Jan 1997. ISSN: 0885-8977. doi: 10.1109/61.568271.

- [24] BORGES, C. L. T., MARTINS, V. F. “Multistage Expansion Planning for Active Distribution Networks under Demand and Distributed Generation Uncertainties”, *International Journal of Electrical Power & Energy Systems*, v. 36, n. 1, pp. 107 – 116, 2012. ISSN: 0142-0615. doi: <https://doi.org/10.1016/j.ijepes.2011.10.031>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0142061511002808>.
- [25] PINTÉR, J. D. *Journal of Global Optimization*, v. 15, n. 1, pp. 105–107, 1999. doi: 10.1023/a:1008335430852.
- [26] LEE, K. Y., EL-SHARKAWI, M. A. “Applications to Power System Scheduling”. In: *Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems*, IEEE, 2008. doi: 10.1002/9780470225868.ch15. Disponível em: <https://ieeexplore-ieee-org.ez29.capes.proxy.ufrj.br/xpl/articleDetails.jsp?arnumber=5396746>.
- [27] MORI, H. “Applications of meta-heuristics to power systems in Japan”. In: *IEEE/PES Transmission and Distribution Conference and Exhibition*, v. 1, pp. 661–663 vol.1, Oct 2002. doi: 10.1109/TDC.2002.1178511.
- [28] ROJAS, D. G., LEZAMA, J. L., VILLA, W. “Metaheuristic Techniques Applied to the Optimal Reactive Power Dispatch: a Review”, *IEEE Latin America Transactions*, v. 14, n. 5, pp. 2253–2263, May 2016. ISSN: 1548-0992. doi: 10.1109/TLA.2016.7530421.
- [29] SALGUEIRO-SICILIA, Y., RIVERA, M. “Population-based metaheuristics in microgrids applications”. In: *2017 IEEE Southern Power Electronics Conference (SPEC)*, pp. 1–6, Dec 2017. doi: 10.1109/SPEC.2017.8333647.
- [30] LEE, K. Y., EL-SHARKAWI, M. A. “Overview of Applications in Power Systems”. In: *Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems*, IEEE, 2008. doi: 10.1002/9780470225868.ch12. Disponível em: <https://ieeexplore-ieee-org.ez29.capes.proxy.ufrj.br/xpl/articleDetails.jsp?arnumber=5396743>.
- [31] KENNEDY, J., EBERHART, R. “Particle Swarm Optimization”. In: *Neural Networks, 1995. Proceedings., IEEE International Conference on*, v. 4, pp. 1942–1948 vol.4, Nov 1995. doi: 10.1109/ICNN.1995.488968.

- [32] ALRASHIDI, M. R., EL-HAWARY, M. E. “A Survey of Particle Swarm Optimization Applications in Electric Power Systems”, *IEEE Transactions on Evolutionary Computation*, v. 13, n. 4, pp. 913–918, Aug 2009. ISSN: 1089-778X. doi: 10.1109/TEVC.2006.880326.
- [33] DEL VALLE, Y., VENAYAGAMOORTHY, G. K., MOHAGHEGHI, S., et al. “Particle Swarm Optimization: Basic Concepts, Variants and Applications in Power Systems”, *IEEE Transactions on Evolutionary Computation*, v. 12, n. 2, pp. 171–195, April 2008. ISSN: 1089-778X. doi: 10.1109/TEVC.2007.896686.
- [34] KENNEDY, J., EBERHART, R. C. “A discrete binary version of the particle swarm algorithm”. In: *1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation*, v. 5, pp. 4104–4108 vol.5, Oct 1997. doi: 10.1109/ICSMC.1997.637339.
- [35] PARSOPOULOS, K. E., VRAHATIS, M. N. “Recent Approaches to Global Optimization Problems through Particle Swarm Optimization”, *Natural Computing*, v. 1, n. 2/3, pp. 235–306, 2002. doi: 10.1023/a:1016568309421.
- [36] WU, W., TSAI, M. “Application of Enhanced Integer Coded Particle Swarm Optimization for Distribution System Feeder Reconfiguration”, *IEEE Transactions on Power Systems*, v. 26, n. 3, pp. 1591–1599, Aug 2011. ISSN: 0885-8950. doi: 10.1109/TPWRS.2010.2094212.
- [37] YIN, S., LU, C. “Distribution Feeder Scheduling Considering Variable Load Profile and Outage Costs”, *IEEE Transactions on Power Systems*, v. 24, n. 2, pp. 652–660, May 2009. ISSN: 0885-8950. doi: 10.1109/TPWRS.2009.2016300.
- [38] GUTIÉRREZ-ALCARAZ, G., TOVAR-HERNÁNDEZ, J. H. “Two-stage heuristic methodology for optimal reconfiguration and Volt/VAr control in the operation of electrical distribution systems”, *IET Generation, Transmission Distribution*, v. 11, n. 16, pp. 3946–3954, 2017. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2016.1870.
- [39] NOJAVAN, M., SEYEDI, H., MOHAMMADI-IVATLOO, B. “Voltage stability margin improvement using hybrid non-linear programming and modified binary particle swarm optimisation algorithm considering optimal transmission line switching”, *IET Generation, Transmission Distribution*, v. 12, n. 4, pp. 815–823, 2018. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2016.1895.

- [40] TING, T. O., RAO, M. V. C., LOO, C. K. “A novel approach for unit commitment problem via an effective hybrid particle swarm optimization”, *IEEE Transactions on Power Systems*, v. 21, n. 1, pp. 411–418, Feb 2006. ISSN: 0885-8950. doi: 10.1109/TPWRS.2005.860907.
- [41] JEONG, Y., PARK, J., JANG, S., et al. “A New Quantum-Inspired Binary PSO: Application to Unit Commitment Problems for Power Systems”, *IEEE Transactions on Power Systems*, v. 25, n. 3, pp. 1486–1495, Aug 2010. ISSN: 0885-8950. doi: 10.1109/TPWRS.2010.2042472.
- [42] PAPPALA, V. S., ERLICH, I. “A Variable-Dimension Optimization Approach to Unit Commitment Problem”, *IEEE Transactions on Power Systems*, v. 25, n. 3, pp. 1696–1704, Aug 2010. ISSN: 0885-8950. doi: 10.1109/TPWRS.2009.2038921.
- [43] BENIDRIS, M., ELSAIAH, S., MITRA, J. “Power system reliability evaluation using a state space classification technique and particle swarm optimisation search method”, *IET Generation, Transmission Distribution*, v. 9, n. 14, pp. 1865–1873, 2015. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2015.0581.
- [44] JAVAID, N., HAFEEZ, G., IQBAL, S., et al. “Energy Efficient Integration of Renewable Energy Sources in the Smart Grid for Demand Side Management”, *IEEE Access*, pp. 1–1, 2018. ISSN: 2169-3536. doi: 10.1109/ACCESS.2018.2866461.
- [45] JAVAID, N., ULLAH, I., AKBAR, M., et al. “An Intelligent Load Management System With Renewable Energy Integration for Smart Homes”, *IEEE Access*, v. 5, pp. 13587–13600, 2017. ISSN: 2169-3536. doi: 10.1109/ACCESS.2017.2715225.
- [46] PEDRASA, M. A. A., SPOONER, T. D., MACGILL, I. F. “Scheduling of Demand Side Resources Using Binary Particle Swarm Optimization”, *IEEE Transactions on Power Systems*, v. 24, n. 3, pp. 1173–1181, Aug 2009. ISSN: 0885-8950. doi: 10.1109/TPWRS.2009.2021219.
- [47] KHAN, N. A., SIDHU, G. A. S., GAO, F. “Optimizing Combined Emission Economic Dispatch for Solar Integrated Power Systems”, *IEEE Access*, v. 4, pp. 3340–3348, 2016. ISSN: 2169-3536. doi: 10.1109/ACCESS.2016.2587665.
- [48] SURESH, K., KUMARAPPAN, N. “Generation Maintenance Scheduling Using Improved Binary Particle Swarm Optimisation Considering Aging Failu-

- res”, *IET Generation, Transmission Distribution*, v. 7, n. 10, pp. 1072–1086, October 2013. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2012.0384.
- [49] MISHRA, C., JONES, K. D., PAL, A., et al. “Binary particle swarm optimisation-based optimal substation coverage algorithm for phasor measurement unit installations in practical systems”, *IET Generation, Transmission Distribution*, v. 10, n. 2, pp. 555–562, 2016. ISSN: 1751-8687. doi: 10.1049/iet-gtd.2015.1077.
- [50] YUN, Y., NAKAYAMA, H., YOON, M. “Generation of Pareto optimal solutions using generalized DEA and PSO”, *Journal of Global Optimization*, v. 64, n. 1, pp. 49–61, jun 2015. doi: 10.1007/s10898-015-0314-3.
- [51] TAHER, S. A., PAKDEL, M. “Solution of Multi-Objective optimal reactive power dispatch using pareto optimality particle swarm optimization method”, *Journal of AI and Data Mining*, v. 2, n. 1, Mar 2014. doi: 10.22044/jadm.2014.149.
- [52] ELHOSSINI, A., AREIBI, S., DONY, R. “Strength Pareto particle swarm optimization and hybrid EA-PSO for multi-objective optimization.” *Evolutionary Computation*, v. 18, n. 1, pp. 127 – 156, 2010. ISSN: 1530-9304. Disponível em: <<http://search.ebscohost-com.ez29.capes.proxy.ufrj.br/login.aspx?direct=true&db=mdc&AN=20064026&lang=pt-br&site=ehost-live>>.
- [53] ENGELBRECHT, A. P. *Computational Intelligence: An Introduction*. John Wiley & Sons, 2007.
- [54] ASTA, S. *MSc Thesis : A NOVEL PARTICLE SWARM OPTIMIZATION ALGORITHM*. Tese de Doutorado, 01 2012.
- [55] GANESAN, T., ELAMVAZUTHI, I., VASANT, P. “Swarm Intelligence for Multiobjective Optimization of Extraction Process”. In: *Handbook of Research on Modern Optimization Algorithms and Applications in Engineering and Economics*, IGI Global, pp. 516–544, 2016.
- [56] *Manual do Usuário - ANAREDE, v11.6.2*. CEPEL, Rio de Janeiro, Brazil, abr. 2022.
- [57] *Manual do Usuário - FLUPOT, v7.10.0*. CEPEL, Rio de Janeiro, Brazil, abr. 2022.
- [58] *Manual do Usuário - NH2, v8.1.0*. CEPEL, Rio de Janeiro, Brazil, dez. 2007.

- [59] REI, A. M., SCHILLING, M. T., MELO, A. C. G. “Monte Carlo Simulation and Contingency Enumeration in Bulk Power Systems Reliability Assessment”. In: *2006 International Conference on Probabilistic Methods Applied to Power Systems*, pp. 1–6, June 2006. doi: 10.1109/PMAPS.2006.360222.
- [60] LI, W., BILLINTON. *Reliability Assessment of Electric Power Systems Using Monte Carlo Methods*. Language of science. Springer US, 1994. ISBN: 9780306447815.
- [61] SNIR, M., GROPP, W., OTTO, S., et al. *MPI—the Complete Reference: The MPI core*. MPI: The Complete Reference. Mass, 1998. ISBN: 9780262692151. Disponível em: <<https://books.google.com.br/books?id=x79puJ2YkroC>>.
- [62] MOULIN, L. S., ROSS, R. P. D., DE ALMEIDA, C. M. P., et al. “Metodologia para Elaboração e Avaliação de Alternativas de Expansão do Sistema de Subtransmissão Incluindo Critério de Confiabilidade”. In: *XXIII Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNP-TEE)*, Foz do Iguaçu, Brazil, 2015.
- [63] SUBCOMMITTEE, P. M. “IEEE Reliability Test System”, *IEEE Transactions on Power Apparatus and Systems*, v. PAS-98, n. 6, pp. 2047–2054, Nov 1979. ISSN: 0018-9510. doi: 10.1109/TPAS.1979.319398.
- [64] RAHMANI, M., VINASCO, G., RIDER, M. J., et al. “Multistage Transmission Expansion Planning Considering Fixed Series Compensation Allocation”, *IEEE Transactions on Power Systems*, v. 28, n. 4, pp. 3795–3805, Nov 2013. doi: 10.1109/TPWRS.2013.2266346.
- [65] SIMON, D. *Evolutionary Optimization Algorithms*. Wiley, 2013. ISBN: 9781118659502. Disponível em: <<https://books.google.it/books?id=gwUwIEPqk30C>>.
- [66] CHUANG, C. Y., HSU, W. L. “Multivariate Multi-Model Approach for Globally Multimodal Problems”. In: *2010 genetic and Evolutionary Computation Conference*, pp. 1–6, jul. 2010.
- [67] DEB, K., PRATAP, A., AGARWAL, S., et al. “A fast and elitist multiobjective genetic algorithm: NSGA-II”, *IEEE Transactions on Evolutionary Computation*, v. 6, n. 2, pp. 182–197, 2002. doi: 10.1109/4235.996017.

