

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA**  
**FACULDADE DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**Felipe Laure Miranda**

**Planejamento Estocástico da Expansão de Sistemas de Transmissão de Energia Elétrica**  
**Baseado em Critério de Dominância**

Juiz de Fora

2024

**Felipe Laure Miranda**

**Planejamento Estocástico da Expansão de Sistemas de Transmissão de Energia  
Elétrica Baseado em Critério de Dominância**

Tese apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Doutor em Engenharia Elétrica. Área de concentração: Sistemas de Energia Elétrica.

Orientador: Leonardo Willer de Oliveira

Coorientador: Edimar José de Oliveira

Coorientador externo: Erivelton Geraldo Nepomuceno

Juiz de Fora

2024

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Laure Miranda, Felipe.

Planejamento Estocástico da Expansão de Sistemas de Transmissão de Energia Elétrica Baseado em Critério de Dominância / Felipe Laure Miranda. -- 2024.

160 p. : il.

Orientador: Leonardo Willer de Oliveira

Coorientadores: Edimar José de Oliveira, Erivelton Geraldo Nepomuceno

Tese (doutorado) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2024.

1. Planejamento da Transmissão. 2. Confiabilidade de Sistemas Elétricos. 3. Otimização Multiobjetivo. 4. Geração Eólica. I. Willer de Oliveira, Leonardo , orient. II. José de Oliveira, Edimar , coorient. III. Geraldo Nepomuceno, Erivelton , coorient. IV. Título.

**Felipe Laure Miranda**

**Planejamento Estocástico da Expansão de Sistemas de Transmissão de Energia Elétrica  
Baseado em Critério de Dominância**

Tese apresentada  
ao Programa de Pós-  
Graduação em  
Engenharia  
Elétrica da Universidade  
Federal de Juiz de  
Fora como requisito  
parcial à obtenção do  
título de Doutor em  
Engenharia Elétrica.  
Área de  
concentração:  
Sistemas de Energia  
Elétrica

Aprovada em 18 de setembro de 2024.

**BANCA EXAMINADORA**

**Prof. Dr. Leonardo Willer de Oliveira** - Orientador

Universidade Federal de Juiz de Fora

**Prof. Dr. Erivelton Geraldo Nepomuceno** - Coorientador

Universidade Federal de São João Del-Rei

**Prof. Dr. Edimar José de Oliveira** - Coorientador

Universidade Federal de Juiz de Fora

**Profa. Dra. Katia Campos de Almeida**

Universidade Federal de Santa Catarina

**Prof. Dr. Francisco Carlos Rodrigues Coelho**

Universidade Federal de São João Del-Rei

**Prof. Dr. Ivo Chaves da Silva Junior**

Universidade Federal de Juiz de Fora

**Prof. Dr. João Alberto Passos Filho**

Universidade Federal de Juiz de Fora

Juiz de Fora, 19/11/2024.



Documento assinado eletronicamente por **Erivelton Geraldo Nepomuceno, Usuário Externo**, em 19/11/2024, às 12:00, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Joao Alberto Passos Filho, Professor(a)**, em 19/11/2024, às 12:08, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Edimar Jose de Oliveira, Professor(a)**, em 19/11/2024, às 12:37, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Leonardo Willer de Oliveira, Professor(a)**, em 19/11/2024, às 12:49, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Ivo Chaves da Silva Junior, Professor(a)**, em 19/11/2024, às 13:02, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Francisco Carlos Rodrigues Coelho, Usuário Externo**, em 19/11/2024, às 13:45, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Katia Campo de Almeida, Usuário Externo**, em 19/11/2024, às 22:05, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf ([www2.ufjf.br/SEI](http://www2.ufjf.br/SEI)) através do ícone Conferência de Documentos, informando o código verificador **2109694** e o código CRC **7525CAB3**.

## AGRADECIMENTOS

Meus sinceros agradecimentos àqueles que de alguma forma me incentivaram e contribuíram para o sucesso em mais essa etapa da minha vida profissional. Nada teria alcançado sem a sabedoria e discernimento obtidos ao longo desses anos que só Deus é capaz de conceder. À Ele, obrigado sempre!

Agradeço especialmente o professor e orientador Leonardo Willer por todo seu apoio na elaboração e desenvolvimento desse trabalho, por sua paciência e conselhos ao longo desses anos, fundamentais para meu crescimento profissional que me incentivaram e permitiram me tornar também profissional docente. Aos professores Edimar e Erivelton pelo suporte e ajuda na elaboração de trabalhos que sustentaram o propósito dessa tese.

À minha família, em especial minha mãe Ione e meu irmão Rafael que sempre estiveram por perto com apoio emocional, tão necessário em alguns momentos. Aos meus amigos de longa data da Universidade Federal de São João del Rei que compartilharam comigo dos mesmos desafios de um doutoramento ao longo desse tempo.

À Universidade Federal de Juiz de Fora pela estrutura fornecida e suporte financeiro através do INERGE – Instituto Nacional de Energia Elétrica, indispensáveis no início do curso. Ao Centro Federal de Educação Tecnológica de Minas Gerais pela oportunidade de iniciar minha carreira como professor juntamente com o Doutorado. Ao Instituto Federal do Triângulo Mineiro pela oportunidade de capacitação para conclusão desse trabalho.

## RESUMO

Este trabalho apresenta as ferramentas desenvolvidas para suporte ao planejamento multiobjetivo da expansão da transmissão (PET) na presença de múltiplas incertezas, entre estas: (i) indisponibilidade de equipamentos de geração e transmissão; (ii) comportamento da carga; (iii) intermitência de fontes renováveis eólicas. Os algoritmos *Non-Dominated - Monte Carlo Simulation* (ND-MCS) e *Improved Non-Dominated - Monte Carlo Simulation* (IND-MCS) desenvolvidos permitem, através da estimação de confiabilidade, uma abordagem eficiente e estocástica do PET baseado em Simulação Monte Carlo (SMC) e critérios probabilísticos de Pareto, resultando em considerável redução de esforço computacional quando comparados ao método de SMC convencional. Além disso, uma rede de Máquinas de Vetores de Suporte (SVM) é incorporada aos algoritmos desenvolvidos para aumentar a robustez do método. A metodologia é aplicada ao *Multi-objective Grey Wolf Optimization* (MOGWO), associado a um critério *Fuzzy* de tomada de decisão para definição das estratégias de expansão baseadas nas soluções Pareto-ótimas. Os estudos de caso demonstram que a representação das incertezas ao longo do processo de busca (*a priori*) permite uma melhor busca no espaço de soluções devido à sua capacidade de identificar soluções candidatas não dominadas e, portanto, atrativas ao longo das etapas de otimização. Os resultados são encontrados com considerável eficiência computacional quando comparados ao método probabilístico convencional, encontrando múltiplas soluções sob diferentes critérios de planejamento e incertezas, o que pode fornecer soluções abrangentes e realistas ao planejador do sistema.

Palavras-chave: Planejamento da expansão da transmissão. Otimização Multi-objetivo. Simulação Monte Carlo. Confiabilidade. Geração Eólica.

## ABSTRACT

This work presents the developed tools to support multi-objective transmission expansion planning (TEP) in the presence of multiple uncertainties, including: (i) unavailability of generation and transmission equipment; (ii) load behavior; (iii) intermittency of wind renewable sources. The Non-Dominated - Monte Carlo Simulation (ND-MCS) and Improved Non-Dominated - Monte Carlo Simulation (IND-MCS) algorithms developed allow, through reliability estimation, an efficient and stochastic approach to TEP based on Monte Carlo Simulation (MCS) and probabilistic Pareto criteria, resulting in considerable reduction in computational effort when compared to the conventional MCS method. In addition, a Support Vector Machines (SVM) network is incorporated into the developed algorithms to increase the robustness of the method. The methodology is applied to Multi-objective Grey Wolf Optimization (MOGWO), associated with a Fuzzy decision-making criterion to define expansion strategies based on Pareto-optimal solutions. The case studies demonstrate that the representation of uncertainties throughout the search process (a priori) allows a better search in the solution space due to its ability to identify non-dominated and therefore attractive candidate solutions throughout the optimization steps. The results are found with considerable computational efficiency when compared to the conventional probabilistic method, finding multiple solutions under different planning criteria and uncertainties, which can provide comprehensive and realistic options to the system planner.

Keywords: Transmission expansion planning. Multi-objective Optimization. Monte Carlo simulation. Reliability. Wind Generation.



## LISTA DE FIGURAS

Figura 1 – Horizonte de crescimento previsto da carga do SIN .....	17
Figura 2 – Dados numéricos da Revisão de Literatura.....	21
Figura 3 – Representação visual das principais palavras-chave.....	22
Figura 4 – Curvas de custos × confiabilidade para um sistema elétrico de potência .....	38
Figura 5 – Níveis hierárquicos para confiabilidade.....	41
Figura 6 – Fluxograma da rede SVM .....	50
Figura 7 – Sistema Garver reforçado.....	64
Figura 8 – Fluxograma do algoritmo IND-MCS proposto .....	73
Figura 9 – Modelo de Markov para curva de carga.....	75
Figura 10 – Curvas de potência para turbinas com controle de estol e de passo.....	77
Figura 11 – Exemplo 1. a) Coeficientes de convergência (%); b) Valor esperado para EENS (Gwh).....	80
Figura 12 – Exemplo 2. a) Coeficientes de convergência; b) Valor esperado para EENS .....	81
Figura 13 – Exemplo 3. a) Coeficientes de convergência; b) Valor esperado para EENS .....	81
Figura 14 – Exemplo 4. a) Coeficientes de convergência; b) Valor esperado para EENS .....	82
Figura 15 – Fronteiras de Pareto obtidas – $MOGWOND-MCS \times MOGWOMCS$ .....	87
Figura 16 – Fronteiras de Pareto obtidas – $MOGWOND-MCS \times MOCSAN-1$ .....	88
Figura 17 – Topologia para o sistema IEEE-RTS reforçado – $MOGWOND-MCS$ .....	90
Figura 18 – Representação gráfica de convergência da EENS para a solução final .....	91
Figura 19 – Fronteiras de Pareto obtidas – $MOGWOND-MCS \times MOGWOMCS$ .....	93
Figura 20 – Topologia para o sistema BSS reforçado – $MOGWOND-MCS$ .....	95
Figura 21 – Representação gráfica de convergência da EENS para a solução final .....	95
Figura 22 – Representação probabilística da velocidade do vento: a) Função densidade de probabilidade; b) Função distribuição acumulada .....	98
Figura 23 – Fronteiras de Pareto obtidas – $CS-1 \times CS-2$ .....	100
Figura 24 – Representação gráfica de convergência da EENS para a solução final ....	101
Figura 25 – Fronteiras de Pareto obtidas para o RTS-WIND em CS-3 – a) Relação entre custo de investimento × EENS; b) Relação entre custo de investimento × EWES; c) Relação entre EENS × EWES .....	103

Figura 26 – Fronteiras de Pareto obtidas para o RTS-WIND em CS-4 – a) Relação entre custo de investimento $\times$ EENS; b) Relação entre custo de investimento $\times$ EWES; c) Relação entre EENS $\times$ EWES .....	103
Figura 27 – Fronteiras de Pareto obtidas para o RTS-WIND em CS-5 – a) Relação entre custo de investimento $\times$ EENS; b) Relação entre custo de investimento $\times$ EWES; c) Relação entre EENS $\times$ EWES .....	104
Figura 28 – Topologia para o sistema RTS-WIND reforçado – a) CS-1; b) CS-3; c) CS-4; d) CS-5.....	105
Figura 29 – Fronteiras de Pareto obtidas – CS-1 $\times$ CS-2 .....	107
Figura 30 – Representação gráfica de convergência da EENS para a solução final ....	108
Figura 31 – Fronteiras de Pareto obtidas para o BSS-WIND em CS-3 – a) Relação entre custo de investimento $\times$ EENS; b) Relação entre custo de investimento $\times$ EWES; c) Relação entre EENS $\times$ EWES .....	109
Figura 32 – Fronteiras de Pareto obtidas para o BSS-WIND em CS-4 – a) Relação entre custo de investimento $\times$ EENS; b) Relação entre custo de investimento $\times$ EWES; c) Relação entre EENS $\times$ EWES .....	110
Figura 33 – Fronteiras de Pareto obtidas para o BSS-WIND em CS-5 – a) Relação entre custo de investimento $\times$ EENS; b) Relação entre custo de investimento $\times$ EWES; c) Relação entre EENS $\times$ EWES .....	111
Figura 34 – Topologia para o sistema BSS-WIND reforçado – a) CS-1; b) CS-3; c) CS-4; d) CS-5.....	112
Figura 35 – Hiperplano de separação (w,b) em um espaço bidimensional .....	127
Figura 36 – Interpretação gráfica da distância $x$ até o hiperplano ótimo para o caso bidimensional.....	129
Figura 37 – Mapeamento de características .....	133
Figura 38 – (a) O ponto $(x_i, y_i)$ se encontra na região de separação, do lado correto. (b) O ponto $(x_i, y_i)$ se encontra na região de separação, do lado incorreto. (c) O ponto de separação $(x_i, y_i)$ se encontra fora da região de separação, do lado incorreto .....	134
Figura 39 – Espaço - Entrada $x$ Característica .....	137
Figura 40 – a) Conjunto soluções; b) Primeira Fronteira de Pareto .....	141
Figura 41 – Representação da Fronteira de Pareto-ótima local e global.....	142
Figura 42 – Distribuição das soluções na Fronteira de Pareto .....	143
Figura 43 – Função de pertinência linear .....	150

## LISTA DE TABELAS

Tabela 1 – Resultados da SMC para o sistema IEEE-RTS.....	51
Tabela 2 – Desvios percentuais da SMC para o sistema IEEE-RTS .....	52
Tabela 3 – Desempenho da rede SVM para o sistema IEEE-RTS .....	52
Tabela 4 – Resultados da SMC para o sistema IEEE-RTS Modificado .....	53
Tabela 5 – Desvios percentuais da SMC para o sistema IEEE-RTS Modificado.....	54
Tabela 6 – Desempenho da rede SVM para o sistema IEEE-RTS Modificado.....	55
Tabela 7 – Resultados da literatura para o sistema teste Garver .....	63
Tabela 8 – Soluções não-dominadas encontradas pelo MOGWO para o sistema teste Garver .....	63
Tabela 9 – Estatísticas de acerto do MOGWO .....	65
Tabela 10 – Dados de convergência para os exemplos tutoriais do algoritmo ND-MCS .....	82
Tabela 11 – Planos finais obtidos para o sistema IEEE-RTS .....	86
Tabela 12 – Comparação entre os estudos de caso, IEEE-RTS.....	87
Tabela 13 – Soluções ‘R’ e ‘L’ para o sistema IEEE-RTS.....	90
Tabela 14 – Planos finais obtidos para o sistema BSS .....	92
Tabela 15 – Planos finais obtidos para o sistema RTS-WIND – objetivos $f_1$ e $f_2$ .....	99
Tabela 16 – Planos finais obtidos para o sistema RTS-WIND considerando o objetivo $f_3$ .....	102
Tabela 17 – Planos finais obtidos para o sistema BSS-WIND – objetivos $f_1$ e $f_2$ .....	106
Tabela 18 – Planos finais obtidos para o sistema BSS-WIND considerando o objetivo $f_3$ .....	109
Tabela 19 – Funções <i>Kernel</i> mais utilizadas em SVM.....	138
Tabela 20 – Dados de barra para o sistema IEEE – RTS 24 barras.....	151
Tabela 21 – Dados de barra para o sistema RTS - WIND .....	151
Tabela 22 – Dados de linhas existentes para os sistemas IEEE – RTS 24 barras e RTS - WIND .....	152
Tabela 23 – Dados de linhas candidatas para os sistemas IEEE – RTS 24 barras e RTS - WIND .....	153
Tabela 24 – Dados de barra para o sistema BSS .....	154
Tabela 25 – Dados de barra para o sistema BSS - WIND .....	155

Tabela 26 – Dados de linhas existentes para os sistemas BSS e BSS - WIND.....	156
Tabela 27 – Dados de linhas candidatas para os sistemas BSS e BSS - WIND.....	158

## LISTA DE ABREVIATURAS E SIGLAS

AHC	Algoritmo Heurístico Construtivo
CDF	Função densidade de probabilidade acumulada
EENS	Expectativa de energia não suprida, do inglês <i>Expected Energy not Supplied</i>
EPNS	Expectativa de potência não suprida, do inglês <i>Expected Power not Supplied</i>
EWES	Expectativa de desperdício de energia eólica, do inglês <i>Expected Wind Energy Spilled</i>
FACTS	<i>Flexible AC Transmission Systems</i>
G&T	Geração e Transmissão
GWO	<i>Grey Wolf Optimization</i>
IND-MCS	<i>Improved Non-dominated – Monte Carlo Simulation</i>
LOLC	Custo de perda de carga, do inglês <i>Loss of Load Cost</i>
LOLD	Duração de perda de carga, do inglês <i>Loss of Load Duration</i>
LOLF	Frequência de perda de carga, do inglês <i>Loss of Load Frequency</i>
LOLP	Probabilidade de perda de carga, do inglês <i>Loss of Load Probability</i>
LOWP	Probabilidade de perda de vento, do inglês <i>Loss of Wind Probability</i>
MILP	Programação linear inteira mista, do inglês <i>Mixed Integer Linear Programming</i>
MOGWO	<i>Multi-objective Grey Wolf Optimization</i>
MTTR	Tempo médio para o reparo, do inglês <i>Mean Time to Repair</i>
ND-MCS	<i>Non-dominated – Monte Carlo Simulation</i>
ONS	Operador Nacional do Sistema Elétrico
PDF	Função densidade de probabilidade
PET	Planejamento da Expansão da Transmissão
SEP	Sistemas Elétricos de Potência
SIN	Sistema Interligado Nacional
SMC	Simulação Monte Carlo
SVM	Máquina de vetor de suporte, do inglês <i>Support Vector Machine</i>

## LISTA DE SÍMBOLOS

### Subscritos

$b$	barra do sistema;
$k$	linha de transmissão;
$ij$	barras $i$ e $j$ adjacentes à linha $k$ ;
$g$	gerador convencional despachável;
$r$	gerador renovável não despachável;

### Conjuntos

$B$	barras do sistema;
$B^D$	barras de carga;
$G$	barras de geradores controláveis;
$G_b$	barras de geradores convencionais controláveis conectados à barra $b$ ;
$K^C$	linhas de transmissão candidatas;
$K^E$	linhas de transmissão existentes;
$K_b$	linhas de transmissão conectadas à barra $b$ ;
$R$	geradores renováveis não controláveis;
$R_b$	geradores renováveis não controláveis conectados à barra $b$ ;

### Variáveis

$hd_b$	corte de carga na barra $b$ , MW;
$f_k$	fluxo de potência ativa na linha de transmissão $k$ , MW;
$pg_g$	potência ativa gerada pelo gerador convencional $g$ , MW
$\theta_{ij}$	abertura angular de tensão nodal entre as barras $i$ e $j$ ;
$hr_b$	corte de geração renovável na barra $b$ , MW;
$pr_r$	potência ativa gerada pelo gerador renovável $r$ , MW;
$I_k^T$	variável binária de decisão de investimento na linha de transmissão;
$\vec{X}$	vetor posição do indivíduo (plano candidato) para o MOGWO;

### Parâmetros

$d_b$	carga na barra $b$ , MW;
-------	--------------------------

$\bar{f}_k$	limite de capacidade de potência ativa na linha de transmissão $k$ , MW;
$g_k$	condutância série na linha de transmissão $k$ , $\Omega^{-1}$ ;
$b_k$	susceptância série na linha de transmissão $k$ , $\Omega^{-1}$ ;
$ch$	penalidade associada ao corte de carga e vento, \$/MW;
$\bar{p}_g$	limite de capacidade de potência ativa do gerador $g$ , em MW;
$u$	nível de carga para o estado operativo avaliado, %;
$u_k$	disponibilidade da linha de transmissão $k$ ;
$C_k^T$	custo de investimento na linha de transmissão $k$ , \$;
$NS$	número de estados amostrados pela SMC;
$\lambda$	taxa de falha do equipamento;
$\mu$	taxa de reparo do equipamento;
$T$	número de indivíduos do MOGWO;
$\eta$	tamanho da população do MOGWO;
$\Psi$	dimensão do repositório para soluções não-dominadas;
$\alpha$	parâmetro de inflação de grade do MOGWO;
$\beta$	parâmetro de pressão para seleção de líder do MOGWO;
$nGrid$	número de grades por dimensão;

## SUMÁRIO

<b>1.</b>	<b>INTRODUÇÃO .....</b>	<b>16</b>
1.1.	CONSIDERAÇÕES INICIAIS .....	16
1.2.	MOTIVAÇÃO DO TRABALHO .....	19
1.3.	DEFINIÇÃO DO PROBLEMA E OBJETIVOS .....	20
1.4.	REVISÃO DE LITERATURA .....	21
1.4.1.	Modelagem do problema PET.....	22
1.4.2.	Otimização aplicada à solução do problema PET .....	24
1.4.3.	Avaliação da confiabilidade composta em sistemas elétricos .....	27
1.4.4.	Redução de esforço computacional em simulação de confiabilidade .....	30
1.4.5.	Fontes renováveis no PET .....	33
1.5.	PUBLICAÇÕES DECORRENTES DA PESQUISA.....	35
1.6.	ESTRUTURA DO DOCUMENTO.....	35
<b>2.</b>	<b>AVALIAÇÃO DA CONFIABILIDADE EM SISTEMAS ELÉTRICOS DE POTÊNCIA.....</b>	<b>38</b>
2.1.	ASPECTOS PRELIMINARES .....	39
2.2.	NÍVEIS HIERÁRQUICOS .....	41
2.3.	AVALIAÇÃO DA CONFIABILIDADE COMPOSTA.....	42
2.4.	SIMULAÇÃO MONTE CARLO NÃO-SEQUENCIAL .....	43
2.5.	AVALIAÇÃO DA CONFIABILIDADE BASEADA EM MÁQUINAS DE VETORES DE SUPORTE (SVM) .....	46
2.6.	APLICAÇÃO DE SVM'S NA AVALIAÇÃO DA CONFIABILIDADE COMPOSTA .....	47
2.6.1.	Dados de entrada .....	47
2.6.2.	Dados de treinamento .....	48
2.6.3.	Análise de desempenho da rede SVM.....	49
2.7.	RESULTADOS.....	50
2.7.1.	Sistema IEEE-RTS .....	51
2.7.2.	Sistema IEEE-RTS Modificado.....	53
2.8.	CONCLUSÕES PARCIAIS .....	55
<b>3.</b>	<b>PLANEJAMENTO MULTI OBJETIVO DA EXPANSÃO DA TRANSMISSÃO BASEADO EM CRITÉRIO DE DOMINÂNCIA.....</b>	<b>56</b>



3.1.	FORMULAÇÃO MULTIOBJETIVO DO PROBLEMA PET .....	56
3.2.	MÉTODO DE OTIMIZAÇÃO IMPLEMENTADO: MOGWO .....	60
3.3.	RESULTADOS PARA O ALGORITMO MOGWO: SISTEMA TESTE GARVER.....	62
3.4.	ALGORITMO PROPOSTO ND-MCS: PLANEJAMENTO MULTIOBJETIVO DA EXPANSÃO DA TRANSMISSÃO BASEADO EM CRITÉRIO DE DOMINÂNCIA.....	65
3.4.1.	Fundamentação da Metodologia Proposta .....	68
3.5.	ALGORITMO PROPOSTO IND-MCS: FORMULAÇÃO MULTIOBJETIVO DO PROBLEMA PET CONSIDERANDO MÚLTIPLAS INCERTEZAS .....	70
3.5.1.	Modelagem da carga .....	74
3.5.2.	Modelagem da geração eólica .....	75
3.5.3.	Confiabilidade composta G&T .....	78
3.6.	EXEMPLO TUTORIAL DE APLICAÇÃO.....	79
3.7.	CONCLUSÕES PARCIAIS .....	83
<b>4.</b>	<b>ESTUDOS DE CASO.....</b>	<b>84</b>
4.1.	RESULTADOS PARA O ALGORITMO ND-MCS – FORMULAÇÃO BÁSICA PARA O PROBLEMA PET PROBABILÍSTICO .....	84
4.1.1.	Sistema IEEE-RTS .....	85
4.1.2.	Sistema sul brasileiro equivalente – BSS.....	91
4.2.	RESULTADOS PARA O ALGORITMO IND-MCS – FORMULAÇÃO COMPLETA PARA O PROBLEMA PET PROBABILÍSTICO COM MÚLTIPLAS INCERTEZAS.....	96
4.2.1.	Sistema RTS-WIND .....	98
4.2.2.	Sistema BSS-WIND .....	106
4.3.	CONCLUSÕES PARCIAIS .....	113
<b>5.</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS.....</b>	<b>114</b>
5.1.	CONCLUSÕES.....	114
5.2.	PROPOSTAS DE TRABALHOS FUTUROS.....	115
	<b>REFERÊNCIAS.....</b>	<b>117</b>
	<b>APÊNDICE A - Máquinas de Vetores de Suporte.....</b>	<b>127</b>
	<b>APÊNDICE B - Otimização Multiobjetivo.....</b>	<b>139</b>
	<b>APÊNDICE C - Grey Wolf Optimizer .....</b>	<b>144</b>

<b>APÊNDICE D - Método <i>Fuzzy</i> de Tomada de Decisão.....</b>	<b>149</b>
<b>APÊNDICE E – Dados dos sistemas .....</b>	<b>151</b>

## 1. INTRODUÇÃO

### 1.1. CONSIDERAÇÕES INICIAIS


Os sistemas elétricos de potência (SEP) são fisicamente constituídos de equipamentos e consumidores, formando grandes redes elétricas interconectadas cujo principal objetivo é o atendimento à demanda por energia elétrica com qualidade e equilíbrio entre custo e segurança. Além de equipamentos físicos, esses sistemas são ainda formados por gestores e agentes responsáveis por planejar a operação da rede diante dos desafios interpostos pelo comportamento dinâmico do mercado de energia.

De modo a interligar redes elétricas de forma segura, os sistemas de transmissão de energia frequentemente necessitam de adequações para atender à demanda em constante crescimento. Assim, o problema de Planejamento da Expansão da Transmissão (PET) tem como principal objetivo a obtenção de planos de investimento para a rede elétrica capazes de atender aos consumidores com o menor custo e a maior confiabilidade possíveis. Embora o comportamento da carga seja uma das principais variáveis no problema de expansão da transmissão, o crescente aumento de sistemas de geração de energia através de fontes renováveis tem se tornado um grande desafio para o planejamento da matriz energética. Para garantir uma operação segura dos SEP, são necessárias novas estratégias que permitam assegurar a qualidade e a confiabilidade diante das incertezas provenientes do comportamento das redes modernas (Gomes & Saraiva, 2019).

Segundo o Plano de Operação Elétrica de Médio Prazo do Sistema Interligado Nacional (SIN) para o ciclo 2024-2028 do Operador Nacional do Sistema (ONS) – PAR/PEL 2023 (ONS, 2024), a carga para o sistema brasileiro será da ordem de 111 GW no ano de 2028, o que corresponde a um aumento de 15% em relação à carga máxima registrada em 2023, conforme ilustrado na Figura 1. Nos últimos anos, a penetração de geração eólica tem se destacado, chegando à proporção de aproximadamente 13% da matriz elétrica. Para os próximos anos, espera-se que a energia fotovoltaica apresente um crescimento percentual expressivo, quase dobrando a capacidade instalada no horizonte 2024-2027. Estima-se que, ao final desse período, a capacidade instalada do SIN seja de quase 247 GW, com cerca de 55 GW provenientes de fontes eólicas e fotovoltaicas centralizadas.

Tendo em vista as situações específicas de atendimento à carga e escoamento dessa geração, estão previstos para o ciclo 2024-2028, obras de expansão que perfazem cerca de 10.000 Km de novas linhas de transmissão e 30.600 MVA de acréscimo na capacidade transformadora em subestações novas e já existentes. Esses empreendimentos representam um acréscimo da ordem de 5,8% na extensão das linhas de transmissão e de 7,5% na potência nominal instalada em transformadores da Rede Básica e da Rede Básica de Fronteira, em relação à rede existente.

Figura 1 – Horizonte de crescimento previsto da carga do SIN



Fonte: Elaborado pelo autor – adaptado de (ONS, 2024)

A avaliação da confiabilidade é uma importante ferramenta de auxílio para o PET uma vez que, através de índices de desempenho, permite encontrar soluções capazes de atender requisitos mínimos de desempenho e segurança frente à disponibilidade dos equipamentos (Gomes & Saraiva, 2019). A abordagem probabilística do problema PET inclui a estimação de índices como a Probabilidade de Perda de Carga (LOLP) (da Costa et al., 2021), Expectativa de Energia Não Suprida (EENS) (Gazijahani et al., 2018a; Hamidpour et al., 2021; Praveen et al., 2018; Ugranli & Karatepe, 2015), Custo de Perda de Carga (LOLC) (Ghadimi et al., 2022a; Leite da Silva, Rezende, da Fonseca Manso, et al.,

2010), entre outros. É comum a utilização de critérios de contingência, e.g., N-1, para solucionar o problema PET considerando restrições de segurança (Huang & Dinavahi, 2019; Zheng et al., 2019) em razão do seu desempenho computacional quando comparados a métodos baseados em amostragem aleatória como a Simulação Monte Carlo (SMC) (Billinton & Allan, 1996; Billinton & Li, 1994). Embora apresentem melhor desempenho computacional, o PET baseado em contingências pode levar a sobreinvestimentos (de Paula, de Oliveira, de Oliveira, et al., 2020; Leite da Silva, Rezende, Manso, et al., 2010). Por outro lado, ainda que a utilização de métodos probabilísticos como a SMC possa ser uma opção para evitar o sobreinvestimento, pode tornar a solução inviável devido ao alto esforço computacional necessário (Leite da Silva, Rezende, Manso, et al., 2010).

A SMC tem sido ainda frequentemente utilizada como suporte ao PET com participação de geração renovável. Em razão do comportamento estocástico da velocidade dos ventos, a SMC é aplicada para estimação de índices de desempenho baseados na redução do desperdício de geração eólica como o *Expected Wind Energy Spilled* (EWES), proposto em (Leite Da Silva et al., 2012), que é um dos principais desafios para a ampliação do uso de fontes renováveis no planejamento de sistemas em razão das limitações de capacidade dos sistemas de transmissão. Dessa forma, a literatura tem aprimorado a representação dessas incertezas no PET através de cenários obtidos por exemplo através de séries históricas agrupadas pelo algoritmo *K-means* (Alizadeh-Mousavi & Zima-Bočkarjova, 2016; Moraes et al., 2022) e métodos baseados em amostragem probabilística como a SMC (Ghadimi et al., 2022a; Roldán et al., 2020), em que o custo da confiabilidade é incorporado ao custo de investimento em um problema de otimização mono-objetivo em sua formulação, ou seja, considerando apenas o custo total como critério.

A solução que melhor atende à função objetivo e às restrições é denominada solução global para o problema. No entanto, a obtenção de uma solução ótima que integre custos de investimento e segurança operacional não é uma tarefa fácil, em virtude da multiplicidade de objetivos e incertezas que levam a uma explosão combinatória de alternativas de expansão. A representação completa do problema PET envolve uma modelagem multiobjetivo e probabilística baseada em critérios de custos e segurança, capazes de considerar múltiplas incertezas ao longo do processo de busca. No entanto, todas essas características podem tornar o problema extremamente complexo e,

normalmente, os métodos de solução utilizados na literatura sugerem soluções superestimadas ao PET, o que pode acarretar em custos elevados e que não retratam o real comportamento do sistema. Dessa forma, diante do aumento das dificuldades inseridas ao problema, torna-se relevante o desenvolvimento de ferramentas eficientes para a solução do PET capazes de considerar de forma eficaz o comportamento dos sistemas modernos.

## 1.2. MOTIVAÇÃO DO TRABALHO

Embora o PET seja extensamente discutido na literatura, é inegável que a inserção de cada vez mais incertezas relacionadas ao comportamento variável da carga e de fontes alternativas de energia gera novos desafios ao problema, o que exige o desenvolvimento de ferramentas robustas capazes de representar a realidade dos sistemas com base em múltiplos objetivos de otimização. No entanto, apesar de existirem ferramentas apropriadas para avaliação probabilística de alternativas de expansão, como a SMC, é comum na literatura a utilização de abordagens mono-objetivo baseadas em cenários de contingência, que podem gerar sobreinvestimentos, mas são preferíveis em razão do baixo esforço computacional.

A explosão combinatória de possíveis soluções torna impraticável para os métodos tradicionais avaliarem o problema PET com modelagem probabilística de incertezas para todos os planos. Dessa forma, quando utilizada, a SMC é empregada na estimação de critérios de confiabilidade somente após o processo de otimização, de modo que os índices não se configuram como objetivo durante o processo de busca.

Na formulação multiobjetivo do PET, grande parte das soluções são dominadas ao longo do processo de otimização, isto é, são inferiores a outras segundo todos os critérios considerados. Neste caso, o interesse é pela obtenção apenas de um conjunto de soluções não dominadas, ou seja, que tenha em seu repertório planos que não perdem em todos os critérios para qualquer solução. Esse conjunto consiste na chamada fronteira de Pareto, contendo soluções concorrentes entre si para os objetivos considerados. A presente tese utiliza dessa característica para propor uma ferramenta baseada no comportamento estocástico das soluções, que permita considerar as incertezas provenientes da performance do sistema ao longo do processo de busca com elevada eficiência computacional. Além do expressivo ganho de desempenho frente ao método de SMC convencional, a capacidade de filtragem de soluções não-dominadas do método

desenvolvido permite a aplicação eficiente do processo de amostragem da SMC, segundo probabilidades, contribuindo para evitar sobreinvestimentos em planos de expansão.

### 1.3. DEFINIÇÃO DO PROBLEMA E OBJETIVOS

Face aos desafios expostos, esta tese propõe uma ferramenta de otimização multiobjetivo para o problema PET probabilístico capaz de considerar abordagens pouco exploradas na literatura devido à sua complexidade. Os critérios de dominância em problemas de otimização multiobjetivo são utilizados para propor índices de convergência para o método de busca baseados em SMC. O objetivo geral é permitir a estimação eficiente da confiabilidade para as alternativas de expansão intrinsecamente ao processo de otimização. Um algoritmo baseado em *Support Vector-Machine Learning* (SVM) é proposto para aprimorar o desempenho da metodologia. Ao considerar a confiabilidade como parte do problema de otimização, a ferramenta proposta visa encontrar soluções de boa qualidade com um tempo computacional praticável, levando em conta o comportamento estocástico da rede.