Apêndice A

Comparação multi-objetivo

Neste trabalho serão utilizadas as seguintes nomenclaturas e definições para comparação multi-objetivo, baseadas na referência [65]:

- Dominância:
 $x^* \succ x$: indica que x^* domina x , ou seja: x^* possui todos os atributos melhores ou tão bons quanto x , e, x^* possui pelo menos um atributo melhor que x .
- Não-dominância:
 x^* é não-dominado se não existe um ponto x que o domine.
- Grupo de Pareto:
É o grupo onde todos os integrantes x^* são não-dominados.

A Figura A.1 ilustra um Grupo de Pareto hipotético considerando, por simplicidade, dois atributos, ambos com objetivos de serem maximizados.

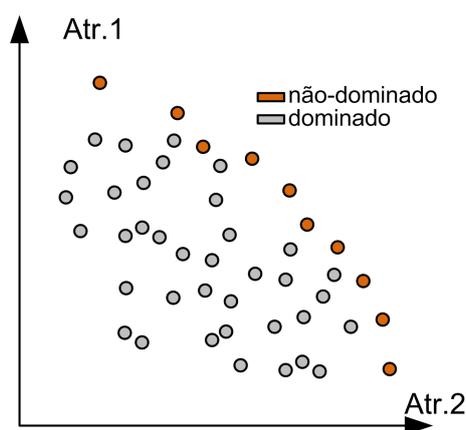


Figura A.1: Exemplo de Grupo de Pareto

Apêndice B

Exemplo de execução: PSO Binário Mono-objetivo

Neste apêndice é exposto um exemplo de execução de otimização por enxame de partículas binária mono-objetivo.

Supondo um espaço de buscas binário de três dimensões, com função objetivo descrita pela Equação (B.1), as possíveis localizações que as partículas podem caminhar são expostas na Tabela B.1, bem como os valores de $f(\mathbf{x})$.

$$f(\mathbf{x}) = \sum_{d=1}^3 \mathbf{x}(d) \quad (\text{B.1})$$

Tabela B.1: Valores da função objetivo em cada localização possível

\mathbf{x}	$f(\mathbf{x})$
[0 ; 0 ; 0]	0
[0 ; 0 ; 1]	1
[0 ; 1 ; 0]	1
[0 ; 1 ; 1]	2
[1 ; 0 ; 0]	1
[1 ; 0 ; 1]	2
[1 ; 1 ; 0]	2
[1 ; 1 ; 1]	3

Por envolver apenas três dimensões, este exemplo pode ser demonstrado graficamente. A Figura B.1 expressa o espaço de buscas deste exemplo, indicando os valores da função objetivo em cada uma das localizações através de um código de cores.

Serão utilizadas duas partículas para ilustrar a caminhada da população durante a otimização.

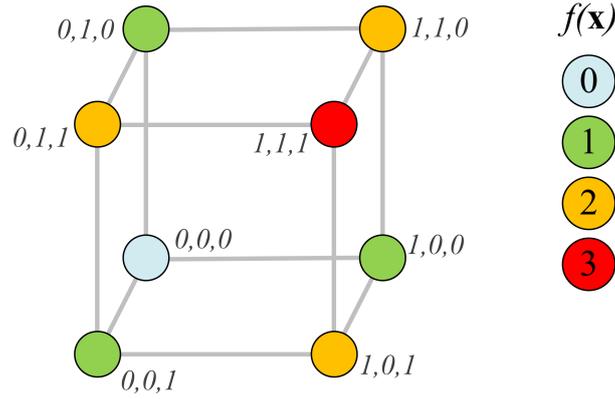


Figura B.1: Espaço de buscas do exemplo

B.1 Inicialização da população

Ao iniciar a simulação, as partículas devem ser inicializadas com velocidade valendo zero em todas as três dimensões. Já as localizações das partículas são determinadas através de um sorteio aleatório:

B.1.1 Partícula 1

$$\mathbf{v}_1^0 = [0; 0; 0]$$

$$\mathbf{x}_1^0 = [0; 1; 0] \text{ (via sorteio)}$$

Aplicando a Equação (B.1), obtém-se:

$$f(\mathbf{x}_1^0) = 0 + 1 + 0 = 1$$

Como a partículas ainda não possuem experiência, esta primeira localização torna-se a melhor visitada (*pBest*):

$$\mathbf{pBest}_1^0 = \mathbf{x}_1^0 = [0; 1; 0]$$

B.1.2 Partícula 2

$$\mathbf{v}_2^0 = [0; 0; 0]$$

$$\mathbf{x}_2^0 = [0; 0; 0] \text{ (via sorteio)}$$

Aplicando a Equação (B.1), obtém-se:

$$f(\mathbf{x}_1^0) = 0 + 0 + 0 = 0$$

Da mesma forma que para a partícula 1, *pBest* é definido como a primeira localização

visitada:

$$\mathbf{pBest}_2^0 = \mathbf{x}_2^0 = [0; 0; 0]$$

Ao final da inicialização, pode ser definido a localização $gBest$ que será utilizada na próxima iteração. Comparando os valores de $f()$ em \mathbf{v}_1^0 e \mathbf{v}_2^0 , pode-se definir:

$$\mathbf{gBest}^0 = [0; 1; 0]$$

B.2 Iteração 1

Considerando a localização $gBest$ da inicialização, pode-se, a partir das Equações 3.12 e 3.15 determinar as velocidades e localizações das partículas:

B.2.1 Partícula 1

Primeiro calcula-se a velocidade para cada uma das três dimensões do espaço de estados ($v_{p,d}^m$):

$$v_{1,1}^1 = 0,00 + 0,353(0 - 0) + 0,912(0 - 0) = 0,00$$

$$v_{1,2}^1 = 0,00 + 0,744(1 - 1) + 0,305(1 - 1) = 0,00$$

$$v_{1,3}^1 = 0,00 + 0,962(0 - 0) + 0,579(0 - 0) = 0,00$$

O vetor binário tridimensional é então definido:

$$\mathbf{v}_1^1 = [0; 0; 0]$$

Aplicando a função sigmóide em cada uma das componentes da velocidade $\mathcal{S}(v_{p,d}^m)$, tem-se:

$$\mathcal{S}(v_{1,1}^1) = \mathcal{S}(0,00) = 0,50$$

$$\mathcal{S}(v_{1,2}^1) = \mathcal{S}(0,00) = 0,50$$

$$\mathcal{S}(v_{1,3}^1) = \mathcal{S}(0,00) = 0,50$$

No sorteio dos números $rSig$ a serem utilizados na comparação descrita na Equação (3.15), foram obtidos os valores 0,6997; 0,9481; 0,7299. Aplicando a comparação, a posição da partícula 1 é obtida:

$$0,6997 > 0,50 \quad \Rightarrow \quad x_{1,1}^1 = 0$$

$$0,9481 > 0,50 \quad \Rightarrow \quad x_{1,2}^1 = 0$$

$$0,7299 > 0,50 \quad \Rightarrow \quad x_{1,3}^1 = 0$$

Assim, a localização da partícula 1 é definida por:

$$\mathbf{x}_1^1 = [0; 0; 0]$$

Aplicando a Equação (B.1):

$$f(\mathbf{x}_1^1) = 0 + 0 + 0 = 0$$

Aplicando o Algoritmo 3.3, atualiza-se $pBest$:

$$\mathbf{pBest}_1^0 \succ \mathbf{x}_1^1 \Rightarrow \mathbf{pBest}_1^1 = \mathbf{pBest}_1^0 = [0; 1; 0]$$

B.2.2 Partícula 2

$$v_{2,1}^1 = 0,00 + 0,798(0 - 0) + 0,664(0 - 0) = 0,00$$

$$v_{2,2}^1 = 0,00 + 0,967(0 - 0) + 0,532(1 - 0) = 0,53$$

$$v_{2,3}^1 = 0,00 + 0,212(0 - 0) + 0,874(0 - 0) = 0,00$$

Assim,

$$\mathbf{v}_2^1 = [0,00; 0,53; 0,00]$$

Aplicando a função sigmóide:

$$\mathcal{S}(v_{2,1}^1) = \mathcal{S}(0,00) = 0,50$$

$$\mathcal{S}(v_{2,2}^1) = \mathcal{S}(0,53) = 0,63$$

$$\mathcal{S}(v_{2,3}^1) = \mathcal{S}(0,00) = 0,50$$

No sorteio de $rSig$, foram obtidos os valores 0,7755; 0,4933; 0,7598. Aplicando a comparação, a posição da partícula 1 é obtida:

$$0,7755 > 0,50 \Rightarrow x_{2,1}^1 = 0$$

$$0,4933 < 0,63 \Rightarrow x_{2,2}^1 = 1$$

$$0,7598 > 0,50 \Rightarrow x_{2,3}^1 = 0$$

Ou seja:

$$\mathbf{x}_2^1 = [0; 1; 0]$$

Aplicando a Equação (B.1):

$$f(\mathbf{x}_2^1) = 0 + 1 + 0 = 1$$

Atualizando $pBest$ através do algoritmo 3.3:

$$\mathbf{x}_2^1 \succ \mathbf{pBest}_2^0 \Rightarrow \mathbf{pBest}_2^1 = \mathbf{x}_2^1 = [0; 1; 0]$$

Ao final da iteração, é feita a atualização da localização $gBest$. Como nenhuma localização explorada nesta iteração obteve valor da função objetivo $f()$ maior que o $f(\mathbf{gBest}^0) = 1$, obtido na inicialização, $gBest$ é mantido:

$$\mathbf{gBest}^1 = \mathbf{gBest}^0 = [0; 1; 0]$$

A Figura B.2 mostra as localizações das duas partículas do exemplo, antes e depois da iteração 1. A localização destacada com estrela é a localização $gBest$.

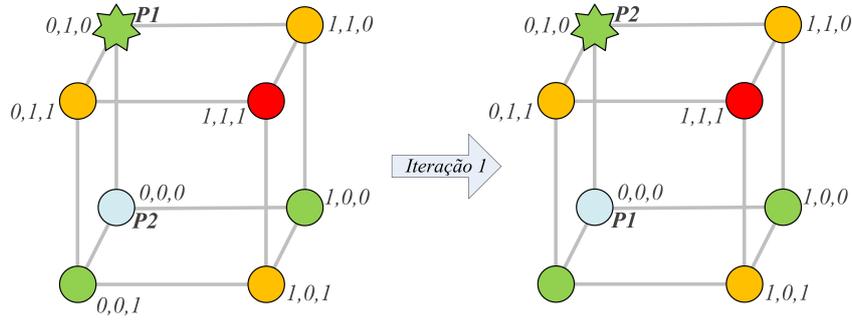


Figura B.2: Movimentação das partículas na iteração 1

B.3 Iteração 2

A seguir tem-se o desenvolvimento da caminhada das partículas na iteração 2.