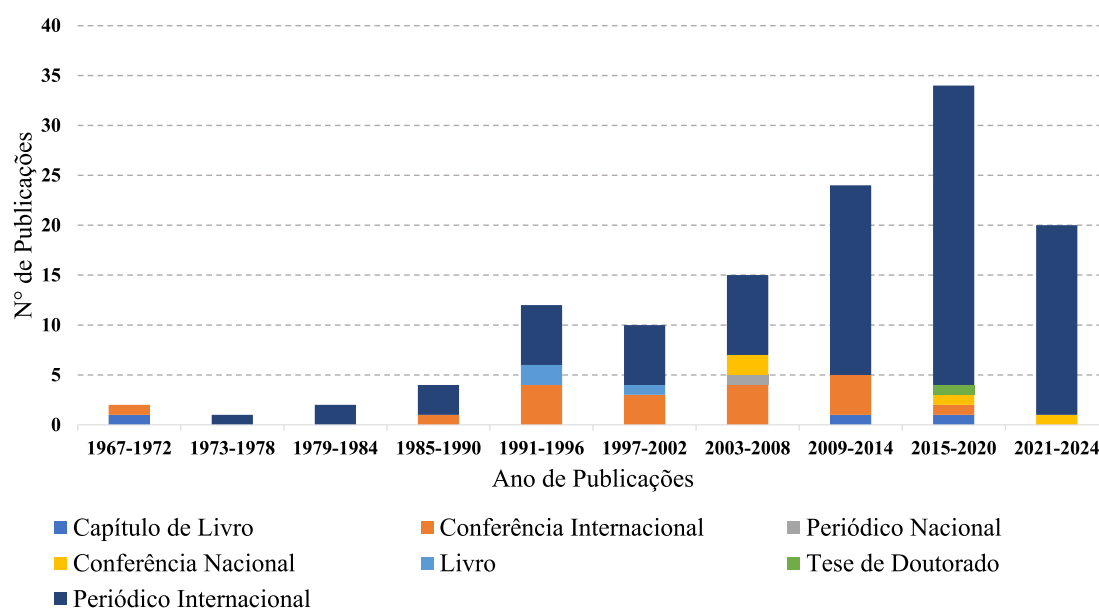
Neste contexto, pode-se citar como objetivos específicos:

- Propor uma nova e eficiente abordagem para o PET probabilístico multiobjetivo que permita a avaliação da confiabilidade para todas as soluções ao longo do processo de otimização;
- Utilizar os recursos de convergência do método de SMC para propor critérios de classificação de soluções quanto à dominância;
- Representar de forma adequada a disponibilidade de equipamentos através do método de SMC para estimação da confiabilidade da transmissão, evitando sobreinvestimentos e otimizando os índices de energia não suprida para os sistemas (EENS);
- Permitir que a maximização da geração eólica seja considerada como objetivo no PET através do índice EWES, estimado em conjunto com a EENS;
- Avaliar o impacto de múltiplas incertezas no PET decorrentes do comportamento estocástico da carga, geração eólica, bem como da disponibilidade dos equipamentos de geração e transmissão (G&T), resultando em uma ferramenta de PET com avaliação de confiabilidade composta intrínseca ao problema;
- Comparar o desempenho da metodologia proposta com soluções obtidas por técnicas tradicionais como a SMC convencional e o critério N-1.

#### 1.4. REVISÃO DE LITERATURA

São apresentados nesta seção alguns dos principais trabalhos relacionados ao problema PET e ferramentas de avaliação abordadas no presente trabalho que motivaram o desenvolvimento da metodologia proposta. Nesta revisão são abordadas as principais metodologias e técnicas a respeito da modelagem do problema PET, otimização aplicada ao PET, avaliação da confiabilidade em sistemas elétricos, técnicas de redução de esforço computacional e, por fim, a consideração de fontes renováveis de geração de energia no PET. A Figura 2 resume numericamente as produções bibliográficas utilizadas como referência com base no ano e o tipo de publicação. Observa-se que cerca de 76% dos trabalhos referem-se a artigos de periódicos internacionais e, destes, cerca de 36% foram publicados nos últimos 5 anos.

Figura 2 – Dados numéricos da Revisão de Literatura



Fonte: Elaborado pelo autor (2024)

A Figura 3 ilustra uma representação das principais palavras-chave adotadas pelos autores presentes nesta revisão de literatura, alinhadas ao objetivo desta tese.



Figura 3 – Representação visual das principais palavras-chave



Fonte: Elaborado pelo autor (2024)

#### 1.4.1. Modelagem do problema PET

As primeiras ferramentas de apoio à solução do PET utilizavam técnicas de análise como fluxo de potência, análises de curto-circuito e estabilidade como apoio ao planejador. Nestes métodos o problema do PET limita-se à consideração de cenários de demanda e parâmetros econômicos, de modo que já havia nessa época um interesse por parte dos engenheiros de planejamento em ferramentas matemáticas capazes de fornecer alternativas de expansão com base no comportamento futuro do sistema.

Com a evolução das técnicas e métodos computacionais, Garver em 1970 (Garver, 1970) propôs um modelo de fluxo de potência baseado em programação linear para definir possíveis alternativas de expansão. O método, fundamentado pelo modelo de transportes satisfazia essencialmente a primeira Lei de Kirchhoff para satisfazer o balanço de potências. Monticelli em 1982 (Monticelli, Santos, Pereira, Cunha, Parker, Pracoa, et al., 1982) propôs um algoritmo heurístico construtivo utilizando modelagem linear. Denominado algoritmo de mínimo esforço, baseia-se no acoplamento entre potência ativa e ângulos de tensão, sendo que as linhas candidatas são determinadas através de análises de sensibilidade das susceptância dos circuitos.

Atualmente, o modelo baseado em programação linear, denominado modelo DC, é considerado como a ferramenta matemática mais apropriada para formular o problema PET de longo prazo em razão de seu desempenho computacional e as boas estimativas de

fluxo de potência ativa. Esse modelo tem como base a solução do fluxo de potência ótimo linear, denominado nessa tese como FPO. Apesar das limitações, o modelo DC tem sido aprimorado na literatura para permitir a abordagem de diversas variáveis do sistema. Em (H. Zhang et al., 2013) os autores apresentam um modelo linear para representar a potência ativa, perfis de tensão e perdas nas linhas de transmissão. Uma formulação baseada em programação linear inteira mista (MILP) é proposta em (C. Li et al., 2022) para o problema de expansão da geração e transmissão baseado em um algoritmo de decomposição de Benders adaptado. Uma otimização bilinear é proposta pelos autores de (Alshamrani et al., 2023) para solucionar o PET em dois níveis. No nível superior trata-se do planejamento conjunto de expansão da transmissão e investimento em energia eólica, no segundo nível é solucionado um despacho econômico com restrições de segurança. Um modelo linear dinâmico para representação das perdas durante a otimização é apresentado em (dos Santos & Diniz, 2011), comparando com um processo iterativo que realimenta o FPO para obtenção das perdas. Segundo (Assis et al., 2018; Poubel et al., 2015), o processo iterativo é mais rápido que o modelo linear dinâmico por partes e amplamente utilizado nos problemas PET, embora a obtenção da solução ótima global do FPO não possa ser garantida (dos Santos & Diniz, 2011). Apesar disso, o modelo linear dinâmico por partes não é adequado para ser utilizado nos problemas PET uma vez que demanda um elevado custo computacional.

O modelo AC para o PET ainda apresenta muitos desafios, principalmente relacionados à participação de fontes renováveis e dispositivos FACTS, que agregam dificuldades adicionais ao método. Em (de Araújo et al., 2023) uma técnica de programação não-linear é proposta para alcançar uma configuração de expansão da transmissão em sistemas com interconexão de corrente contínua em alta tensão - HVDC e dispositivos FACTS. Devido às limitações da modelagem em corrente alternada, tem-se encontrado na literatura métodos híbridos AC/DC para modelagem do PET. Em (Moradi-Sepahvand & Amraee, 2021) um modelo dinâmico (plurianual) do PET utilizando corrente AC em alta tensão e conversores baseados em corrente contínua de alta tensão. Além da inserção de novas linhas AC e DC, os autores propõem a conversão de linhas AC para DC e inserção de dispositivos de armazenamento de energia devido à intermitência dos recursos renováveis, também considerados.

O estudo do PET é feito considerando um horizonte temporal para alocação dos reforços no sistema. Normalmente esse horizonte pode ser considerado a curto, médio e

longo prazo, de modo que a depender da abordagem definida, o nível de detalhamento do sistema e suas variáveis devem ser ajustados. De acordo com o período de investimento e alocação de reforços, o problema de expansão do sistema pode ser classificado como estático ou dinâmico, também definido como multiestágio. O planejamento dinâmico é mais complexo que o estático, uma vez que um grande número de variáveis e restrições aumentam o esforço computacional. Essa abordagem é encontrada em trabalhos como (Akbari et al., 2011; Allahvirdizadeh et al., 2023; Kamyab et al., 2014; Moutinho et al., 2023). Apesar de mais simplificada, a abordagem estática se apresenta como uma excelente opção em estudos iniciais de planejamento da expansão, sendo amplamente utilizada na literatura, como exemplo em (El-Meligy & Sharaf, 2024; Vilaça et al., 2022).

Embora as técnicas matemáticas tenham evoluído de forma consistente ao longo dos anos, mudanças contínuas no perfil de carga e novos mercados de geração de energia abrem espaço para novas modelagens capazes de considerar cenários ainda pouco explorados. Os trabalhos citados reiteram a importância da modelagem linear do sistema em estudos de expansão; no entanto, se limitam a abordagens baseadas unicamente em custo de investimento e, em alguns casos, com restrição de confiabilidade. Na presente tese, um modelo linearizado iterativo para consideração de perdas é aplicado em um problema de múltiplos objetivos.

#### 1.4.2. Otimização aplicada à solução do problema PET

A solução do problema de expansão pode ser obtida a partir de ferramentas de otimização, em que a função objetivo normalmente é relacionada à minimização de custos de investimento, custos operacionais e custos de interrupção, sujeitos a uma série de restrições técnicas e econômicas. As ferramentas de otimização utilizadas no PET podem ser classificadas como clássicas, heurísticas e metaheurísticas (Latorre et al., 2003; Lee et al., 2006). Apesar de garantirem soluções ótimas para o problema PET, as técnicas clássicas não são recomendadas para estudos a longo prazo, em virtude da impossibilidade de se modelar todos os critérios de comportamento do sistema ao longo do tempo. Dessa forma, métodos clássicos de otimização fornecem soluções ótimas mediante restrições inseridas no modelo.

Em (Villasana et al., 1985) é proposto um método baseado na combinação de um fluxo de potência linear e um modelo de transportes para solução do PET. A modelagem linear é aplicada para solução dos fluxos de potência nos circuitos de acordo com as Leis

de Kirchhoff, enquanto o modelo de transportes lida com as sobrecargas obedecendo o princípio de conservação do fluxo em uma barra e minimizando uma função objetivo de custo de investimento. Um método baseado em programação não-linear é proposto em (Rider et al., 2007) via algoritmo de pontos interiores e algoritmo heurístico construtivo para encontrar alternativas de expansão. São ainda encontradas na literatura ferramentas baseadas em decomposição como o algoritmo *Branch and Bound* (Y. Lee et al., 1974), (Haffner et al., 2000) e Benders (F. Pereira et al., 1985; MacRae et al., 2016).

A utilização de técnicas metaheurísticas tem sido amplamente discutida na literatura como alternativas para solução do planejamento da expansão da transmissão. Estes métodos tem a capacidade de considerar variáveis discretas e contínuas no processo de otimização para problemas não lineares com baixa complexidade de implementação e possibilidade de inserção do tratamento de incertezas (Assis, 2018). Apesar de não garantirem ótimos globais, fornecem soluções de alta qualidade com baixos tempos de processamento, o que pode ser um fator preponderante em estudos com consideração de incertezas.

A partir da formulação do modelo de transportes, o primeiro algoritmo heurístico do tipo construtivo (AHC) é o proposto por Garver (Garver, 1970). Com o advento da modelagem DC, novos algoritmos heurísticos são propostos para solução do PET, em que se destacam o algoritmo de mínimo esforço (Monticelli, Santos, Pereira, Cunha, Parker, Pracoa, et al., 1982) e o algoritmo de mínimo corte de carga (M. Pereira & Pinto, 1985). Apesar de carregarem semelhanças, a diferença entre esses algoritmos está na determinação do indicador de sensibilidade utilizado. Os autores em (Rider et al., 2007) propõem um AHC a partir da modelagem AC para solução do PET incluindo a otimização de potência reativa no sistema. A abordagem não-linear para o AHC é ainda encontrada em (Bustamante-Cedeño & Arora, 2009), a partir de uma programação não-linear inteira mista e não convexa (MINLP).

Fundamentalmente, as metaheurísticas são baseadas em conceitos populacionais e inspiradas em comportamentos naturais. De acordo com a metodologia de solução, as metaheurísticas podem ser distinguidas entre metaheurísticas de busca local, que realizam pequenas alterações iterativas em uma única solução; metaheurísticas populacionais, que combinam soluções a partir de recombinações baseadas em comportamentos naturais para originar novas e metaheurísticas construtivas, que constroem soluções de forma gradual a partir de uma solução vazia.

Entre as metaheurísticas de busca local para solução do problema PET pode-se encontrar na literatura o *Simulated Annealing* (Gallego et al., 1997; Romero et al., [s.d.]) e a Busca Tabu (Armando M. Leite da Silva; et al., 2008; E. L. Da Silva et al., 2001). No método de *Simulated Annealing* a busca é baseada na minimização de energia da estrutura cristalina de um material sólido, quando o mesmo é submetido ao processo de recozimento para remoção de defeitos em sua estrutura. Os estados possíveis de um material representam as soluções do espaço de busca, sendo as posições moleculares do sistema correspondentes às variáveis de decisão do problema de otimização. A energia de cada estado corresponde ao valor da função objetivo associada ao problema. De modo semelhante, a Busca Tabu progride iterativamente de uma solução a outra, evitando o aprisionamento em ótimos locais. Partindo de uma solução inicial, a busca se move de uma solução para a vizinha melhor, sem movimentos repetidos (soluções já avaliadas). Para que não haja busca em ciclos, os movimentos reversos são armazenados em uma estrutura de memória (lista tabu) durante o processo iterativo.

Os métodos populacionais são baseados em um conjunto inicial de soluções, denominado população inicial. A partir do processo iterativo que ocorre por estratégias evolutivas as soluções são aprimoradas. Pode-se citar *Particle Swarm Optimization* (de Mendonça et al., 2014), *Artificial Immune System* (Rezende et al., 2009) e *Genetic Algorithm* (Abdelaziz, [s.d.]). Recentemente, um modelo baseado no comportamento de caça de lobos cinzentos, denominado *Grey Wolf Optimization* foi aplicado no problema de expansão da transmissão (Ghadimi et al., 2022a).

As metaheurísticas construtivas consistem em técnicas de construção de soluções viáveis de forma gradativa, adicionando um elemento à solução parcial a cada passo iterativo. Assim, partindo de uma solução inicialmente vazia, incrementos são realizados até que o critério de parada seja atingido, como por exemplo, até que a solução se torne viável. Entre as técnicas mais comuns desta classe, tem-se o *Greedy Randomized Adaptive Search Procedure* – GRASP (Binato et al., 2001) e *Ant Colony Optimization* (Leite da Silva, Rezende, da Fonseca Manso, et al., 2010). Recentemente, Assis (Assis et al., 2021) propuseram um algoritmo metaheurístico construtivo para solução do PET de sistemas de grande porte considerando diferentes cenários de geração e carga considerando o critério de segurança N-1.

Em razão das características multiobjetivo do PET, é comum em estudos mais complexos a utilização das metaheurísticas para solução do problema de otimização

multicritério, como é o caso do PET que visa minimização de custos de investimento e maximização da segurança através dos índices de desempenho do sistema. Em (Arabali et al., 2014) é desenvolvida uma metodologia de PET multiestágio e multiobjetivo que considera o custo de investimento e a confiabilidade via enumeração de estados como objetivos. O algoritmo *non-dominated sorting genetic algorithm* (NSGA II) é utilizado para determinação das soluções não-dominadas. Um PET multiobjetivo considerando a natureza variável da energia eólica e estrutura de carga variável é proposto em (Ugranli & Karatepe, 2015) via técnicas de agrupamento de cenários. É utilizado o algoritmo NSGA-II para otimização e um método *Fuzzy* para decisão da solução final. Um problema PET multiobjetivo considerando múltiplos cenários de geração é proposto em (C. Florez et al., 2014) solucionado pelo NSGA-II. O algoritmo NSGA-II é ainda aplicado no PET em (Maghouli et al., 2009, 2011). Uma abordagem para expansão conjunta da geração e transmissão é proposta em (Praveen et al., 2018) considerando investimento e confiabilidade via método determinístico como objetivos através do algoritmo *multi-objective grey wolf optimization* (MOGWO).

Apesar de ser um problema essencialmente multicritério, grande parte dos trabalhos citados abordam o PET como uma otimização de objetivo único, o que limita as metodologias na consideração de critérios importantes para a expansão como a confiabilidade. Embora alguns autores tenham abordado o problema multi-objetivo, técnicas de agrupamento de cenários são utilizadas devido ao menor esforço computacional. Na presente tese, é proposta uma ferramenta eficiente que permite uma abordagem multi-objetivo do PET com a utilização da SMC para representação de comportamentos estocásticos, o que possibilita redução nos sobreinvestimentos em planos ótimos de expansão devido à representação mais realista dos equipamentos.

#### 1.4.3. Avaliação da confiabilidade composta em sistemas elétricos

Um estudo de planejamento de sistemas de energia prevê a determinação de reforços de equipamentos com o propósito de atender o aumento da demanda e melhorar o nível de confiabilidade. No entanto, esses objetivos são conflitantes, visto que níveis altos de confiabilidade requerem altos investimentos, de modo que é necessário obter o melhor equilíbrio entre custo e confiabilidade, reconhecendo as incertezas de flutuação de carga e disponibilidade de equipamentos. Os principais conceitos envolvidos na avaliação da confiabilidade composta como caracterização dos estados do sistema, seleção de estados, estimativa de índices, consideração de incertezas, técnicas de redução

de esforço computacional são abordados em (M. V. F. Pereira et al., 1992), sendo este considerado um dos principais trabalhos nessa temática.

Frequentemente são encontrados trabalhos que avaliam o nível de risco dos sistemas por meio de cenários, como exemplo a saída de uma linha de transmissão através do critério de contingências N-1 (Gazijahani et al., 2018a; Ghadimi et al., 2022a; Praveen et al., 2018). No entanto, critérios determinísticos não apresentam dados quantitativos da adequação do sistema de modo que, se duas ou mais alternativas satisfazem tais critérios, não é possível determinar, do ponto de vista de adequação, a de melhor desempenho. Além disso, tais métodos não consideram a natureza aleatória de variáveis como falha de equipamentos, intermitência de fontes, o que pode acarretar em sobreinvestimentos nos planos de expansão (de Paula, de Oliveira, de Oliveira, et al., 2020; Leite da Silva, Rezende, Manso, et al., 2010).

Metodologias para estimação de índices de confiabilidade são as mais indicadas para a representação dos riscos citados (Billinton & Allan, 1996). Baseadas em técnicas probabilísticas, a enumeração de estados (Billinton & Wenyuan, 1991; Rei & Schilling, 2008) e a simulação Monte Carlo (SMC) (González-fernández et al., 2013; Ubeda & Allan, 1992) têm sido utilizadas para estimação de índices de desempenho. Entre os principais índices de confiabilidade estimados pode-se citar a probabilidade de perda de carga (LOLP), expectativa de energia não suprida (EENS) e índices relacionados à frequência (LOLF) e duração (LOLD) de perda de carga (Melo et al., 1992).

Segundo os autores em (Rei & Schilling, 2008), a enumeração de estados é geralmente simples e requer baixo esforço computacional, por outro lado a SMC é mais versátil para modelagem de aspectos aleatórios. Nesse trabalho, os autores retratam aspectos práticos quanto à aplicação dos dois métodos na estimação de índices para um sistema elétrico de grande porte no Brasil. Uma abordagem híbrida utilizando técnicas de enumeração e SMC é proposta em (Billinton & Wenyuan, 1991). O método apresentado é baseado na técnica de amostragem aleatória com uma abordagem analítica, sendo adequado para análise de sistemas de grande porte, podendo ser utilizado para inclusão de modelos multi-estados de geração. O estudo demonstra a relação dos índices de adequação do sistema com a carga, sendo proposto um procedimento para estabelecer relações entre a sensibilidade dos índices estimados e os patamares da curva de carga.

A estimação de índices de frequência e duração (F&D) é abordada em (Melo et al., 1992) e (Billinton & Li, 1993). No primeiro trabalho os índices são obtidos a partir de um modelo de SMC não sequencial. A metodologia utiliza multiplicadores de Lagrange para redução do esforço computacional, identificando as regiões de fronteira entre estados de falha e sucesso. O segundo trabalho apresenta uma técnica de simulação Monte Carlo em uma abordagem de transição de estados, de modo que o cálculo de frequência é feito sem um procedimento de enumeração adicional.

No problema PET, a confiabilidade pode ser considerada como restrição ou como objetivo. Em (Ghadimi et al., 2022a) a restrição de segurança busca encontrar soluções com boa relação entre custo de investimento e confiabilidade. Através da LOLC, os autores em (Leite da Silva, Rezende, da Fonseca Manso, et al., 2010) avaliam o custo da confiabilidade no problema de planejamento multiestágio em um *loop* externo ao de otimização após a identificação de  $n$  melhores soluções. Além da LOLP e EPNS, em (da Costa et al., 2021) é proposto um índice baseado em valor de risco (VaR) utilizando decomposição de Benders para dividir o PET em um subproblema de investimento e dois subproblemas que avaliam o custo de operação e a confiabilidade do sistema, avaliado por SMC. Uma abordagem de co-planejamento entre expansão da transmissão e alocação de dispositivos de armazenamento é proposta em (Kazemi & Ansari, 2022). Os autores avaliam o impacto de melhoria na confiabilidade do sistema em razão dos dispositivos de armazenamento e consideram o critério N-1 para restrição de segurança e N-2 para estimação da confiabilidade através da EENS. Em (de Paula, de Oliveira, Oliveira, et al., 2020) é proposto um modelo de PET multiestágio com restrições de segurança avaliados pelos índices de perda de carga – LOLP e índices relacionados à não utilização de energia renovável – LOWP e EWES.

A estimação de segurança através de índices de confiabilidade em alternativas de expansão tem sido ainda amplamente utilizada em diferentes abordagens multiobjetivo para o PET. Em (Ugranli & Karatepe, 2015) é utilizada uma modelagem de dados de carga e geração eólica através da técnica denominada *Agglomerative Hierarchical Clustering* para considerar as incertezas na estimação da EENS. A estrutura considera duas funções objetivo; custo de investimento associado à penalidade de energia não suprida; custo total de produção de geradores convencionais que compensam o corte de vento das fontes eólicas. O planejamento conjunto de geração e transmissão baseado em confiabilidade é encontrado em (Davoodi et al., 2021; Hamidpour et al., 2021). Em ambos



os trabalhos, os autores agregam a EENS como objetivo para o planejamento juntamente com os custos de investimento em novas linhas e unidades geradoras.

Ainda que métodos baseados em listas de contingência, como o critério N-1 utilizado em grande parte dos trabalhos descritos sejam preferíveis em estudos de expansão da transmissão devido ao seu baixo custo computacional, técnicas baseadas em amostragem como a SMC permitem a representação do comportamento estocástico de equipamentos e carga. Além disso, a literatura frequentemente aborda a confiabilidade como uma restrição ao problema PET e não como objetivo. Nesta tese é proposta uma formulação para consideração da confiabilidade a priori como objetivo no PET, ou seja, como parte da otimização estimada durante todo o processo de busca. Essa abordagem, embora complexa, visa evitar sobreinvestimentos nos sistemas uma vez que o real comportamento da carga e equipamentos é modelada através de uma eficiente ferramenta baseada em SMC.

#### 1.4.4. Redução de esforço computacional em simulação de confiabilidade

Metodologias baseadas em conceitos de probabilidade podem ser extremamente úteis na avaliação do desempenho de sistemas de energia (Billinton & Allan, 1996). Esses métodos são aplicados com sucesso em diversas áreas, como o planejamento da expansão de sistemas, avaliação da reserva operacional, sistemas de distribuição. Sua aplicação em sistemas compostos torna obrigatório saber o status de operação para cada estado do sistema, definido pela disponibilidade dos equipamentos.

A análise do estado operativo do sistema normalmente é feita a partir de fluxo de potência que define se esse estado é adequado ou não, ou seja, se é sucesso ou falha. No entanto, o custo computacional dessas análises depende de várias características do sistema, incluindo sua dimensão e o quão raro são os estados de falha (Leite da Silva et al., 2007). De modo a reduzir o esforço computacional para estimação de índices em abordagens baseadas em simulação Monte Carlo, a literatura tem dedicado diversos estudos ao longo do tempo.

Entre os métodos mais comuns de redução de esforço computacional em simulação Monte Carlo está a redução de variância. Os autores em (Singh et al., 2006) propõem uma perspectiva híbrida utilizando Monte Carlo e inteligência artificial para redução do tempo de simulação. Em (Leite da Silva et al., 2007) e (A. M. L. Da Silva et al., 2008), uma rede polinomial, chamada *Group Method Data Handling* (GMDH), é

usada para seleção dos dados de entrada para o conjunto de treinamento e teste da rede neural artificial. Um grande número de estados de sucesso é classificado por uma função polinomial simples (modelo de RNA), proporcionando reduções significativas no custo computacional.

Em (Da Rosa et al., 2012) os autores discutem o desenvolvimento de uma plataforma baseada em Sistemas Multi-Agentes (MAS) aplicados em processos de gerenciamento e simulação de sistemas de potência. Baseada em simulação Monte Carlo, o método proposto explora os benefícios da inteligência artificial construindo comportamentos autônomos de modo a mitigar o esforço computacional. São propostas duas abordagens diferentes para solução do problema de confiabilidade da geração utilizando o método de Monte Carlo sequencial.

Os autores de (Urgun & Singh, 2019) apresentam uma abordagem para avaliação da confiabilidade de sistemas compostos combinando simulação Monte Carlo e algoritmo *Multi Label K-Nearest Neighbor* (MLKNN). MLKNN é uma técnica de classificação na qual o vetor de destino de cada instância é atribuído a várias classes. Para esse artigo, o MLKNN é usado para classificar os estados de falha e sucesso de um sistema de potência sem a necessidade de análise de fluxo de potência, exceto na fase de treinamento.

Um método de avaliação da confiabilidade de sistemas compostos baseado em simulação Monte Carlo não sequencial por amostragem de estados usando algoritmo de otimização por enxame de partículas (PSO) é proposto em (Ashok Bakkiyaraj & Kumarappan, 2013). O problema de planejamento da confiabilidade foi formulado como um problema de otimização para minimizar o custo de interrupção e de investimento de componentes. O algoritmo PSO é empregado para minimizar o modelo de planejamento com base no índice de expectativa de demanda não suprida (EDNS) do sistema.

Apesar da maioria dos estudos para redução de esforço computacional em métodos probabilísticos concentrarem-se em técnicas de amostragem, em (Yong et al., 2019) é proposto um método de avaliação rápido de confiabilidade que acelera o cálculo de fluxo de potência ótimo usando programação linear multi-paramétrica (MPLP). Um algoritmo de aprendizagem dinâmica é aplicado para resolver o MPLP para avaliação de índices em um sistema IEEE e um sistema na China.

De acordo com os autores em (Geng et al., 2019), o método de Entropia Cruzada (CEM) pode efetivamente acelerar a avaliação da confiabilidade de sistemas de potência.

Neste artigo é proposto um CEM aprimorado que aborda dois problemas: a modelagem probabilística da função densidade de probabilidade (PDF) para as variáveis contínuas correlacionadas, amostragem por importância na PDF. Testes são conduzidos na avaliação do sistema MRTS e IEEE-RTS79. Em (Zhao et al., 2019) é apresentado um CEM com base no método sequencial para avaliação de sistemas compostos e estimação de índices de frequência e perda de carga.

Os autores em (Urgun et al., 2020) propõem uma abordagem de classificação de estados para o cálculo de índices de confiabilidade usando uma combinação de redes de função de base radiais multilabel (MLRBF) e amostragem por importância no contexto de simulação Monte Carlo. A característica de vários rótulos (multilabel) permite classificar os estados do sistema (sucesso ou falha) tanto em âmbito de barras quanto de sistema. Essa classificação não requer análise de fluxos de potência ótimo, exceto na fase de treinamento.

Em (N. Piandoriya, P. Jirutitijaroen, D. Srinivasan, 2011), é apresentado um método rápido e eficiente que combina simulação Monte Carlo e o classificador de máquina de vetores de suporte de mínimos quadrados (LSSVM), para avaliação de sistemas compostos. O LSSVM é usado para pré-classificar com precisão os estados operacionais como estados de sucesso e falha, definindo aqueles que serão avaliados pelo fluxo de potência DC para estimar os índices de confiabilidade.

De modo semelhante, (Resende et al., 2015) propõe uma metodologia para avaliar índices de confiabilidade de sistemas compostos de geração e transmissão baseados em *Support Vector Machines* (SVM), utilizadas para classificar dados em duas classes distintas (positiva ou negativa). Para isso, uma pré-classificação de estados é feita realizando treinamento de uma rede neural, onde os estados amostrados durante o início do método Monte Carlo não sequencial são considerados como dados de entrada para conjuntos de treinamento e validação. A partir desse procedimento, um grande número de estados é classificado a partir de uma simples avaliação da rede, o que proporciona uma redução significativa do número de análises de adequação por fluxo de potência ótimo e consequente redução do custo computacional.

É importante ressaltar que os trabalhos citados, que abordam técnicas de aprimoramento da SMC para estimação de índices de confiabilidade, não consideram sua aplicação no problema PET. Dessa forma, na presente tese, é utilizada uma ferramenta

baseada em máquina de vetor de suporte para aperfeiçoar o algoritmo de SMC para avaliação da confiabilidade composta utilizado na metodologia proposta para solução do PET. Além disso, é proposta a aplicação de uma nova variável de entrada para classificação de estados, baseada na geração renovável disponível por região do sistema.

#### 1.4.5. Fontes renováveis no PET

A presença cada vez maior de fontes renováveis variáveis na matriz energética, aliada à necessidade de redução na utilização de fontes de geração com altos custos de operação tende a forçar inevitáveis mudanças na topologia das redes de transmissão. No entanto, a intermitência de operação das fontes renováveis tem aumentado significativamente o nível de incertezas, contribuindo para uma operação menos segura no fornecimento de energia. Segundo dados do ONS (ONS, 2024), atualmente a penetração de geração eólica é de aproximadamente 13% da matriz brasileira. É esperado que ao fim de 2027, a capacidade instada do SIN seja de quase 247 GW, sendo que cerca de 55 GW sejam provenientes de fontes eólicas e fotovoltaicas centralizadas.

Para garantir uma operação segura dos sistemas, torna-se necessário o provisionamento de recursos que assegurem a qualidade e confiabilidade necessárias para o atendimento ao consumidor, frente às mudanças nos patamares tanto de carga quanto de geração variável ao longo do horizonte de operação. Em muitas situações, devido à incapacidade dos sistemas em absorver toda geração renovável, ocorre a interrupção de uso da geração renovável em um determinado instante de tempo. Um dos principais desafios de planejadores para maior aproveitamento da geração variável é a limitação de capacidade do sistema de transmissão (Billinton & Wangdee, 2007).

O tratamento das incertezas provenientes da intermitência de fontes necessita de abordagens diferenciadas para sua modelagem no problema de expansão da transmissão. Os modelos tradicionais de incorporação de variáveis ao problema, muitas vezes determinísticos, não são capazes de considerar o comportamento estocástico necessário. As abordagens estocásticas tem sido cada vez mais consideradas na obtenção de planos ótimos sob incertezas. Em (Park et al., 2015) os autores desenvolvem um modelo de programação estocástica de modo a considerar as incertezas no PET. A técnica de estimação de estados é incorporada ao modelo matemático de otimização pelos autores em (Moeini-Aghaie et al., 2012) para modelagem de incertezas associadas à carga e geração eólica.

Técnicas de *data clustering* (agrupamento de dados) têm sido consideradas na literatura para agrupar de cenários prováveis de geração eólica dados a partir de séries históricas de vento. Um dos mais conhecidos algoritmos de agrupamento é o *k-means*, inicialmente apresentado em (J. MacQueen, 1967). Trata-se de um método que necessita de parâmetros de inicialização, sendo, portanto, dependente de uma interação externa. Apesar disso, o *k-means* é bastante popular na literatura. Em (X. Zhang & Conejo, 2018) é proposto um planejamento de curto (incertezas na variabilidade e produção de energia eólica/solar, disponibilidade de equipamentos) e longo prazo (crescimento de carga). A solução é dada a partir de um algoritmo de decomposição de Benders e *k-means* para representação dos cenários de condições operacionais referentes às 8760 h do ano alvo. O agrupamento de séries históricas de vento para representação de cenários de carga e geração eólica é recentemente abordado em (de Paula, de Oliveira, de Oliveira, et al., 2020) e (Garcia-Cerezo et al., 2021) para solução do PET com incertezas.

Os métodos baseados em SMC para representação do comportamento variável de fontes renováveis frequentemente é abordada na literatura a partir de simulação de distribuições de probabilidade. Em (Orfanos et al., 2013) os autores usam decomposição de Benders e SMC para avaliar as incertezas de geração eólica e disponibilidade de equipamentos no problema PET. A distribuição Weibull de probabilidades representa as variações de vento determinadas por séries históricas. O método de Monte Carlo é aplicado em (Marmidis et al., 2008) para alocação ótima de geradores eólicos definida a partir de critérios de máxima produção de energia e custo mínimo de instalação. Em (Naderi et al., 2020) a SMC modela as incertezas de geração eólica em um problema de expansão combinando diferentes algoritmos evolutivos de otimização.

A consideração de fontes renováveis pode ainda ser feita através de índices que maximizam o uso da geração. Um dos termos mais conhecidos na literatura de planejamento é a minimização do corte de vento. A proposta do objetivo de minimização do corte de vento implica na maximização do aproveitamento da energia eólica, embora é sabido que, na prática, o corte de vento não leva o sistema a um estado de falha, mas deve ser evitado para aumentar o uso de geração renovável. O corte de vento é inserido no planejamento como objetivo em (Ugranlı & Karatepe, 2015) a partir da geração de cenários e em (Liu et al., 2021) utilizando teoria de superquantis de probabilidade para modelagem da potência de saída. Em (de Paula, de Oliveira, Oliveira, et al., 2020) e (Leite Da Silva et al., 2012) é proposto o índice de confiabilidade *expected wind energy spilled* (EWES). do

inglês expectativa de energia eólica não aproveitada, de modo a estimar o impacto do corte de vento na segurança do sistema via SMC não sequencial e o tradicional critério de contingências N-1, respectivamente.

Nos trabalhos descritos, técnicas baseadas em cenários e SMC são utilizadas para modelagem do comportamento da geração de fontes renováveis em estudos de expansão da transmissão. Embora ainda sejam consideradas incertezas relacionadas à disponibilidade de equipamentos através de índices como a EENS, os autores não o consideram como parte do problema de otimização. No presente trabalho, é proposta uma ferramenta que permite a consideração de múltiplas incertezas “*a priori*” no problema PET, capaz de representar de forma concomitante o comportamento da carga e fontes eólicas, bem como a disponibilidade de equipamentos de geração e transmissão através da SMC com considerável eficiência computacional, quando comparada com métodos convencionais.

#### 1.5. PUBLICAÇÕES DECORRENTES DA PESQUISA

Ao longo do desenvolvimento desta tese, os seguintes trabalhos decorrentes da pesquisa foram publicados em periódicos internacionais:

- <https://doi.org/10.1016/j.epsr.2022.108864>. Miranda, F. L., Oliveira, L. W., Oliveira, E. J., Nepomuceno, E. G., & Dias, B. H. (2023). Multi-objective transmission expansion planning based on Pareto dominance and neural networks. *Electric Power Systems Research*, 214, 108864.
- <https://doi.org/10.1007/s00202-024-02403-x>. Miranda, Felipe L. et al. Transmission expansion planning based on Pareto dominance considering load variation and wind power. *Electrical Engineering*, p. 1-12, 2024.

Foi ainda publicado o seguinte artigo em evento científico nacional:

- Miranda, F. L., Oliveira, L. W., Oliveira, E. J. Planejamento Multiobjetivo de Expansão da Transmissão baseado em Dominância de Pareto Considerando Geração Eólica. Congresso Brasileiro de Automática, Rio de Janeiro, Brasil, 2024.

#### 1.6. ESTRUTURA DO DOCUMENTO

O presente capítulo desta Tese apresentou sumariamente as principais linhas de abordagem do problema de expansão da transmissão e seus desafios relacionados ao comportamento não determinístico das variáveis envolvidas como variação da carga,

indisponibilidade de equipamentos e intermitência de fontes renováveis. Com base em eventuais lacunas identificadas em modelagens atuais do problema, foi apresentada a motivação para o desenvolvimento do trabalho bem como os objetivos desta pesquisa. Uma revisão bibliográfica destacou importantes metodologias da literatura para lidar com o problema PET e modelagem de incertezas.

O Capítulo 2 apresenta a metodologia de avaliação de segurança dos sistemas a partir de índices de confiabilidade como parte do problema PET. São descritos os conceitos básicos relacionados à consideração da confiabilidade no planejamento de sistemas e a implementação de Máquinas de Vetores de Suporte (SVM) como ferramenta de apoio à estimação de índices para avaliação da confiabilidade composta através do método de simulação Monte Carlo. Resultados parciais de sistemas-teste demonstram a eficácia de SVM's na obtenção de índices de desempenho dos sistemas.

A metodologia desenvolvida para formulação do PET multi-objetivo probabilístico é apresentada no Capítulo 3. Além da formulação matemática do problema é descrito o algoritmo implementado denominado *Non-Dominated - Monte Carlo Simulation* (ND-MCS) em sua versão básica e com consideração de múltiplas incertezas, *Improved Non-Dominated - Monte Carlo Simulation* (IND-MCS). Exemplos de aplicação da metodologia ilustram o desempenho do algoritmo que podem auxiliar a busca de soluções de boa qualidade para o PET considerando múltiplos objetivos e incertezas.

O Capítulo 4 é dedicado à apresentação de estudos de caso para verificação da eficácia da metodologia em estudos de expansão dos sistemas de transmissão. A metodologia é testada em diversos caso para conhecidos sistemas da literatura e seus resultados destacam ganhos relevantes de eficiência computacional para as abordagens descritas quando comparadas com técnicas tradicionalmente aplicadas. Os estudos de caso demonstram o potencial de aplicação da metodologia em estudos com elevada presença de incertezas.

No Capítulo 5 são apresentadas as principais conclusões desta Tese, destacando suas contribuições bem como os desafios de sua idealização para o PET. Destaca-se ainda possíveis futuros desenvolvimentos para aprimorar a técnica e permitir sua implementação de forma sistemática em formulações multicritério do problema.

Os Apêndices são dedicados a detalhes da formulação da Avaliação da Confiabilidade composta em sistemas, Máquinas de Vetores de Suporte, Otimização

Multiobjetivo, algoritmo GWO e Método *Fuzzy* de decisão. São ainda apresentados os dados determinísticos e estocásticos para os sistema-teste utilizados nos estudos de caso.

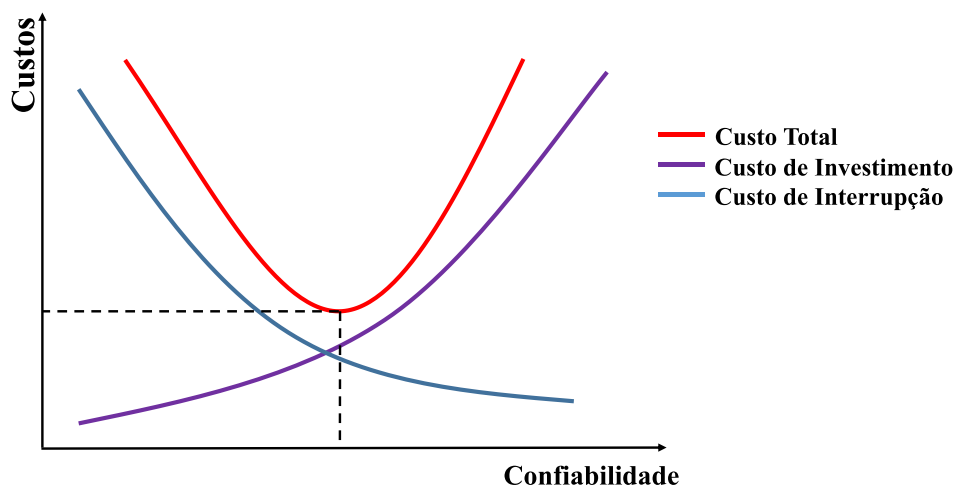


## 2. AVALIAÇÃO DA CONFIABILIDADE EM SISTEMAS ELÉTRICOS DE POTÊNCIA

Entre os desafios interpostos aos estudos de planejamento de um sistema elétrico tem-se a definição de estratégias de suprimento da demanda a níveis aceitáveis de segurança e com menores custos. Metodologias de avaliação da confiabilidade dos sistemas têm sido amplamente aplicadas como ferramentas de auxílio na determinação de planos de expansão com níveis adequados de segurança e, ao mesmo tempo, com tarifas reduzidas ao consumidor final em razão da minimização dos custos de investimento e operação da rede.

Confiabilidade e economia são pilares no processo de tomada de decisão em um estudo de planejamento de sistemas elétricos de potência. Por serem objetivos conflitantes a se alcançar, dizer quanto e como investir no sistema para se obter maior confiabilidade é uma tarefa complexa. A Figura 4 ilustra as curvas de *custos × confiabilidade* para um sistema elétrico de potência. Uma maior confiabilidade só é obtida com um aumento no custo de investimento, refletido pela diminuição no custo de interrupção.

Figura 4 – Curvas de custos × confiabilidade para um sistema elétrico de potência



Fonte: Elaborado pelo autor (2024)

O custo total de expansão será composto pela soma dos custos de investimento e interrupção, representado por uma curva cujo mínimo refere-se ao ponto ótimo de confiabilidade. Os métodos mais eficientes para estimação de índices de confiabilidade

em estudos de planejamento, como o Método de Monte Carlo apresentado neste capítulo, normalmente demandam um custo computacional limitante, de modo que grande parte dos estudos utiliza de métodos simplificados baseados em listas de contingências, como o critério “N-1”. Além disso, o crescente aumento das incertezas associadas à operação da carga e fontes variáveis pode dificultar ainda mais tal análise. Métodos baseados em inteligência artificial têm sido utilizados na literatura com o objetivo de reduzir o esforço computacional em análise de confiabilidade e podem ser associados a estudos de planejamento.

O objetivo desse capítulo é apresentar os conceitos e fundamentos da avaliação da confiabilidade em sistemas compostos de geração e transmissão, bem como a aplicação de inteligência artificial baseada em máquinas de vetores de suporte na avaliação da confiabilidade, elementos necessários para a compreensão da metodologia proposta no presente trabalho. Aspectos preliminares do problema de avaliação da confiabilidade de sistemas elétricos e níveis hierárquicos são descritos nas seções 2.1 e 2.2, respectivamente. A seção 2.3 apresenta as principais abordagens de inteligência artificial na literatura para avaliação da confiabilidade e a aplicação de máquinas de vetores de suporte é abordada na seção 2.4. Por fim, a seção 2.5 traz resultados preliminares de testes feitos no sistema IEEE-RTS e IEEE-RTS Modificado para demonstrar a aplicabilidade da técnica na estimação dos índices que serão utilizados na metodologia desta tese.

## 2.1. ASPECTOS PRELIMINARES

A avaliação da confiabilidade auxilia o planejador de sistemas em decisões mediante incertezas como eventos causados por interrupções forçadas, indisponibilidade de equipamentos e comportamento variável de carga e geração. A quantificação dessas incertezas, em geral, é traduzida em índices de confiabilidade que podem ser utilizados como critérios de relevância na tomada de decisão nos estudos de planejamento da expansão de sistemas. Historicamente, os estudos de confiabilidade seguem duas abordagens, determinística e probabilística (BILLINTON; ALLAN, 1996).

Na abordagem determinística, heurísticas baseadas em experiências de operação são utilizadas para quantificar a confiabilidade do sistema elétrico. Tais heurísticas são obtidas de experiências passadas das próprias operadoras do sistema e das características de operação. Entre essas, pode-se citar o critério N-1, amplamente utilizado na literatura que corresponde a uma avaliação de confiabilidade em que se assume a indisponibilidade

não simultânea dos equipamentos do sistema. O critério N-1 estabelece que a operação do sistema de transmissão deve ocorrer dentro dos padrões exigidos para condição normal, ou seja, sem contingências, bem como para todas as interrupções simples de linhas (Billinton & Allan, 1996). Na prática, devido às dimensões dos sistemas, é comum que os estudos de confiabilidade baseados nesse critério utilizem uma lista pré-definida e selecionada de contingências de maior impacto ao sistema (de Paula, de Oliveira, de Oliveira, et al., 2020). No entanto, deve-se destacar que planejar um sistema sob a premissa de que tais eventos de contingência necessariamente ocorrerão, ou seja, com 100% de probabilidade, pode implicar em sobreinvestimento na rede, aumentando os custos de expansão.

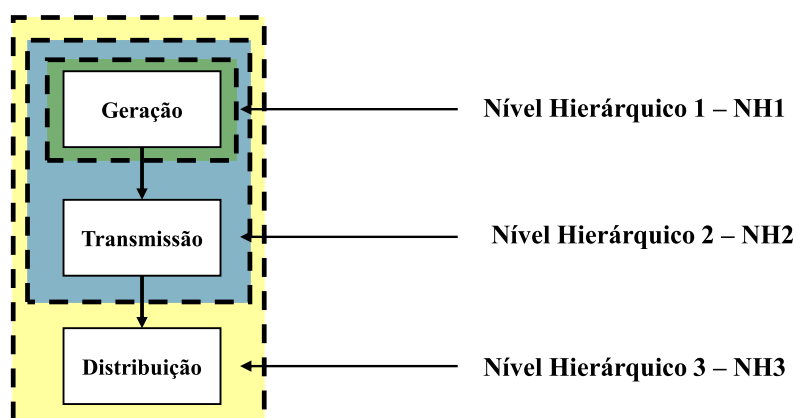
Já em uma abordagem probabilística, os equipamentos do sistema são modelados matematicamente de forma estocástica, ou seja, com base em comportamentos probabilísticos relacionados ao seu padrão de operação. Métodos baseados em abordagem probabilística assumem uma representação mais completa e realista do sistema em comparação às técnicas determinísticas pois levam em consideração as incertezas associadas à disponibilidade dos equipamentos (Billinton & Allan, 1996; M. V. F. Pereira et al., 1992). Neste contexto, métodos como a Simulação Monte Carlo estão entre as metodologias mais utilizadas na avaliação da confiabilidade de sistemas (Billinton & Li, 1994), especialmente de sistemas compostos de geração e transmissão. Segundo Billinton, os métodos baseados em Simulação Monte Carlo podem ser divididos essencialmente em duas abordagens: não sequencial e sequencial. A abordagem não sequencial baseia-se em amostragens aleatórias do sistema, de modo que a cronologia das ocorrências não é considerada, enquanto que na abordagem sequencial pode-se reproduzir ciclos de falha e reparo de equipamentos através de representação do tempo.

A abordagem probabilística, portanto, permite avaliar o risco de interrupções e as respectivas consequências das falhas para o sistema ou para um plano de expansão. No entanto, um dos grandes desafios enfrentados no emprego de técnicas baseadas em abordagens probabilísticas de confiabilidade está relacionado aos custos computacionais exigidos, especialmente em estudos de planejamento que demandam recursivas análises para diversas configurações e topologias da rede.

## 2.2. NÍVEIS HIERÁRQUICOS

Os sistemas elétricos de potência modernos apresentam alto grau de complexidade e dimensões consideravelmente elevadas. Dessa forma, os estudos de avaliação da adequação dos sistemas devem adotar modelagens distintas para equipamentos e técnicas de simulação diferentes em razão do nível de detalhamento desejado. Como consequência, os sistemas elétricos de potência podem ser divididos em zonas funcionais de geração, transmissão e distribuição (Billinton & Allan, 1996). Essas zonas podem ser combinadas para formar níveis hierárquicos para análise de confiabilidade, conforme Figura 5.

Figura 5 – Níveis hierárquicos para confiabilidade



Fonte: Elaborado pelo autor (2024)

Nos métodos de análise da confiabilidade da geração, ou nível hierárquico 1 (NH1), toda a carga e toda a geração estão concentradas em uma única barra e as limitações no transporte de energia pela rede de transmissão são ignoradas. O aumento das dimensões das redes de transmissão e das interconexões entre sistemas tornou necessária a representação do efeito das falhas compostas de geração e transmissão.

Nos estudos incluindo o nível hierárquico 2 (NH2), o modelo simplificado geração/carga é estendido para inclusão da transmissão, denominados por confiabilidade composta. Essa análise é muito mais complexa que a avaliação de sistemas de geração, pois aumenta o número de variáveis aleatórias envolvidas e a análise de desempenho de cada estado exige uma avaliação do estado operativo do sistema (Fluxo de Potência). Além disso, é necessário representar medidas corretivas baseadas em otimização, para suprir as violações decorrentes das falhas dos equipamentos.

O terceiro nível hierárquico (NH3) compreende a análise conjunta de todas as zonas funcionais do sistema. Entretanto, devido à complexidade e dimensões do problema, a avaliação da confiabilidade de sistemas de distribuição tem sido tradicionalmente desenvolvida separadamente dos sistemas de geração e transmissão. Embora as falhas ocorram muito mais na distribuição, falhas na geração e transmissão produzem danos muito maiores ao sistema, por isso são mais importantes. Além disso, com a reorganização dos sistemas aliado às inovações promovidas pela integração massiva de geração distribuída, a análise do nível hierárquico NH3 deve considerar a capacidade de geração distribuída em redes de distribuição (da Rosa et al., 2010).

### 2.3. AVALIAÇÃO DA CONFIABILIDADE COMPOSTA

A avaliação da adequação de sistemas de geração e transmissão, também conhecida como avaliação da confiabilidade composta, está contida no nível hierárquico NH2 (M. V. F. Pereira et al., 1992). Dessa forma, além da modelagem de geradores e da carga do sistema, os equipamentos de transmissão também estão presentes, de modo que um número muito maior de restrições como limites de tensão, limites de carregamento dos circuitos e considerações de potência ativa e reativa devem ser consideradas.

A partir da consideração concomitante de sistemas de geração e transmissão é possível capturar, de forma mais precisa, os efeitos das cargas e recursos energéticos na avaliação da adequação de longo prazo do sistema. Uma falha envolvendo o subsistema de geração é caracterizada pela indisponibilidade de geração para atender à demanda de carga, de modo que o corte de carga é dado pela carga nominal do sistema e a capacidade de geração disponível. Já uma falha no subsistema de transmissão ocorre quando há corte de carga, apesar de disponibilidade de geração suficiente para atendimento à demanda. O restante das falhas é provocado por faltas simultâneas de geração e transmissão.

A falha de um equipamento do sistema é uma ocorrência imprevisível (não determinística), por esse motivo, não se pode prever quando ocorrerá, mas é possível estimar um número de vezes em que irá falhar em um determinado tempo. Portanto, métodos probabilísticos são amplamente aplicados para avaliar a confiabilidade de tais sistemas. A avaliação da confiabilidade composta de sistemas elétricos se sustenta basicamente em 3 estágios:

- Seleção dos estados a serem avaliados;
- Avaliação da condição de operação do estado, incluindo, caso exista, o cálculo de corte de carga;
- A estimação dos índices de confiabilidade do sistema.

Cada estado de um sistema de potência pode ser representado por um vetor  $X = (x_1, x_2, \dots, x_n)$  onde  $x_i$  é o estado do  $i$ -ésimo equipamento. Conhecendo-se o espaço de estados dos equipamentos, suas probabilidades de ocorrência e suas falhas estatisticamente independentes, é possível determinar a probabilidade do estado  $P(x)$  como o produto das probabilidades individuais de cada componente.

O desempenho de cada estado é avaliado por meio de funções testes  $F(x)$ , com o objetivo de verificar se determinada configuração de equipamentos é capaz de atender os requisitos de sucesso do sistema. Como  $X$  é um vetor aleatório,  $F(x)$  é uma variável aleatória, cujo valor esperado é dado pela Equação 2.1:

$$E(F) = \sum_{x \in X^{eq}} F(x)P(x) \quad (2.1)$$

onde  $X^{eq}$  é o conjunto de vetores de estados dos equipamentos.

#### 2.4. SIMULAÇÃO MONTE CARLO NÃO-SEQUENCIAL

Baseado na representação de estados, a Simulação Monte Carlo Não-Sequencial (SMCNS) corresponde à amostragem de “retratos” dos estados dos componentes do sistema. A confiabilidade desses estados é estimada a partir de exploração estocástica do espaço de estados. Uma vez conhecidas as distribuições de probabilidade dos componentes, com base em uma representação Markoviana, é possível determinar o valor das Funções-Teste associadas aos estados.

Como exemplo, as probabilidades de ocorrência dos estados de falha ( $P_{DN}$ ) e operação ( $P_{UP}$ ) são conhecidas. Desta forma, o estado de cada componente é determinado por um número amostrado a partir de uma distribuição uniforme  $U[0,1]$ , como na Equação 2.2. Se  $P(x_i) \leq P_{DN}$ , então o componente  $i$  está falhado, caso contrário, está em operação. Determina-se então o vetor  $x$  composto por  $m$  componentes, sua probabilidade  $P(x)$  e as Funções-Teste  $F(x)$  (Billinton & Allan, 1996).

$$P(x_i) = U \quad U = 1, \dots, m \quad (2.2)$$

O valor esperado da Função-Teste associada aos estados  $x^\xi$  dos componentes,  $\tilde{E}(x)$ , é calculado pelo seguinte estimador, para  $NS$  amostras (Billinton & Allan, 1996):

$$\tilde{E}(F) = \frac{1}{NS} \sum_{k=1}^{NS} F(x^k) \quad (2.3)$$

Uma vez que  $F(x)$  é uma variável aleatória, a estimativa ou média amostral acima é uma variável aleatória com variância dada por:

$$V(\tilde{E}(F)) = \frac{V(F)}{NS} \quad (2.4)$$

Em que  $V(F)$  é a variância amostral da função  $F(x)$ . A Equação 2.4 confirma a noção intuitiva de que a precisão do experimento é tão melhor quanto maior for o número de amostras analisadas. A incerteza do processo é normalmente representada pelo coeficiente de variação, dado por:

$$\beta = \frac{\sqrt{V(\tilde{E}(F))}}{\tilde{E}(F)} \times 100\% \quad (2.5)$$

A convergência do processo de simulação é verificada pelo coeficiente  $\beta$ .

A Equação 2.3 é válida para qualquer Função-Teste. Como exemplo, para os índices LOLP e EPNS tem-se:

$$F_{LOLP}(x^k) = \begin{cases} 0, & \text{se } x^\xi \text{ é estado de sucesso} \\ 1, & \text{se } x^\xi \text{ é estado de falha} \end{cases} \quad (2.6)$$

$$F_{EPNS}(x^k) = \begin{cases} 0, & \text{se } x^\xi \text{ é estado de sucesso} \\ \Delta P, & \text{se } x^\xi \text{ é estado de falha} \end{cases} \quad (2.7)$$

Onde  $\Delta P$  é o valor do corte de carga no estado  $x^\xi$ .

Um algoritmo para implementação da simulação não-sequencial é apresentado a seguir (Melo et al., 1992):

- a) Faça o número de sorteios  $NS = 0$ ;
- b) Sorteie um vetor  $x^\xi \in X$  a partir de sua distribuição de probabilidade  $P(x^\xi)$ ;
- c) Atualize  $NS$ ;
- d) Calcule  $F(x^\xi)$  para o vetor amostrado;
- e) Estime  $\tilde{E}(F)$  como a média dos valores encontrados;
- f) Calcule a incerteza relativa através do coeficiente de variação ( $\beta$ ) da estimativa  $\tilde{E}(F)$ ;
- g) Se ( $\beta$ ) é menor que a tolerância, pare, senão, retorne ao passo b).

Para o nível hierárquico NH2, uma avaliação a partir de um fluxo de potência ótimo torna-se necessário. No entanto, recorrer à um problema de otimização para cada estado avaliado torna o problema de difícil convergência em razão do elevado esforço computacional requerido. Inicialmente, basta apenas classificar o estado como de sucesso através de um simples fluxo de potência, uma vez que sua solução é mais rápida que de um fluxo de potência ótimo. Quando limites operativos são violados pelos despachos base a otimização torna-se necessária para readequar o ponto de operação do sistema redistribuindo os fluxos e redespachando geradores. Com isso, se obtém de forma direta o corte de carga em caso de estado de falha. A pré-avaliação do sistema a partir de um fluxo de potência comum e depois a um fluxo de potência ótimo denomina-se como uma abordagem “tradicional” (M. V. F. Pereira et al., 1992), que engloba a avaliação do sistema representado por equações lineares ou não linearizado (Gomes & Saraiva, 2019; Ugranli & Karatepe, 2015; Zolfaghari Moghaddam, 2019).

Mesmo com a abordagem de pré-avaliação, os tempos computacionais para avaliação da confiabilidade composta através da Simulação Monte Carlo podem ser muito elevados, principalmente para sistemas robustos, ou seja, que apresentam eventos de falha raros. Uma característica atrativa da Simulação Monte Carlo não-sequencial é a independência entre o número de amostras ( $NS$ ) utilizados para estimar  $\tilde{E}(F)$  e o número de estados  $X' \subseteq X$ . Já sua principal limitação encontra-se no fato de que o esforço computacional aumenta com o quadrado da precisão desejada ( $NS \propto \beta^2$ ). Dessa forma, para aumentar sua eficiência, técnicas de redução do esforço computacional têm sido



amplamente utilizadas na literatura, como a identificação de padrões por Máquinas de Vetores de Suporte.

## 2.5. AVALIAÇÃO DA CONFIABILIDADE BASEADA EM MÁQUINAS DE VETORES DE SUPORTE (SVM)

Os métodos de avaliação da confiabilidade em grande parte classificam os estados de operação em dois grupos: falha e sucesso. O sistema está em estado de sucesso quando é capaz de atender a demanda de carga, sem violação de limites operacionais, enquanto que no estado de falha há corte de carga por insuficiência de geração ou violação de limites. Para grandes sistemas, o método de simulação Monte Carlo não-sequencial apresenta uma maior eficiência computacional quando comparada com métodos como o de Enumeração de Estados.

No entanto, o custo computacional da simulação Monte Carlo não-sequencial depende de várias características do sistema como: i) a dimensão da rede, que afeta o esforço computacional utilizado nas análises de adequação dos estados amostrados, ii) a raridade dos estados de falha, o que modifica o processo de convergência dos índices estimados (Resende et al., 2015). Tendo em vista a constante evolução dos sistemas e agregação de novas variáveis ao problema de planejamento, muitos estudos estão disponíveis na literatura para redução do esforço computacional.

Métodos baseados em inteligência artificial e aprendizado de máquina têm sido amplamente abordados na literatura em virtude do desenvolvimento de sistemas de análise capazes de adquirir conhecimento de forma automática. Na avaliação da confiabilidade, técnicas de Redes Neurais polinomiais (GMDH) (Leite da Silva et al., 2007), Fluxo de Potência Ótimo *Fuzzy* (Tome Saraiva et al., 1996), redução de variância (ANDERS, 1990), Redes Neurais baseadas em mapas de auto-organização (SOM) (Luo et al., 1999) são utilizadas como metodologias para classificação de estados de falha e sucesso dos sistemas.

As Máquinas de Vetores de Suporte (SVM) compõem uma técnica fundamentada na Teoria da Aprendizagem Estatística que pode ser utilizada na redução do esforço computacional em análises que exigem avaliações repetidas, como a avaliação da confiabilidade por simulação Monte Carlo não-sequencial. As SVM's são usadas para classificar dados em classes distintas – positivo e negativo, o que permite classificar os estados operativos dos sistemas como falha ou sucesso. Para isso, um conjunto de estados

é inicialmente gerado para serem utilizados como dados de entrada para grupos de treinamento e validação (Resende et al., 2015). Dessa forma, é possível classificar estados a partir de avaliações simples da rede, o que garante expressiva redução do esforço computacional na estimação dos índices de confiabilidade. O Apêndice A traz os principais aspectos matemáticos a respeito das SVM's.

## 2.6. APLICAÇÃO DE SVM'S NA AVALIAÇÃO DA CONFIABILIDADE COMPOSTA

Nas metodologias probabilísticas de avaliação da confiabilidade como a simulação Monte Carlo são requeridas sucessivas análises de fluxo de potência com otimização de medidas corretivas para definir se o estado avaliado é de falha ou de sucesso. A capacidade da inteligência artificial em distinguir esses estados baseia-se em grupos de estados treinados que apresentem características bem definidas. Durante a fase de treinamento, o método de classificação deve ser capaz de capturar esses padrões e classificá-los corretamente.

Para as SVM's, diversas variáveis podem ser utilizadas como dados de entrada para treinamento e classificação dos estados do sistema. É possível utilizar por exemplo a carga do sistema, a reserva de geração disponível, fluxos de potência nos circuitos, disponibilidades de equipamentos de geração e transmissão, etc. Em (Leite da Silva et al., 2007), a reserva de geração por área, a capacidade indisponível de geração por área e a capacidade indisponível total foram utilizadas como variáveis para treinamento da rede neural GMDH. Já em (L. C. Resende, 2008) foram adotadas a carga total e reserva de geração do sistema. A principal razão para escolha destas variáveis é a robustez apresentada na relação com os estados do sistema (Leite da Silva et al., 2007).

### 2.6.1. Dados de entrada

A distinção entre estados de sucesso e estados de falha pela SVM se baseia em um conjunto de variáveis do problema que apresenta padrões característicos bem definidos entre esses estados. Durante a fase de treinamento a rede deve capturar estes padrões e armazená-los em um banco de dados para efetuar corretamente as classificações quando aplicada a um sistema e seus estados amostrados.

Diversas combinações de variáveis podem ser consideradas como dados de entrada no problema de classificação dos estados. Como exemplo em sistemas elétricos

de potência, pode-se citar: a carga do sistema, a reserva de geração disponível, as injeções de potência nas barras, os fluxos de potência nos circuitos, as indisponibilidades de equipamentos de geração e de transmissão, capacidade de transmissão indisponível, etc. Nesta tese, foram realizadas quatro análises a partir da combinação dessas variáveis de modo a definir o conjunto de dados que melhor fornecesse resultados positivos de classificação quando aplicados na avaliação da confiabilidade composta de sistemas através da Simulação Monte Carlo não-sequencial. São elas:

#### **Análise 1**

- Soma das gerações por área;
- Soma das cargas por área;

#### **Análise 2**

- Soma das gerações por área;
- Soma das cargas por área;
- Geração indisponível por área;

#### **Análise 3**

- Soma das gerações por área;
- Soma das cargas por área;
- Reserva de geração por área;

#### **Análise 4**

- Soma das gerações por área;
- Soma das cargas por área;
- Capacidade de transmissão indisponível por área.

A definição dessas variáveis, comumente adotadas na literatura no treinamento de redes neurais para classificação de estados (Leite da Silva et al., 2007) busca capturar o impacto da disponibilidade de geração e características da carga, bem como da disponibilidade das linhas de transmissão nos estados de falha, uma vez que, normalmente, a indisponibilidade de equipamentos em áreas específicas do sistema naturalmente acarretam em estados de falha. Dessa forma, a rede armazena tais informações para classificação dos estados.

#### **2.6.2. Dados de treinamento**

Os dados para o treinamento e validação da rede SVM são gerados a partir de um conjunto de estados amostrados pela simulação Monte Carlo não sequencial. O tamanho

desse conjunto, ou seja, a quantidade de estados avaliados pertencentes a ele, é definido por meio da experiência advinda de testes preliminares. Para este trabalho foi definido um conjunto de 300 amostras. Em sistemas com baixas probabilidades de falha, a amostra de dados deverá possuir um número de estados de sucesso superior ao de estados de falha. Isto pode dificultar a captura de padrões corretos do sistema, principalmente relacionados aos estados de falha (Leite da Silva et al., 2007). Por esse motivo, foi adotado o critério de recolher dois casos de sucesso para cada caso de falha (200 de sucesso e 100 de falha).

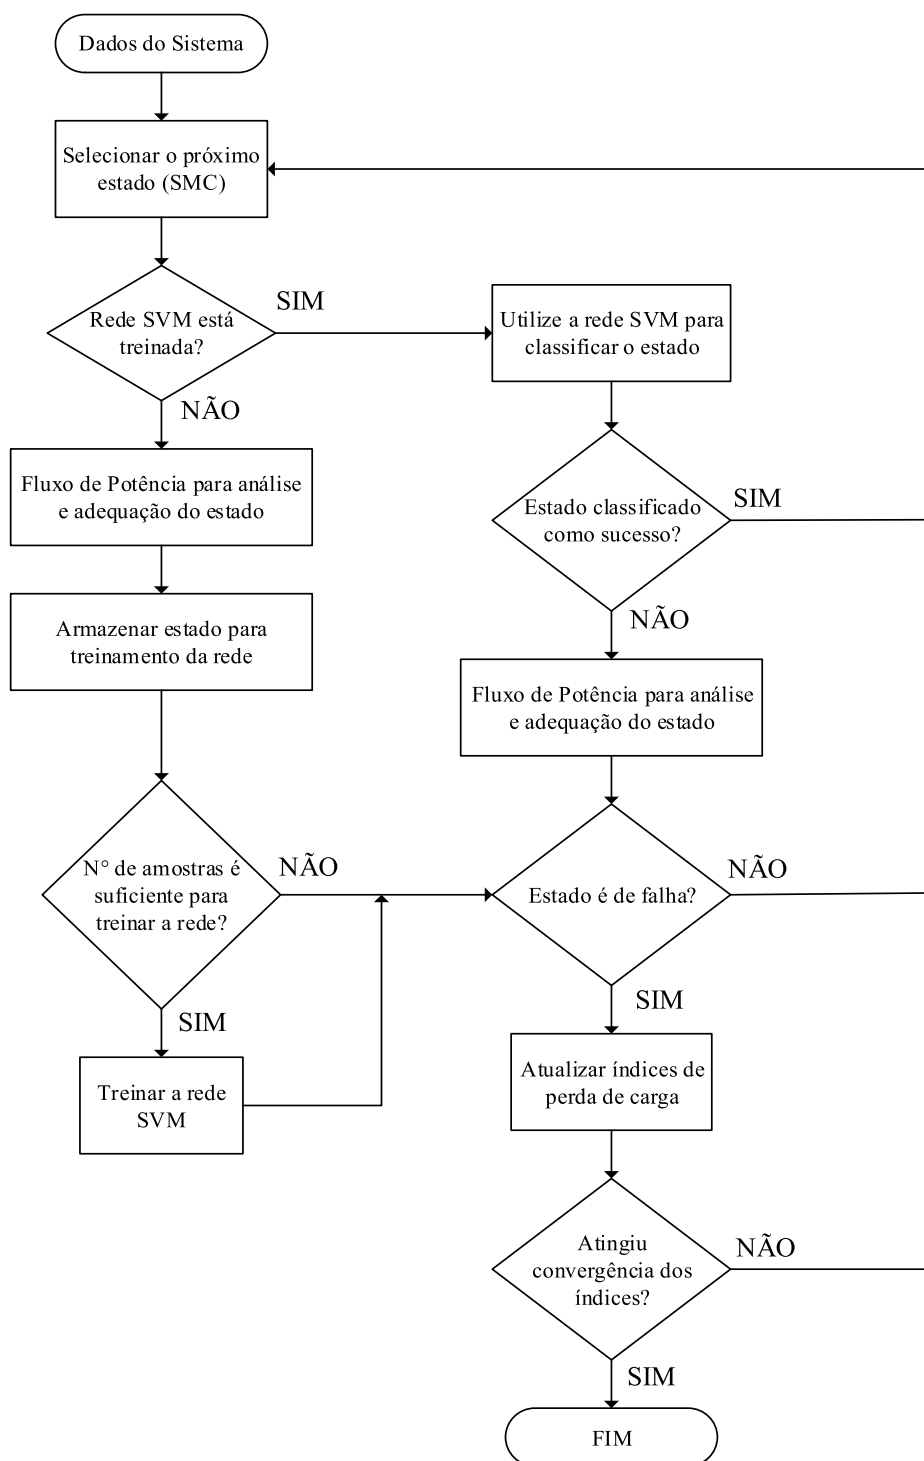
É importante ressaltar que conjuntos de treinamento muito grandes se tornam computacionalmente inviáveis, visto que durante o processo de obtenção do hiperplano ótimo de separação das classes pelo SVM, é necessária a inversão de uma matriz  $N \times N$ , onde  $N$  é o número de amostras do conjunto de treinamento. Os valores numéricos -1 e +1 foram adotados para representar as saídas desejadas para os estados de falha e sucesso, respectivamente.