B.3.1 Partícula 1

Cálculo da velocidade para cada dimensão do espaço de estados ($v_{p,d}^m$):

$$v_{1,1}^2 = 0,00 + 0,750(0 - 0) + 0,028(0 - 0) = 0,00$$

$$v_{1,2}^2 = 0,00 + 0,207(1 - 0) + 0,350(1 - 0) = 0,56$$

$$v_{1,3}^2 = 0,00 + 0,338(0 - 0) + 0,429(0 - 0) = 0,00$$

O vetor velocidade:

$$\mathbf{v}_1^2 = [0,00; 0,56; 0,00]$$

Aplicando a função sigmóide em cada uma das componentes da velocidade $\mathcal{S}(v_{p,d}^m)$, tem-se:

$$\mathcal{S}(v_{1,1}^2) = \mathcal{S}(0,00) = 0,50$$

$$\mathcal{S}(v_{1,2}^2) = \mathcal{S}(0,56) = 0,64$$

$$\mathcal{S}(v_{1,3}^2) = \mathcal{S}(0,00) = 0,50$$

No sorteio dos números $rSig$, foram obtidos os seguintes valores: 0,2636; 0,7293; 0,4481. Aplicando a comparação, a posição da partícula 1 é obtida:

$$0,2636 < 0,50 \quad \Rightarrow \quad x_{1,1}^2 = 1$$

$$0,7293 > 0,64 \quad \Rightarrow \quad x_{1,2}^2 = 0$$

$$0,4481 < 0,50 \quad \Rightarrow \quad x_{1,3}^2 = 1$$

Assim, a localização da partícula 1 é definida por:

$$\mathbf{x}_1^2 = [1; 0; 1]$$

Aplicando a Equação (B.1):

$$f(\mathbf{x}_1^2) = 1 + 0 + 1 = 2$$

Aplicando o Algoritmo 3.3, atualiza-se $pBest$:

$$\mathbf{x}_1^2 \succ \mathbf{pBest}_1^1 \quad \Rightarrow \quad \mathbf{pBest}_1^2 = \mathbf{x}_1^2 = [1; 0; 1]$$

B.3.2 Partícula 2

$$v_{2,1}^2 = 0,00 + 0,235(0 - 0) + 0,866(0 - 0) = 0,00$$

$$v_{2,2}^2 = 0,53 + 0,616(1 - 1) + 0,772(1 - 1) = 0,53$$

$$v_{2,3}^2 = 0,00 + 0,505(0 - 0) + 0,748(0 - 0) = 0,00$$

Assim,

$$\mathbf{v}_2^2 = [0,00; 0,53; 0,00]$$

Aplicando a função sigmóide:

$$\mathcal{S}(v_{2,1}^2) = \mathcal{S}(0,00) = 0,50$$

$$\mathcal{S}(v_{2,2}^2) = \mathcal{S}(0,53) = 0,63$$

$$\mathcal{S}(v_{2,3}^2) = \mathcal{S}(0,00) = 0,50$$

No sorteio de $rSig$, foram obtidos os valores 0,1829; 0,2133; 0,5477. Aplicando a comparação, a posição da partícula 2 é obtida:

$$\begin{aligned}
0,1829 < 0,50 &\Rightarrow x_{2,1}^2 = 1 \\
0,2133 < 0,63 &\Rightarrow x_{2,2}^2 = 1 \\
0,5477 > 0,50 &\Rightarrow x_{2,3}^2 = 0
\end{aligned}$$

Ou seja:

$$\mathbf{x}_2^2 = [1; 1; 0]$$

Aplicando a Equação (B.1):

$$f(\mathbf{x}_2^2) = 1 + 1 + 0 = 2$$

Atualizando $pBest$ da partícula 2:

$$\mathbf{x}_2^2 \succ \mathbf{pBest}_2^1 \Rightarrow \mathbf{pBest}_2^2 = \mathbf{x}_2^2 = [1, 1, 0]$$

Ao final da segunda iteração, duas novas localizações dominam a localização $gBest$ da iteração anterior. A decisão de qual delas se tornará o novo melhor global é feita através de um sorteio aleatório. neste caso do exemplo, \mathbf{x}_2^2 foi escolhida:

$$\mathbf{gBest}^2 = \mathbf{x}_2^2 = [1; 0; 1]$$

A Figura B.3 mostra as localizações antes e depois da segunda iteração.

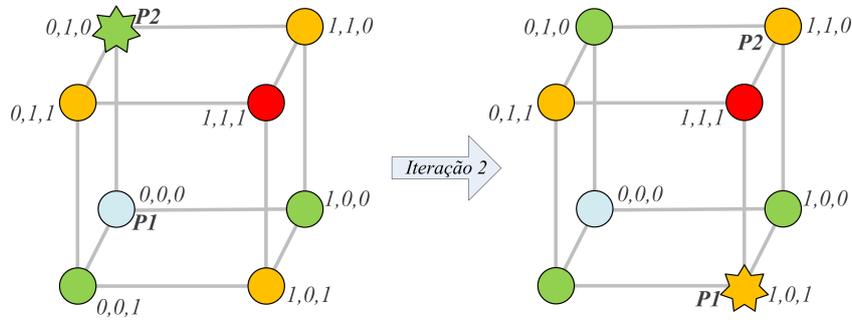


Figura B.3: Movimentação das partículas na iteração 2

B.4 Iteração 3

A seguir tem-se o desenvolvimento da caminhada das partículas na iteração 3.

B.4.1 Partícula 1

Cálculo da velocidade para cada dimensão do espaço de estados ($v_{p,d}^m$):

$$v_{1,1}^3 = 0,00 + 0,480(1 - 1) + 0,509(1 - 1) = 0,00$$

$$v_{1,2}^3 = 0,56 + 0,148(0 - 0) + 0,814(0 - 0) = 0,56$$

$$v_{1,3}^3 = 0,00 + 0,667(1 - 1) + 0,770(1 - 1) = 0,00$$

O vetor velocidade:

$$\mathbf{v}_1^3 = [0,00; 0,56; 0,00]$$

Aplicando a função sigmóide em cada uma das componentes da velocidade $\mathcal{S}(v_{p,d}^m)$, tem-se:

$$\mathcal{S}(v_{1,1}^3) = \mathcal{S}(0,00) = 0,5$$

$$\mathcal{S}(v_{1,2}^3) = \mathcal{S}(0,56) = 0,64$$

$$\mathcal{S}(v_{1,3}^3) = \mathcal{S}(0,00) = 0,5$$

No sorteio dos números *rSig*, foram obtidos os seguintes valores: 0,3803; 0,5683; 0,7305. Aplicando a comparação, a posição da partícula 1 é obtida:

$$0,3803 < 0,5 \quad \Rightarrow \quad x_{1,1}^3 = 1$$

$$0,5683 < 0,64 \quad \Rightarrow \quad x_{1,2}^3 = 1$$

$$0,7305 > 0,5 \quad \Rightarrow \quad x_{1,3}^3 = 0$$

Assim, a localização da partícula 1 é definida por:

$$\mathbf{x}_1^3 = [1; 1; 0]$$

Aplicando a função objetivo:

$$f(\mathbf{x}_1^3) = 1 + 1 + 0 = 2$$

Aplicando o Algoritmo 3.1, atualiza-se *pBest*:

$$f(\mathbf{x}_1^3) = f(\mathbf{pBest}_1^2) \quad \Rightarrow \quad \mathbf{pBest}_1^3 = \mathbf{pBest}_1^2 = [1; 0; 1]$$

B.4.2 Partícula 2

$$v_{2,1}^3 = 0,00 + 0,668(1 - 1) + 0,180(1 - 1) = 0,00$$

$$v_{2,2}^3 = 0,53 + 0,074(1 - 1) + 0,751(0 - 1) = -0,22$$

$$v_{2,3}^3 = 0,00 + 0,011(0 - 0) + 0,225(1 - 0) = 0,22$$

Assim,

$$\mathbf{v}_2^3 = [0, 00; -0, 22; 0, 00]$$

Aplicando a função sigmóide:

$$\mathcal{S}(v_{2,1}^3) = \mathcal{S}(0, 00) = 0, 50$$

$$\mathcal{S}(v_{2,2}^3) = \mathcal{S}(-0, 22) = 0, 44$$

$$\mathcal{S}(v_{2,3}^3) = \mathcal{S}(0, 22) = 0, 56$$

No sorteio de $rSig$, foram obtidos os valores 0,9159; 0,3555; 0,8102. Aplicando a comparação, a posição da partícula 2 é obtida:

$$0, 9159 > 0, 50 \Rightarrow x_{2,1}^3 = 0$$

$$0, 3555 < 0, 44 \Rightarrow x_{2,2}^3 = 1$$

$$0, 8102 > 0, 56 \Rightarrow x_{2,3}^3 = 0$$

Ou seja:

$$\mathbf{x}_2^3 = [0; 1; 0]$$

Aplicando a Equação (B.1):

$$f(\mathbf{x}_2^3) = 0 + 1 + 0 = 1$$

Atualizando $pBest$ da partícula 2:

$$f(\mathbf{x}_2^3) < f(\mathbf{pBest}_2^2) \Rightarrow \mathbf{pBest}_2^3 = \mathbf{pBest}_2^2 = [1; 1; 0]$$

Ao final da terceira iteração, nenhuma nova localização obteve valor maior de função objetivo ao comparar com a localização $gBest$ da iteração anterior. Assim:

$$\mathbf{gBest}^3 = \mathbf{gBest}^2 = [1; 0; 1]$$

A Figura B.4 mostra as localizações antes e depois da terceira iteração.

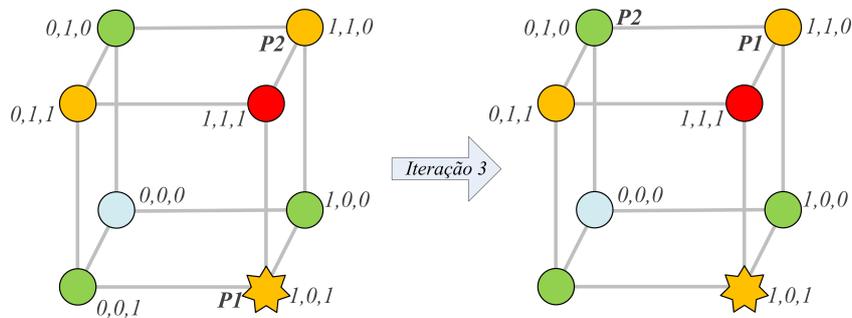


Figura B.4: Movimentação das partículas na iteração 3

B.5 Iteração 4

Para a iteração 4, obteve-se o desenvolvimento a seguir.

B.5.1 Partícula 1

Cálculo da velocidade para cada dimensão do espaço de estados ($v_{p,d}^m$):

$$\begin{aligned}v_{1,1}^4 &= 0,00 + 0,384(1 - 1) + 0,787(1 - 1) = 0,00 \\v_{1,2}^4 &= 0,56 + 0,188(0 - 1) + 0,433(0 - 1) = -0,06 \\v_{1,3}^4 &= 0,00 + 0,951(1 - 0) + 0,889(1 - 0) = 1,84\end{aligned}$$

O vetor velocidade:

$$\mathbf{v}_1^4 = [0,00; -0,06; 1,84]$$

Aplicando a função sigmóide em cada uma das componentes da velocidade $\mathcal{S}(v_{p,d}^m)$, tem-se:

$$\begin{aligned}\mathcal{S}(v_{1,1}^4) &= \mathcal{S}(0,00) = 0,50 \\ \mathcal{S}(v_{1,2}^4) &= \mathcal{S}(-0,06) = 0,48 \\ \mathcal{S}(v_{1,3}^4) &= \mathcal{S}(1,84) = 0,86\end{aligned}$$

No sorteio dos números *rSig*, foram obtidos os seguintes valores: 0,4679; 0,0137; 0,2972. Aplicando a comparação, a posição da partícula 1 é obtida:

$$\begin{aligned}0,4679 < 0,50 &\Rightarrow x_{1,1}^4 = 1 \\ 0,0137 < 0,48 &\Rightarrow x_{1,2}^4 = 1 \\ 0,2972 < 0,86 &\Rightarrow x_{1,3}^4 = 1\end{aligned}$$

Assim, a localização da partícula 1 na quarta iteração é definida por:

$$\mathbf{x}_1^4 = [1; 1; 1]$$

Aplicando a função objetivo:

$$f(\mathbf{x}_1^4) = 1 + 1 + 1 = 3$$

Aplicando o Algoritmo 3.1, atualiza-se *pBest*:

$$f(\mathbf{x}_1^4) > f(\mathbf{pBest}_1^3) \Rightarrow \mathbf{pBest}_1^4 = \mathbf{x}_1^4 = [1; 1; 1]$$

B.5.2 Partícula 2

$$v_{2,1}^2 = 0,00 + 0,869(1 - 0) + 0,626(1 - 0) = 1,50$$

$$v_{2,2}^2 = -0,22 + 0,596(1 - 1) + 0,855(0 - 1) = -1,07$$

$$v_{2,3}^2 = 0,00 + 0,118(0 - 0) + 0,208(1 - 0) = 0,43$$

Assim,

$$\mathbf{v}_2^4 = [1,50; -1,07; 0,43]$$

Aplicando a função sigmóide:

$$\mathcal{S}(v_{2,1}^4) = \mathcal{S}(1,50) = 0,82$$

$$\mathcal{S}(v_{2,2}^4) = \mathcal{S}(-1,07) = 0,25$$

$$\mathcal{S}(v_{2,3}^4) = \mathcal{S}(0,43) = 0,61$$

No sorteio de $rSig$, foram obtidos os valores 0,3872; 0,3555; 0,4978. Aplicando a comparação, a posição da partícula 2 é obtida:

$$0,3872 < 0,82 \quad \Rightarrow \quad x_{2,1}^4 = 1$$

$$0,3555 > 0,25 \quad \Rightarrow \quad x_{2,2}^4 = 0$$

$$0,4978 < 0,61 \quad \Rightarrow \quad x_{2,3}^4 = 1$$

Ou seja:

$$\mathbf{x}_2^4 = [1; 0; 1]$$

Aplicando a Equação (B.1):

$$f(\mathbf{x}_2^4) = 1 + 0 + 1 = 2$$

Atualizando $pBest$ da partícula 2:

$$f(\mathbf{x}_2^4) = f(\mathbf{pBest}_2^3) \quad \Rightarrow \quad \mathbf{pBest}_2^4 = \mathbf{pBest}_2^3 = [1; 1; 0]$$

Ao final da quarta iteração, a partícula 1 visitou uma localização cuja função objetivo possui um valor de função objetivo melhor que o melhor até a iteração anterior. Assim:

$$\mathbf{gBest}^4 = \mathbf{x}_1^4 = [1; 1; 1]$$

A Figura B.5 mostra as localizações antes e depois da quarta iteração.