### 2.6.3. Análise de desempenho da rede SVM

Em uma rede SVM cem por cento confiável, todos os estados classificados como negativos (-1) são efetivamente estados de falha. Da mesma forma, todos os estados classificados como positivos (+1) são efetivamente estados de sucesso. No entanto, podem ocorrer erros de classificação e, para evitá-los, são considerados como sucesso todos os estados classificados pela rede com valores acima de um limiar predeterminado. A obtenção desse limiar é feita automaticamente considerando-se o número de estados classificados como sucesso.

Destaca-se que a rede efetivamente só comete o erro quando um estado de falha é classificado como estado de sucesso, prejudicando o cálculo de estimação dos índices de confiabilidade. Caso um estado de sucesso seja classificado como de falha, a análise de adequação por meio de fluxo de potência será executada para esse estado, mas como não haverá corte de carga e a estimação dos índices não é afetada. No entanto, este último caso pode reduzir a eficiência computacional do método. A Figura 6 apresenta um fluxograma da técnica de SVM aplicada à simulação Monte Carlo não-sequencial utilizada nesta tese.

Figura 6 – Fluxograma da rede SVM



Fonte: Elaborado pelo autor (2020)

## 2.7. RESULTADOS

Nesta seção apresentam-se os resultados de validação para a aplicação da SVM na avaliação da confiabilidade composta por meio da Simulação Monte Carlo não-sequencial. O sistema IEEE-RTS, bem como uma versão modificada desse sistema, são

utilizados para demonstrar a capacidade de classificação no problema de confiabilidade como ferramenta auxiliar na metodologia proposta nesta tese. As simulações foram implementadas no ambiente de computação numérica MATLAB<sup>®</sup>. Os tempos de processamento se referem a um processador Intel i5 e 2,2 GHz e 8 Gb de RAM.

### 2.7.1. Sistema IEEE-RTS

O sistema IEEE-RTS (Subcommittee, 1979) possui 24 barras e 34 ramos em seu caso base, distribuídos em duas áreas de tensão, 230 KV e 138 KV, sendo a produção constituída por geradores térmicos, hídricos e nucleares distribuídas entre 14 usinas, totalizando 3405 MW de potência instalada. O valor de pico anual da carga total do sistema atinge 2850 MW. Os resultados obtidos referem-se à curva anual de carga do sistema. Os dados estocásticos podem ser encontrados no Apêndice E.

Foram considerados dois estudos de caso considerando falhas múltiplas na transmissão. No primeiro, método de referência, os resultados são obtidos por meio da simulação Monte Carlo convencional, ou seja, sem aplicação da rede SVM. Já no segundo caso, a rede SVM é utilizada para classificar os estados na simulação Monte Carlo não-sequencial em cada uma das 4 análises descritas na seção 2.6.1. A Tabela 1 apresenta os valores encontrados para os índices LOLP e EPNS, tempo de simulação para o sistema e o número de fluxos de potência.

Tabela 1 – Resultados da SMC para o sistema IEEE-RTS

Análise	LOLP	EPNS	Tempo (s)	NFE
SMC Convencional	0,001	0,151	3419,09	141.566
1	0,001	0,151	369,08	768
2	0,001	0,151	421,61	768
3	0,001	0,151	416,68	768
4	0,001	0,151	420,90	809

NFE = N° de Fluxos de potência ótimo executados

Fonte: Elaborado pelo autor (2020)

Foram necessárias 141.566 execuções de fluxo de potência ótimo no caso referência, com um tempo de simulação de 3.419 (aprox. 57 min) segundos. É importante ressaltar que uma pré-análise dos estados por meio de um fluxo de potência linear é executada de modo a identificar violações do sistema para as configurações simuladas. Já com a aplicação da rede SVM o número de fluxos de potência ótimo executados nas quatro análises reduziu substancialmente, para em torno de 800 execuções. Além disso, o

tempo de simulação com a aplicação da rede SVM reduziu-se para em torno de 400 segundos (aprox. 6 min), o que pode ser considerado um ganho expressivo em custo computacional. A Tabela 2 apresenta os desvios percentuais para os índices, redução de tempo e redução de número de fluxos de potência ótimo para cada uma das análises, comparadas ao método convencional de referência.

Tabela 2 – Desvios percentuais da SMC para o sistema IEEE-RTS

Desvios Percentuais				
Análise	LOLP(%)	EPNS(%)	Tempo (%)	NFE(%)
1	0,00	0,00	89,21	99,46
2	0,00	0,00	87,67	99,46
3	0,00	0,00	87,81	99,46
4	0,00	0,00	87,69	99,43

NFE = Número de fluxos de potência ótimo executados

Fonte: Elaborado pelo autor (2020)

Os desvios nos índices nas quatro análises consideradas foram desprezíveis, de modo que é possível dizer que foram encontrados os mesmos resultados da simulação Monte Carlo convencional. A redução de tempo de simulação, em torno de 90%, torna a rede SVM altamente eficaz para estimação de índices no sistema IEEE-RTS. Essa redução de esforço computacional ocorre, pois, a quantidade de estados de falha para as condições de simulação consideradas é muito pequena, o que pode ser observado no percentual de redução do número de fluxos de potência ótimo executados. O desempenho da rede para o sistema IEEE-RTS pode ser verificado na Tabela 3.

Tabela 3 – Desempenho da rede SVM para o sistema IEEE-RTS

Análise	VP	VN	FP	FN	Tace(%)
1	200	100	0	0	100,00
2	200	100	0	0	100,00
3	199	100	0	1	99,67
4	200	100	0	0	100,00

VP = verdadeiro Positivo, VN = Verdadeiro Negativo

FP = Falso Positivo, FN = Falso Negativo

Tace(%) = Taxa de Acerto da rede SVM

Fonte: Elaborado pelo autor (2020)

Para um conjunto de treinamento de 300 estados e, considerando dois estados de sucesso para cada estado de falha, tem-se para a amostra descrita, 200 estados de sucesso e 100 estados de falha. Os estados classificados como verdadeiros (positivo ou negativo)

são considerados como classificações corretas pelo SVM. Os estados classificados como Falso Positivo foram classificados como sucesso, mas são de falha. Esse erro da rede compromete a estimação dos índices. Já os estados classificados como Falso Negativo foram classificados como falha, mas são de sucesso. Esse erro da rede não compromete os índices, no entanto reduz o desempenho computacional.

Percebe-se que, para o sistema IEEE-RTS, praticamente não há erros de classificação (exceto 1 caso de Falso Negativo na Análise 3), o que corresponde a taxas de acerto de praticamente 100% em todas as análises. É importante ressaltar que o caso único de erro de classificação, em que um estado de sucesso tenha sido classificado como falha, não compromete a estimação de índices e, por esse motivo, os desvios percentuais em relação ao método referência são desprezíveis.

### 2.7.2. Sistema IEEE-RTS Modificado

O sistema IEEE-RTS Modificado é amplamente utilizado na literatura e basicamente consiste em dobrar a demanda e a capacidade de geração com o objetivo de reduzir sua confiabilidade e aumentar a dificuldade em problemas de planejamento da expansão da transmissão. Naturalmente tal modificação reduz a robustez do sistema e compromete o sistema de transmissão, o que impacta na predição de estados pelas análises descritas anteriormente para o sistema original.

A Tabela 4 apresenta os resultados para os índices LOLP e EPNS, número de fluxos de potência executados e tempo de simulação para o sistema no método de referência e para as quatro análises considerando a rede SVM. As análises consideram a curva anual de carga descrita para o sistema IEEE-RTS original.

Tabela 4 – Resultados da SMC para o sistema IEEE-RTS Modificado

Análise	LOLP	EPNS	tempo(s)	NFE
SMC Convencional	0,005	0,706	1564,87	55.822
1	0,004	0,670	239,13	3.513
2	0,004	0,670	247,35	3.496
3	0,004	0,670	251,73	3.492
4	0,005	0,696	213,57	2.617

NFE = Número de fluxos de potência ótimo executados

Fonte: Elaborado pelo autor (2020)

A princípio, observa-se que há um aumento dos índices de confiabilidade se comparados com o sistema original, uma vez que as modificações descritas tornam o



sistema menos confiável, o que acarreta em um maior número de eventos de falha e corte de carga. Para o caso referência foram necessárias 55.822 avaliações de fluxo de potência ótimo e um tempo de 1.564,8 (aprox.26 min) segundos para estimação dos índices apresentados. Já com a aplicação da rede SVM ocorreu uma redução substancial do número de fluxos de potência ótimo executados e, conseqüentemente, de tempo de simulação. A Tabela 5 apresenta os desvios percentuais para os índices, redução de tempo e redução de número de fluxos de potência para cada uma das análises, comparadas ao método convencional de referência.

Tabela 5 – Desvios percentuais da SMC para o sistema IEEE-RTS Modificado

Desvios Percentuais				
Análise	LOLP(%)	EPNS(%)	tempo(%)	NFE(%)
1	18,34	5,16	84,72	93,71
2	18,34	5,16	84,19	93,74
3	18,34	5,16	83,91	93,74
4	5,31	1,42	86,35	95,31

NFE = Número de fluxos de potência ótimo executados

Fonte: Elaborado pelo autor (2020)

Um desvio em torno de 18% para o índice LOLP é verificado nas Análises 1, 2 e 3, enquanto que a Análise 4 apresenta um desvio de cerca de 5% em torno do método de referência. A Análise 4 é única que utiliza a capacidade indisponível de transmissão como variável de entrada no processo de treinamento da rede, conforme descrito na Seção 2.6.1. Embora no sistema original todas as análises tenham apresentado bom desempenho, a estimação dos índices para o sistema em condições de maior estresse da rede de transmissão ressalta a importância dessa variável para uma predição mais assertiva do índice de perda de carga pelo método baseado em SVM. Para o índice EPNS os desvios de 5,31% são próximos da margem de incerteza do método de Monte Carlo adotada, de 5%. A redução do número de fluxos de potência ótimo executados é satisfatória, maior que 90%, o que leva a uma redução de mais de 80% no esforço computacional para as 4 análises descritas.

O desempenho da rede para o sistema IEEE-RTS Modificado pode ser verificado na Tabela 6. Considerando o conjunto de treinamento com 300 estados, o desempenho da rede SVM para esse sistema pode ser considerado satisfatório em virtude das taxas de acerto maiores que 90% para as 4 análises. No entanto, os desvios da LOLP identificados

na Tabela 6 podem ser interpretados pelo número de estados classificados como Falso Positivo para as Análises 1, 2 e 3.

Tabela 6 – Desempenho da rede SVM para o sistema IEEE-RTS Modificado

Análise	VP	VN	FP	FN	Tace(%)
1	193	82	18	7	91,67
2	193	82	18	7	91,67
3	191	87	13	9	92,67
4	194	90	10	6	94,67

VP = verdadeiro Positivo, VN = Verdadeiro Negativo

FP = Falso Positivo, FN = Falso Negativo

Tace(%) = Taxa de Acerto da rede SVM

Fonte: Elaborado pelo autor (2020)

Por consequência desses resultados e testes com configurações variadas dos sistemas descritos, as variáveis de entrada para o treinamento da rede SVM descritas na Análise 4 são utilizadas nesta tese durante a aplicação da metodologia proposta. Tal escolha deve-se ao melhor desempenho dessas variáveis em condições de menor robustez dos sistemas, o que impacta significativamente a estimação dos índices de confiabilidade.

## 2.8. CONCLUSÕES PARCIAIS

Este capítulo apresentou o estado da arte da avaliação da confiabilidade composta de sistemas elétricos de potência. Além disso, foram apresentadas as Máquinas de Vetores de Suporte, SVM, como ferramenta de auxílio na avaliação da confiabilidade composta de sistemas elétricos de potência. Entre os pontos de interesse do capítulo, podem ser enfatizados:

- Modelagem probabilística dos componentes do sistema para estimação de índices de confiabilidade que podem ser utilizados como critérios de relevância na tomada de decisão nos estudos de planejamento da expansão de sistemas.
- Limitações do método de Simulação Monte Carlo relacionadas ao número de estados avaliados com base na precisão requerida para estimação da confiabilidade do sistema.
- Resultados satisfatórios da aplicação das SVM's na estimação de índices de confiabilidade em sistemas-teste como suporte à metodologia de planejamento proposta nesta tese.

### 3. PLANEJAMENTO MULTIOBJETIVO DA EXPANSÃO DA TRANSMISSÃO BASEADO EM CRITÉRIO DE DOMINÂNCIA

O objetivo do Planejamento da Expansão da Transmissão (PET) é adequar o sistema a partir de reforços adicionados para suprir a demanda crescente de carga e atender às restrições operacionais e de confiabilidade a um mínimo custo total. No entanto, conforme apresentado no Capítulo 2, uma redução no custo de interrupção de um sistema está associada a um aumento do custo de investimento. Dessa forma, custo de confiabilidade e custo de investimento são objetivos conflitantes no problema PET. A determinação de soluções de boa qualidade para expansão da transmissão baseada em objetivos distintos tem como base a aplicação de estratégias de otimização multiobjetivo.

Este capítulo apresenta, na Seção 3.1, a formulação multiobjetivo básica do problema PET, utilizando como funções objetivo o custo de investimento e o critério de confiabilidade baseado no índice EENS. Na Seção 3.2 é apresentado o método de otimização utilizado para a busca de soluções, o algoritmo “*Multi-objective Grey Wolf Optimizer (MOGWO)*”. O sistema teste Garver é utilizado na Seção 3.3 para demonstrar a capacidade do MOGWO em encontrar boas soluções, difundidas na literatura, além de considerar o critério de confiabilidade como parte do processo de busca. Na Seção 3.4, é apresentado o novo algoritmo ND-MCS proposto nesta tese para resolução do problema PET multiobjetivo baseado em critério de dominância de Pareto. Uma versão aprimorada desse algoritmo, denominado IND-MCS é apresentada na Seção 3.5, capaz de solucionar o problema PET com múltiplas incertezas com a mesma eficiência do algoritmo original, incluindo um terceiro objetivo – o índice EWES. Por fim, a Seção 3.6 ilustra exemplos tutoriais da atuação do algoritmo proposto em soluções encontradas para o sistema teste Garver.

#### 3.1. FORMULAÇÃO MULTIOBJETIVO DO PROBLEMA PET

O problema PET consiste na definição de reforços na transmissão tendo em vista o atendimento ao crescimento de carga futuro. De modo geral, o planejamento da expansão pode ser classificado como: a) *determinístico*, em que a adição de reforços é baseada essencialmente nos custos de investimento considerando a rede intacta ou uma lista de contingências (critério N-1); b) *probabilístico*, em que incertezas associadas ao

processo, como variabilidade da carga, indisponibilidade de equipamentos e intermitência de geração por fontes renováveis, são inseridas no problema de expansão.

Quanto à evolução temporal dos reforços, o PET pode ser: a) *estático*, em que se considera um único ano do planejamento (ano horizonte), determinando para um dado estágio de planejamento, a localização e dimensionamento dos reforços; b) *dinâmico*, em que um horizonte de planejamento é considerado, por exemplo 10 anos, levando em conta não somente a localização e o montante de capacidade, mas também a evolução cronológica das decisões de expansão.

Tradicionalmente, a abordagem do planejamento sob critérios determinísticos, como o N-1, baseia-se em análises das piores situações de operação associadas a contingências simples para planos candidatos à expansão do sistema. No entanto, metodologias determinísticas como o critério N-1 consideram uma probabilidade de 100% para ocorrência de contingências, o que acarreta em maiores estimativas de perda de carga e, conseqüentemente, mais reforços da rede de transmissão.

A razão para tal está no fato do problema não considerar os aspectos aleatórios inerentes à operação dos sistemas. Esses comportamentos podem ser capturados por métodos probabilísticos como a Simulação Monte Carlo não sequencial apresentada no Capítulo 2, que considera incertezas através de índices de confiabilidade a partir de parâmetros como taxas de falha, tempos médios de reparo e curvas de carga e geração variável, por exemplo.

A consideração da confiabilidade no problema PET pode ser realizada de duas formas: a) como *restrição*, em que são analisadas apenas soluções dentro de valores especificados de níveis de confiabilidade; b) como *parte da função objetivo*, em que o valor da confiabilidade é parte da função objetivo do problema de otimização. Além disso, a confiabilidade pode ser considerada “*a posteriori*”, em que a avaliação é feita somente para as melhores soluções definidas na etapa de otimização com base em critérios operativos e de investimento, ou “*a priori*”, em que todas as soluções geradas durante o processo de busca são avaliadas, o que naturalmente gera um grande esforço do ponto de vista computacional.

Conforme apresentado no Capítulo 2, custos de investimento e de confiabilidade são objetivos conflitantes a serem contemplados em um estudo de planejamento de sistemas. Dessa forma, de modo a obter melhores soluções conservando as características

estocásticas dos sistemas, nesta tese é proposto um método multiobjetivo para o problema estático de expansão da transmissão, em que se deseja obter um conjunto de soluções Pareto-ótimas com menor custo e maior confiabilidade. A consideração da confiabilidade é feita “*a priori*”, que tende a fornecer planos de expansão que evitem o sobreinvestimento. A proposta é determinar o número de novas linhas a serem adicionadas ao sistema, visando minimizar dois custos de expansão: ( $f_1$ ) custo mínimo de investimento; ( $f_2$ ) mínima expectativa de energia não suprida– EENS. As funções objetivo são modeladas em (3.1) e (3.2), sujeitas às restrições de rede e planejamento de (3.3) - (3.10), utilizando modelo linearizado de fluxo de carga, amplamente aplicado em formulações do PET (Alguacil et al., 2003; Gomes & Saraiva, 2019). Em sistemas de transmissão algumas simplificações são admitidas como desconsideração das resistências das linhas em relação à reatância e tensões de barra definidas como 1 pu, uma vez que as aberturas angulares são pequenas. Alguns estudos consideram as perdas para o modelo linear no PET através de um processo iterativo (H. Zhang et al., 2013).

$$f_1 = \text{Min} \left[ \sum_{k \in K^C} C_k^T I_k^T + \sum_{b \in B^D} ch \times hd_b \right] \quad (3.1)$$

$$f_2 = \text{Min}[EENS] \quad (3.2)$$

s.a.

$$\sum_{g \in G_b} pg_g - \sum_{k \in K_b} f_k + hd_b = d_b, \forall b \in B \quad (3.3)$$

$$f_k = I_k^T \left( -b_k \theta_{ij} + g_k \frac{(\theta_{ij})^2}{2} \right), \forall k \in K \quad (3.4)$$

$$|f_k| \leq \bar{f}_k \cdot u_k, \forall k \in K \quad (3.5)$$

$$0 \leq pg_g \leq \bar{p}g_g, \forall g \in G, \forall \quad (3.6)$$

$$0 \leq hd_b \leq d_b, \forall b \in B^D \quad (3.7)$$

$$I_k^T \in \{0,1\}, \forall k \in K^C \quad (3.8)$$

$$I_k^T = 1, \forall k \in K^E \quad (3.9)$$

$$EENS = EPNS \times 8760 \text{ (horas)} \quad (3.10)$$

A Equação 3.1 representa o custo de operação do problema PET, composta por uma parcela correspondente ao custo de investimento  $C_k^T$  na linha de transmissão  $k$ , determinadas pela variável binária  $I_k^T$  e por uma parcela relacionada à minimização do corte de carga  $hd_b$  na barra  $b$ , que possui um elevado custo de penalidade associado  $ch$ .  $K^C$  é o conjunto de linhas de transmissão candidatas à expansão e  $B^D$  é o conjunto de barras com carga conectada. A Equação 3.2 refere-se ao critério de confiabilidade relacionado à expectativa de energia não suprida – EENS.

O balanço de potência na barra  $b$  é restrito pela Equação 3.3, relacionado à aplicação da Primeira Lei de Kirchhoff, onde  $pg_g$  é a potência gerada no gerador  $g$  e  $G_b$  é o conjunto de geradores convencionais.  $f_k$  é o fluxo de potência que flui pela linha de transmissão  $k$ ,  $K_b$  é o conjunto de barras conectadas à barra  $b$ .  $d_b$  é a carga na barra  $b$ .

O fluxo de potência ativa nas linhas de transmissão  $I_k^T$  é avaliado pela Equação 3.4, que descreve a representação das perdas pelo modelo linearizado adotado. O fluxo de potência nas linhas é limitado pela Equação 3.5, em que  $b_k$  é a susceptância série do circuito;  $\theta_{ij}$  é a abertura angular de tensão nodal entre as barras  $i$  e  $j$ ;  $\bar{f}_k$  é o limite de capacidade de potência da linha de transmissão  $k$ ;  $u_k$  é a disponibilidade da linha de transmissão  $k$  e  $g_k$  é a condutância série da linha de transmissão  $k$ .

A potência ativa  $pg_g$  gerada pelos geradores convencionais conectados na barra  $g$  é limitada pela Equação 3.6. O corte de carga  $hd_b$  na barra  $b$  é representado por uma geração fictícia de alto custo de despacho (penalidade  $ch$ ) cuja capacidade é limitada pela carga  $d_b$  na Equação 3.7.

A Equação 3.8 representa a variável binária de investimento  $I_k^T$  para a linha de transmissão  $k$  candidata. A Equação 3.9 representa a variável binária  $I_k^T$  como 1 para as linhas de transmissão existentes, onde  $K^E$  é o conjunto de linhas de transmissão existentes no caso base. O índice de interrupção de energia é formulado na Equação 3.10, baseado no índice de expectativa de potência não suprida pelo sistema - EPNS. As propriedades e conceitos relacionados à otimização multiobjetivo, necessárias para entendimento da metodologia proposta, são apresentadas em detalhes no Apêndice B, destacando o conceito de dominância e condições de otimalidade de Pareto.

### 3.2. MÉTODO DE OTIMIZAÇÃO IMPLEMENTADO: MOGWO

No contexto da otimização multiobjetivo as metaheurísticas são bastante populares na busca de conjuntos de soluções, uma vez que tais problemas são considerados difíceis ou de complexa implementação por métodos clássicos de otimização, visto que muitos desses métodos são baseados no gradiente da função e abordagens de programação matemática, bem como no comportamento e na organização de certos sistemas naturais.

Nesta tese, é utilizado o algoritmo *Grey Wolf Optimizer* (GWO) proposto em (Mirjalili et al., 2014) no processo de busca de soluções na metodologia proposta. Esse algoritmo é proposto sob duas variantes: algoritmo mono-objetivo *Grey Wolf Optimizer* (GWO); algoritmo *Multi-objective Grey Wolf Optimizer* (MOGWO) (Mirjalili et al., 2016). A variante multiobjetivo é utilizada neste trabalho e sua compreensão no problema PET é descrita em etapas na sequência. As propriedades desses algoritmos, bem como seus pseudocódigos, são apresentadas em detalhes nas seções C.1 e C.2 do Apêndice C, respectivamente.

Originalmente, o algoritmo MOGWO utiliza codificação real na representação de seus indivíduos, ou seja, para problemas com variáveis contínuas. No problema PET considerado os indivíduos representam a posição de linhas de transmissão que podem ser instaladas nos sistemas. De modo a tornar possível a representação da posição dos ramos candidatos no algoritmo, as seguintes etapas são seguidas:

#### **Etapa 1: Inserção de Dados**

Nessa etapa são inseridos os parâmetros iniciais do algoritmo MOGWO como o número de indivíduos -  $T$ , tamanho da população -  $\eta$ , dimensão do repositório de indivíduos não dominados -  $\Psi$ , parâmetro de inflação de grade -  $\alpha$ , parâmetro de pressão de seleção de líder -  $\beta$ , número de grades por dimensão -  $nGrid$ .

#### **Etapa 2: Inicialização da População**

Por se tratar de uma metaheurística bio-inspirada, a população inicial do MOWGO é gerada randomicamente e composta por  $\eta$  indivíduos, representados por suas respectivas posições de ramos candidatos. Dessa forma, cada indivíduo é representado por um vetor cuja dimensão é dada pelo número de ramos alternativos possíveis do sistema elétrico. De modo a conservar as características estocásticas do método, a cada

rodada de simulação uma nova população inicial é gerada. A representação de um indivíduo da população é dada na Equação 3.11.

$$\vec{X} = [x_1^p, x_2^p, \dots, x_{NT}^p] \quad (3.11)$$

onde  $NT$  é o número total de ramos alternativos para expansão do sistema.

### **Etapa 3: Avaliação da população**

Na etapa de avaliação é obtida a função *fitness* para cada indivíduo. Para o problema multi-critério proposto são adotadas inicialmente as duas funções objetivo descritas na Equações 3.1 e 3.2 que representam o custo de investimento e o índice EENS, respectivamente. A avaliação dos critérios é sequencial, de modo que a estimação do índice de confiabilidade só ocorre após a pré-avaliação do indivíduo pelo fluxo de potência linear que determina a existência de cortes de carga e/ou redespacho de geração necessários. Indivíduos que não apresentam corte de carga são considerados aptos e avaliados quanto ao custo de investimento e submetidos ao método de SMC para estimação da EENS. Caso sejam identificados cortes de carga para o plano de expansão em análise, a penalidade  $ch$  é aplicada e o indivíduo não sofrerá as etapas de evolução do algoritmo.

### **Etapa 4: Atualização da População**

O algoritmo MOGWO é originalmente proposto para o tratamento de problemas de variáveis contínuas, representados por codificação real. No problema PET descrito, as posições dos indivíduos descrevem a existência ou não de uma nova linha de transmissão candidata em um ramo. Dessa forma, a codificação binária é adotada representando a posição 1 para instalação de uma nova linha e posição 0 para não instalação de uma nova linha. O vetor posição binária possui a dimensão do número de linhas de transmissão candidatas à expansão. Considerando que cada ramo pode receber até 3 novas linhas, a cada 3 posições do vetor tem-se um novo ramo candidato. Para permitir a conversão do vetor de posições em variáveis contínuas gerado pelo MOGWO em um vetor binário, é utilizada uma função de transferência sigmóide (Pan et al., 2023). A função sigmóide é aplicada após ação dos operadores de busca do MOGWO que resultam em modificações no vetor binário. A função de transferência utilizada é descrita nas Equações 3.12. e 3.13:



$$FT(\vec{X}) = \frac{1}{1 + e^{-10(\vec{X}-0,5)}} \quad (3.12)$$

$$\vec{X}_{BIN} = \begin{cases} 1, & \text{se } FT(\vec{X}) \geq rand \\ 0, & \text{se caso contrário} \end{cases} \quad (3.13)$$

onde *rand* é um número gerado aleatoriamente a partir de uma distribuição uniforme no intervalo [0,1].

### **Etapa 5: Interrupção da otimização**

Após a avaliação dos indivíduos e atualização de suas posições é avaliado o critério de parada do algoritmo. Caso o número máximo de iterações  $T$  tenha sido alcançado, a otimização é interrompida. Caso contrário, é atualizado o contador de iterações e o processo se reinicia na Etapa 3.

### **3.3. RESULTADOS PARA O ALGORITMO MOGWO: SISTEMA TESTE GARVER**

Esta seção apresenta os resultados da aplicação do algoritmo MOGWO no problema PET do sistema teste Garver (Villasana et al., 1985) para demonstrar a capacidade de busca de soluções de qualidade do otimizador, de acordo com resultados já encontrados na literatura. O problema é formulado a partir das duas funções objetivo descritas nas Equações 3.1 e 3.2. A avaliação da confiabilidade é feita pela Simulação Monte Carlo não-sequencial com suporte de SVM.

Na implementação do MOGWO, foram adotados os seguintes parâmetros (Mirjalili et al., 2016):  $T = 100$ ;  $\eta = 25$ ;  $\Psi = 50$ ;  $\alpha = 0,1$ ;  $\beta = 4$ ;  $nGrid = 10$ . Em razão da natureza estocástica do algoritmo MOGWO e a inerente repetição de indivíduos ao longo do processo de busca, uma heurística de armazenamento de soluções repetidas foi construída de modo a evitar análises desnecessárias de avaliação de confiabilidade para as soluções em curso. As simulações foram implementadas no ambiente de computação numérica MATLAB® e as análises de condições operativas (FPO) das soluções avaliadas, bem como dos estados amostrados pela SMC, são feitas pelo pacote de otimização CPLEX 12.9.0 (Copyright© IBM Corp.).

Os dados do sistema Garver referentes às linhas de transmissão existentes e candidatas podem ser obtidas em (Villasana et al., 1985). Para obtenção do índice EENS de cada solução, a carga pico foi utilizada e as taxas de falha ( $\lambda$ ) e tempo médio de reparo

(*MTTR*) dos equipamentos de transmissão foram 0,0781 falhas/milha.ano e 10h, respectivamente, como em (Leite da Silva, Rezende, Manso, et al., 2010).

A Tabela 7 apresenta os resultados encontrados na literatura para estudos mono-objetivo focados no custo de investimento, desconsiderando qualquer critério de segurança, considerando carga pico e perdas ôhmicas. Esta tabela apresenta os reforços – ‘número de linhas adicionadas’ (ramo) – e o custo de investimento  $f_1$ . A notação ‘3’(4–6), por exemplo, significa um investimento em três linhas no ramo (4–6).

Tabela 7 – Resultados da literatura para o sistema teste Garver

Referência	Reforços	$f_1$ (10 <sup>6</sup> US\$)
(De Oliveira et al., 2018)	‘3’(4-6), ‘1’(2-3), ‘1’(3-5)	130,00
(Alguacil et al., 2003)	‘2’(4-6), ‘2’(2-6), ‘1’(3-5)	140,00

Fonte: Elaborado pelo autor (2022)

A Tabela 8 apresenta as soluções não-dominadas da fronteira de Pareto obtida pelo MOGWO, nomeadas de P1 a P4, com seus respectivos reforços adicionados, custo de investimento ( $f_1$ ) e EENS ( $f_2$ ). É importante destacar que um algoritmo multiobjetivo fornece um conjunto de soluções, localizadas na Fronteira de Pareto encontrada. Dessa forma, a definição de uma solução ótima final exige um procedimento de tomada de decisão por parte do planejador. Além da expertise do decisor, métodos baseados em critérios matemáticos podem auxiliar no processo, como os baseados em lógica nebulosa. Nesta tese é adotado o Método *Fuzzy* de tomada de decisão para definição da solução final. Esse método é descrito em detalhes no Apêndice D.

Tabela 8 – Soluções não-dominadas encontradas pelo MOGWO para o sistema teste Garver

Plano	Reforços	$f_1$ (10 <sup>6</sup> US\$)	$f_2$ (MWh)
P1	‘3’(4-6), ‘1’(2-3), ‘1’(3-5)	130,00	5.126,00
P2	‘2’(4-6), ‘2’(2-6), ‘1’(3-5)	140,00	4.176,30
P3	‘3’(4-6), ‘1’(2-3), ‘2’(3-5)	150,00	3.706,60
P4	‘3’(4-6), ‘1’(2-6), ‘2’(3-5)	160,00	0


Fonte: Elaborado pelo autor (2022)

É possível notar que os planos da Tabela 7, encontrados na literatura, estão entre os planos da fronteira de Pareto obtido pelo algoritmo MOGWO - P1 e P2 na Tabela 8.

Isso prova que o MOGWO é capaz de encontrar soluções de boa qualidade, incluindo aqueles já encontrados na literatura apenas por um custo mínimo de investimento. Em relação ao conceito de não dominância, a solução P1 não domina P2, pois embora P1 tenha  $f_1$  menor que P2, P1 tem o maior  $f_2$  valor. Isto significa que P1 é melhor que P2 em termos de investimento, mas P2 tem a melhor confiabilidade. O mesmo raciocínio pode ser estendido às demais soluções da fronteira de Pareto.

As soluções da Tabela 8 mostram a relação conflitante entre o custo de investimento e confiabilidade. Isto significa que o aumento do investimento em linhas de transmissão diminui a EENS devido à melhoria na segurança do sistema (Maghouli et al., 2009). Do portfólio de soluções não-dominadas, o decisor aplica o Método *Fuzzy* de Tomada de Decisão, definindo as funções objetivo mínima e máxima nos respectivos limites da Tabela 3.2, ou seja:  $f_1^{min} = 130,00$   $f_1^{max} = 160,00$ ;  $f_2^{min} = 0$  e  $f_2^{max} = 5.126,00$ . Outros limites podem ser definidos para  $f_1$  e  $f_2$  de acordo com os requisitos de planejamento. Em relação às referências  $\mu_{r1}$  e  $\mu_{r2}$  que também dependem dos critérios de planejamento, os seguintes casos foram avaliados:  $\mu_{r1} = \mu_{r2} = 0,8$ ;  $\mu_{r1} = 0,8$  e  $\mu_{r2} = 0,6$ ;  $\mu_{r1} = 0,6$  e  $\mu_{r2} = 0,8$ , e o plano selecionado foi P2 em todos os casos. A Figura 7 ilustra os reforços construídos no sistema Garver, conectando a barra 6 ao sistema de modo a atender a carga.

Figura 7 – Sistema Garver reforçado



Fonte: Elaborado pelo autor (2024)

Para avaliar a significância estatística dos resultados obtidos, 50 execuções do algoritmo proposto foram feitas, considerando  $\mu_{r1} = \mu_{r2} = 0,8$  para o critério de decisão; os resultados são apresentados na Tabela 9. Observa-se que P2 é obtido em 94% das execuções, o que mostra que o algoritmo em análise tem relevância estatística.

Tabela 9 – Estatísticas de acerto do MOGWO

Nº de ocorrências	Plano	$f_1$ (10 <sup>6</sup> US\$)	$f_2$ (MWh)
47 (94%)	P2	140,00	4.176,30
1 (2%)	P3	150,00	3.706,60
2 (4%)	P4	160,00	0

Fonte: Elaborado pelo autor (2022)

Apesar dos resultados satisfatórios obtidos pelo MOGWO para o sistema teste Garver, sua aplicação em estudos de planejamento na formulação descrita para sistemas maiores pode se tornar impraticável, mesmo considerando a SMC com suporte de SVM. A análise “*a priori*” da confiabilidade através do método de SMC é capaz de fornecer planos de expansão com excelente relação entre custo e segurança evitando sobreinvestimentos, mas exige um esforço computacional extremo. Dessa forma, esta tese propõe uma nova abordagem para solução do problema PET multiobjetivo baseado na integração do critério de dominância de Pareto e o processo de convergência da SMC, que permite de forma eficiente a análise probabilística “*a priori*” dos critérios de segurança dos sistemas. O algoritmo proposto, denominado *Non-Dominated – Monte Carlo Simulation* (ND-MCS) é apresentado nas Seções 3.4 e 3.5 a seguir em sua formulação básica e com consideração de múltiplas incertezas, respectivamente.

#### 3.4. ALGORITMO PROPOSTO ND-MCS: PLANEJAMENTO MULTI OBJETIVO DA EXPANSÃO DA TRANSMISSÃO BASEADO EM CRITÉRIO DE DOMINÂNCIA

O planejamento da expansão da transmissão é, por essência, um problema multicritério, uma vez que os principais objetivos analisados nesses estudos são considerados conflitantes. Tradicionalmente, os objetivos mais avaliados são custos de investimento, atrelados à implantação de novos equipamentos e custos relacionados à segurança do sistema, como os custos de perda de carga. Os custos de perda de carga podem ser calculados a partir de técnicas de cenários de patamares de geração e carga ou por índices de confiabilidade. Técnicas baseadas em cenários e listas de contingências

são frequentemente utilizadas na literatura por permitirem a obtenção de planos considerando incertezas.

O critério N-1, por exemplo, estabelece que o sistema de transmissão deve operar em condições normais para todas as interrupções de um único equipamento. Na prática, uma lista selecionada e reduzida de contingências é utilizada (de Paula, de Oliveira, de Oliveira, et al., 2020), em que os equipamentos selecionados devem ter considerável impacto para o sistema. Dessa forma, planejar o sistema considerando que os eventos de falha desses equipamentos ocorrerão necessariamente, ou seja, com 100% de probabilidade, pode acarretar em decisões de sobreinvestimento.

Mesmo em casos em que as probabilidades de interrupção são consideradas no critério N-1 para o cálculo de índices de confiabilidade, os métodos probabilísticos como a Simulação Monte Carlo são capazes de obter planos com investimentos reduzidos e ainda manter um nível de confiabilidade adequado, uma vez que o histórico de comportamento dos equipamentos é levado em conta nas estatísticas de falha. De acordo com Leite da Silva (Leite da Silva, Rezende, Manso, et al., 2010), embora o critério N-1 tem sido adotado pela maioria das empresas de energia elétrica, a melhor estratégia é de garantir esta prática apenas nas áreas mais vitais dos sistemas, uma vez que seria necessário um alto investimento se o critério fosse garantido para todo ele.

A estimação de índices de confiabilidade através da SMC é uma excelente maneira de mensurar a segurança de um sistema. No entanto, conforme descrito no Capítulo 2, diversas características desses sistemas podem afetar o custo computacional do método, o que pode inviabilizar sua aplicação em estudos que exigem avaliações recursivas de segurança como os de planejamento da expansão. Se forem ainda consideradas incertezas relacionadas à carga ou mesmo a intermitência de fontes renováveis, esses estudos podem se tornar impraticáveis, ainda que ofereçam resultados mais precisos e com melhores custos. Por esse motivo, trabalhos que utilizam a SMC para avaliação de segurança de planos de expansão tradicionalmente a fazem “*à posteriori*”, ou seja, os planos são avaliados somente ao fim da otimização, de modo que os índices não se configuram como objetivo durante o processo de busca.

Com base nas restrições apresentadas, a metodologia desta tese propõe uma nova abordagem eficiente para o problema PET multiobjetivo que permite considerar o critério probabilístico de confiabilidade como parte do processo de otimização e, ao mesmo

tempo, como recurso de convergência do método, denominado *Non-Dominated – Monte Carlo Simulation* (ND-MCS). Dessa forma, devido aos elevados custos computacionais envolvidos, a técnica se apresenta como uma eficiente ferramenta em estudos complexos de planejamento da expansão com incertezas, uma vez que métodos probabilísticos são essenciais para a representação de comportamentos variáveis do sistema. Além do expressivo ganho computacional, foi observado que a ferramenta desenvolvida possui vantagens sobre a abordagem determinística de avaliação de segurança, uma vez que a adequada consideração probabilística do problema em questão oferece alternativas para evitar o sobreinvestimento em planos de expansão, que podem ser alternativos ao procedimento tradicionalmente utilizado no critério N-1 para definir uma lista de eventos.

Destaca-se que a estrutura proposta pode ser aplicada para obter os mesmos índices de confiabilidade comumente utilizados na literatura (da Costa et al., 2021; Gazijahani et al., 2018b; Ghadimi et al., 2022b; Leite da Silva, Rezende, da Fonseca Manso, et al., 2010), e ainda inseridos como parte do problema de otimização, ou seja, *à priori*, com viável custo computacional da ferramenta. Por se tratar de um método probabilístico, foi observado ainda que a consideração de múltiplas incertezas como intermitência de carga e geração não altera significativamente o esforço computacional do método em relação à abordagem baseada em carga pico e geração constante. A consideração dessas incertezas ainda é um grande desafio na literatura para o problema PET, o que reforça a aplicabilidade do ND-MCS.

Pode-se citar como principais contribuições da metodologia para o problema PET:

- Nova abordagem multiobjetivo para o problema de expansão da transmissão com avaliação probabilística da confiabilidade *à priori*;
- Representação adequada das características estocásticas relacionadas às indisponibilidades de equipamentos e natureza variável de carga e geração, com o objetivo de evitar sobreinvestimentos e, ao mesmo tempo, otimizar os índices de confiabilidade comumente utilizados no problema PET;
- Alternativa ao critério N-1 tradicionalmente utilizado, fornecendo soluções de menor custo frente à probabilidade de eventos no processo de tomada de decisão sob critérios práticos;
- Busca direcionada e mais eficiente no espaço de soluções devido à característica de filtragem de soluções.

### 3.4.1. Fundamentação da Metodologia Proposta

De modo geral, a estrutura proposta consiste em um algoritmo de otimização multiobjetivo para o problema PET probabilístico que permite a representação de incertezas para avaliação da confiabilidade *à priori* ao longo do processo de busca. O diferencial da proposta é a aplicação dos critérios de dominância de Pareto no cálculo dos índices de confiabilidade pela SMC, agregando substancial ganho computacional e otimização do espaço de buscas pela metaheurística.

O principal fundamento do algoritmo ND-MCS está no fato que, durante o processo de busca de soluções por metaheurísticas, como o MOGWO, a maioria das soluções encontradas são dominadas (no conceito de dominância de Pareto apresentado no Apêndice B) sob os critérios impostos pelas funções objetivo e não irão compor a Fronteira de Pareto encontrada ao fim da otimização. Em um estudo de planejamento da expansão considerando a confiabilidade *à priori* como um dos objetivos, o maior esforço computacional encontra-se na estimação dos índices e modelagem das incertezas, uma vez que o método de SMC, mesmo com suporte de SVM, exige recursivas análises de FPO para cada solução encontrada. Portanto, ao levar em conta que a maioria das soluções encontradas ao longo do processo de busca não irão compor a fronteira final por serem muito caras ou pouco robustas, a estimação completa dos índices para essas estratégias não é necessária, pois serão consideradas dominadas.

Com base em uma abordagem probabilística dos conceitos de dominância de Pareto, o objetivo do ND-MCS é estabelecer critérios estocásticos para interrupção da estimação dos índices de confiabilidade para soluções associadas a planos de expansão identificados como dominados, reduzindo consideravelmente o esforço computacional necessário para as análises. Além disso, a característica de redução do espaço de busca imposta pelo ND-MCS permite uma busca direcionada e eficiente no espaço de soluções, melhorando a qualidade dos planos finais. É importante destacar que a solução interrompida pelo algoritmo não é descartada pela otimização, apenas seu segundo objetivo deixa de ser avaliado. Dessa forma, é mantida a característica evolutiva do método em que os indivíduos existentes continuam a compor a população a ser otimizada.

Visando interromper a SMC baseada em SVM para as soluções dominadas e, ao mesmo tempo, garantir uma estimação precisa dos critérios de segurança para soluções

não-dominadas, a integração dos requisitos de dominância de Pareto são propostos como parte do processo de convergência no ND-MCS, da seguinte forma:

**Definição 1.** Dominância de Pareto

Supondo duas soluções,  $\mathbf{X}$  e  $\mathbf{Y}$ ,  $\mathbf{X}$  domina  $\mathbf{Y}$  (denota-se como  $\mathbf{X} > \mathbf{Y}$ ) se

$$[f_i(\mathbf{X}) \geq f_i(\mathbf{Y})] \quad \forall i \in [1, \dots, n] \quad (3.14)$$

**Definição 2.** Otimalidade de Pareto

Uma solução  $\mathbf{X}$  é nomeada como Pareto-ótima se

$$\nexists \mathbf{Y} \mid f_i(\mathbf{Y}) > f_i(\mathbf{X}) \quad \forall i \in [1, \dots, n] \quad (3.15)$$

Na Equação 3.15,  $n$  é o número de funções objetivo do problema de otimização:  $f_1, \dots, f_n$ . Para determinar um critério de convergência baseado nas definições descritas, a função-teste de dominância  $F_{DOM}$  é avaliada concomitantemente às funções-teste dos índices de desempenho do sistema. A função  $F_{DOM}$ , formulada na Equação 3.16, é atualizada a cada iteração e estima de forma precisa a probabilidade de uma solução ser dominada por outra em um conjunto de soluções candidatas.

$$F_{DOM}(\mathbf{X}) = \begin{cases} 0, & \text{se } \mathbf{X} \text{ é não - dominada} \\ 1, & \text{se } \mathbf{X} \text{ é dominada} \end{cases} \quad (3.16)$$

O valor esperado de  $F_{DOM}$  para a solução  $\mathbf{X}$  é dado pela Equação 3.17:

$$\tilde{E}(F_{DOM}(\mathbf{X})) = \frac{1}{NS(\mathbf{X})} \sum_{s=1}^{NS(\mathbf{X})} F_{DOM,s}(\mathbf{X}) \quad (3.17)$$

Em que  $F_{DOM,s}(\mathbf{X})$  é o valor estimado de  $F_{DOM}(\mathbf{X})$  para o estado  $s$  e  $NS(\mathbf{X})$  é o número de estados amostrados do sistema. Observa-se que índices de confiabilidade, e.g. EENS, são obtidos de forma similar à Equação 3.17, substituindo  $F_{DOM}$  por  $F_{EPNS}$  (Função-teste para a EPNS, descrita no Capítulo 2). A incerteza associada à estimativa do



índice de dominância é dada pela variância da função-teste ( $V(X)$ ) e pelo coeficiente de variância ( $\beta_{DOM}(X)$ ), dados pelas Equações 3.18 e 3.19, respectivamente.

$$V(X) = \frac{V(F_{DOM}(X))}{NS(X)} \quad (3.18)$$

$$\beta_{DOM}(X) = \frac{\sqrt{V(\tilde{E}(F_{DOM}(X)))}}{\tilde{E}(F_{DOM}(X))} \times 100\% \quad (3.19)$$

Se o critério ( $\beta_{DOM}(X)$ ) não for atingido, ou seja, se a solução for considerada como não-dominada, o ND-MCS converge com base nos critérios tradicionais relacionados aos índices de desempenho do sistema, e.g.  $\beta_{EPNS}$ . Um critério de 1% é adotado nos estudos de caso, ou seja, exige-se 99% de probabilidade de certeza de que uma solução é realmente dominada. Assim, apenas soluções não-dominadas que integram a fronteira de Pareto tem seus índices de confiabilidade estimados, evitando análises desnecessários pelo método de SMC.

### 3.5. ALGORITMO PROPOSTO IND-MCS: FORMULAÇÃO MULTIOBJETIVO DO PROBLEMA PET CONSIDERANDO MÚLTIPLAS INCERTEZAS

Com base na formulação multiobjetivo básica apresentada na Seção 3.1, essa seção apresenta a modelagem completa da metodologia proposta para solução do problema PET considerando múltiplas incertezas, relacionadas à intermitência da carga e de fontes renováveis de geração, denominada *Improved Non-dominated – Monte Carlo Simulation* (IND-MCS). A Equação 3.25 descreve o conjunto de funções objetivo utilizadas pelo otimizador para determinação das soluções.

$$\text{Min}(f_1) = \sum_{k \in K^C} C_k^T I_k^T + ch \sum_u \left( \sum_{b \in B^D} hd_{b,\forall u} + \sum_{b \in B^R} hr_{b,\forall u} \right) \quad (3.25)$$

$$\text{Min}(f_2) = [EENS]$$

$$\text{Min}(f_3) = [EWES]$$

As restrições de rede são modeladas em (3.26) - (3.33).

$$\sum_{g \in G_b} p g_{g,u} - \sum_{k \in K_b} f_{k,u} + h d_{b,u} - h r_{b,u} = d_{b,u} - \sum_{r \in R_b} p r_{r,u}, \forall b \in B, \forall u \quad (3.26)$$

$$f_{k,u} = I_k^T \left( -b_k \theta_{ij,u} + g_k \frac{(\theta_{ij,u})^2}{2} \right), \forall k \in K, \forall u \quad (3.27)$$

$$|f_{k,u}| \leq \bar{f}_k \cdot I_k^T, \forall k \in K, \forall u \quad (3.28)$$

$$0 \leq p g_{g,u} \leq \bar{p} \bar{g}_g, \forall g \in G, \forall u \quad (3.29)$$

$$0 \leq h d_{b,u} \leq d_{b,u}, \forall b \in B^D, \forall u \quad (3.30)$$

$$0 \leq h r_{b,u} \leq \sum_{r \in R_b} p r_{r,u}, \forall r \in R, \forall u \quad (3.31)$$

$$I_k^T \in \{0,1\}, \forall k \in K^C \quad (3.32)$$

$$I_k^T = 1, \forall k \in K^E \quad (3.33)$$

A função  $f_l$  descreve o custo mínimo de investimento associado às penalidades por corte de carga e corte de vento. O primeiro termo corresponde ao investimento relacionado à expansão do sistema de transmissão, os dois últimos termos são relacionados à minimização do corte de carga e de vento, respectivamente. O conceito de corte de vento refere-se ao montante de potência oriunda de geração eólica não despachada devido às restrições operacionais das linhas de transmissão. Embora, na prática, o corte de vento não leva o sistema a um estado de falha, deve-se evitá-lo de modo a maximizar o uso de energia eólica. Como o corte de carga e corte de vento são indesejáveis no planejamento, um alto custo  $ch$  é associado à penalidade. A função  $f_2$  representa o índice de confiabilidade EENS e  $f_3$  representa o índice *Expected Wind Energy Spilled* (EWES) proposto em (Leite Da Silva et al., 2012), que estima o montante de energia eólica desperdiçada (não utilizada) pelo sistema por falta de demanda ou por restrições operacionais. O uso destes pares de índices é vantajoso por garantir que cargas pequenas ou pequenas usinas de vento não sejam desconsideradas no PET, uma vez que elas não têm uma participação expressiva nos índices EWES e EENS.

O balanço de potência na barra  $b$  relacionado à primeira lei de Kirchhoff é modelado em (3.26). O modelo linearizado de (3.27) é utilizado para o fluxo de potência ativa, que é comum nas abordagens PET (Gomes & Saraiva, 2019; Ugranli & Karatepe, 2015; Zolfaghari Moghaddam, 2019). Os limites para variáveis são formulados em (3.28)

- (3.31). As restrições em (3.32) - (3.33) modelam a variável de decisão de investimento para linhas de transmissão. A variável  $u$  refere-se ao nível de carga do estado operativo avaliado.

Os índices EENS e EWES, referentes às funções  $f_2$  e  $f_3$  são calculados em (3.34) e (3.35) pela Simulação Monte Carlo não-sequencial com suporte de SVM. Estes índices são dados em MWh/ano uma vez que são obtidos pela potência esperada, dada em MWh, multiplicada pela duração de 1 ano em horas, isto é, 8760 h/ano.

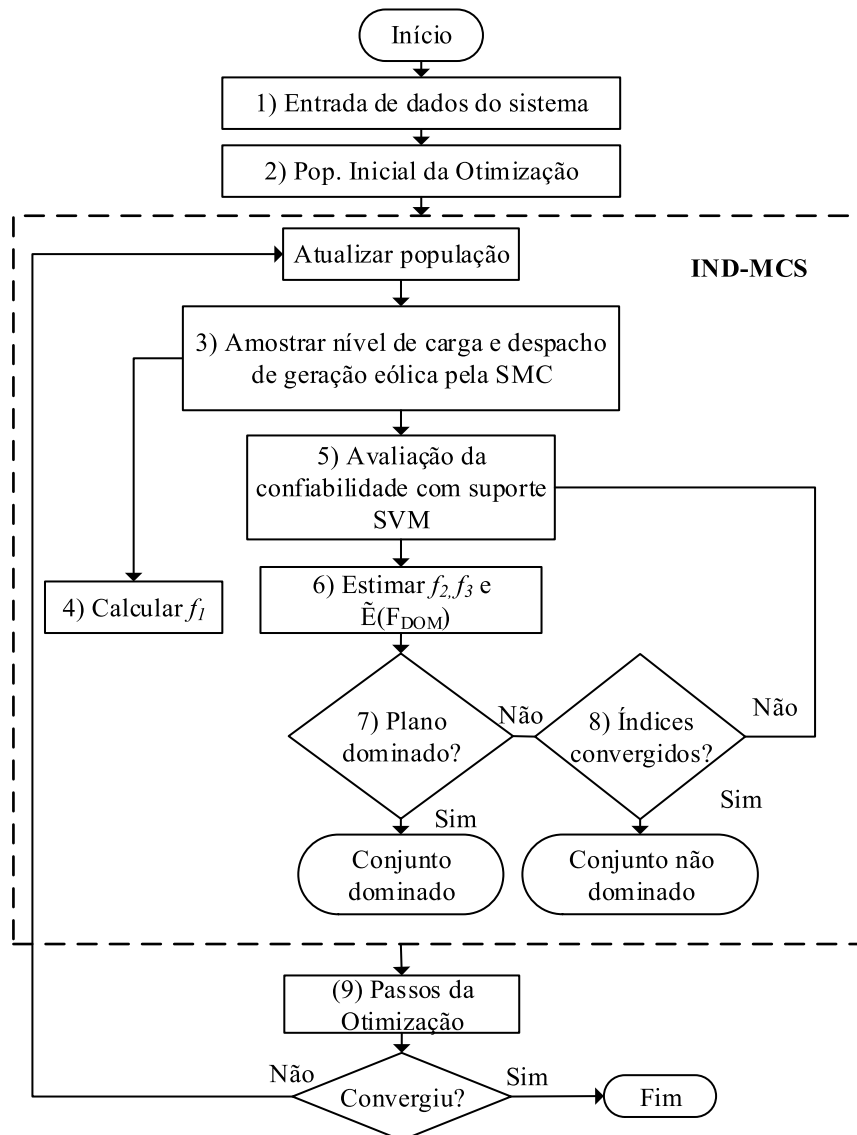
$$EENS = \frac{8760}{NS} \sum_{s=1}^{NS} \sum_{b \in B^D} h d_{b,u} \quad (3.34)$$

$$EWES = \frac{8760}{NS} \sum_{s=1}^{NS} \sum_{b \in R_b} h r_{b,u} \quad (3.35)$$

É importante ressaltar que, devido a inserção de geração eólica, uma nova variável foi inserida no treinamento da rede SVM para que os padrões oriundos do despacho dessas fontes fossem capturados corretamente na estimação dos índices EENS e EWES pela Simulação Monte Carlo. Dessa forma, a soma de geração eólica por área é adicionada ao conjunto das variáveis de treinamento previamente definidas no Capítulo 2.

Este estudo se propõe a avaliar a confiabilidade “*a priori*”, o que significa que os índices EENS e EWES são estimados durante o procedimento de busca, pouco explorado na literatura. Os passos de execução do algoritmo proposto, semelhantes ao algoritmo básico, são ilustrados no fluxograma da Figura 8, destacados pela linha tracejada e explicados a seguir.

Figura 8 – Fluxograma do algoritmo IND-MCS proposto



Fonte: Elaborado pelo autor (2024)

- 1) Inserir os dados do sistema (parâmetros determinísticos e estocásticos).
- 2) Gerar população aleatória de lobos cinzentos. Inicializar os parâmetros do MOGWO.
- 3) Amostrar nível de carga e geração eólica com base na curva de carga e série histórica de vento, respectivamente, pela SMC.
- 4) Para cada indivíduo da população (plano candidato), calcular  $f_i$ .
- 5) Inicializar estimativa dos índices de confiabilidade através da SMC com suporte de SVM para cada indivíduo.
- 6) Atualizar a estimativa para  $f_2$ ,  $f_3$  e a probabilidade de dominância para cada solução ( $\tilde{E}(F_{DOM})$ ).

- 7) Com base nos passos 3) e 5), verificar o critério de dominância. Se a solução é dominada, finalizar o IND-MCS e ir para o passo 9). Caso contrário, ir para o passo 8).
- 8) Se os índices EENS e EWES não convergirem, retornar ao passo 4); caso contrário, armazenar o plano no conjunto de soluções não dominadas e ir para o passo 9).
- 9) Se o número máximo de iterações do MOGWO não for atingido, retornar ao passo 5) para avaliar o *fitness* de cada lobo cinzento atualizado. Caso contrário, finalizar o MOGWO e formar a Fronteira de Pareto.

Após determinar o conjunto final de soluções não dominadas, o método *Fuzzy* de Tomada de Decisão é aplicado para determinar o plano de expansão.

### 3.5.1. Modelagem da carga

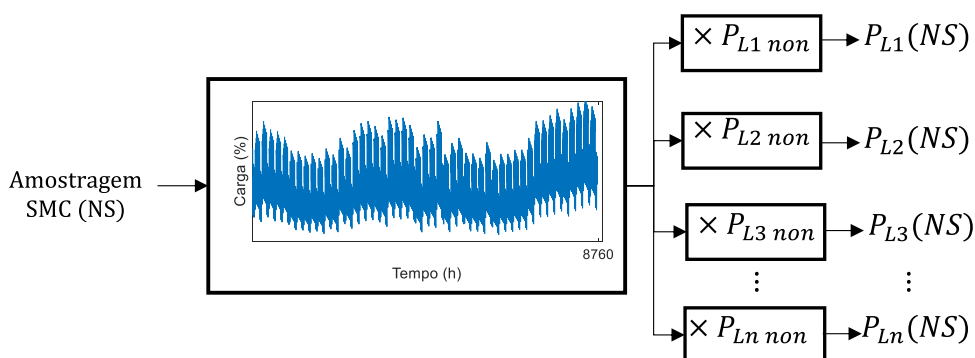
É comum em estudos que envolvam análise de confiabilidade composta a suposição que a carga do sistema se mantenha constante em seu valor de pico durante todo o período de modo a tornar a análise simplificada. No entanto, sabe-se que, na realidade, a carga de um sistema varia continuamente por barra (ou região) ao longo do tempo. Dessa forma, a avaliação de um determinado estado do sistema pode levar a uma condição de sucesso para um dado valor de carga, ou seja, a carga é suprida sem cortes, e um estado de falha para outro patamar de carga. O impacto da consideração de uma carga variável pode ser exemplificado por uma linha de transmissão que pode sair de operação durante um período de carga pesada, mas manter-se operando em condições normais na condição de carga leve.

Qualquer modelo de carga reproduz uma aproximação de seu real comportamento (Manso & Silva, 2004), de modo que a precisão de cada modelo adotado depende da quantidade e qualidade dos dados disponíveis e ainda do tipo de análise feita. O comportamento da carga ao longo do período de análise no cálculo dos índices de confiabilidade pode ser feito através de um modelo cronológico ou um modelo de Markov. Curvas cronológicas de carga com 8760 patamares horários são frequentemente disponíveis e utilizadas em estudos de confiabilidade pela SMC sequencial (Melo et al., 1993). Nesse modelo, a consideração de diferentes curvas de carga por área ou barra do sistema pode ser feita de forma direta, apenas considerando o valor das cargas em cada passo de simulação.

Na análise de confiabilidade através da modelagem não-sequencial da SMC é comum a adoção de um modelo de Markov semelhante ao descrito para modelagem de falha e reparo de equipamentos. Os modelos de Markov adotados na representação da carga podem ser agregados ou não-agregados. Uma abordagem possível é tratar a curva de carga como um modelo de Markov a nível do sistema e fazer uso de fatores de participação para distribuir as cargas pelas barras (Melo et al., 1993), o que implica em considerar que as cargas nas barras e a carga do sistema são totalmente correlacionadas entre si, embora, na prática isto não seja verdade (W. Li & Billinton, 1991).

O modelo de carga adotado nesta tese não tem o objetivo de aprofundar-se na consideração de diferentes curvas por barra (ou área), uma vez que o método de SMC não-sequencial adotado permite encontrar estimações dos índices de confiabilidade suficientes para um estudo de expansão da transmissão. Dessa forma, o modelo de carga adotado é o modelo de Markov agregado único para todo o sistema, de modo que cada barra responde por um percentual da carga pico, conforme ilustrado na Figura 9.

Figura 9 – Modelo de Markov para curva de carga



Fonte: Elaborado pelo autor (2024)

O estado da carga, ou seja, o nível do patamar de carga pode ser determinado com base em um sorteio aleatório de um número  $U$  e sua posterior comparação com a probabilidade acumulada do estado.

### 3.5.2. Modelagem da geração eólica

A crescente necessidade de uso de geração limpa tem estimulado o desenvolvimento de tecnologias de geração renovável como a eólica nos últimos anos. Apesar dos benefícios do uso da energia gerada pelo vento, a modelagem das características desses geradores para os sistemas elétricos não é simples, uma vez que a

intermitência das fontes renováveis agrega um número grande de incertezas ao problema de planejamento da expansão e técnicas probabilísticas tornam-se necessárias.

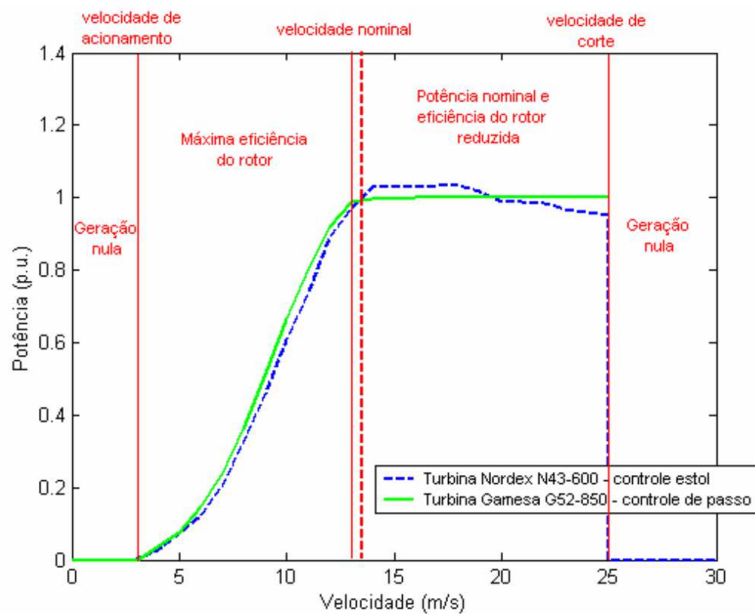
As turbinas eólicas são constituídas por diversos componentes, responsáveis pela captação da energia cinética dos ventos, conversão dessa energia em energia mecânica e, finalmente, conversão da energia mecânica em energia elétrica. Fatores climáticos como variações de temperatura, regimes de vento podem influenciar na velocidade de rotação das turbinas e conseqüentemente na potência elétrica gerada. A potência desenvolvida por uma turbina eólica pode ser expressa conforme Equação 3.20 (Leite et al., 2006):

$$P = \frac{1}{2} C_p \rho A v^3 \quad (3.20)$$

onde  $C_p$  é o coeficiente de eficiência aerodinâmica da turbina,  $\rho$  é a densidade de fluxo de ar na turbina,  $A$  é a área cilíndrica transversal varrida pelas pás e  $v$  é a velocidade do vento. É importante observar que a potência da turbina é proporcional ao cubo da velocidade do vento, de modo que variações de velocidade acarretam em um grande impacto na potência gerada. De modo a permitir um controle da potência de saída, controles de estol e de passo são implementados nas pás das turbinas. Velocidades muito altas podem danificar o equipamento e uma velocidade de corte é delimitada para seu funcionamento, denominada velocidade de *cut out*, em torno de 20 a 25 m/s. Por outro lado, velocidades de vento muito baixas são insuficientes para partida do gerador, então uma velocidade inicial, denominada velocidade de *cut in* é delimitada para que a turbina entre em operação; normalmente entre 3 e 5 m/s. Fora desse intervalo a potência gerada é nula.

A Figura 10, extraída de (Leite et al., 2006), ilustra a curva de potência de duas turbinas eólicas comerciais com controle de estol e de passo. É possível observar uma geração constante em torno do intervalo de velocidades de operação na turbina com controle de passo, enquanto que uma variação da potência de saída é observado na turbina com controle de estol.

Figura 10 – Curvas de potência para turbinas com controle de estol e de passo.



Fonte: (Leite et al., 2006)

A velocidade dos ventos assume um comportamento aleatório devido às mudanças constantes de intensidade. Dessa forma, métodos estocásticos se configuram como a melhor forma de modelar esse comportamento. Dentre as funções densidade de probabilidade existentes, a que melhor representa o comportamento dos ventos é a distribuição Weibull. A literatura (Dorvlo, 2002; Lun & Lam, 2000) demonstra que essa distribuição apresenta precisão adequada para simular a velocidade dos ventos. As Equações 3.21 e 3.22 representam, respectivamente, as funções densidade de probabilidade e densidade acumulada para a modelagem do vento através da função Weibull.

$$p(v, c, k) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} e^{-(v/c)^k}, v \geq 0 \quad (3.21)$$

$$P(v, c, k) = 1 - e^{-(v/c)^k} \quad (3.22)$$

onde  $v$  é a velocidade do vento,  $k > 0$  é o parâmetro de forma e  $c > 0$  é o parâmetro de escala da distribuição Weibull. Para obter a potência de saída das turbinas eólicas esta tese utiliza a própria SMC para sorteio das velocidades. O procedimento é descrito a seguir:



- Passo 1: Sortear um número aleatório  $u$  a partir de uma distribuição uniforme no intervalo  $[0,1]$ ;
- Passo 2: O valor de  $u$  é inserido na Equação 3.23 para se obter uma amostragem de velocidade do vento:

$$v = c[-\ln(1 - u)]^{1/k} \quad (3.23)$$

- Passo 3: Com base na amostragem de velocidade do vento, a potência de saída produzida pela turbina eólica  $P_{wind}$  é dada pela Equação 3.24:

$$P_{wind} = \begin{cases} 0, & 0 \leq v \leq v^{ci} \\ \frac{p^{rated}(v - v^c)}{v^{rated} - v^c}, & v^c \leq v \leq v^{rated} \\ p^{rated}, & v^{rated} \leq v \leq v^{co} \\ 0, & v \geq v^{co} \end{cases} \quad (3.24)$$

onde  $v^{ci}$ ,  $v^{rated}$  and  $v^{co}$  são as velocidades *cut in*, nominal e *cut out*, respectivamente;  $p^{rated}$  é a potência nominal da turbina eólica.

- Passo 4: Os passos 1 a 3 são repetidos por um número pré-determinado de simulações até que se obtenha o valor esperado de potência de saída para a turbina.

### 3.5.3. Confiabilidade composta G&T

Um dos elementos mais básicos no planejamento de sistemas é a determinação de quanta capacidade de geração é necessária para satisfazer de forma razoável os requisitos de carga. A preocupação neste caso é determinar se existe capacidade suficiente no sistema para gerar a energia para atender às cargas do sistema. Um segundo elemento, igualmente importante no processo de planejamento é o desenvolvimento de uma rede de transmissão adequada para transportar a energia gerada para os pontos de carga. O acoplamento entre esses dois sistemas na avaliação da confiabilidade pode ser feito usando índices de perda de carga que estimam o impacto das falhas múltiplas de equipamentos do sistema.

Em um estudo da confiabilidade de sistemas de geração é suposto que carga e geração estão localizadas em uma única barra, de modo que a diferença negativa entre a carga solicitada e a geração disponível é computada como falha do atendimento. Ao considerar sistemas compostos de geração e transmissão (G&T) tem-se a necessidade de avaliação das restrições impostas pelos sistemas de transmissão e consequente adequação

do sistema a partir de otimização com medidas corretivas para minimizar ou suprimir a perda de carga. Falhas compostas de G&T são incorporadas ao algoritmo IND-MCS em estudos de caso de modo a demonstrar o impacto da indisponibilidade de unidades geradoras nos índices de confiabilidade avaliados.