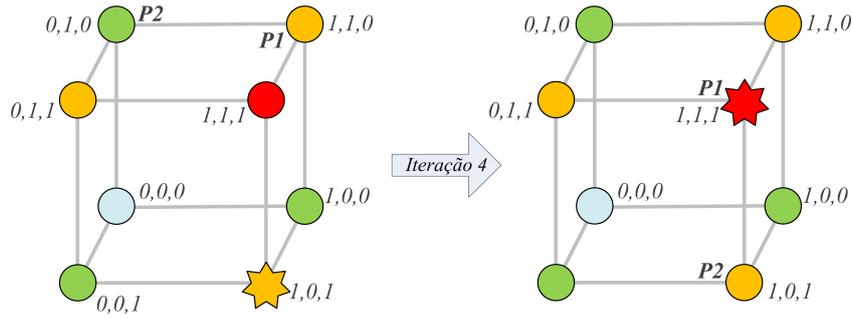


Figura B.5: Movimentação das partículas na iteração 4

B.6 Iterações seguintes

Ao fim da quarta iteração, a melhor localização do espaço de busca foi visitada. O algoritmo continuaria até atingir um número de iterações onde não houvesse melhoria na melhor localização.

Neste exemplo numérico, podem ser feitas algumas observações: quando as melhores localizações valem 1 em dada dimensão, há a tendência de aumento nas velocidades, uma vez que as parcelas de v são positivas ou nulas. Neste caso, aplicando a função sigmóide, a probabilidade de $rSig > \mathcal{S}(v)$ diminui, diminuindo a chance de o valor de x ser zero na mesma dimensão.

Na situação da partícula 1 na quarta iteração, onde tanto $pBest$ e $gBest$ não podem melhorar mais, é garantido que a velocidade só aumentará neste exemplo.

Apêndice C

Validador BP-PSO

Para validar a implementação do método PSO Binário Pareto-ótimo, o código foi isolado e aplicado na otimização de funções binárias preparadas para isto.

As Funções $f1 - f10$, expostas na Tabela C.1 foram criadas para maximizarem em diversas localizações do espaço de buscas binário. Ao considerar duas ou mais funções que maximizam em localizações diferentes, monta-se um problema de múltiplos objetivos, e pode-se observar as frentes de Pareto resultantes.

Tabela C.1: Funções binárias usadas no validador BP-PSO

Função	Maximiza em
$f1(\mathbf{x}) = x[1] + x[2] + x[3] + x[4] + x[5] + \dots$	$\mathbf{x} = [1, 1, 1, 1, 1, 1, \dots]$
$f2(\mathbf{x}) = -x[1] + 2x[2] - x[3] + 2x[4] - x[5] + \dots$	$\mathbf{x} = [0, 1, 0, 1, 0, 1, \dots]$
$f3(\mathbf{x}) = f1(\mathbf{x})^2$	$\mathbf{x} = [1, 1, 1, 1, 1, 1, \dots]$
$f4(\mathbf{x}) = f2(\mathbf{x})^2$	$\mathbf{x} = [0, 1, 0, 1, 0, 1, \dots]$
$f5(\mathbf{x}) = \sqrt{f1(\mathbf{x})}$	$\mathbf{x} = [1, 1, 1, 1, 1, 1, \dots]$
$f6(\mathbf{x}) = \sqrt{f2(\mathbf{x})}$	$\mathbf{x} = [0, 1, 0, 1, 0, 1, \dots]$
$f7(\mathbf{x}) = -(x[1] + x[2] + \dots) + (\dots + x[n-1] + x[n])^2$	$\mathbf{x} = [0, 0, 0, \dots, 1, 1, 1]$
$f8(\mathbf{x}) = 1,01x[1] + 1,02x[2] + 1,03x[3] + \dots$	$\mathbf{x} = [1, 1, 1, 1, 1, 1, \dots]$
$f9(\mathbf{x}) = 1,01x[1] + 1,02x[2] + \dots)^2 - (\dots + x[n-1] + x[n])$	$\mathbf{x} = [1, 1, 1, \dots, 0, 0, 0]$
$f10(\mathbf{x}) = \sqrt{(1,01x[1] + 1,02x[2] + \dots)} + (\dots + (1 + \frac{n-1}{100})x[n-1] + (1 + \frac{n}{100})x[n])$ teste	$\mathbf{x} = [1, 1, 1, 1, 1, 1, \dots]$

Na lista de funções abaixo, possuem porém funções que derivam de outras, como por exemplo $f1$ e $f3$. Ao associá-las no mesmo problema de otimização, haveria duas funções objetivo com mesmo ponto de maximização, e haveria um único máximo global. Funções como $f3$ e $f5$ foram criadas apenas para gerar frentes de Pareto com perfis diferentes ao se associarem a funções com outras características.

A Figura C.1, expõe o primeiro exemplo de gráfico de dispersão, expondo os possíveis valores das funções $f1$ e $f2$. Neste exemplo, os vetores binários possuem tamanho 16, ou seja, dezesseis dimensões no espaço binário para as partículas percorrerem. Como cada dimensão pode assumir 2 valores (0 ou 1), há $2^{16} = 65536$ localizações possíveis para percorrer, porém há apenas 81 pontos, ou seja, 81 possíveis

valores onde, numa execução BP-PSO, as partículas podem alcançar. Isso indica que várias localizações podem assumir os mesmos valores nas funções objetivo $f1$ e $f2$.

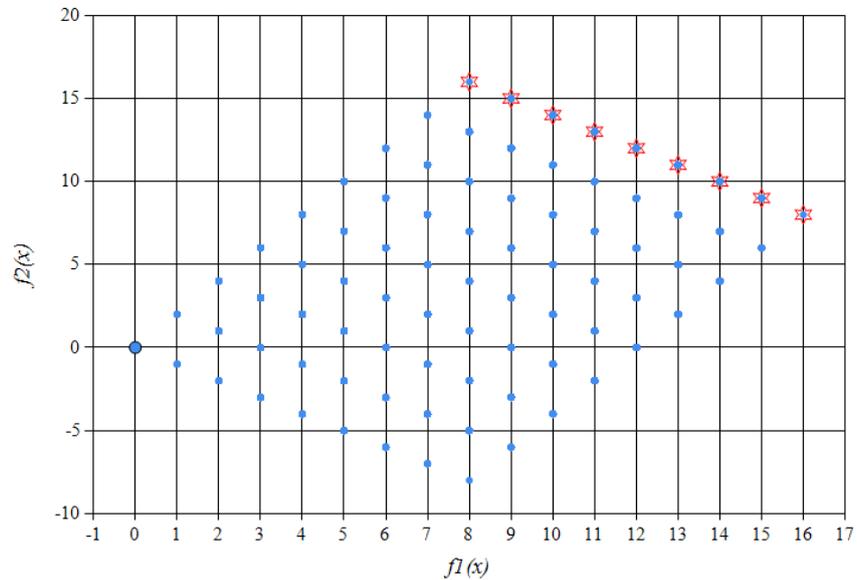
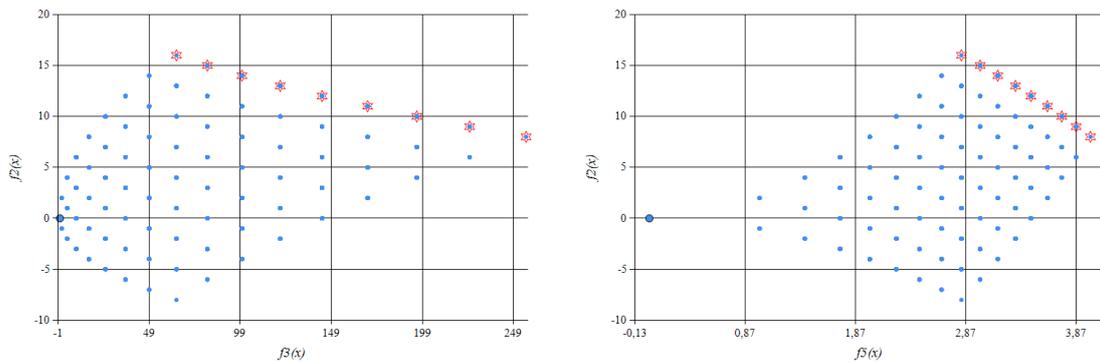


Figura C.1: Todas as posições possíveis para $f1(x)$ vs. $f2(x)$

Ao trocar $f1$ por $f3$ (Figura C.2a), ou por $f5$ (Figura C.2b) mantém-se o número de pontos no gráfico, porém é alterada a disposição dos pontos e consequentemente a frente de Pareto.



(a) Posições possíveis para $f3(x)$ vs. $f2(x)$ (b) Posições possíveis para $f5(x)$ vs. $f2(x)$

Figura C.2

Combinando diversas funções objetivo, foi possível obter frentes de Pareto interessantes. A Figura C.3 expõe os possíveis valores das funções objetivo $f7$ e $f9$, por exemplo.

Nas funções $f8$, $f9$ e $f10$, foi usado um artifício para que posições diferentes não se agrupassem no mesmo ponto do gráfico de funções objetivo, através de uma

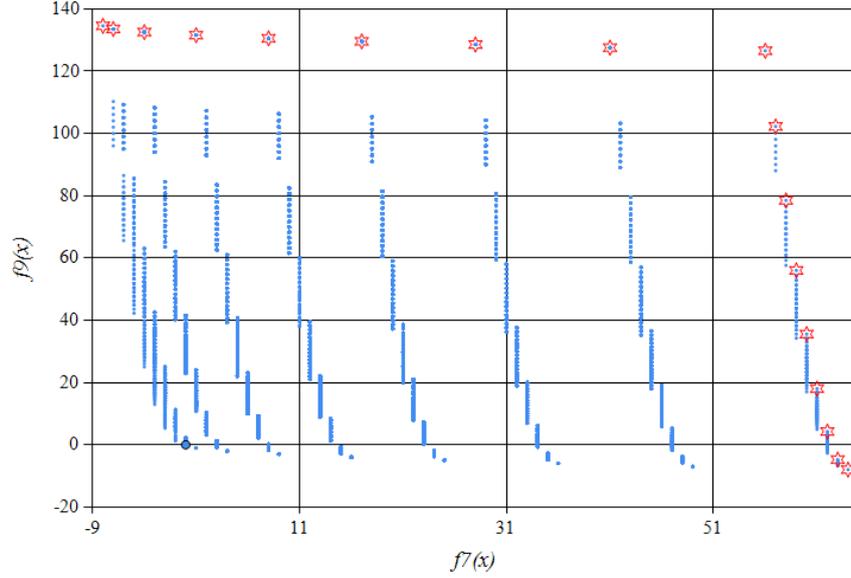


Figura C.3: Todas as posições possíveis para $f7(x)$ vs. $f9(x)$

valoração diferente para cada dimensão do espaço binário. A função $f8$ por exemplo é uma variação de $f1$, aplicando este artifício. A Figura ?? expõe graficamente este artifício. A Figura C.4 expõe este comportamento disperso de cada posição binária possível do espaço de buscas para as duas funções simuladas, gerando um gráfico dispersos em ambas as direções.