### 3.6. EXEMPLO TUTORIAL DE APLICAÇÃO

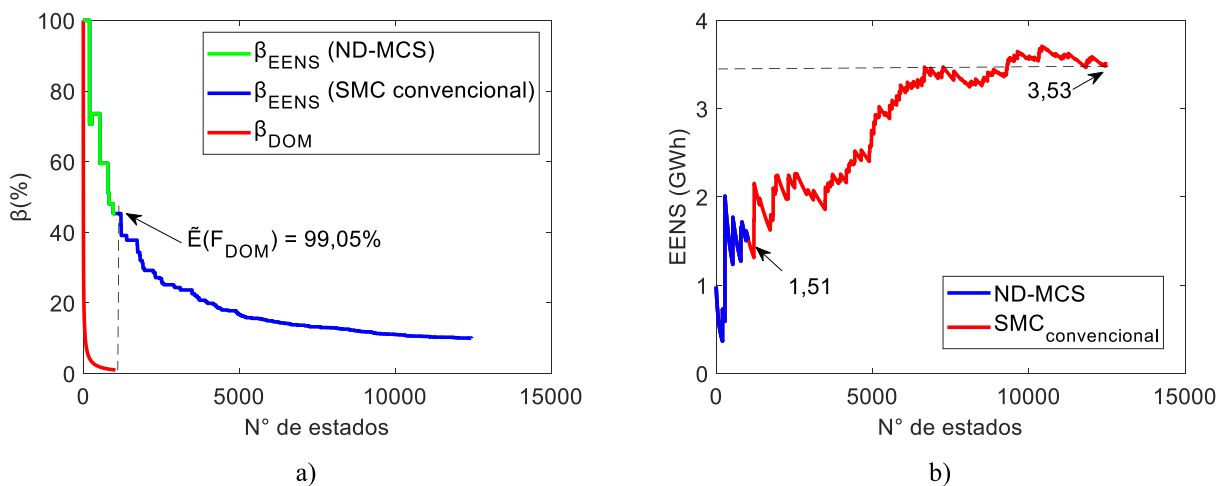
Esta seção ilustra numericamente a aplicação do algoritmo ND-MCS no processo de convergência das soluções. Para exemplificação, foram selecionadas quatro soluções obtidas pelo algoritmo para o sistema teste Garver, consideradas dominadas sob o ponto de vista da metodologia e seus índices de verificação propostos. Isso significa que, por terem sido consideradas dominadas, houve atuação do algoritmo ND-MCS para interromper precocemente a etapa de estimação dos índices de confiabilidade por meio da SMC, etapa de maior dispêndio computacional. Embora se observem modificações significativas na estrutura do algoritmo IND-MCS para estimação das funções objetivo, o processo de convergência baseado no índice de energia não suprida é o mesmo que no algoritmo básico, de modo que a atuação na interrupção é semelhante à obtida nos exemplos a seguir. Em razão do montante de energia não suprida para os exemplos demonstrativos, a EENS é expressa em GWh. Uma tolerância de 10% é admitida para convergência do índice de confiabilidade.

O Exemplo 1, ilustrado na Figura 3.5, refere-se à análise de uma solução cujo plano de expansão apresenta um custo de investimento (objetivo  $f_1$ ) de US\$  $180,00 \times 10^6$ . Considerando um erro máximo de 10% para a estimação do índice EENS ( $E(F_{EENS})$ ), 12.457 verificações de estados seriam necessárias através da SMC convencional para se obter uma EENS (objetivo  $f_2$ ) integral de 3,52 GWh. Esse valor, juntamente com o custo de  $f_1$ , torna a solução dominada frente aos outros planos (indivíduos da população) em análise.

Com atuação do algoritmo ND-MCS, o plano de expansão é considerado dominado a partir de 1.034 verificações de estados, o que corresponde a uma redução de 91,69% no número de avaliações de estado. Nessa situação, o valor esperado para a função teste de dominância ( $E(F_{DOM})$ ) obtido é de 99,05%, ou seja, a probabilidade de a solução ser efetivamente dominada com erro máximo admitido de 1% ( $\beta_{DOM}$ ). A Figura 11a) ilustra os coeficientes de convergência descritos. O valor estimado para a EENS até a interrupção pelo ND-MCS é de 1,51 GWh (42,89% do total) e, embora esse valor

corresponda a um erro ( $\beta_{EENS}$ ) de 45,3%, a integralização da simulação não é necessária uma vez que o plano se encontra dominado. Na Figura 11b) é possível observar a interrupção precoce do valor estimado pelo ND-MCS se comparado com a SMC convencional. Embora o índice obtido não seja condizente com a realidade do critério de segurança para a configuração do sistema em análise, o plano será descartado pelo otimizador e o valor real torna-se irrelevante.


Figura 11 – Exemplo 1. a) Coeficientes de convergência (%); b) Valor esperado para EENS (Gwh)



Fonte: Elaborado pelo autor (2024)

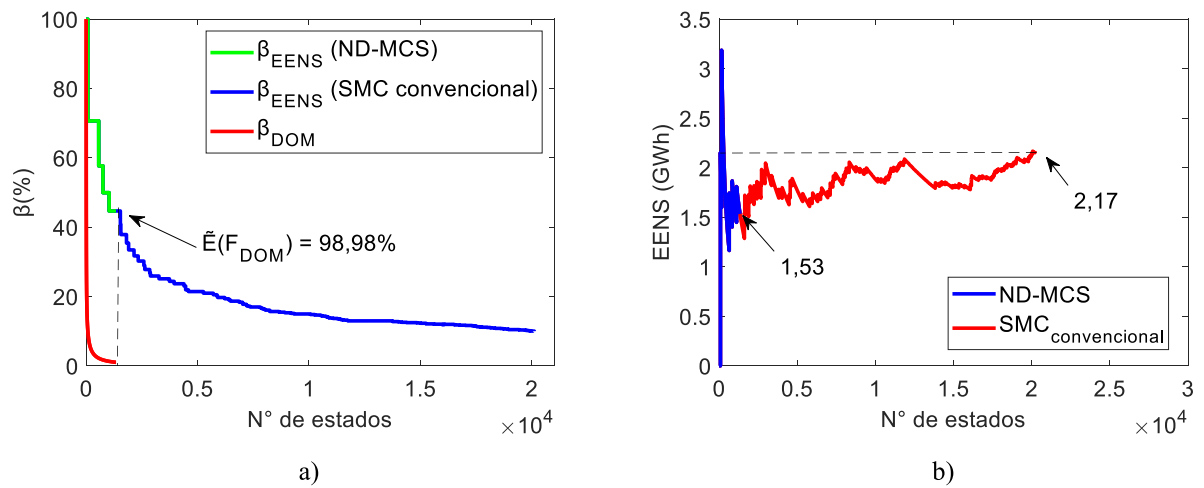
Os Exemplos 2, 3 e 4 de soluções dominadas para o sistema teste Garver são igualmente ilustrados nas Figuras 12, 13 e 14, respectivamente. Observa-se características semelhantes ao Exemplo 1, de modo que a ação do algoritmo ND-MCS, bem como seus respectivos percentuais de acerto em relação à definição de dominância apresenta resultados semelhantes. A Tabela 10 resume os resultados numéricos para os casos avaliados.

Figura 12 – Exemplo 2. a) Coeficientes de convergência; b) Valor esperado para EENS




Fonte: Elaborado pelo autor (2024)

Figura 13 – Exemplo 3. a) Coeficientes de convergência; b) Valor esperado para EENS



Fonte: Elaborado pelo autor (2024)

Figura 14 – Exemplo 4. a) Coeficientes de convergência; b) Valor esperado para EENS



Fonte: Elaborado pelo autor (2024)

Tabela 10 – Dados de convergência para os exemplos tutoriais do algoritmo ND-MCS

	Análise	$C_{INV}(f_1)$ ( $10^6$ US\$)	$E(F_{DOM})$ (%)	$\beta_{DOM}$ (%)	$E(F_{EENS})$ (MW)	$\beta_{EENS}$ (%)	Nº estados
Ex. 1	SMC convencional	180,00	-	-	3,53	9,99	12.457
	ND-MCS		99,05	1,00	1,51	45,30	1.034
Ex. 2	SMC convencional	200,00	-	-	2,6	9,99	33.443
	ND-MCS		98,35	1,00	1,49	49,97	2.213
Ex. 3	SMC convencional	336,00	-	-	2,17	9,96	20.203
	ND-MCS		98,98	1,00	1,53	44,66	1.340
Ex. 4	SMC convencional	321,00	-	-	1,89	9,99	20.974
	ND-MCS		99,21	1,00	1,44	44,63	1.206

Fonte: Elaborado pelo autor (2024)

De modo a evitar a convergência antecipada do índice de dominância, o algoritmo ND-MCS exige um número mínimo de 100 estados avaliados. Por fim, é importante destacar que, além do expressivo ganho computacional que a ferramenta propõe, é observada maior eficiência no processo de busca do otimizador, uma vez que o ND-MCS permite a filtragem de soluções não-dominadas, aprimorando o conjunto de soluções de Pareto. No capítulo seguinte são apresentados os resultados de aplicação das metodologias propostas em sistemas comumente utilizados na literatura em estudos de planejamento da expansão da transmissão, IEEE-RTS e Sistema sul brasileiro (BSS).

### 3.7. CONCLUSÕES PARCIAIS

Este capítulo apresentou a formulação multiobjetivo para o problema PET como parte da metodologia proposta de tese. A modelagem linear do problema de operação, em conjunto com a modelagem probabilística dos índices de confiabilidade tradicionalmente avaliados pela literatura através da Simulação Monte Carlo compõem a estrutura do MOGWO, algoritmo utilizado no processo de otimização para busca de soluções do problema. Os resultados encontrados na literatura para o problema de expansão do sistema testem Garver são comparados com os resultados encontrados pelo MOGWO, evidenciando sua capacidade de encontrar soluções de qualidade.

Os fundamentos do algoritmo básico ND-MCS desenvolvido e sua versão completa para modelagem de incertezas no problema PET, IND-MCS, foram apresentados. As premissas de atuação da metodologia proposta em conjunto com o otimizador multiobjetivo permitem uma busca assertiva de soluções com elevado ganho computacional, se comparado com técnicas tradicionais da literatura para o problema PET probabilístico. Pode-se destacar os seguintes pontos:

- O algoritmo de otimização MOGWO utilizado na busca de soluções é capaz de encontrar planos de expansão de qualidade, comparáveis à literatura;
- O algoritmo ND-MCS permite, por essência de seus fundamentos, a solução do problema PET considerando avaliação de segurança durante o processo de busca (“a priori”) com elevada eficiência computacional;
- O algoritmo proposto pode ser aprimorado para solução do problema PET com múltiplas incertezas como o comportamento variável da carga e intermitência de geração renovável;

Os exemplos tutoriais apresentados têm o objetivo de demonstrar passo-a-passo a atuação do algoritmo ND-MCS no processo de filtragem de soluções e estimação precisa dos índices avaliados.

## 4. ESTUDOS DE CASO

Neste capítulo, são apresentados resultados de aplicação dos algoritmos ND-MCS e IND-MCS propostos, em estudos de caso para o planejamento estocástico de expansão da transmissão considerando o critério de dominância desenvolvido para problemas multiobjetivo. Na Seção 4.1, são apresentados os resultados de aplicação do algoritmo ND-MCS considerando como objetivos de otimização o custo de investimento e o índice EENS. Já na Seção 4.2, são apresentados os resultados de aplicação do algoritmo IND-MCS, considerando múltiplas incertezas de carga e geração renovável através de três objetivos de otimização: custo de investimento, índice EENS e índice EWES. São utilizados para os testes o sistema IEEE-RTS (Subcommittee, 1979) e o Sistema sul brasileiro equivalente (BSS) (Monticelli, Santos, Pereira, Cunha, Parker, & Praça, 1982) em diferentes configurações. Destes sistemas, derivam-se os sistemas RTS-WIND (IEEE-RTS modificado para conter usinas eólicas); e BSS-WIND (sistema equivalente do sul brasileiro modificado para conter usinas eólicas).

As metodologias e algoritmos foram implementados utilizando o software MATLAB<sup>®</sup> de computação numérica. O processamento foi realizado por computador Intel<sup>®</sup> Core<sup>™</sup> i5-5200 de 2,2 GHz. As análises que envolvem solução de fluxos de potência ótimo são realizadas pelo pacote de otimização CPLEX 12.9.0 (Copyright© IBM Corp.), através do método dos pontos interiores.

Os dados para os sistemas IEEE-RTS, BSS, bem como suas versões modificadas para geração renovável, IEEE RTS-WIND e BSS-WIND estão disponíveis no Apêndice E.

### 4.1. RESULTADOS PARA O ALGORITMO ND-MCS – FORMULAÇÃO BÁSICA PARA O PROBLEMA PET PROBABILÍSTICO

O algoritmo ND-MCS proposto é associado ao MOGWO para determinação do conjunto de soluções para os sistemas IEEE-RTS e BSS, conforme descrito no Capítulo 3. Foram adotados os seguintes parâmetros para o processo de otimização:  $t_{max} = 100$ ;  $\eta = 25$ ;  $\Psi = 50$ ;  $\alpha = 0,1$ ;  $\beta = 4$ ;  $nGrid = 10$ . A carga pico dos sistemas é considerada para estimar o índice EENS. Cada ramo candidato pode receber um número máximo de três reforços. Com o objetivo de definir uma solução final, o método *Fuzzy* de tomada de

decisão (vide Apêndice D) é utilizado e  $\mu_{r1} = \mu_{r2} = 0,8$ . Para analisar os resultados da abordagem proposta os seguintes estudos de caso são propostos:

- i) **MOGWO<sub>ND-MCS</sub>**: consiste na aplicação do MOGWO associado à metodologia proposta - ND-MCS para encontrar os custos de investimento associados ao índice EENS no problema PET;
- ii) **MOGWO<sub>MCS</sub>**: consiste na aplicação do MOGWO associado à SMC convencional para encontrar os custos de investimento associados ao índice EENS no problema PET;
- iii) **MOGWO<sub>N-1</sub>**: consiste na aplicação do MOGWO associado ao critério N-1 de contingências para encontrar os custos de investimento associados ao índice EENS no problema PET;
- iv) **MOCSA<sub>N-1</sub>**: consiste nos resultados obtidos pelo método proposto em (Rashedi & Askarzadeh, 2022) que utiliza o algoritmo multi-objetivo de busca denominado *multiobjective crow search* (MOCSA), associado ao critério N-1 de contingências, para encontrar os custos de investimento associados ao índice EENS no problema PET;
- v) **MOGWO<sub>ND-MCS5%</sub>**: consiste na aplicação do MOGWO associado à metodologia proposta - ND-MCS - semelhante à análise i), mas com incremento de 5% nas taxas de falha de todos os ramos candidatos.

Os estudos de caso propostos em ii), iii) e iv) buscam fornecer uma base de comparação para demonstrar a eficiência e a qualidade das soluções encontradas pela metodologia proposta em relação a abordagens encontradas na literatura. O estudo de caso v), por sua vez, busca avaliar o impacto da variação nas taxas de falha para o plano final encontrado. O critério N-1 de contingências considera a interrupção de uma única linha de transmissão do sistema. Para os casos avaliados, as falhas da geração não são consideradas na estimação do índice EENS, de modo que o planejamento é feito essencialmente com base nas falhas múltiplas do sistema de transmissão. Falhas de sistemas compostos de geração e transmissão são consideradas na modelagem do algoritmo IND-MCS na seção 4.2.

#### 4.1.1. Sistema IEEE-RTS

O sistema IEEE-RTS é composto por 24 barras e interligado por 34 ramos que contêm linhas existentes e candidatas. Os parâmetros determinísticos e estocásticos sobre



as linhas de transmissão, geração e cargas podem ser consultados no Apêndice E. A carga pico é de 8.550 MW e a capacidade máxima de geração é de 10.215 MW. O sistema é comumente modificado na literatura duplicando sua demanda e capacidade de geração para torná-lo menos confiável e aumentar a dificuldade do problema PET (de Paula, de Oliveira, de Oliveira, et al., 2020).

A literatura frequentemente aborda o problema PET de objetivo único focado no custo de investimento, considerando as restrições operacionais do sistema. A melhor solução encontrada na literatura nesse caso possui um custo de investimento de US\$  $152,00 \times 10^6$ . Essa solução também é encontrada pelo MOGWO nas simulações desse trabalho, o que reforça a capacidade da otimização de buscar boas soluções para o problema PET. Inicialmente, o algoritmo proposto é comparado com o método convencional de SMC para estimação da EENS. Os planos de expansão selecionados a partir do método *Fuzzy* de tomada de decisão são apresentados na Tabela 11.

Tabela 11 – Planos finais obtidos para o sistema IEEE-RTS

Estudo de caso	Reforços	$f_1$ ( $10^6$ US\$)	$f_2$ (MWh)	Tempo de CPU
MOGWO <sub>ND-MCS</sub>	'1'(1-2), '1'(1-5), '1'(3-24), '2'(6-10), '2'(7-8), '1'(10-12), '1'(14-16), '1'(16-17)	279,00	9.240,90	2h. 10 min. (18%)
MOGWO <sub>MCS</sub>	'1'(1-5), '1'(3-24), '2'(6-10), '2'(7-8), '1'(10-12), '1'(14-16), '1'(16-17)	276,00	11.064,00	12h. 15 min. (100%)

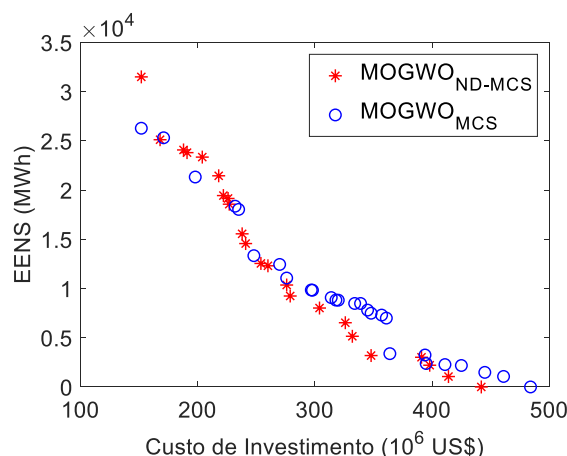
Fonte: Elaborado pelo autor (2022)

A solução encontrada para o MOGWO<sub>ND-MCS</sub> aumenta o custo de investimento em US\$  $3,00 \times 10^6$  (1,08%), enquanto que a EENS é reduzida em 1.823,1 MWh (16,47%) em relação ao MOGWO<sub>MCS</sub>. Essas soluções diferem-se por apenas uma linha de transmissão – '1'(1-2) – que é adicionada na abordagem proposta, aumentando o custo de investimento e melhorando a confiabilidade.

A Figura 15 ilustra as fronteiras de Pareto encontradas nos estudos de caso descritos na Tabela 11. Observa-se que a fronteira de Pareto obtida pelo MOGWO<sub>ND-MCS</sub> é aderente à fronteira obtida pelo MOGWO<sub>MCS</sub>, o que demonstra que a abordagem proposta mantém as características originais do método de SMC convencional. Como vantagem, o método proposto reduziu em 82% o tempo computacional para obtenção das soluções em relação ao método convencional. Além disso, a Figura 15 mostra que os

pontos do  $\text{MOGWO}_{\text{ND-MCS}}$  tendem a ser inferiores aos do  $\text{MOGWO}_{\text{MCS}}$ , o que significa que a qualidade das soluções propostas tende a ser melhor, uma vez que o objetivo é a minimização de ambas as funções  $f_1$  e  $f_2$ . Isso ocorre porque o algoritmo ND-MCS conduz o problema PET a uma busca direcionada e eficiente no espaço de soluções devido à filtragem de soluções não-dominadas ao longo do processo de otimização.

Figura 15 – Fronteiras de Pareto obtidas –  $\text{MOGWO}_{\text{ND-MCS}} \times \text{MOGWO}_{\text{MCS}}$



Fonte: Elaborado pelo autor (2022)

A capacidade de filtragem de soluções pelo ND-MCS pode ser ainda evidenciada quando comparada com os resultados obtidos pelo algoritmo MOCSA proposto em (Rashedi & Askarzadeh, 2022). Nesse trabalho, os autores propõem a solução multiobjetivo para o problema PET visando minimizar custos de investimento e EENS, utilizando o critério “N-1” de contingências para estimação do índice de confiabilidade. Adicionalmente, o algoritmo  $\text{MOGWO}_{\text{N-1}}$  é implementado para comparar a o algoritmo proposto com a mesma otimização, mas considerando também o critério “N-1” de contingências. A Tabela 12 resume as soluções encontradas para cada estudo de caso.

Tabela 12 – Comparação entre os estudos de caso, IEEE-RTS

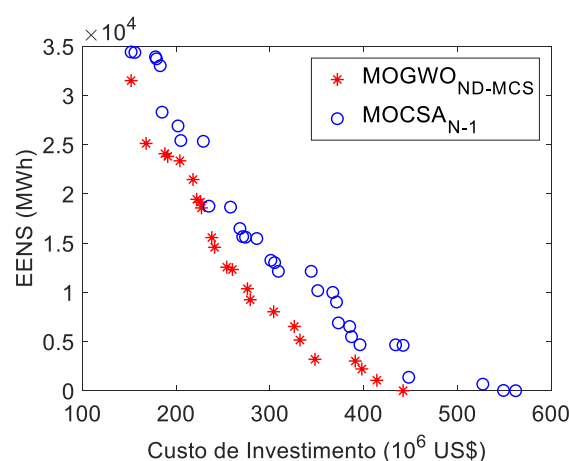
Estudo de caso	$f_1$ ( $10^6$ US\$)	$f_2$ (MWh)
$\text{MOGWO}_{\text{ND-MCS}}$	279.00	9,240.90
$\text{MOGWO}_{\text{MCS}}$	276.00	11.064,00
$\text{MOGWO}_{\text{N-1}}$	326.00	5.673,9
$\text{MOGWO}_{\text{ND-MCS5}}$	306.00	9.294,50
$\text{MOCSA}_{\text{N-1}}$	286.00	15.470,00

Fonte: Elaborado pelo autor (2022)

Em termos de custo de investimento ( $f_1$ ), embora a solução indicada para o  $\text{MOGW}_{\text{MCS}}$  tenha um melhor valor, a diferença em relação ao plano definido pelo  $\text{MOGW}_{\text{ND-MCS}}$  é de 1,08%, enquanto o plano proposto tem uma EENS melhor que a obtida pelo  $\text{MOGW}_{\text{MCS}}$  com um percentual de 16,47% menor como previamente descrito. Em termos de confiabilidade ( $f_2$ ), por sua vez, o melhor valor de EENS (5.673,9 MWh) é obtido pelo  $\text{MOGW}_{\text{N-1}}$ . Entretanto, a solução associada a esse estudo de caso tem o maior custo de investimento, com uma diferença em torno de 16,8% maior em relação ao  $\text{MOGW}_{\text{ND-MCS}}$  proposto, o que indica que o critério N-1 de fato implica em sobreinvestimentos.

Quando comparado com a solução proposta em (Rashedi & Askarzadeh, 2022) pelo  $\text{MOCSA}_{\text{N-1}}$ , ambos os objetivos são menores, sendo  $f_1$  aproximadamente 2,5% menor e  $f_2$ , em torno de 40,3% menor em relação ao  $\text{MOGW}_{\text{ND-MCS}}$ . De modo semelhante ao descrito para o  $\text{MOGW}_{\text{N-1}}$ , a característica de evitar o sobreinvestimento da metodologia proposta em relação à técnica baseada em contingências torna-se evidente. A Figura 16 ilustra uma comparação entre as fronteiras de Pareto obtidas pelos estudos de caso  $\text{MOGW}_{\text{ND-MCS}}$  e  $\text{MOCSA}_{\text{N-1}}$ .

Figura 16 – Fronteiras de Pareto obtidas –  $\text{MOGW}_{\text{ND-MCS}} \times \text{MOCSA}_{\text{N-1}}$



Fonte: Elaborado pelo autor (2022)

A Tabela 12 descreve ainda a solução obtida pelo  $\text{MOGW}_{\text{ND-MCS}5\%}$ , que considera um incremento de 5% nas taxas de falha das linhas de transmissão existentes e candidatas à expansão. Pode-se verificar que mesmo com tal incremento, o custo de investimento obtido pelo  $\text{MOGW}_{\text{ND-MCS}5\%}$  ainda é menor que o obtido pelo  $\text{MOGW}_{\text{N-1}}$ . Essa análise mostra que embora a incerteza sobre as taxas de transição tenha impacto

no plano final de expansão, a prática tradicionalmente adotada baseada em contingências N-1 tende a ser mais conservadora em termos de reforços e, portanto, pode levar ao sobreinvestimento, conforme apontado anteriormente em (de Paula, de Oliveira, de Oliveira, et al., 2020; Leite da Silva, Rezende, da Fonseca Manso, et al., 2010; Leite da Silva, Rezende, Manso, et al., 2010). De modo geral, o sistema tornou-se menos confiável, mas ainda assim a solução encontrada pela metodologia proposta é mais barata que a proposta pelo algoritmo tradicionalmente utilizado no problema PET probabilístico.

A Tabela 13 compara de forma sistemática os estudos de caso, apresentando as soluções extremas das fronteiras de Pareto obtidas. Os casos descritos como ‘R’ referem-se à solução extrema tendo o objetivo  $f_1$  mais baixo e o objetivo  $f_2$  mais alto. Já os casos descritos como ‘L’ têm o objetivo  $f_1$  mais alto e o objetivo  $f_2$  mais baixo. Observa-se que a solução ‘R’ é igual para todas as análises e corresponde ao plano encontrado na literatura para o problema PET de objetivo único (Rashedi & Askarzadeh, 2022; Rathore & Roy, 2016). Por outro lado, todas as soluções ‘L’ possuem o índice EENS iguais a zero. Assim, o custo de investimento deve ser utilizado neste caso para definir a dominância entre esses planos. A conclusão é que o  $L_{MOGWOND-MCS}$  domina as outras soluções ‘L’ por ter o menor custo de investimento ( $f_1$ ). Como as soluções ‘R’ são iguais, pode-se auferir que a fronteira de Pareto obtida pela metodologia proposta domina as fronteiras das demais análises, mostrando que o algoritmo ND-MCS é um potencial instrumento de suporte ao PET, fornecendo planos alternativos e de boa qualidade.

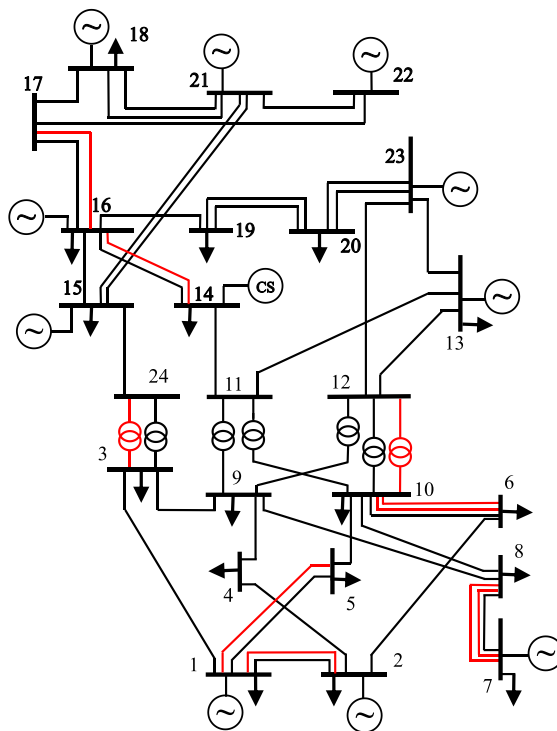
A topologia do sistema IEEE-RTS com os reforços adicionados pelo plano de expansão obtido pelo  $MOGWOND-MCS$  é ilustrada na Figura 17. Cumprindo o requisito de expansão da capacidade de transmissão do sistema, a maioria dos reforços adicionados encontra-se na região de 138 KV em que a capacidade dos equipamentos é de 175 KVA 1(1-2), 1(1-5), 2(7-8), 2(6-10). Foram ainda adicionados dois transformadores que interligam as duas regiões de tensão 1(3-24), 1(10-12), bem como as linhas 1(14-16), 1(16-17) na região de 230 KV.

Tabela 13 – Soluções ‘R’ e ‘L’ para o sistema IEEE-RTS

Estudo de caso	Reforços	$f_1$ (10 <sup>6</sup> US\$)	$f_2$ (MWh)
$R_{MOGWON-1}$ , $R_{MOCSAN-1}$ , $R_{MOGWOND-MCS}$ , $R_{MOGWOND-MCS5\%}$	‘1’(6-10), ‘2’(7-8), ‘1’(10-12), ‘1’(14-16)	152.00	31,264.00
$L_{MOGWON-1}$	‘1’(1-2), ‘1’(1-5), ‘1’(2-6), ‘1’(3-24), ‘1’(4-9), ‘3’(6-10), ‘2’(7-8), ‘1’(9-11), ‘1’(10-12), ‘1’(11-13), ‘1’(14-16), ‘1’(15-24), ‘1’(16-17)	560.00	0
$L_{MOGWOND-MCS}$	‘1’(3-24), ‘2’(6-10), ‘2’(7-8), ‘1’(10-11), ‘1’(10-12), ‘1’(11-13), ‘1’(14-16), ‘1’(15-24), ‘1’(16-17)	442.0	0
$L_{MOCSAN-1}$	‘1’(1-2), ‘1’(1-5), ‘1’(2-4), ‘1’(3-24), ‘2’(6-10), ‘2’(7-8), ‘1’(9-12), ‘1’(10-12), ‘1’(12-13), ‘1’(14-16), ‘1’(15-21), ‘1’(15-24), ‘1’(20-23)	562.00	0
$L_{MOGWOND-MCS5\%}$	‘1’(1-2), ‘1’(1-5), ‘1’(3-9), ‘1’(3-24), ‘2’(6-10), ‘2’(7-8), ‘1’(9-11), ‘1’(10-11), ‘1’(10-12), ‘1’(11-13), ‘1’(14-16), ‘1’(16-17), ‘1’(17-18), ‘1’(20-23)	526.00	0

Fonte: Elaborado pelo autor (2022)


Figura 17 – Topologia para o sistema IEEE-RTS reforçado – MOGWOND-MCS



Fonte: Elaborado pelo autor (2024)

Embora a essência da metodologia proposta seja a interrupção recursiva da SMC para indivíduos dominados ao longo do processo de otimização, foi possível observar, de forma empírica, que o algoritmo ND-MCS mantém as características originais do método não-sequencial da SMC para indivíduos não-dominados, de modo que a estimação precisa do índice avaliado não é prejudicada. A Figura 18 ilustra graficamente a convergência da EENS correspondente à solução final obtida pelo algoritmo proposto.

Figura 18 – Representação gráfica de convergência da EENS para a solução final



Fonte: Elaborado pelo autor (2024)

O valor esperado para a EENS é atingido com incerteza máxima de 5%, conforme tolerância adotada para o método de SMC não-sequencial para avaliação da confiabilidade composta. Foram necessários 50.991 estados para estimação do índice.

#### 4.1.2. Sistema sul brasileiro equivalente – BSS

Uma configuração equivalente para o Sistema Sul Brasileiro (BSS) (Monticelli, Santos, Pereira, Cunha, Parker, & Praça, 1982) é utilizada para demonstrar a robustez da metodologia proposta na solução do problema PET com dados reais determinísticos e estocásticos para os equipamentos. A configuração equivalente utilizada possui 46 barras, sendo que 11 encontram-se inicialmente isoladas. Entre as barras isoladas, 2 possuem geração e 9 são consideradas barras de passagem. As interligações são feitas por 47 ramos ativos, nos quais são instalados 62 circuitos (linhas de transmissão e transformadores). Além disso, 32 novos ramos perfazem um total de 79 ramos candidatos à expansão, sendo possível adicionar até 3 reforços em cada um. O sistema BSS tem uma capacidade máxima de geração de 10.545 MW e uma carga instalada de 6.880 MW para o horizonte de planejamento. Os dados de falha dos equipamentos de transmissão para avaliação

probabilística foram extraídos do ONS sendo  $\lambda = 0,02542$  falhas/milhas.ano e  $MTTR = 2,958$  h para linhas de transmissão de 138 kV;  $\lambda = 0,00707$  falhas/milhas.ano e  $MTTR = 1,521$  h para linhas de transmissão de 500 kV.

De acordo com a literatura, em estudos de expansão do sistema BSS para o objetivo único de investimento baseado nas restrições operacionais a melhor solução tem um custo de US\$  $75,89 \times 10^6$  (de Paula, de Oliveira, de Oliveira, et al., 2020). Análogo ao sistema RTS analisado anteriormente, essa solução também é encontrada pelo MOGWO, destacando a capacidade da otimização do espaço de busca por boas soluções para o problema PET. É importante destacar que, devido à presença de um considerável número de barras isoladas, a solução do problema PET para o sistema BSS torna-se mais difícil para a otimização.

Ao longo do tempo de pesquisa e planejamento do presente trabalho não foram encontrados na literatura estudos multi-objetivo para expansão da transmissão do sistema BSS nas condições realizadas, de modo que os resultados encontrados pelo algoritmo ND-MCS foram comparados com a SMC convencional, uma vez que a robustez do método já foi demonstrada para o sistema-teste IEEE-RTS anteriormente. Os planos de expansão selecionados a partir do método *Fuzzy* de tomada de decisão são apresentados na Tabela 14:

Tabela 14 – Planos finais obtidos para o sistema BSS

Estudo de caso	Reforços	$f_1$ (10 <sup>6</sup> US\$)	$f_2$ (MWh)	Tempo de CPU
MOGWO <sub>ND-MCS</sub>	'1'(12-14), '1'(18-20), '1'(19-21), '1'(14-22), '1'(20-23), '1'(24-34), '2'(20-21), '2'(42-43), '1'(46-6), '1'(29-30), '2'(5-6)	146,31	20.173,00	2h. 33 min. (38%)
MOGWO <sub>MCS</sub>	'1'(2-5), '1'(9-14), '1'(12-14), '1'(13-18), '1'(18-20), '1'(14-22), '1'(20-23), '1'(36-37), '1'(34-35), '1'(37-39), '1'(37-42), '1'(39-42), '2'(38-42), '1'(32-43), '1'(19-32), '1'(46-16), '3'(20-21), '2'(42-43), '1'(46-6), '1'(16-32), '1'(28-43), '1'(41-43), '1'(29-30), '1'(2-3), '3'(5-6)	388,42	23.692,00	6h. 39 min. (100%)

Fonte: Elaborado pelo autor (2022)

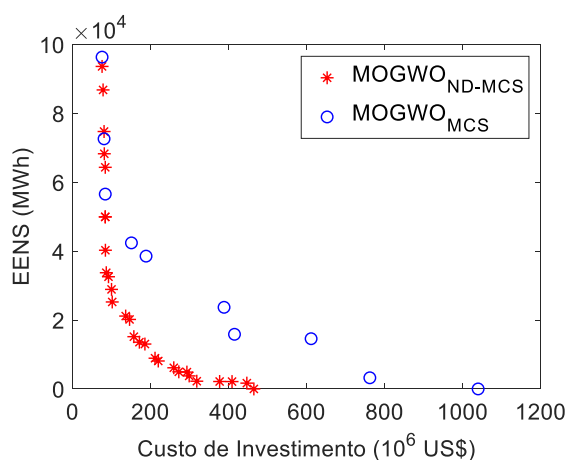
Embora concentrados em uma abordagem de objetivo único, os autores em (De Oliveira et al., 2018) e (de Paula, de Oliveira, de Oliveira, et al., 2020) propuseram soluções restritas em confiabilidade baseadas no critério N-1 de contingências,

encontrando soluções cujos custos de investimento foram de US\$  $153,10 \times 10^6$  e US\$  $189,50 \times 10^6$ , respectivamente. Tais soluções reforçam a característica de evitar o sobre investimento em planos de expansão pela metodologia proposta, uma vez que essa aponta para um custo menor de US\$  $146,31 \times 10^6$ , representando de maneira mais realista as características probabilísticas de interrupção dos equipamentos.

A solução proposta pelo  $\text{MOGWO}_{\text{ND-MCS}}$  é 62,33% mais barata (objetivo  $f_1$ ) se comparada com a fornecida pelo  $\text{MOGWO}_{\text{MCS}}$ . Além disso, o plano proposto tem um valor de EENS (objetivo  $f_2$ ) inferior ao obtido pelo método convencional em 14,85%. É possível observar que reforços nos corredores como - (18–20), (20–23), (20–21), (42–43), (46–6) e (5–6) – estão presentes em ambas as soluções, o que indica considerável relevância para operação segura do sistema.

A Figura 19 apresenta as fronteiras de Pareto obtidas para os estudos de caso descritos na Tabela 14. É evidente que o conjunto de Pareto obtido pelo  $\text{MOGWO}_{\text{ND-MCS}}$  tem melhor qualidade se comparado ao obtido pela otimização através do método convencional –  $\text{MOGWO}_{\text{MCS}}$ , uma vez que se distancia inferiormente em relação aos objetivos avaliados. Portanto, o conjunto não-dominado de soluções tem planos mais baratos e mais confiáveis em relação ao conjunto de comparação. Como se trata de dois estudos de caso baseados em métodos probabilísticos, pode-se dizer que o método proposto foi superior ao convencional tanto em planos obtidos quanto em eficiência computacional, uma vez que a solução encontrada apresenta custo  $f_1$  62,33% menor e  $f_2$ , 14,85% menor, além de uma redução do tempo de CPU em 69%.

Figura 19 – Fronteiras de Pareto obtidas –  $\text{MOGWO}_{\text{ND-MCS}} \times \text{MOGWO}_{\text{MCS}}$



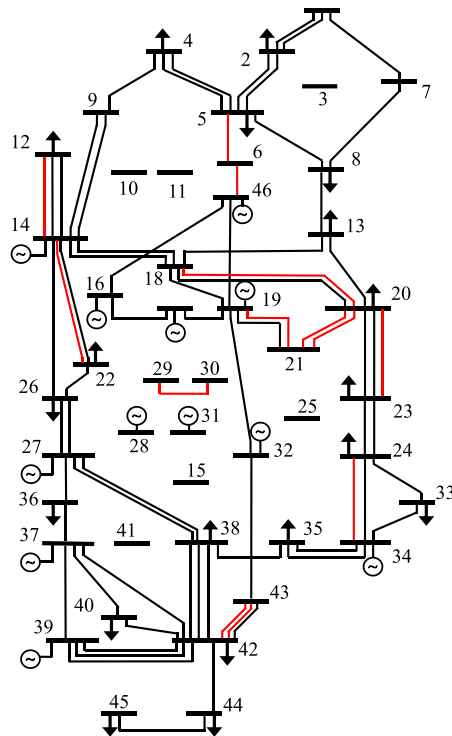
Fonte: Elaborado pelo autor (2024)



Ainda sobre o tempo computacional, pode-se destacar que a metodologia proposta pode ser considerada como uma ferramenta potencial de apoio a ser aplicada em planejamento de sistemas de grande porte, suportada pelo fato de que a eficiência do método de SMC é mais dependente da disponibilidade dos equipamentos do que da dimensão da rede (Lei et al., 2018). Em particular, quanto mais confiável for o sistema, maior será o esforço do método de SMC. Assim, como o algoritmo proposto é baseado em uma eficiente SMC (ND-MCS), o requisito computacional será mais dependente da confiabilidade do sistema do que seu porte.

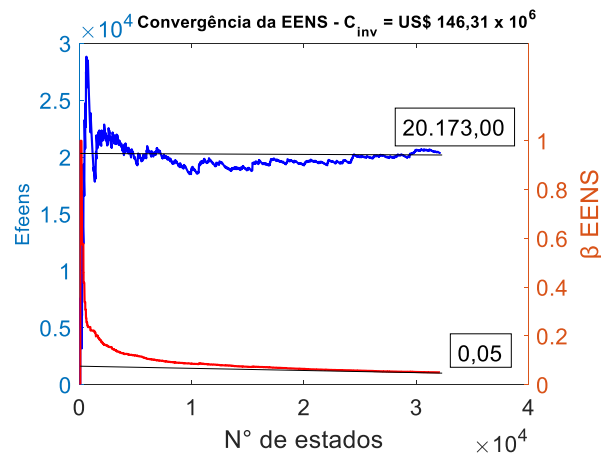
A topologia do sistema BSS reforçado com as linhas adicionadas pelo plano de expansão obtido pelo  $MOGW_{ND-MCS}$  é ilustrada na Figura 20. Com base nos dados de carga e capacidade de transmissão dos circuitos é possível observar que reforços importantes como os que interligam as barras 19-20-21, bem como 42-43, foram adicionados ao sistema de modo a atender com segurança o objetivo do problema PET. Destaca-se ainda que as barras 28 e 31, embora sejam barras isoladas que possuem geração disponível, não foram interligadas ao sistema. Nesse caso, identificou-se que o sistema já interligado possui geração suficiente para atender a demanda sem necessidade de criação de novos corredores, acarretando menores custos ao planejamento. Destaca-se ainda a ligação entre as barras isoladas 29-30 sugerida pela solução que não traz benefícios à operação, mas que foi mantida neste trabalho de modo a manter a integridade do método de otimização. No entanto, tal circuito poderia ser retirado da solução sem qualquer prejuízo ao sistema, fazendo com que a solução final tenha um custo de investimento associado de  $US\$ 138,13 \times 10^6$ , ou seja, 5,59% menor.

Figura 20 – Topologia para o sistema BSS reforçado – MOGWO<sub>ND-MCS</sub>



Fonte: Elaborado pelo autor (2024)

Figura 21 – Representação gráfica de convergência da EENS para a solução final



Fonte: Elaborado pelo autor (2024)

O valor esperado para a EENS é atingido com incerteza máxima de 5%, conforme tolerância adotada para o método de SMC não-sequencial para avaliação da confiabilidade composta. Foram necessários 32.105 estados para estimação do índice.

#### 4.2. RESULTADOS PARA O ALGORITMO IND-MCS – FORMULAÇÃO COMPLETA PARA O PROBLEMA PET PROBABILÍSTICO COM MÚLTIPLAS INCERTEZAS

Com base nos fundamentos que alicerçam a formulação básica do algoritmo ND-MCS, é proposta nessa seção uma nova versão da metodologia para solução do problema PET na presença de múltiplas incertezas, incorporando o comportamento probabilístico da carga e geração variável de fontes eólicas. A versão aprimorada da metodologia proposta, denominada *Improved Non-dominated – Monte Carlo Simulation* (IND-MCS), conserva as características da metodologia original de evitar sobreinvestimentos nos planos de expansão da transmissão, uma vez que a representação probabilística de equipamentos e da carga permite encontrar planos mais realistas e com bons níveis de confiabilidade atrelados a custos muitas vezes semelhantes ou menores que encontrados por metodologias tradicionais.

Embora simples, as modificações feitas no algoritmo IND-MCS representam um efetivo benefício para estudos do problema PET uma vez que a consideração de múltiplas incertezas como da carga e fontes variáveis pode tornar o problema impraticável, mesmo para metodologias baseadas em SMC convencionais. Os resultados encontrados sugerem uma expressiva eficiência computacional para o algoritmo IND-MCS quando comparado ao método de SMC convencional, o que o torna uma importante ferramenta de apoio ao problema multicritério de expansão da transmissão na presença de geração variável.

A presença massiva de fontes eólicas é ainda considerada no problema PET multiobjetivo inserindo um terceiro custo, o índice EWES para estimar a quantidade de energia eólica gerada e não utilizada pelo sistema. O objetivo do índice EWES é maximizar o aproveitamento de geração renovável através da minimização de corte de vento. Contudo, é importante ressaltar que, na prática, o corte de vento não leva o sistema a um estado de falha, mas deve ser evitado para maximizar o uso de geração eólica (de Paula, de Oliveira, Oliveira, et al., 2020).

O MOGWO é novamente associado agora à metodologia aprimorada para determinação do conjunto de soluções para os sistemas RTS-WIND e BSS-WIND, anteriormente descritos como modificações dos sistemas originais para representação de fontes eólicas. Foram adotados os seguintes parâmetros para o processo de otimização:  $t_{max} = 100$ ;  $\eta = 25$ ;  $\Psi = 50$ ;  $\alpha = 0,1$ ;  $\beta = 4$ ;  $nGrid = 10$ . Inicialmente são apresentados os


resultados para o algoritmo IND-MCS apenas para os objetivos custo de investimento ( $f_1$ ) e EENS ( $f_2$ ) com carga pico de modo a demonstrar a eficiência computacional da metodologia quando comparada ao método convencional na presença de geração eólica. Os estudos de caso seguintes consideram o índice EWES como parte do problema de otimização em diferentes condições. Devido a variabilidade de casos simulados, os resultados são descritos da seguinte forma:

- i) **CS-1:** consiste na aplicação do MOGWO associado à metodologia aprimorada - IND-MCS para encontrar os custos de investimento associados ao índice EENS ( $f_1$  e  $f_2$ ) no problema PET na presença de geração eólica e carga pico. Apenas falhas nos equipamentos de transmissão são consideradas.
- ii) **CS-2:** consiste na aplicação do MOGWO associado à SMC convencional para encontrar os custos de investimento associados ao índice EENS ( $f_1$  e  $f_2$ ) no problema PET na presença de geração eólica e carga pico. Apenas falhas nos equipamentos de transmissão são consideradas.
- iii) **CS-3:** consiste na aplicação do MOGWO associado à metodologia aprimorada - IND-MCS para encontrar os custos de investimento associados ao índice EENS e EWES ( $f_1$ ,  $f_2$  e  $f_3$ ) no problema PET na presença de geração eólica e carga pico. Apenas falhas nos equipamentos de transmissão são consideradas.
- iv) **CS-4:** consiste na aplicação do MOGWO associado à metodologia aprimorada - IND-MCS para encontrar os custos de investimento associados ao índice EENS e EWES ( $f_1$ ,  $f_2$  e  $f_3$ ) no problema PET na presença de geração eólica e curva de carga anual. Apenas falhas nos equipamentos de transmissão são consideradas.
- v) **CS-5:** consiste na aplicação do MOGWO associado à metodologia aprimorada - IND-MCS para encontrar os custos de investimento associados ao índice EENS e EWES ( $f_1$ ,  $f_2$  e  $f_3$ ) no problema PET na presença de geração eólica e curva de carga anual. Falhas nos equipamentos de geração e transmissão são consideradas.

É válido ressaltar que em todos os estudos de caso a estimação dos objetivos EENS e/ou EWES é feita “*a priori*”, ou seja, ao longo de todo o processo de otimização. Ademais, dentro dos esforços de pesquisa realizados ao longo desta tese, não foram encontrados na literatura estudos que considerassem as condições abordadas, reforçando a robustez do método proposto e capacidade de suporte ao planejamento na presença de múltiplas incertezas.

A potência entregue ao sistema pelos geradores eólicos está relacionada à velocidade do vento, conforme descrito no Capítulo 3 e modelada a partir de uma distribuição Weibull. Considerando as equações que descrevem o comportamento estocástico dos ventos, neste trabalho foram adotados os parâmetros de escala e de forma conforme Figura 22, que ilustra as funções densidade de probabilidade (PDF) e distribuição acumulada (CDF) para representar o comportamento dos geradores em função da velocidade do vento.

Figura 22 – Representação probabilística da velocidade do vento: a) Função densidade de probabilidade; b) Função distribuição acumulada



Fonte: Elaborado pelo autor (2024)

Ao avaliar o estado operativo do caso base dos sistemas, ou seja, sem adição de reforços, constata-se uma expectativa de corte de carga de 6,92% e 29,5% para os sistemas RTS-WIND e BSS-WIND, respectivamente. Com base nesse desempenho, tem-se que o sistema RTS-WIND é dito mais confiável que o sistema BSS-WIND nas condições de geração simuladas. Dessa forma, ao definir os pesos no método *Fuzzy* de tomada de decisão, o critério de confiabilidade dado por  $\mu_{r2}$  recebe maior importância para o sistema BSS-WIND, em particular  $\mu_{r1} = 0,8$  e  $\mu_{r2} = 1$ . Para o sistema RTS-WIND,  $\mu_{r1} = 1$  e  $\mu_{r2} = 0,9$  pois este sistema é mais confiável e, portanto, o critério econômico torna-se o mais importante. Nos estudos de caso que se considera o índice EWES, o critério relacionado a  $f_3$  recebe a maior importância,  $\mu_{r3} = 1$ , priorizando o custo ambiental do plano de expansão associado à redução mínima do corte de vento.

#### 4.2.1. Sistema RTS-WIND

Além das modificações descritas na seção 4.1.1 para esse sistema, a partir de uma segunda modificação origina-se o sistema RTS-WIND onde duas usinas eólicas são

instaladas nas barras 1 e 15, conforme descrito em (de Paula, de Oliveira, Oliveira, et al., 2020; Leite Da Silva et al., 2012). Em particular, as duas usinas a carvão na barra 1 de 152 MW ( $2 \times 76$  MW) são substituídas por 524 turbinas eólicas de 2 MW cada, enquanto a usina a carvão da barra 15 de 155 MW é substituída por 396 geradores eólicos de 2 MW cada. Os despachos das usinas eólicas são dados a partir da SMC, uma vez que esse método já faz parte da metodologia proposta.

Inicialmente a solução do problema PET através do algoritmo IND-MCS é comparado com o resultado obtido pela metodologia convencional de SMC para um problema de dois objetivos, com inserção das usinas eólicas. As soluções para o plano de expansão, definidas pelo método *Fuzzy* de decisão, são apresentadas na Tabela 15. Nota-se que as soluções encontradas por CS-1 e CS-2 são semelhantes, embora a metodologia proposta tenha encontrado um plano cujo custo de investimento seja 0,62% mais barato, com uma EENS, 22,67% menor. Circuitos importantes para o atendimento à demanda como – (6-10), (7-8), (14-16), (15-21), (15-24) e (16-17), são encontrados em ambos os casos. No entanto, a solução proposta em CS-1 foi encontrada em 4 horas de simulação, enquanto que em CS-2 foram gastas 14h. 05 min. para obtenção dos resultados. Dessa forma, a metodologia proposta foi capaz de encontrar uma solução de melhor qualidade em termos de custo e confiabilidade em um tempo que corresponde a 28% do tempo gasto pela metodologia convencional.

Tabela 15 – Planos finais obtidos para o sistema RTS-WIND – objetivos  $f_1$  e  $f_2$

Estudo de caso	Reforços	$f_1$ (10 <sup>6</sup> US\$)	$f_2$ (MWh)	Tempo de CPU
CS-1	'1'(1-5), '1'(3-24), '2'(6-10), '2'(7-8), '1'(10-12), '1'(12-13), '1'(14-16), '1'(15-21), '1'(15-24), '1'(16-17)	482,00	35,68	4h. 00 min. (28%)
CS-2	'1'(1-2), '1'(1-5), '1'(3-24), '2'(6-10), '2'(7-8), '1'(10-11), '1'(11-13), '1'(14-16), '1'(15-21), '1'(15-24), '1'(16-17)	485,00	46,14	14h. 05 min. (100%)

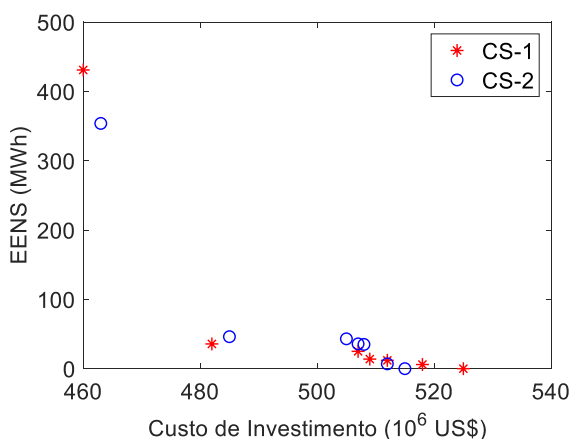
Fonte: Elaborado pelo autor (2024)

Embora as fronteiras de Pareto encontradas por CS-1 e CS-2, ilustradas na Figura 4.9, contenham poucas soluções, é possível observar que são próximas em relação ao espaço de soluções, de modo que se pode concluir que o algoritmo IND-MCS também

mantem as características originais do método de SMC convencional. Além disso, a Figura 23 permite ainda observar que, devido à injeção massiva de geração eólica, a maioria das soluções apresentam maior custo de investimento, o que indica que mais reforços são necessários para não violar os limites operativos do sistema.

Os autores em (de Paula, de Oliveira, de Oliveira, et al., 2020) propõem uma solução para o problema PET de objetivo único para o sistema RTS-WIND, em que se considera as mesmas modificações abordadas nessa tese para inserção das usinas eólicas. Nesse trabalho a solução encontrada de menor custo de investimento é de US\$  $473,00 \times 10^6$  e nenhum critério de segurança é considerado. Já o algoritmo proposto foi capaz de encontrar uma solução cujo custo de investimento é de US\$  $460,00 \times 10^6$ , associado à uma EENS de 430,81 MWh.

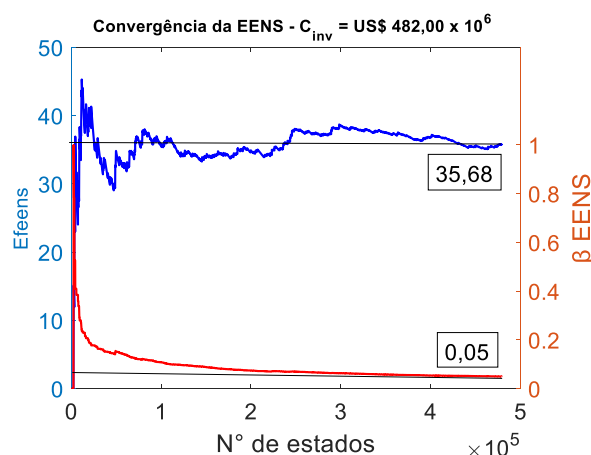
Figura 23 – Fronteiras de Pareto obtidas – CS-1  $\times$  CS-2



Fonte: Elaborado pelo autor (2024)

A Figura 24 ilustra o processo completo de convergência da EENS para o plano de expansão definido em CS-1. Conforme esperado, a estimação do índice para a solução (não-dominada) não sofre qualquer interferência do algoritmo IND-MCS sendo o valor de EENS, portanto, estimado com a incerteza máxima de 5% adotada para o método de SMC não-sequencial.

Figura 24 – Representação gráfica de convergência da EENS para a solução final



Fonte: Elaborado pelo autor (2024)

Em relação aos casos simulados pelo algoritmo original, ND-MCS, observa-se um expresso aumento do número de estados avaliados para estimação do índice de confiabilidade, utilizando 479.142 estados. Isso ocorre em razão do aumento da robustez do sistema frente à maior disponibilidade de geração advinda das usinas eólicas, bem como dos reforços adicionados pelo plano de expansão escolhido.

Ao considerar o índice EWES como parte do problema PET (objetivo  $f_3$ ) tem-se a finalidade de maximizar o aproveitamento de geração eólica e, conseqüentemente, uma menor utilização das fontes despacháveis e de maior custo operacional/ambiental. Diferentes condições de incerteza para carga, geração variável, bem como para a disponibilidade dos equipamentos de geração e transmissão são avaliados pela metodologia proposta e os planos de expansão obtidos são apresentados na Tabela 16.

Em SC-3 é apresentado o plano de expansão quando se considera o índice EWES como parte do problema de otimização considerando as mesmas configurações simuladas em SC-1. A solução encontrada apresenta um custo de investimento de US\$  $559,00 \times 10^6$ , sendo 15,97% mais cara, associado a uma EENS de 50,96 MWh e uma EWES de 28,41 MWh. Embora não tenha sido considerado para determinação da solução em SC-1, o índice EWES estimado nesse caso após obtenção do plano ótimo foi de 595,56 MWh, ou seja, a solução de SC-3 apresenta uma redução expressiva na expectativa de desperdício de geração eólica ao encontrar uma EWES associada de 28,41 MWh, correspondendo a uma redução de 95,22% em relação a SC-1. O plano definido para SC-3 está, portanto,



em conformidade com as expectativas de decisão inicialmente adotadas ao considerar critério máximo de importância para  $f_3$ ,  $\mu_{r3} = 1$ .


Tabela 16 – Planos finais obtidos para o sistema RTS-WIND considerando o objetivo  $f_3$

Estudo de caso	Reforços	$f_1$ ( $10^6$ US\$)	$f_2$ (MWh)	$f_3$ (MWh)	Tempo de CPU
SC-3	'3'(1-2), '1'(1-5), '1'(3-9), '1'(4-9), '2'(6-10), '2'(7-8), '1'(9-12), '1'(10-12), '1'(12-13), '2'(14-16), '1'(16-17), '1'(20-23)	559,00	50,96	28,41	3h. 36 min.
SC-4	'3'(1-2), '2'(1-5), '1'(2-4), '1'(2-6), '1'(3-9), '1'(3-24), '2'(5-10), '1'(6-10), '1'(10-11), '1'(11-14), '1'(14-16), '1'(16-17)	477,00	25,12	12,18	3h. 04 min.
SC-5	'2'(1-2), '2'(1-5), '1'(2-4), '1'(3-24), '1'(5-10), '2'(6-10), '3'(7-8), '1'(8-9), '1'(8-10), '1'(10-11), '1'(11-13), '1'(14-16), '1'(15-16), '1'(15-21), '1'(15-24), '1'(16-17), '1'(20-23)	722,00	2.132,60	38,48	3h. 19 min.

Fonte: Elaborado pelo autor (2024)

A Figura 25 mostra as soluções não-dominadas para SC-3. Em razão da dificuldade em se exibir de forma efetiva um conjunto não dominado em um plano tridimensional, foram utilizados três gráficos de relação dos objetivos tomados dois a dois, conforme (Maghouli et al., 2009). Nota-se que as soluções que aparecem dominadas em cada gráfico, são na verdade não dominadas quando se considera o terceiro objetivo não exibido naquele gráfico. É possível observar ainda que as soluções se concentram próximas aos eixos dos gráficos, com predominância de planos com custos em torno de US\$  $500,00 \sim 800,00 \times 10^6$ . Uma relação de conflito pode facilmente ser observada entre o custo de investimento e os índices EENS e EWES. No entanto, não se pode atribuir uma relação clara entre os índices de confiabilidade no terceiro gráfico, uma vez que, embora ambos medidos em MWh, tratam-se de objetos de natureza distinta.

Figura 25 – Fronteiras de Pareto obtidas para o RTS-WIND em CS-3 – a) Relação entre custo de investimento  $\times$  EENS; b) Relação entre custo de investimento  $\times$  EWES; c) Relação entre EENS  $\times$  EWES




Fonte: Elaborado pelo autor (2024)

Ao incorporar a incerteza na carga a partir da curva anual para o sistema em SC-4, observa-se uma considerável redução para os três objetivos em análise. Naturalmente, com a representação probabilística da demanda é esperado que o investimento necessário para expansão seja menor - US\$  $477,00 \times 10^6$  (14,67% menor), uma vez que nas simulações anteriores é considerada a carga pico do sistema. Consequentemente, observa-se uma redução da EENS para 25,12 MWh (50,71% menor) e da EWES para 12,18 MWh (57,13% menor).

A relação entre os objetivos para SC-4 é ilustrada na Figura 26. Um número maior de soluções apresenta custo de investimento em torno de US\$  $350,00 \sim 450,00 \times 10^6$ . Observa-se ainda que soluções com maiores EWES estão contidas neste portfólio se comparado a SC-3. Isso ocorre devido à redução da demanda e não necessidade de utilização de geração eólica, o que pode levar a um aumento na expectativa de corte de vento.

Figura 26 – Fronteiras de Pareto obtidas para o RTS-WIND em CS-4 – a) Relação entre custo de investimento  $\times$  EENS; b) Relação entre custo de investimento  $\times$  EWES; c) Relação entre EENS  $\times$  EWES




Fonte: Elaborado pelo autor (2024)

Em SC-5 é adicionada a indisponibilidade dos equipamentos de geração, ou seja, os índices EENS e EWES são avaliados a partir da confiabilidade composta de geração e

transmissão (G&T), além do comportamento probabilístico da carga e das fontes eólicas. Esse caso simula a presença múltipla de incertezas, dificilmente abordado na literatura em razão da complexidade de solução por parte de metodologias baseadas em cenários e listas de contingências. Com a falha de geração, é natural que os casos de perda de carga sejam mais frequentes, o que acarreta no aumento do custo de investimento do plano de expansão, além de um expressivo aumento na expectativa de energia não suprida. Nesse caso, a solução obtida apresenta um custo de investimento de US\$  $722,00 \times 10^6$ , EENS de 2.132,60 MWh e EWES de 38,48 MWh, o que corresponde a um aumento de 51,36%, 8.389,65% e 215,93%, respectivamente.

Isso ocorre devido à representação de falhas dos geradores despacháveis que levam a falhas graves para o sistema, o que piora significativamente a métrica de confiabilidade (8.389,65%) e aumenta o custo de investimento (51,36%) devido à mudança no despacho econômico causada pela perda de capacidade de geração. Além disso, diante de uma falha no gerador, algumas linhas de transmissão tendem a ficar sobrecarregadas, de modo que a geração eólica deve ser cortada (aumento da EWES) para evitar violação na capacidade de transmissão. A relação entre os objetivos é ilustrada na Figura 27. Embora os objetivos tenham valores substancialmente maiores que os casos anteriores, é notória a capacidade do algoritmo em aglutinar as soluções em regiões mais próximas da fronteira ótima.

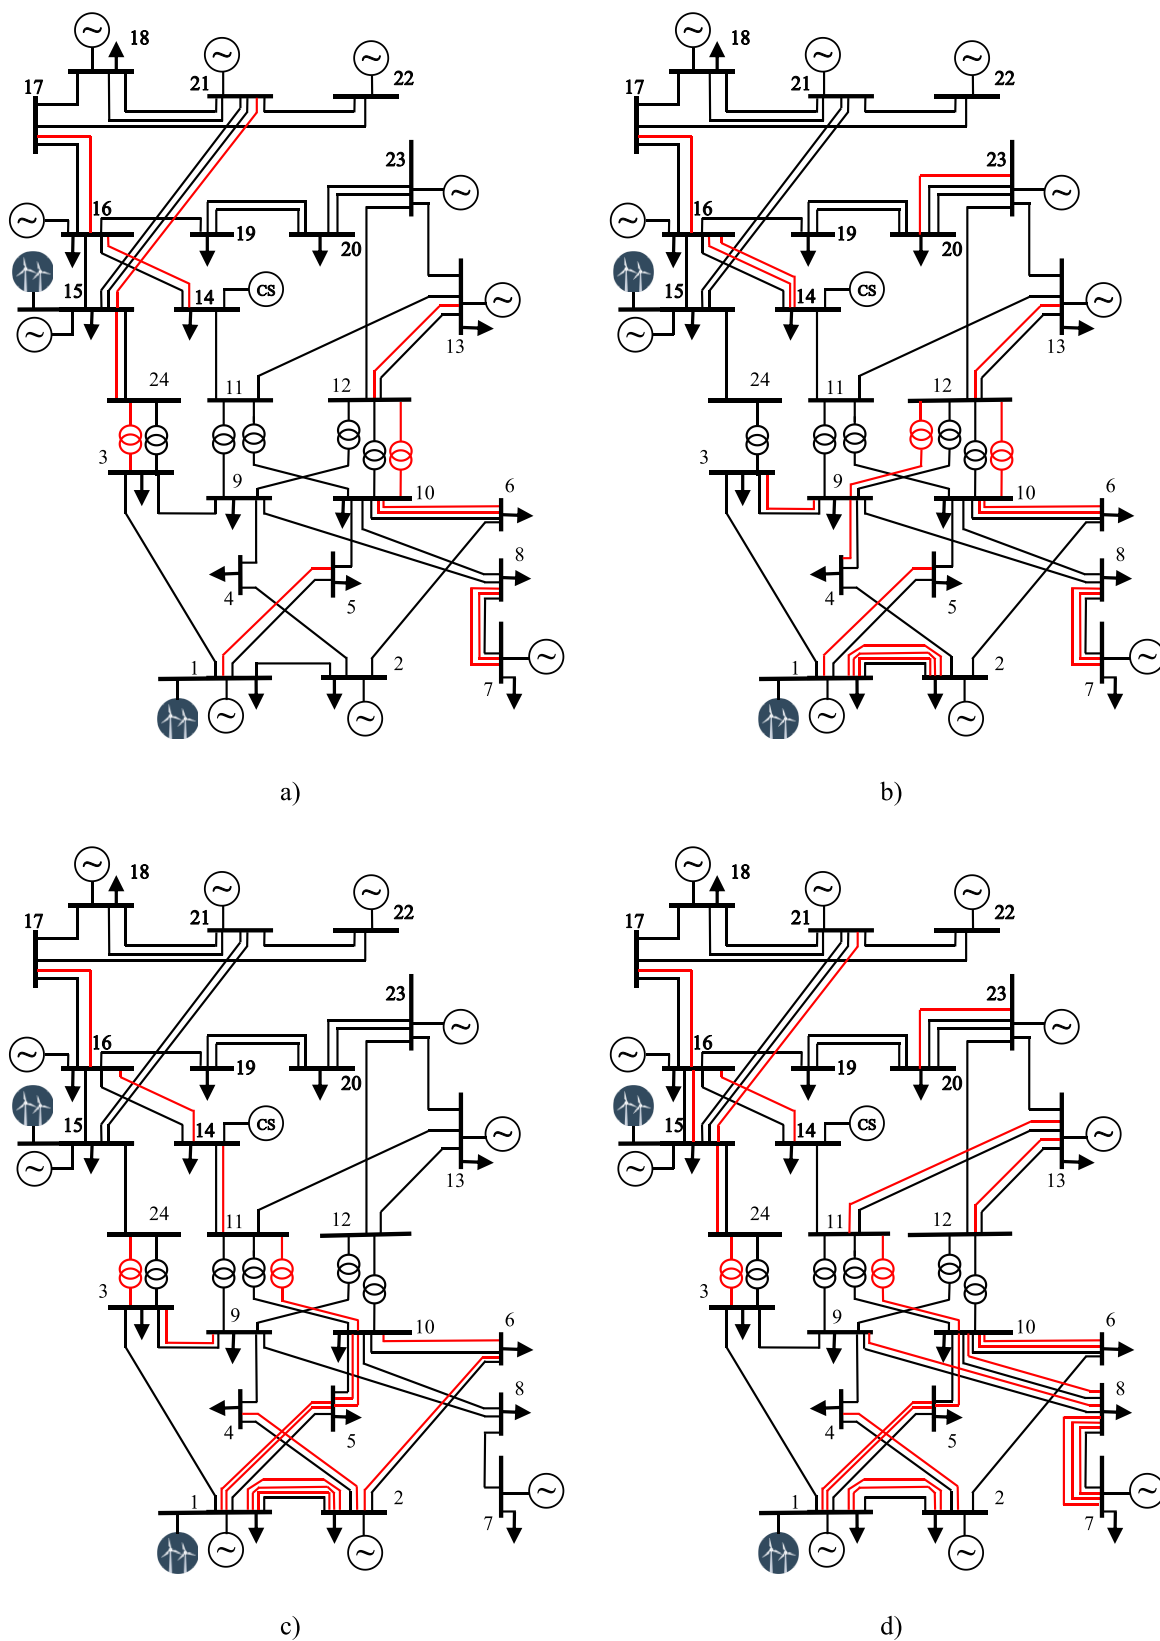
Figura 27 – Fronteiras de Pareto obtidas para o RTS-WIND em CS-5 – a) Relação entre custo de investimento  $\times$  EENS; b) Relação entre custo de investimento  $\times$  EWES; c) Relação entre EENS  $\times$  EWES



Fonte: Elaborado pelo autor (2024)

A topologia de reforços para os casos obtidos pela metodologia proposta nos estudos de caso descritos é apresentada na Figura 28.

Figura 28 – Topologia para o sistema RTS-WIND reforçado – a) CS-1; b) CS-3; c) CS-4; d) CS-5



Fonte: Elaborado pelo autor (2024)

#### 4.2.2. Sistema BSS-WIND

O equivalente do sistema sul brasileiro modificado para inserção de geração eólica, denominado BSS-WIND, adiciona três usinas eólicas de 700 MW contendo 250 turbinas de 2,8 MW cada nas barras 1, 21 e 43. O total de geração renovável tem uma participação de 16,61% na capacidade de geração do sistema. Os despachos das usinas eólicas são dados a partir do método de SMC, derivados da abordagem probabilística baseada na velocidade do vento apresentada no Capítulo 3.

Assim como para o sistema RTS-WIND, a solução do problema PET através do algoritmo IND-MCS é comparado com o resultado obtido pela metodologia convencional de SMC para um problema de dois objetivos, com inserção das usinas eólicas. As soluções para o plano de expansão, definidas pelo método *Fuzzy* de decisão, são apresentadas na Tabela 17. Embora corredores importantes para a expansão tenham sido encontrados em ambos os estudos de caso, como (20-21), (42-43), (46-6) e (5-6), é observada vantagem do plano definido por CS-1, uma vez que esse apresenta um custo de investimento de US\$  $162,17 \times 10^6$  associado a uma EENS de 10,77 MWh, o que representa valores 19,49% e 98,03% menores em relação a CS-2, respectivamente. Além disso, um expressivo *speed up* computacional é obtido em CS-1, que gasta aproximadamente 13h de simulação, enquanto que CS-2 encontra a solução em torno de 36h, o que corresponde a 36% do tempo gasto pela metodologia convencional.