Na literatura, foram encontradas poucas funções binárias utilizadas em validação de otimizadores binários. A referência [66] apresenta as Equações C.1 e C.2, que recebem vetores binários \mathbf{x} de tamanhos 41 e 42 respectivamente.

$$Ch1(\mathbf{x}) = \begin{cases} g0(x_1, x_2 \dots x_{40}), & \text{se } x_{41} = 0 \\ g1(x_1, x_2 \dots x_{40}), & \text{se } x_{41} = 1 \end{cases} \quad (C.1)$$

$$Ch2(\mathbf{x}) = \begin{cases} g00(x_1, x_2 \dots x_{40}), & \text{se } x_{41}x_{42} = 00 \\ g10(x_1, x_2 \dots x_{40}), & \text{se } x_{41}x_{42} = 01 \\ g10(x_1, x_2 \dots x_{40}), & \text{se } x_{41}x_{42} = 10 \\ g11(x_1, x_2 \dots x_{40}), & \text{se } x_{41}x_{42} = 11 \end{cases} \quad (C.2)$$

Estas duas equações assumem comportamento de funções diferentes dependendo das últimas posições dos vetores \mathbf{x} . Tais funções são apresentadas na Tabela C.2. Na tabela, estão preparadas para receber vetores de tamanho 40, mas pode ser facilmente adaptado para receber vetores binários de qualquer tamanho múltiplo de 4.

onde:

Tabela C.2: Funções binárias encontradas em [66]

Função	Maximiza em
$g0(\mathbf{x}) = \sum_{i=0}^9 \bar{f}_t^{(4)}(x_{4i+1} + x_{4i+2} + x_{4i+3} + x_{4i+4})$	$\mathbf{x} = [0, 0, 0, 0, 0, 0, \dots]$
$g1(\mathbf{x}) = \sum_{i=0}^9 f_t^{(4)}(x_{4i+1} + x_{4i+2} + x_{4i+3} + x_{4i+4})$	$\mathbf{x} = [1, 1, 1, 1, 1, 1, \dots]$
$g00(\mathbf{x}) = \sum_{i=0}^4 \bar{f}_t^{(4)}(x_{8i+1} + \dots + x_{8i+4}) + \bar{f}_t^{(4)}(x_{8i+5} + \dots + x_{8i+8})$	$\mathbf{x} = [0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, 0, \dots]$
$g01(\mathbf{x}) = \sum_{i=0}^4 \bar{f}_t^{(4)}(x_{8i+1} + \dots + x_{8i+4}) + f_t^{(4)}(x_{8i+5} + \dots + x_{8i+8})$	$\mathbf{x} = [0, 0, 0, 0, 1, 1, 1, 1, 0, 0, 0, 0, 1, 1, 1, \dots]$
$g10(\mathbf{x}) = \sum_{i=0}^4 f_t^{(4)}(x_{8i+1} + \dots + x_{8i+4}) + \bar{f}_t^{(4)}(x_{8i+5} + \dots + x_{8i+8})$	$\mathbf{x} = [1, 1, 1, 1, 0, 0, 0, 0, 1, 1, 1, 1, 0, 0, 0, \dots]$
$g11(\mathbf{x}) = \sum_{i=0}^4 f_t^{(4)}(x_{8i+1} + \dots + x_{8i+4}) + f_t^{(4)}(x_{8i+5} + \dots + x_{8i+8})$	$\mathbf{x} = [1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, \dots]$

$$\bar{f}_t^{(k)} = \begin{cases} k, & \text{se } u = k \\ u - 1, & \text{senão} \end{cases} \quad (\text{C.3})$$

$$f_t^{(k)} = \begin{cases} k, & \text{se } u = k \\ k - 1 - u, & \text{senão} \end{cases} \quad (\text{C.4})$$

Assim, foram utilizadas as funções das Tabelas C.1 e C.2 na validação do algoritmo.

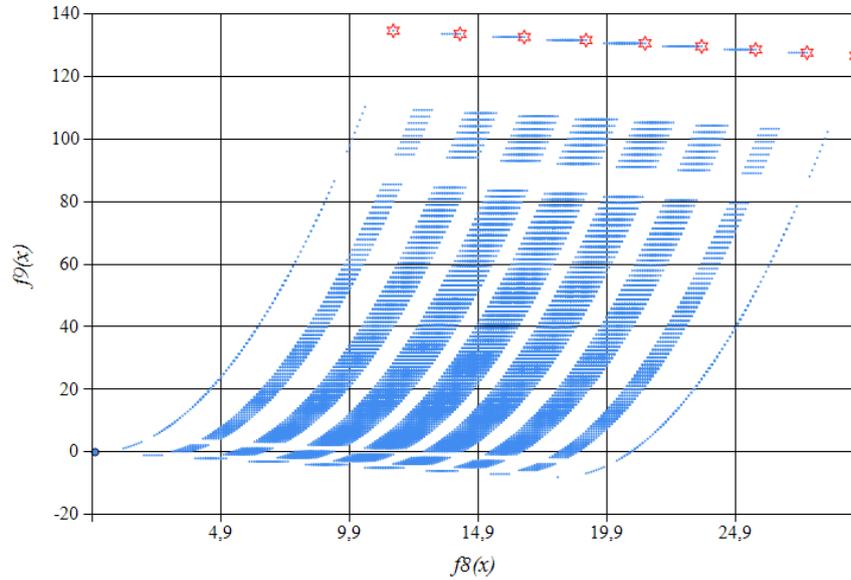


Figura C.4: Todas as posições possíveis para $f8(x)$ vs. $f9(x)$

C.1 Aplicação do BP-PSO nas funções de teste

A cada teste de convergência do método implementado, foram feitas duas execuções: uma do método BP-PSO e outra com a abordagem exaustiva, para se comparar a frente de Pareto encontrada.

Todas as execuções foram feitas considerando 16 dimensões, que possibilitam a existência de 65536 localizações no espaço de buscas. O tamanho da população utilizado foi de 20 partículas.

Como o objetivo deste apêndice é validar o código do método BP-PSO implementado, foi colocado um critério rígido de parada. O número de iterações sem alteração da frente de Pareto necessário para considerar a rodada convergente foi de 50 iterações.

C.1.1 $f1$ vs. $f2$

Neste primeiro teste, foram utilizadas as funções $f1$ e $f2$. O Método proposto convergiu em 105 iterações, e percorreu 1799 das 65536 localizações possíveis (2,75%). Observa-se que todas as localizações da frente de Pareto foram visitadas, mostrando a eficácia do método. Vale lembrar que em 50 destas 105 iterações o método já havia percorrido a Frente de Pareto final, e as iterações excedentes se deram apenas para cumprir o rígido critério de parada imposto.

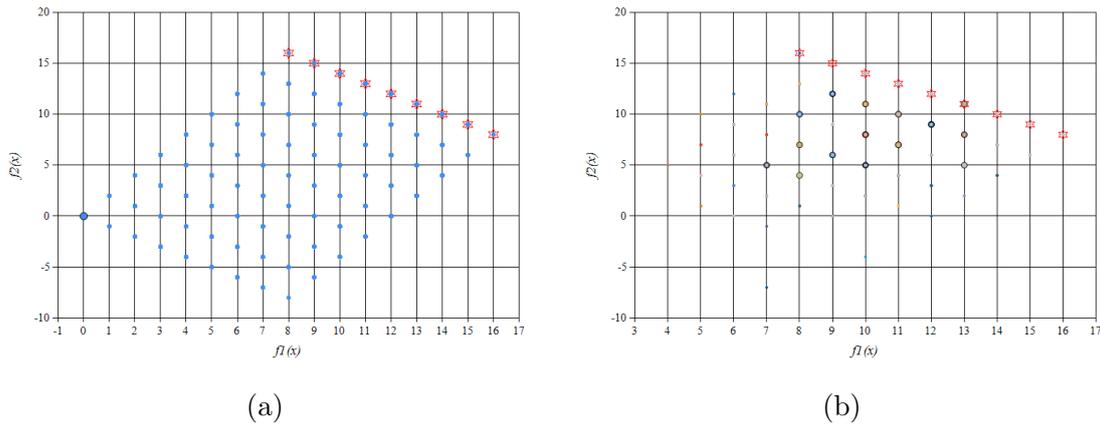


Figura C.5: Valores de $f1$ e $f2$ visitados pelos métodos a) exaustivo e b) BP-PSO

A título de ilustração, a Figura C.6 mostra as localizações de cada uma das 20 partículas nas 9 primeiras iterações do método. É possível observar o rápido aumento na Frente de Pareto do gráfico. As linhas tracejadas presentes a partir da segunda iteração mostram o deslocamento da partícula com relação à iteração anterior. As marcações com o símbolo \star que representam os valores do grupo $gBests$ são atualizados e substituídos ao avançar das iterações.

Observa-se também que mesmo com partículas algumas vezes se afastando da frente de Pareto, o comportamento coletivo se encarrega de encontrar boas localizações e atualizar o grupo de Pareto.

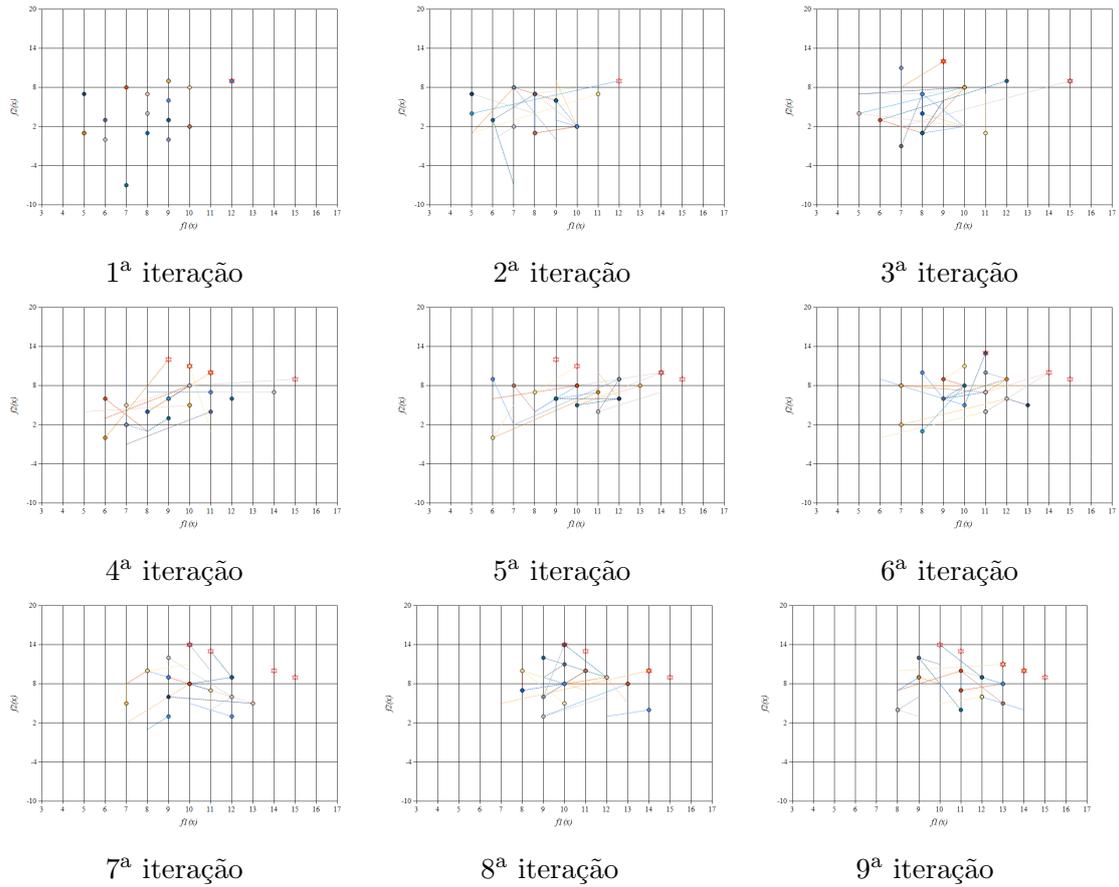


Figura C.6: 9 primeiras iterações das partículas com f_1 e f_2

C.1.2 f_8 vs. f_2

Neste teste, foram utilizadas as funções f_8 e f_2 , com o objetivo de mostrar a maior dificuldade na convergência ao possuir maior dispersão do gráfico das funções objetivo. O Método proposto convergiu em 131 iterações, e percorreu 2163 das 65536 localizações possíveis (3,30%). Novamente, todas as localizações da frente de Pareto foram visitadas, indicando eficácia.

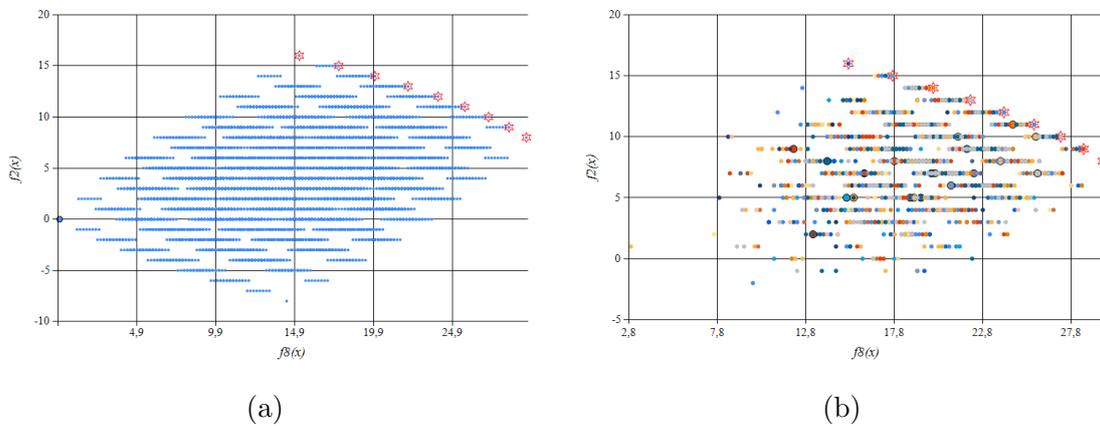


Figura C.7: Valores de f_8 e f_2 visitados pelos métodos a) exaustivo e b) BP-PSO

C.1.3 $f3$ vs. $f2$ vs. $f7$ vs. $g00$

Como neste trabalho de dissertação são utilizados quatro atributos, foi aplicado o método isolado em quatro funções objetivo que maximizam em localizações diferentes. Para isto, foram escolhidas as funções $f3$, $f2$, $f7$ e $g00$.

A Figura C.8 mostra todas as localizações possíveis, bem como as frentes de paretos em destaque, obtidas ao se executar todas as posições exaustivamente.

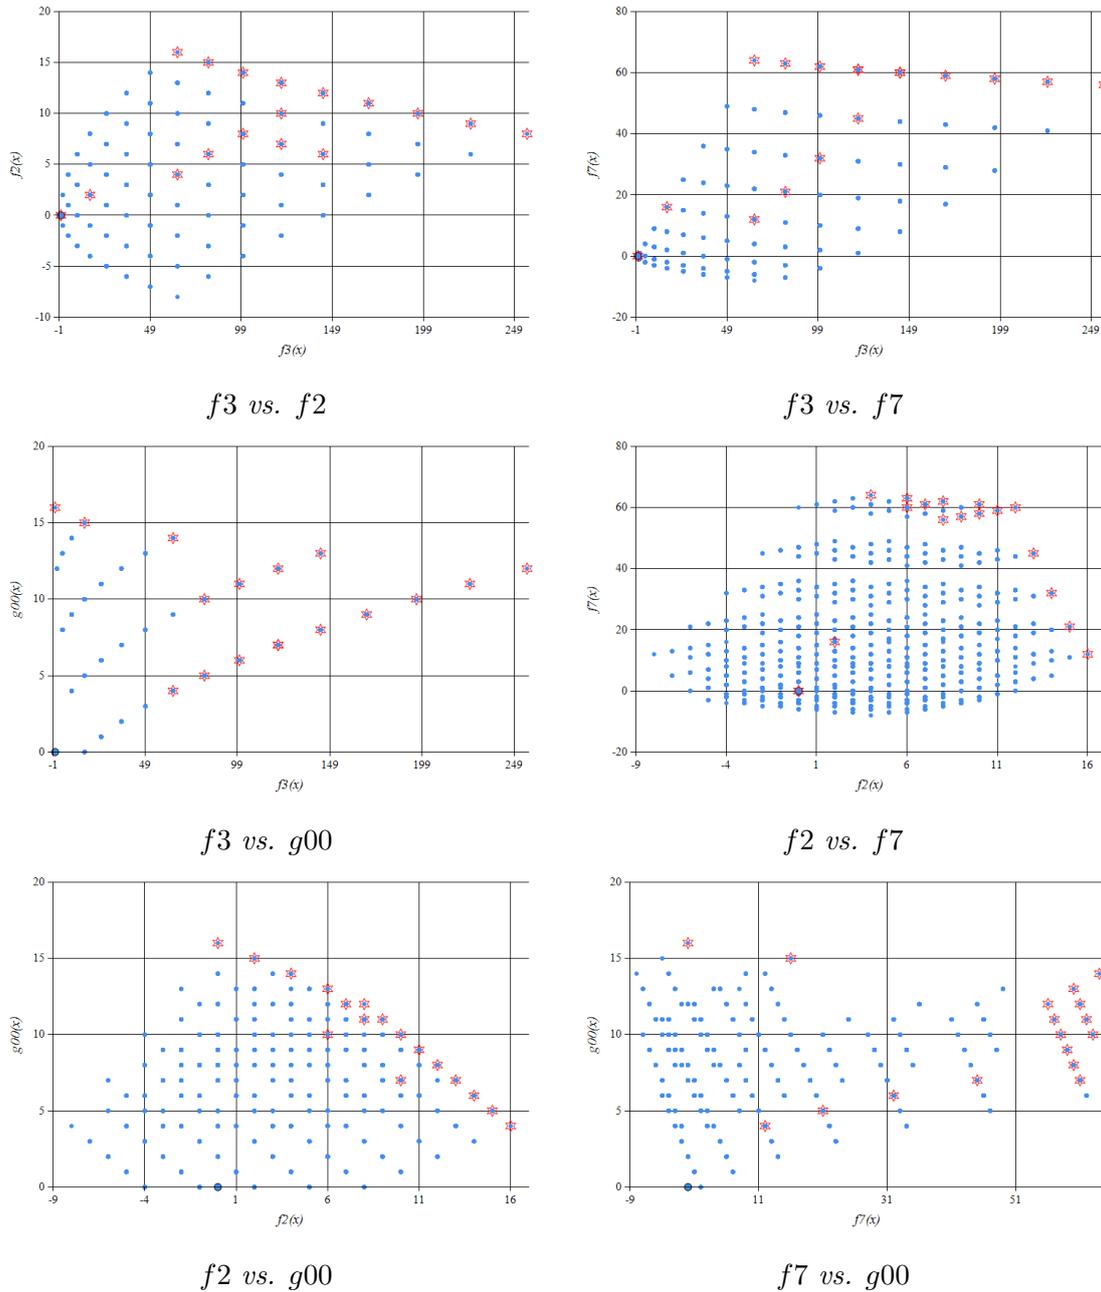


Figura C.8: $f3$ vs. $f2$ vs. $f7$ vs. $g00$: frentes de Pareto com o método exaustivo

A Figura C.9 mostra o resultado obtido ao executar o método BP-PSO, também destacando as Frentes de Pareto. O algoritmo levou 175 iterações para convergir, e visitou 2983 localizações, 4,6% das 65536 localizações possíveis e visitadas na

abordagem exaustiva. É importante destacar que, apesar da grande redução nas posições visitadas, observa-se, comparando as Figuras C.8 e C.9 que as Frentes de Pareto apresentam os mesmos contornos, indicando que as posições encontradas pelo método otimizador representam bem as posições que maximizam as quatro funções objetivo.

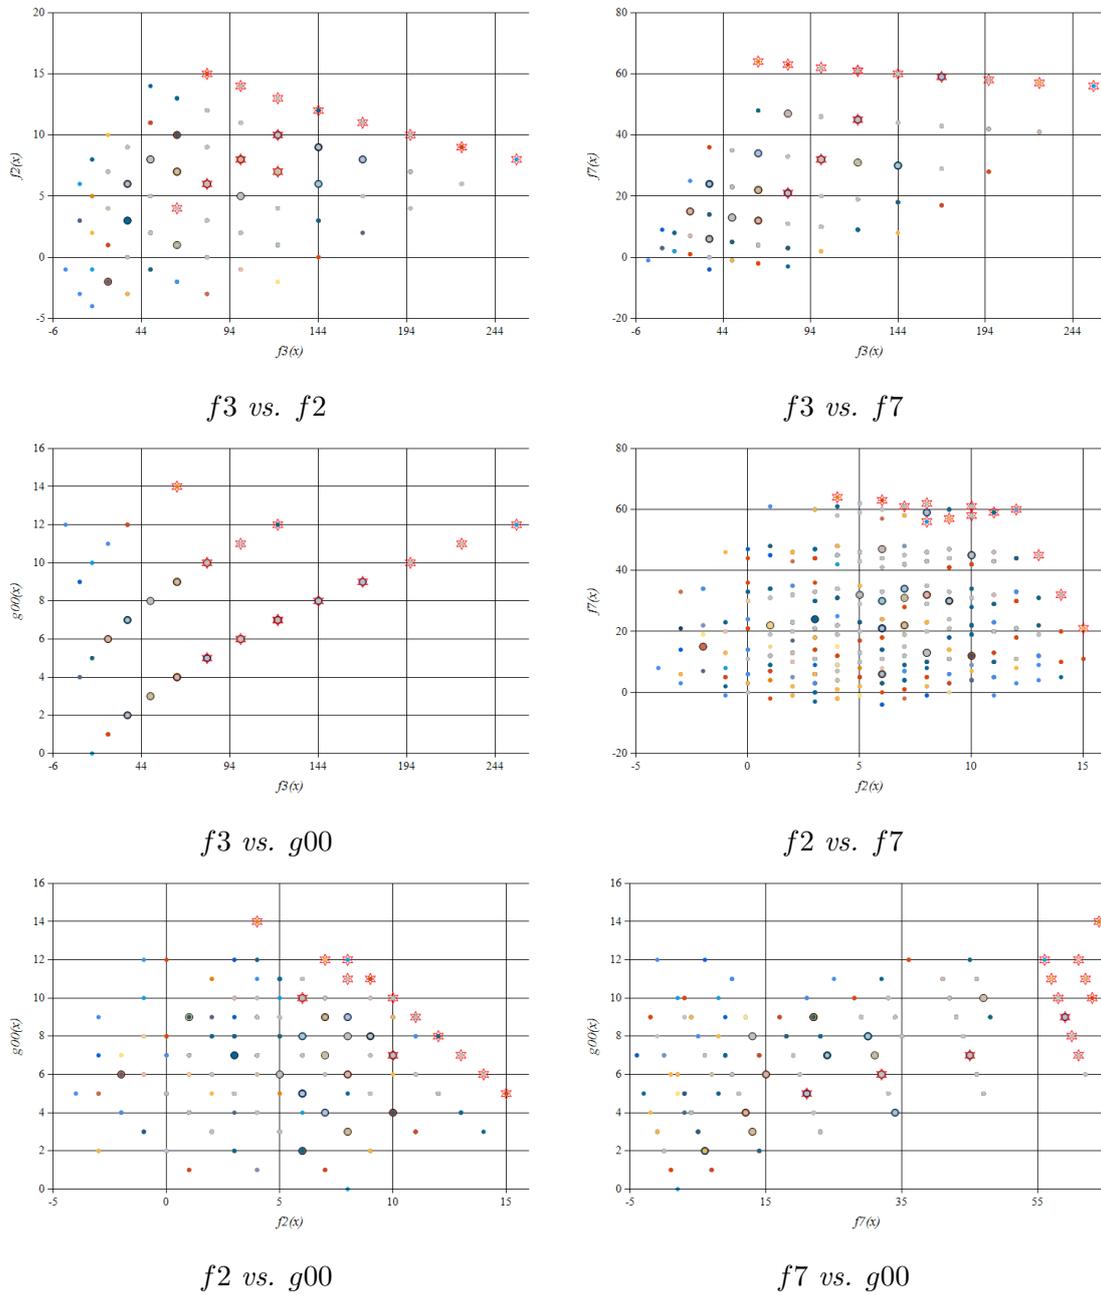


Figura C.9: f_3 vs. f_2 vs. f_7 vs. g_{00} : frentes de Pareto com o método BP-PSO

Apêndice D

Exemplo numérico do cálculo dos índices de classificação de obras

Este Apêndice tem como objetivo ilustrar através de um exemplo numérico, o cálculo dos índices de Severidade e Probabilidade expostos na Seção 3.8.

Após a execução e convergência do estudo plurianual via programação pseudo-dinâmica, o grupo \mathbb{GP}^* é definido, como exposto nas Seções 3.6 e 3.7.

Neste exemplo, por simplicidade, \mathbb{GP}^* será composto de 4 configurações. Para cada uma delas, há disponível os valores anuais dos quatro atributos, bem como as informações do ano de entrada de cada obra. Serão consideradas duas obras, *Ob1* e *Ob2*, ambas com entrada em operação planejada para o primeiro dos três anos do horizonte de estudo. A Tabela D.1 expõe o grupo \mathbb{GP}^* com valores anuais dos 4 atributos considerados no exemplo.

Tabela D.1: Grupo de Pareto com valores anuais

	Atributo $f1$			Atributo $f2$			Atributo $f3$			Atributo $f4$			<i>Ob1</i>	<i>Ob2</i>
	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3		
CP_1	10	15	20	3	4	2	1200	800	400	100	100	40	1	1
CP_2	50	45	25	9	5	10	800	400	600	40	60	20	1	X
CP_3	30	20	40	4	2	5	1000	400	1000	25	40	50	X	2
CP_4	30	35	20	4	3	2	1000	2000	400	25	30	40	2	3

As últimas duas colunas da tabela representam o cronograma de obras de cada configuração, com o ano em que a obra foi construída. Neste caso, “X” indica que a obra foi atrasada para além do cronograma de estudo. Neste exemplo de três anos, quer dizer que ela atrasou no ano 3.

Neste exemplo, foram escolhidos valores para os atributos que possuíssem ordens de grandeza diferentes, como ocorre no caso estudado. Por simplicidade os atributos serão denominados $f1$, $f2$, $f3$ e $f4$. Foi procurado também retratar situações que acontecem ao analisar configurações plurianuais, como por exemplo, tanto em CP_3

quanto em CP_4 , as obras $Ob1$ e $Ob2$ são atrasadas no ano 1. Portanto os atributos do ano 1 nestas configurações tem o mesmo valor ($f1 = 30$, $f2 = 4$, $f3 = 1000$, $f4 = 25$).

Da mesma forma, CP_1 e CP_4 possuem a mesma topologia no ano 3, com todas as obras construídas ($f1 = 20$, $f2 = 2$, $f3 = 400$, $f4 = 40$).

Com as informações anuais, é possível calcular o impacto médio do atraso de cada obra em cada ano: É checado o atraso de cada obra em todas as configurações de Pareto. Se a obra é atrasada, o valor dos atributos naquele ano são contabilizados no cálculo da média.

Considerando o atributo $f1$:

Ano 1:

- $Ob1$ atrasa nas configurações 3 e 4. Então o valor armazenado é a média dos valores de $f1$ no ano 1 das configurações 3 e 4: $(30 + 30)/2 = 30$
- $Ob2$ atrasa nas configurações 2, 3 e 4. Então o valor armazenado é a média dos valores de $f1$ no ano 1 das configurações 2, 3 e 4: $(50 + 30 + 30)/3 = 36,7$

Ano 2:

- $Ob1$ atrasa apenas na configuração 3. Então o valor armazenado é a média dos valores de $f1$, que é o próprio valor da configuração 3: 20
- $Ob2$ atrasa nas configurações 2 e 4. Então o valor armazenado é a média dos valores de $f1$ no ano 1 das configurações 2 e 4: $(45 + 35)/2 = 40$

Ano 3:

- $Ob1$ atrasa apenas na configuração 3. Então o valor armazenado é a média dos valores de $f1$, que é o próprio valor da configuração 3: 40
- $Ob2$ atrasa apenas na configuração 2. Então o valor armazenado é a média dos valores de $f1$, que é o próprio valor da configuração 2: 25

Isso é feito para todos os 4 atributos.

Tabela D.2: arquivo1 com média dos impactos anuais por obra considerando as configurações de Pareto

	Atributo $f1$			Atributo $f2$			Atributo $f3$			Atributo $f4$		
	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3
$Ob1$	30	20	40	4	2	5	1000	400	1000	25	40	50
$Ob2$	36,7	40	25	5,7	4	10	933,3	1200	600	30	45	20

Como mostrado nas Equações (3.6) a (3.9), os valores plurianuais dos atributos de cada configuração são calculados considerando a média dos valores anuais associados

a cada configuração, expressos na Tabela D.1. Valores plurianuais dos atributos serão expressos em letras maiúsculas ($F1, F2, \dots$).

Considerando a configuração CP_1 :

- $F1 = (10 + 15 + 20)/3 = 15$
- $F2 = (3 + 4 + 2)/3 = 3$
- $F3 = (1200 + 800 + 400)/3 = 800$
- $F4 = (100 + 100 + 40)/3 = 80$

Estendendo para todas as configurações, a Tabela D.3 é composta.

Tabela D.3: Valores plurianuais dos atributos de cada configuração em \mathbb{GP}^*

	$F1$	$F2$	$F3$	$F4$	$Ob1$	$Ob2$
CP_1	15	3	800	80	1	1
CP_2	40	8	600	40	1	X
CP_3	30	3,7	800	38,33	X	2
CP_4	28,3	3	1133,3	31,66	2	3

Neste ponto, os atributos ainda possuem ordens de grandeza diferentes, mas tudo bem. A normalização será feita no próximo passo.

D.1 Cálculo do Índice de Severidade IS

O índice de severidade proposto IS considera se a obra analisada foi atrasada ou não no horizonte de estudo. Para isto serão compostos os grupos \mathbb{A}_j a partir de \mathbb{GP}^* :

- $Ob1$ atrasa nas configurações 3 e 4, então $\mathbb{A}_1 = \{CP_3, CP_4\}$
- $Ob2$ atrasa nas configurações 2, 3 e 4. $\mathbb{A}_2 = \{CP_2, CP_3, CP_4\}$

Considerando o atributo $F1$ seu valor por obra j pode ser calculado, como nas Equações (3.19 a 3.22):

$$F1_j = \frac{1}{|\mathbb{A}_j|} \sum_{CP \in \mathbb{A}_j} f1_{CP} \quad (D.1)$$

Assim,

$$F1_1 = \frac{1}{|\mathbb{A}_1|} \sum_{CP \in \mathbb{A}_1} f1_{CP} = \frac{1}{2}(30 + 28,3) = 29,2 \quad (D.2)$$

$$F1_2 = \frac{1}{|\mathbb{A}_2|} \sum_{CP \in \mathbb{A}_2} f1_{CP} = \frac{1}{3}(40 + 30 + 28, 3) = 32,8 \quad (\text{D.3})$$

A Tabela D.4 é então montada:

Tabela D.4: Valores dos atributos associados a cada obra j

	$F1_j$	$F2_j$	$F3_j$	$F4_j$
<i>Ob1</i>	29,2	3,3	966,7	35,0
<i>Ob2</i>	32,8	4,9	844,4	36,7

Depois disso, é feita a normalização dos atributos. Para isto, são utilizados os valores máximos dos atributos, compilados na Tabela D.5:

Tabela D.5: valores máximos de cada atributo

	$F1_j$	$F2_j$	$F3_j$	$F4_j$
$\max\{F_j\}$	32,8	4,9	966,7	36,7

Aplicando a normalização descrita nas Equações (3.23 a 3.26):

Tabela D.6: Valores normalizados pelo máximo

	$\hat{F}1_j$	$\hat{F}2_j$	$\hat{F}3_j$	$\hat{F}4_j$
<i>Ob1</i>	0,89	0,68	1	0,95
<i>Ob2</i>	1	1	0,87	1

D.2 Cálculo do Índice de Probabilidade

Para calcular IP , definido pela Equação 3.28, são necessárias as cardinalidades dos grupos \mathbb{A}_j e de \mathbb{GP}^* . Neste exemplo, como $\mathbb{A}_1 = \{CP_3, CP_4\}$, $\mathbb{A}_2 = \{CP_2, CP_3, CP_4\}$, e $\mathbb{GP}^* = \{CP_1, CP_2, CP_3, CP_4\}$, tem-se:

$$IP_1 = \frac{|\mathbb{A}_1|}{|\mathbb{GP}^*|} = \frac{2}{4} = 0,5 \quad (\text{D.4})$$

$$IP_2 = \frac{|\mathbb{A}_2|}{|\mathbb{GP}^*|} = \frac{3}{4} = 0,75 \quad (\text{D.5})$$

Tabela D.7: Valores de IS no exemplo ilustrativo

	IS
$Ob1$	2,16
$Ob2$	1,87

Tabela D.8: Valores de IP no exemplo ilustrativo

	IP
$Ob1$	0,50
$Ob2$	0,75

D.3 Índices anuais

Como explicado na Seção 3.8, podem ser feitas adaptações nos índices de severidade e probabilidade propostos, porém a análise anual pode levar à equívocos ao serem aplicados em metodologias de múltiplos estágios, como visto na Seção 4.

D.3.1 Cálculo do índice de Severidade anual

Para o cálculo dos valores anuais de IS , serão utilizados os resultados expressos na Tabela D.2.

Para cada um dos k anos, podem-se encontrar os valores máximos de cada atributo, gerando a Tabela D.9.

Tabela D.9: Valores anuais máximos de cada atributo

	Atributo $f1$			Atributo $f2$			Atributo $f3$			Atributo $f4$		
	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3
$\max\{f_{j,k}\}$	36,7	40	40	5,7	4	10	1000	1200	1000	30	45	50

Depois disto, os valores da Tabela D.2 são divididos pelos máximos, normalizando as grandezas e obtendo a Tabela D.10.

Com todos os valores estão normalizados e com mesma ordem de grandeza, é possível aplicar a soma de parcelas:

Foram utilizados pesos unitários neste exemplo, bem como na aplicação final, porém, assim como no método proposto, a função $f2$ é somada com peso negativo. Assim, para $Ob1$ tem-se:

- $IS_{1,1} = 0,82 - 0,706 + 1 + 0,833 = 1,94$

Tabela D.10: Valores anuais dos atributos normalizados pelo máximo

	Atributo $f1$			Atributo $f2$			Atributo $f3$			Atributo $f4$		
	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3	Ano 1	Ano 2	Ano 3
<i>Ob1</i>	0,82	0,5	1	0,71	0,5	0,5	1	0,33	1	0,83	0,89	1
<i>Ob2</i>	1	1	0,62	1	1	1	0,93	1	0,6	1	1	0,4

- $IS_{1,2} = 0,5 - 0,5 + 0,33 + 0,89 = 1,22$
- $IS_{1,3} = 1 - 0,5 + 1 + 1 = 2,5 \dots$

Expandindo os cálculos para *Ob2*, obtém-se a Tabela D.11.

Tabela D.11: IS anual para o exemplo numérico

	$IS_{j,k}$		
	ano1	ano2	ano3
<i>Ob1</i>	1,95	1,22	2,50
<i>Ob2</i>	1,93	2,00	0,63

D.3.2 Cálculo da probabilidade anual

Para calcular a probabilidade anual, são utilizados os grupos $\mathbb{A}_{j,k}$, definidos pelas configurações onde a obra j é atrasada no ano k :

Para o Ano 1, *Ob1* atrasa em 2 configurações: CP_3 e CP_4 , então $\mathbb{A}_{1,1} = \{CP_3, CP_4\}$.

Da mesma forma são montados os demais grupos: $\mathbb{A}_{2,1} = \{CP_2, CP_3, CP_4\}$, $\mathbb{A}_{1,2} = \{CP_3\}$, $\mathbb{A}_{2,2} = \{CP_2, CP_4\}$, $\mathbb{A}_{1,3} = \{CP_3\}$, $\mathbb{A}_{2,3} = \{CP_2\}$

Utilizando a Equação 3.38, calcula-se para cada ano k , os índices de probabilidade $IP_{j,k}$ de cada obra j :

$$IP_{1,1} = \frac{|\mathbb{A}_{1,1}|}{|\mathbb{GP}^*|} = \frac{2}{4} = 0,5 \quad (\text{D.6})$$

$$IP_{2,1} = \frac{|\mathbb{A}_{2,1}|}{|\mathbb{GP}^*|} = \frac{3}{4} = 0,75 \quad (\text{D.7})$$

$$IP_{1,2} = \frac{|\mathbb{A}_{1,2}|}{|\mathbb{GP}^*|} = \frac{1}{4} = 0,25 \quad (\text{D.8})$$

$$IP_{2,2} = \frac{|\mathbb{A}_{2,2}|}{|\mathbb{GP}^*|} = \frac{2}{4} = 0,5 \quad (\text{D.9})$$

$$IP_{1,3} = \frac{|\mathbb{A}_{1,3}|}{|\mathbb{GP}^*|} = \frac{1}{4} = 0,25 \quad (\text{D.10})$$

$$IP_{2,3} = \frac{|\mathbb{A}_{2,3}|}{|\mathbb{GP}^*|} = \frac{1}{4} = 0,25 \quad (\text{D.11})$$

Tabela D.12: IP anual para o exemplo numérico

	ano1	ano2	ano3
<i>Ob1</i>	0,5	0,25	0,25
<i>Ob2</i>	0,75	0,5	0,25

Apêndice E

Método alternativo NSGA-II

O Algoritmo Genético de Classificação Não-dominada II (NSGA-II), do inglês “*Non-dominated Sorting Genetic Algorithm II*” é um método heurístico baseado em população que aplica conceitos de teoria genética para a evolução da população, proposto em [67]. Ao contrário dos métodos baseados em enxames de partículas, os algoritmos genéticos não preservam os indivíduos da população de uma iteração para outra, se os mesmos não forem os melhores. Para manter uma consistência no tamanho da população, os indivíduos participam de cruzamentos, e competem com seus descendentes para se manterem vivos na iteração seguinte. Esta variação de algoritmo genético atende a problemas de múltiplos objetivos, e utiliza conceitos de frente de Pareto para tal.

Assim, o problema de atrasos de obras elétricas estudado nesta dissertação pode-se utilizar desta ferramenta de otimização.

E.1 Conceitos teóricos do método NSGA-II

O método NSGA-II segue os passos descritos na Figura E.1, que apresenta o fluxograma geral da metodologia, e será detalhado a seguir.

Assim como no método BP-PSO, o método NSGA-II executa repetidas iterações até atingir a convergência.

A população inicial da iteração t é denominada P_t . A Figura E.2 ilustra um exemplo de população inicial. Através de cruzamentos entre os indivíduos, são gerados descendentes, que formam o grupo Q_t . Na Figura E.3, Q_t é representada pelos pontos vermelhos.

O número de indivíduos que serão selecionados para seguir na próxima iteração deve ser o mesmo presente na população inicial, formando o grupo P_{t+1} . É iniciada então a seleção, que é dividida em duas etapas. A primeira delas, é chamada de “Classificação das não dominadas”, e a outra, “Classificação por distância de aglomeração”.

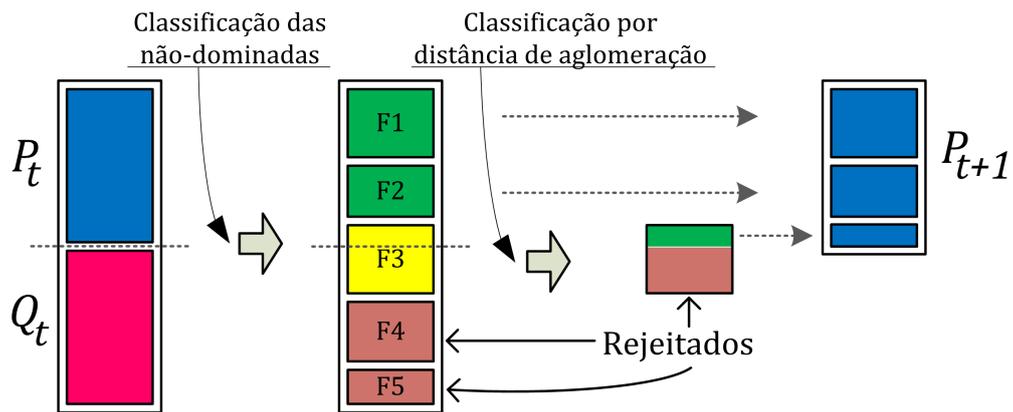


Figura E.1: Método NGS-II

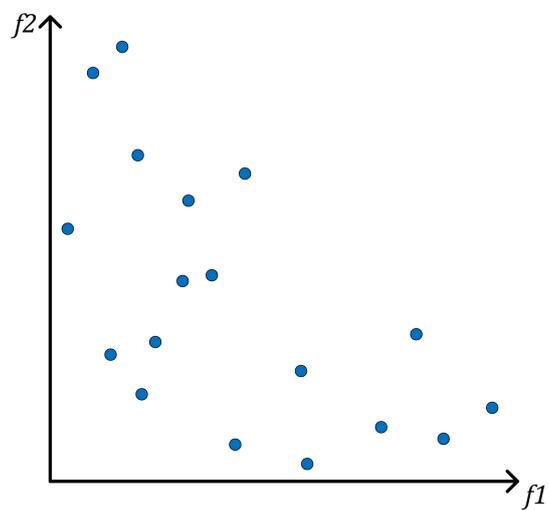


Figura E.2: População inicial

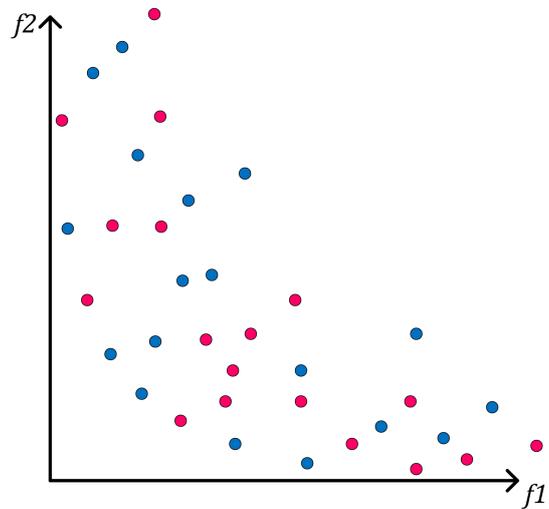


Figura E.3: População inicial mais descendentes

E.1.1 Classificação das não dominadas

Nesta etapa, todos os indivíduos, iniciais e descendentes são comparados entre si através dos conceitos de dominância multi-objetivo e separados em Frentes de Pareto.

Na Figura E.4, $F1$ contém os indivíduos mais aptos a seguirem vivos, e $F5$, os menos aptos.

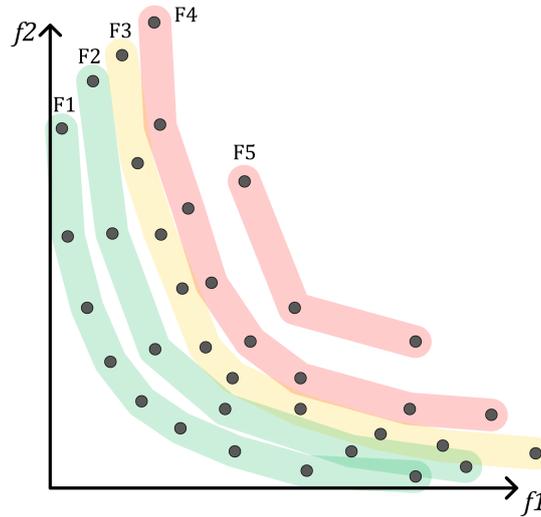


Figura E.4: Frentes de Pareto identificadas pela classificação das não-dominadas

Neste exemplo, $F1$ e $F2$ terão todos seus indivíduos selecionados para seguir, pois somam uma quantidade menor que a desejada para P_{t+1} . $F3$ todavia, possui indivíduos que não serão escolhidos. Neste caso, é adentrada a etapa “Classificação por distância de aglomeração”.

E.1.2 Classificação por distância de aglomeração

Esta etapa tem como objetivo definir, para certa frente de Pareto, uma fração que seja mais diversificada. Isso é feito calculando a distância relativa entre os indivíduos e selecionando os que estejam menos aglomerados, através do algoritmo abaixo:

Para cada dimensão do problema, os indivíduos são ordenados de acordo com seus valores da função objetivo. No exemplo exposto nas figuras, esta etapa é aplicada na frente de Pareto $F3$.

Considerando duas funções objetivo:

No grupo $F3$ do exemplo, $|\Upsilon| = 10$ Para cada função objetivo f_m , os indivíduos são ordenados pelos valores associados as funções objetivo.

$$\Upsilon = \text{ordena}(\Upsilon, m) \tag{E.1}$$

São então calculadas as distâncias relativas associadas a cada indivíduo i . Os

indivíduos que possuírem as maiores distâncias serão os selecionados para progredir para a próxima etapa. Aos indivíduos das extremidades ($i = 1$ e $i = l$) são associadas distâncias de valor infinito, garantindo que estes serão selecionados para a próxima etapa:

$$dist(\Upsilon[1]) = dist(\Upsilon[l]) = \infty \quad (E.2)$$

Para os outros indivíduos ($1 < i < l$) a distância relativa a cada função objetivo m é calculada como mostrado a seguir:

$$dist(\Upsilon[i])_m = \frac{\Upsilon[i+1]_m - \Upsilon[i-1]_m}{\Upsilon[l]_m - \Upsilon[1]_m} \quad (E.3)$$

Como os indivíduos foram ordenados pelos seus valores da função objetivo, $\Upsilon[l]_m$ representa o maior valor de f_m obtido pelos indivíduos considerados e $\Upsilon[1]_m$, o menor valor da função objetivo. Assim, estes valores de distância são valores normalizados.

As distâncias totais são obtidas somando-se as distâncias de referentes a cada função objetivo:

$$dist(\Upsilon[i]) = \sum_{m=1}^{nM} dist(\Upsilon[i])_m \quad (E.4)$$

Uma vez calculadas as distâncias totais de cada indivíduo, estes são comparados e os que possuírem maior valor são considerados mais aptos, e preencherão as vagas restantes para avançarem para a próxima etapa.

A Figura E.5 representa um possível resultado para a etapa de classificação por distância de aglomeração no exemplo, onde os pontos verdes são os indivíduos aptos a progredir no algoritmo, enquanto os pontos marrons serão eliminados.

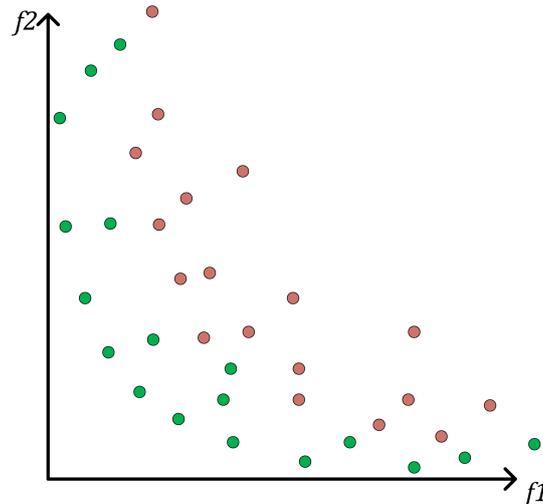


Figura E.5: Identificação dos indivíduos aptos a progredir

Após concluídas as duas etapas de classificação, os indivíduos selecionados compõem a população da próxima iteração P_{t+1} o ciclo se repetirá.

E.2 Aplicação do método NSGA-II na classificação dos atrasos de obras

Para a utilização do NSGA-II como otimizador na busca por cenários de atraso, este será utilizado dentro do algoritmo pseudo-dinâmico, em execuções anuais, assim como o BP-PSO. Nesta sessão serão descritas algumas escolhas e adaptações feitas para que o correto funcionamento do algoritmo fosse obtido:

E.2.1 Cruzamentos

Na geração de cada indivíduo de Q_t , são sorteados aleatoriamente dois indivíduos de P_t que serão seus pais. Como o que define cada indivíduo é a sua combinação dos atrasos de obras, para cada obra é sorteado se seu atraso ou não será herdado do progenitor 1 ou 2. Foi implementado na lógica de cruzamento a possibilidade de considerar mutações nos cruzamentos, onde o atraso ou não de dada obra seria invertido com relação ao valor encontrado, com probabilidade de 5%. Porém, não foram observadas melhorias nos resultados, e por simplicidade foi decidido deixar a mutação zerada nos resultados finais.

E.2.2 Inclusão de múltiplas funções objetivo

Como neste trabalho são utilizadas quatro funções objetivo para a classificação dos atrasos de obras, ao implementar o algoritmo, isto foi considerado em ambas as etapas de classificação. Na “Classificação das não dominadas”, as frentes de Pareto montadas tiveram que considerar os quatro atributos. Na etapa de “Classificação por distância de aglomeração”, as Equações descritas na Seção E.1.2 puderam ser utilizadas, considerando o índice que define o número de funções objetivo $M = 4$.

E.2.3 Definição da convergência

Para considerar o fim da execução do NSGA-II, além de um número máximo de iterações, foi também considerada a estagnação da Frente de Pareto, indicando uma estabilidade nos resultados, onde a execução de novos indivíduos provenientes de cruzamentos não trazem informações relevantes na busca por configurações de atrasos críticos ao sistema simulado.