Tabela 17 – Planos finais obtidos para o sistema BSS-WIND – objetivos  $f_1$  e  $f_2$

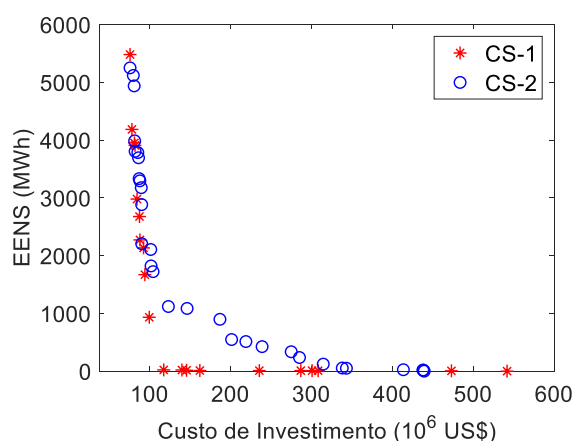
Estudo de caso	Reforços	$f_1$ ( $10^6$ US\$)	$f_2$ (MWh)	Tempo de CPU
CS-1	'1'(12-14), '1'(18-20), '1'(19-21), '1'(20-23), '2'(20-21), '2'(42-43), '1'(46-6), '1'(16-28), '1'(40-45), '2'(5-6)	162,17	10,77	13h. 03 min. (36%)
CS-2	'1'(12-14), '1'(18-20), '2'(14-26), '1'(14-22), '1'(20-23), '1'(34-35), '1'(37-40), '1'(40-42), '2'(20-21), '2'(42-43), '1'(46-6), '1'(25-32), '1'(40-45), '1'(24-25), '1'(2-3), '2'(5-6)	201,42	547,44	36h. 15 min. (100%)

Fonte: Elaborado pelo autor (2024)

As fronteiras de Pareto encontradas para as soluções de CS-1 e CS-2 são ilustradas na Figura 29. De modo semelhante ao obtido pelo algoritmo ND-MCS para o sistema BSS, o conjunto de soluções obtido em CS-1 tem melhor qualidade se comparado ao

obtido pela otimização através do método convencional – CS-2, uma vez que se distancia inferiormente em relação aos objetivos avaliados. Portanto, o conjunto não-dominado de soluções tem planos mais baratos e mais confiáveis em relação ao conjunto de comparação. Dessa forma, o algoritmo proposto novamente se apresenta superior ao método probabilístico convencional tanto em planos obtidos quanto em eficiência computacional.

Figura 29 – Fronteiras de Pareto obtidas – CS-1 × CS-2




Fonte: Elaborado pelo autor (2024)

Em (de Paula, de Oliveira, de Oliveira, et al., 2020), os autores propõem uma solução para o problema PET de objetivo único para o sistema BSS-WIND com as mesmas características de inserção de fontes eólicas. Nesse trabalho, a solução proposta tem um custo de investimento de US\$  $75,89 \times 10^6$ , sem considerar critérios de segurança. A solução também é encontrada por CS-1 e CS-2, considerando a EENS como parte do problema de otimização.

A convergência da EENS para o plano de expansão definido em CS-1 é apresentada na Figura 30. O nível de precisão não é afetado pelo IND-MCS, convergindo com a incerteza máxima de 5% adotada para o método de SMC não-sequencial. Um total de 22.702 estados foram avaliados na estimação do índice.

Figura 30 – Representação gráfica de convergência da EENS para a solução final



Fonte: Elaborado pelo autor (2024)

O índice EWES é então considerado na metodologia como parte do problema PET (objetivo  $f_3$ ), o que reflete a maximização do uso de geração eólica. As diferentes condições de incerteza para carga, geração variável, bem como para a disponibilidade dos equipamentos de geração e transmissão são avaliados pela metodologia proposta e os planos de expansão obtidos são apresentados na Tabela 18.

A princípio é possível observar que as soluções apontadas apresentam índice EWES nulo. Isso significa que para os planos de expansão encontrados toda geração eólica é aproveitada, o que permite menor utilização das fontes despacháveis e de maior custo operacional/ambiental. Em SC-3 a solução encontrada apresenta um custo de investimento de  $\text{US\$ } 171,13 \times 10^6$ , associado a uma EENS de 109,06 MWh e EWES nula. Embora não tenha sido considerado para determinação da solução em SC-1, o índice EWES estimado nesse caso após obtenção do plano ótimo foi de 1,09 MWh, ou seja, ainda que em baixos valores, a solução de SC-3 reduz por completo o corte de vento esperado. Nesse caso, a solução de SC-1 é competitiva em relação a SC-3 pois, apesar da redução por completo de  $f_3$ , há um aumento de 5,52% no custo de investimento e 912,63% no índice EENS.

A

Figura 31 mostra as soluções não-dominadas para SC-3 apresentadas a partir da relação dos objetivos tomados dois a dois. Nota-se maior concentração de soluções associadas a menores custos de investimento, em torno de  $\text{US\$ } 100,00 \sim 200,00 \times 10^6$ .


Embora não haja uma relação clara entre  $f_2$  e  $f_3$ , é também evidente a presença da maior quantidade de soluções associadas a baixos valores de EENS e EWES.

Tabela 18 – Planos finais obtidos para o sistema BSS-WIND considerando o objetivo  $f_3$

Estudo de caso	Reforços	$f_1$ ( $10^6$ US\$)	$f_2$ (MWh)	$f_3$ (MWh)	CPU time
CS-3	'1'(1-2), '1'(4-5), '1'(12-14), '1'(18-20), '1'(14-26), '1'(27-38), '1'(40-42), '2'(20-21), '2'(42-43), '1'(46-6), '1'(21-25), '1'(26-29), '1'(40-45), '1'(24-25), '2'(5-6)	171,13	109,06	0	7h. 30 min.
CS-4	'1'(1-2), '1'(4-5), '1'(2-5), '1'(12-14), '1'(18-20), '1'(20-23), '1'(18-19), '2'(20-21), '1'(42-43), '1'(46-6), '1'(31-32), '1'(40-45), '3'(5-6)	132,11	0,42	0	20h. 14 min.
CS-5	'2'(1-7), '3'(4-9), '2'(14-18), '1'(13-18), '1'(14-22), '1'(22-26), '2'(20-23), '1'(26-27), '1'(38-42), '1'(18-19), '2'(20-21), '2'(42-43), '1'(2-4), '1'(46-10), '1'(46-6), '1'(31-32), '1'(28-31), '1'(26-29), '1'(29-30), '2'(5-6), '1'(9-10)	219,19	1,530.0 0	0	4h. 49 min.

Fonte: Elaborado pelo autor (2024)

Figura 31 – Fronteiras de Pareto obtidas para o BSS-WIND em CS-3 – a) Relação entre custo de investimento  $\times$  EENS; b) Relação entre custo de investimento  $\times$  EWES; c) Relação entre EENS  $\times$  EWES



Fonte: Elaborado pelo autor (2024)


Em SC-4 a incerteza da carga a partir da curva anual é incorporada. Nesse caso, a solução encontrada apresenta um custo de investimento de US\$  $132,11 \times 10^6$ , associado a uma EENS de apenas 0,42 MWh e EWES nula. Em relação a SC-3, equivale a uma redução de 22,80% e 99,61% para  $f_1$  e  $f_2$ , respectivamente. Naturalmente o menor patamar simulado pelas características probabilísticas da curva reduz o número de falhas por perda de carga no sistema (aumento da confiabilidade) e conseqüentemente o esforço computacional do algoritmo.

A Figura 32 apresenta a relação entre os objetivos para SC-4. É possível observar uma maior concentração de soluções associadas a custos de investimento próximos de



US\$  $100,00 \times 10^6$  e EENS menor que 500 MWh, portanto, mais baratas e mais robustas que em SC-3. Além disso, os valores de EENS e EWES são expressivamente menores que o caso anterior.

Figura 32 – Fronteiras de Pareto obtidas para o BSS-WIND em CS-4 – a) Relação entre custo de investimento  $\times$  EENS; b) Relação entre custo de investimento  $\times$  EWES; c) Relação entre EENS  $\times$  EWES




Fonte: Elaborado pelo autor (2024)

Com comportamento semelhante ao sistema RTS-WIND, a solução em SC-5 apresenta um aumento substancial do custo de investimento e da EENS em relação a SC-4, 65,91% e 364.185,71%, respectivamente. Isso se deve ao fato de que nesse caso de simulação são consideradas as falhas compostas dos equipamentos de geração e transmissão do sistema. Conforme descrito anteriormente, o sistema BSS-WIND apresenta uma menor confiabilidade de seu caso base, o que justifica o aumento expressivo da EENS nesse caso e maior sensibilidade ao corte de carga frente a perda da geração convencional. Pode-se destacar ainda que toda a energia eólica está disponível, ou seja, não há corte de vento, uma vez que o sistema BSS-WIND tem capacidade de transmissão suficiente para a energia renovável, mesmo sob as interrupções consideradas.

A relação entre os objetivos é ilustrada na Figura 33. Os custos de investimento associados aumentaram substancialmente em comparação com SC-4. Em relação aos índices de confiabilidade, no entanto, observa-se que, apesar do aumento nos valores para a EENS, a maioria das soluções encontradas possuem valores baixos para o índice EWES, o que reforça o fato de que as configurações encontradas são capazes de utilizar quase toda a geração eólica disponível.

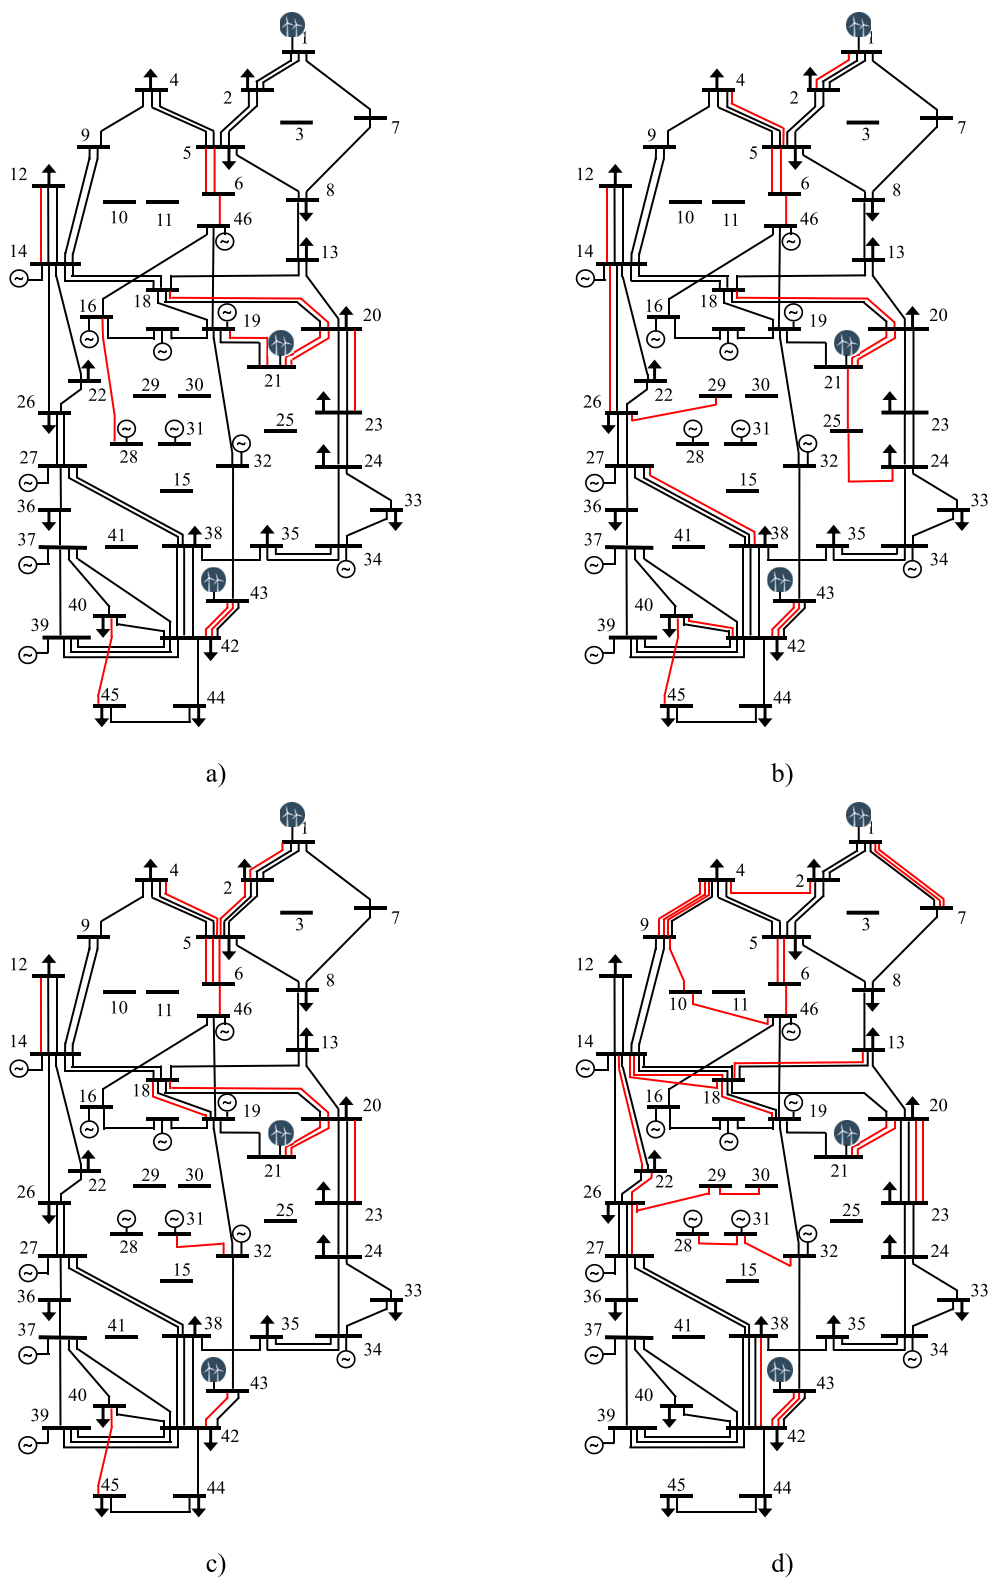
Figura 33 – Fronteiras de Pareto obtidas para o BSS-WIND em CS-5 – a) Relação entre custo de investimento  $\times$  EENS; b) Relação entre custo de investimento  $\times$  EWES; c) Relação entre EENS  $\times$  EWES



Fonte: Elaborado pelo autor (2024)

Por fim, é importante destacar que a eficiência computacional dos casos simulados depende das características de incerteza consideradas para o sistema BSS-WIND. Pode-se observar que os tempos de CPU para as soluções obtidas pelo IND-MCS foram menores que o de CS-1, com exceção de SC-4 que representa a incerteza na carga como complexidade adicional. A eficiência computacional está fortemente relacionada com a robustez do sistema, ou seja, com o nível de confiabilidade do plano de expansão. Dessa forma, os baixos valores para EENS e EWES em SC-4 justificam o maior tempo computacional necessário. Além disso, vale ressaltar que o tempo computacional em todos os casos simulados seriam impraticáveis se o método de SMC convencional fosse utilizado. Isso reforça a aplicabilidade da metodologia proposta em fornecer estudos abrangentes com múltiplas incertezas no problema PET com razoáveis tempos computacionais. A Figura 34 ilustra a topologia de reforços para os casos descritos.

Figura 34 – Topologia para o sistema BSS-WIND reforçado – a) CS-1; b) CS-3; c) CS-4; d) CS-5



Fonte: Elaborado pelo autor (2024)

#### 4.3. CONCLUSÕES PARCIAIS

Este capítulo apresentou os resultados obtidos da aplicação dos algoritmos propostos – ND-MCS e IND-MCS para solução do problema PET multicritério básico e com múltiplas incertezas. Os estudos de caso realizados têm o objetivo de demonstrar o desempenho da técnica proposta, ressaltando as características positivas de obtenção de soluções frente a métodos convencionais de solução frequentemente abordados na literatura, bem como sua capacidade computacional.

As diferentes configurações simuladas para o sistema IEEE-RTS e para o sistema equivalente sul brasileiro, BSS, estabelecem condições frequentemente consideradas em estudos de expansão de sistemas de transmissão como as incertezas relacionadas à carga e à presença de geração renovável. A partir dos resultados obtidos, é possível estabelecer um aprendizado a respeito do comportamento dos algoritmos ND-MCS e IND-MCS e como podem contribuir de forma significativa na obtenção de planos de expansão.

Em razão das características probabilísticas de representação de equipamentos, foi observada a capacidade de se evitar sobreinvestimentos no problema PET, um dos principais desafios de planejamento de sistemas. Uma melhor relação entre custos de investimento e confiabilidade podem ser assegurados, uma vez que o problema multicritério avalia a segurança dos sistemas ao longo do processo de otimização (“*a priori*”) com considerável eficiência computacional. Além disso, os algoritmos propostos permitem uma melhor busca no espaço de soluções devido à sua capacidade de identificação e filtragem de soluções não-dominadas, portanto, mais atrativas ao longo das etapas de otimização.

A consideração de múltiplas incertezas através do comportamento probabilístico de cargas, fontes eólicas e da disponibilidade dos equipamentos demonstrou como essas variáveis afetam significativamente os planos de expansão quando se utilizam critérios multiobjetivos. Os resultados indicam que a representação probabilística de incertezas pelo algoritmo IND-MCS leva a soluções com melhores objetivos se comparados com as abordagens tradicionalmente vistas na literatura. Um aspecto importante da abordagem proposta é o seu potencial para encontrar soluções que abordem problemas com incertezas simultâneas sem aumento considerável do esforço computacional quando comparado ao ND-MCS original.

## 5. CONCLUSÕES E TRABALHOS FUTUROS

### 5.1. CONCLUSÕES

Esta tese apresentou uma nova abordagem multiobjetivo para solucionar o problema de expansão da transmissão considerando incertezas, baseada em critérios estocásticos de dominância de Pareto. A principal contribuição da metodologia proposta é o desenvolvimento de uma eficiente ferramenta estocástica de apoio ao planejamento multiobjetivo de sistemas baseada em Simulação Monte Carlo, um dos métodos mais difundidos na literatura para consideração de incertezas no PET. A técnica desenvolvida possibilita a consideração de múltiplas incertezas ao longo do processo de otimização com considerável eficiência computacional e filtragem de boas soluções no espaço de busca que, juntamente com a modelagem probabilística das variáveis do sistema, permite uma redução de sobreinvestimentos nos planos selecionados.

A avaliação da confiabilidade em sistemas elétricos foi revisada no Capítulo 2, sendo proposto neste trabalho o método de Simulação Monte Carlo não-sequencial para estimação dos índices de confiabilidade que compõem a metodologia proposta. Como auxílio na estratégia de planejamento, foi proposta ainda a utilização da técnica de Máquinas de Vetores de Suporte para redução do esforço computacional na análise da confiabilidade composta de sistemas. O método foi validado através de análises baseadas em diferentes variáveis de treinamento para o sistema teste IEEE-RTS e os resultados demonstraram alto desempenho na identificação de estados de falha e estimação correta de índices.

A modelagem matemática do problema PET multiobjetivo foi apresentada no Capítulo 3 em conjunto com a metodologia proposta. O primeiro algoritmo proposto, ND-MCS, realiza o planejamento da transmissão baseado na minimização do custo de investimento e do índice EENS de planos alternativos avaliados. A ferramenta adota funções probabilísticas baseadas em critérios de dominância para filtrar soluções no espaço de busca e melhorar consideravelmente a eficiência computacional do modelo quando comparada ao método tradicional de SMC. O segundo algoritmo, IND-MCS, traz uma versão modificada do algoritmo fonte capaz de considerar múltiplas incertezas no planejamento com participação de fontes renováveis de geração de energia eólica. Em ambas as abordagens, a confiabilidade é avaliada *a priori*, ou seja, os índices são estimados ao longo de todo o procedimento de busca da otimização.

No Capítulo 4, foram apresentados estudos de caso da aplicação das metodologias propostas para demonstrar seu desempenho na busca de soluções para o PET probabilístico. Os algoritmos propostos foram aplicados em diferentes condições de planejamento para dois sistemas – IEEE RTS 24 barras e Sistema sul brasileiro equivalente (BSS). Os resultados para ambos os algoritmos sugeriram uma capacidade da metodologia de filtragem de soluções não-dominadas que reduzem o sobreinvestimento nos sistemas através da modelagem probabilística dos critérios de segurança considerados. Além disso, um expressivo ganho computacional em relação à técnica tradicional foi obtido em razão do processo de interrupção precoce da estimação de índices para soluções dominadas, tornando a ferramenta atrativa para estudos complexos de planejamento com incertezas.

Em face dos atuais desafios de modelagem de incertezas para o problema PET, as ferramentas desenvolvidas nesta tese abrem espaço para uma utilização mais eficiente do método de Simulação Monte Carlo para representação de condições probabilísticas no planejamento multicritério da expansão de sistemas. Em razão da complexidade da modelagem de incertezas em todo o processo de otimização, há um grande potencial de desenvolvimento de novos estudos baseados em critérios probabilísticos de dominância que podem aprimorar as ferramentas atuais de auxílio no processo de tomada de decisão por parte de planejadores de sistemas.

## 5.2. PROPOSTAS DE TRABALHOS FUTUROS

A partir dos aspectos identificados nos estudos de caso e da relevância da temática abordada, pode-se citar como sugestões de melhoria da metodologia atual e desenvolvimentos futuros os seguintes tópicos:

- Os algoritmos ND-MCS e IND-MCS são formulados para o planejamento estático da transmissão e podem ser estendidos para permitir a obtenção de soluções para o planejamento multiestágio (dinâmico) da transmissão.
- O método de Simulação Monte Carlo não sequencial é utilizado em razão de sua menor complexidade na amostragem de estados. A técnica proposta permite a utilização da Simulação Monte Carlo sequencial, capaz de representar aspectos cronológicos de operação dos sistemas.

- É possível a utilização de outros índices importantes para a transmissão como os relacionados à frequência de duração (F&D) das falhas. Novos testes de variáveis de treinamento da rede SVM para identificação de falhas são necessários.
- Aplicar as metodologias desenvolvidas em sistemas de grande porte que permitirão avaliar sua robustez em sistemas mais confiáveis, o que dificulta a obtenção de índices a partir de métodos probabilísticos tradicionais.
- Aplicar técnicas computacionais de melhoramento de desempenho para permitir um aumento na precisão dos índices obtidos (e.g. computação paralela).
- Estender a modelagem para outras fontes variáveis de geração, e. g., usinas fotovoltaicas.
- Implementar uma modelagem não-linear para o fluxo de potência ótimo de modo a permitir melhor representação de efeitos da geração variável de fontes renováveis como os efeitos da injeção de potência reativa na rede.
- Aprimorar a codificação dos indivíduos da otimização.
- Elaborar estratégias de tomada de decisão para seleção da solução final de planejamento com menor interferência do planejador.

## REFERÊNCIAS

- Abdelaziz, A. R. ([s.d.]). Genetic algorithm-based power transmission expansion planning. *ICECS 2000. 7th IEEE International Conference on Electronics, Circuits and Systems (Cat. No.00EX445)*, 642–645. <https://doi.org/10.1109/ICECS.2000.912959>
- Akbari, T., Rahimikian, A., & Kazemi, A. (2011). A multi-stage stochastic transmission expansion planning method. *Energy Conversion and Management*, 52(8–9), 2844–2853. <https://doi.org/10.1016/j.enconman.2011.02.023>
- Alguacil, N., Motto, A. L., & Conejo, A. J. (2003). Transmission expansion planning: a mixed-integer LP approach. *IEEE Transactions on Power Systems*, 18(3), 1070–1077. <https://doi.org/10.1109/TPWRS.2003.814891>
- Alizadeh-Mousavi, O., & Zima-Bočkarjova, M. (2016). Efficient Benders cuts for transmission expansion planning. *Electric Power Systems Research*, 131, 275–284. <https://doi.org/10.1016/j.epsr.2015.10.022>
- Allahvirdizadeh, Y., Galvani, S., & Shayanfar, H. (2023). Stochastic multi-stage joint expansion planning of transmission system and energy hubs in the presence of correlated uncertainties. *IET Renewable Power Generation*, 17(9), 2335–2365. <https://doi.org/10.1049/rpg2.12762>
- Alshamrani, A. M., El-Meligy, M. A., Sharaf, M. A. F., Mohammed Saif, W. A., & Awwad, E. M. (2023). Transmission Expansion Planning Considering a High Share of Wind Power to Maximize Available Transfer Capability. *IEEE Access*, 11, 23136–23145. <https://doi.org/10.1109/ACCESS.2023.3253201>
- ANDERS, G. J. et al. (1990). Fast Monte Carlo simulation techniques for power system reliability studies. *1990 CIGRE Meeting*.
- Arabali, A., Ghofrani, M., Etezadi-Amoli, M., Fadali, M. S., & Moeini-Aghtaie, M. (2014). A multi-objective transmission expansion planning framework in deregulated power systems with wind generation. *IEEE Transactions on Power Systems*, 29(6), 3003–3011. <https://doi.org/10.1109/TPWRS.2014.2316529>
- Armando M. Leite da Silva;, Luiz A. da Fonseca Manso;, Leonidas C. de Resende;, & Leandro S. Rezende. (2008). Tabu Search Applied to Transmission Expansion Planning Considering Losses and Interruption Costs. *Proceedings of the 10th International Conference on Probabilistic Methods Applied to Power Systems*, 25–29.
- Ashok Bakkiyaraj, R., & Kumarappan, N. (2013). Optimal reliability planning for a composite electric power system based on Monte Carlo simulation using particle swarm optimization. *International Journal of Electrical Power and Energy Systems*, 47(1), 109–116. <https://doi.org/10.1016/j.ijepes.2012.10.055>
- Assis, F. A. de. (2018). Algoritmo Metaheurístico Construtivo para Solução do Problema de Planejamento da Expansão da Transmissão [Tese de Doutorado]. Em *Pontifícia Universidade Católica do Rio de Janeiro*. [http://www.maxwell.vrac.puc-rio.br/Busca\\_etds.php?strSecao=resultado&nrSeq=35771@1](http://www.maxwell.vrac.puc-rio.br/Busca_etds.php?strSecao=resultado&nrSeq=35771@1)
- Assis, F. A., Leite da Silva, A. M., Manso, L. A. F., & Castro, J. F. C. (2021). Transmission expansion planning of large power networks via constructive metaheuristics with security



constraints and load uncertainty analysis. *International Transactions on Electrical Energy Systems*, 31(1). <https://doi.org/10.1002/2050-7038.12595>

Assis, F. A., Manso, L. A. F., da Silva, A. M. L., & Leon, J. E. A. (2018). Transmission expansion planning with wind sources based on constructive metaheuristics. *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, 1–6. <https://doi.org/10.1109/SBSE.2018.8395638>

Billinton, R., & Allan, R. N. (1996). *Reliability Evaluation of Power Systems*. Springer US. <https://doi.org/10.1007/978-1-4899-1860-4>

Billinton, R., & Li, W. (1993). A system state transition sampling method for composite system reliability evaluation. *IEEE Transactions on Power Systems*, 8(3), 761–770. <https://doi.org/10.1109/59.260930>

Billinton, R., & Li, W. (1994). *Reliability Assessment of Electric Power Systems Using Monte Carlo Methods*. Springer US. <https://doi.org/10.1007/978-1-4899-1346-3>

Billinton, R., & Wangdee, W. (2007). Reliability-Based Transmission Reinforcement Planning Associated With Large-Scale Wind Farms. *IEEE Transactions on Power Systems*, 22(1), 34–41. <https://doi.org/10.1109/TPWRS.2006.889126>

Billinton, R., & Wenyuan, L. (1991). Hybrid approach for reliability evaluation of composite generation and transmission systems using Monte-Carlo simulation and enumeration technique. *IEE Proceedings C Generation, Transmission and Distribution*, 138(3), 233–241. <https://doi.org/10.1049/ip-c.1991.0029>

Binato, S., de Oliveira, G. C., & de Araujo, J. L. (2001). A greedy randomized adaptive search procedure for transmission expansion planning. *IEEE Transactions on Power Systems*, 16(2), 247–253. <https://doi.org/10.1109/59.918294>

Bustamante-Cedeño, E., & Arora, S. (2009). Multi-step simultaneous changes Constructive Heuristic Algorithm for Transmission Network Expansion Planning. *Electric Power Systems Research*, 79(4), 586–594. <https://doi.org/10.1016/j.epsr.2008.08.011>

C. Florez, C. A. ; B. Ocampo, R. A. ; & E. Zuluaga, A. H. (2014). Multi-objective transmission expansion planning considering multiple generation scenarios. *International Journal of Electrical Power & Energy Systems*, 62, 398–409. <https://doi.org/10.1016/j.ijepes.2014.04.063>

da Costa, L. C., Thome, F. S., Garcia, J. D., & Pereira, M. V. F. (2021). Reliability-Constrained Power System Expansion Planning: A Stochastic Risk-Averse Optimization Approach. *IEEE Transactions on Power Systems*, 36(1), 97–106. <https://doi.org/10.1109/TPWRS.2020.3007974>

Da Rosa, M. A., Leite Da Silva, A. M., & Miranda, V. (2012). Multi-agent systems applied to reliability assessment of power systems. *International Journal of Electrical Power and Energy Systems*, 42(1), 367–374. <https://doi.org/10.1016/j.ijepes.2012.03.048>

da Rosa, M. A., Miranda, V., Carvalho, L., & Leite da Silva, A. M. (2010). Modern computing environment for power system reliability assessment. *2010 IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*, 664–671. <https://doi.org/10.1109/PMAPS.2010.5528321>

Da Silva, A. M. L., De Resende, L. C., Luiz A., D. F. M., & Miranda, V. (2008). Artificial neural networks applied to reliability and well-being assessment of composite power systems.

*Proceedings of the 10th International Conference on Probabilistic Methods Applied to Power Systems, PMAPS 2008, 1996*, 310–315.

Da Silva, E. L., Ortiz, J. M. A., De Oliveira, G. C., & Binato, S. (2001). Transmission network expansion planning under a Tabu Search approach. *IEEE Transactions on Power Systems*, *16*(1), 62–68. <https://doi.org/10.1109/59.910782>

Davoodi, A., Reza Abbasi, A., & Nejatian, S. (2021). Multi-objective dynamic generation and transmission expansion planning considering capacitor bank allocation and demand response program constrained to flexible-secureable clean energy. *Sustainable Energy Technologies and Assessments*, *47*. <https://doi.org/10.1016/j.seta.2021.101469>

de Araujo, R. A., Torres, S. P., Filho, J. P., Castro, C. A., & Van Hertem, D. (2023). Unified AC Transmission Expansion Planning Formulation incorporating VSC-MTDC, FACTS devices, and Reactive Power compensation. *Electric Power Systems Research*, *216*, 109017. <https://doi.org/10.1016/j.epsr.2022.109017>

de Mendonça, I. M., Junior, I. C. S., & Marcato, A. L. M. (2014). Static planning of the expansion of electrical energy transmission systems using particle swarm optimization. *International Journal of Electrical Power & Energy Systems*, *60*, 234–244. <https://doi.org/10.1016/j.ijepes.2014.02.028>

De Oliveira, E. J., Moraes, C. A., Oliveira, L. W., Honório, L. M., & Poubel, R. P. B. (2018). Efficient hybrid algorithm for transmission expansion planning. *Electrical Engineering*, *100*(4), 2765–2777. <https://doi.org/10.1007/s00202-018-0744-2>

de Paula, A. N., de Oliveira, E. J., de Oliveira, L. W., & Honório, L. M. (2020). Robust Static Transmission Expansion Planning Considering Contingency and Wind Power Generation. *Journal of Control, Automation and Electrical Systems*, *31*(2), 461–470. <https://doi.org/10.1007/s40313-019-00556-w>

de Paula, A. N., de Oliveira, E. J., Oliveira, L. W., & Moraes, C. A. (2020). Reliability-constrained dynamic transmission expansion planning considering wind power generation. *Electrical Engineering*, *102*(4), 2583–2593. <https://doi.org/10.1007/s00202-020-01054-y>

Deb, K. (2011). Multi-objective Optimisation Using Evolutionary Algorithms: An Introduction. Em *Multi-objective Evolutionary Optimisation for Product Design and Manufacturing* (p. 3–34). Springer London. [https://doi.org/10.1007/978-0-85729-652-8\\_1](https://doi.org/10.1007/978-0-85729-652-8_1)

Dorvlo, A. S. S. (2002). Estimating wind speed distribution. *Energy Conversion and Management*, *43*(17), 2311–2318. [https://doi.org/10.1016/S0196-8904\(01\)00182-0](https://doi.org/10.1016/S0196-8904(01)00182-0)

dos Santos, T. N., & Diniz, A. L. (2011). A Dynamic Piecewise Linear Model for DC Transmission Losses in Optimal Scheduling Problems. *IEEE Transactions on Power Systems*, *26*(2), 508–519. <https://doi.org/10.1109/TPWRS.2010.2057263>

El-Meligy, M. A., & Sharaf, M. (2024). Robust transmission expansion planning under robust network constrained-unit commitment. *Electric Power Systems Research*, *229*, 110164. <https://doi.org/10.1016/j.epsr.2024.110164>

F. Pereira, M., V. G. Pinto, L., F. Cunha, S., & Oliveira, G. (1985). A Decomposition Approach To Automated Generation/Transmission Expansion Planning. *IEEE Transactions on Power Apparatus and Systems*, *PAS-104*(11), 3074–3083. <https://doi.org/10.1109/TPAS.1985.318815>

- Gallego, R. A., Alves, A. B., Monticelli, A., & Romero, R. (1997). Parallel simulated annealing applied to long term transmission network expansion planning. *IEEE Transactions on Power Systems*, 12(1), 181–188. <https://doi.org/10.1109/59.574938>
- Garcia-Cerezo, A., Garcia-Bertrand, R., & Baringo, L. (2021). Enhanced Representative Time Periods for Transmission Expansion Planning Problems. *IEEE Transactions on Power Systems*, 36(4), 3802–3805. <https://doi.org/10.1109/TPWRS.2021.3067148>
- Garver, L. L. (1970). Transmission Network Planning Using Linear Programming. *IEEE Transactions on Apparatus and Systems*, PAS-89(7), 1688–1697. <https://doi.org/10.1109/MPER.1985.5528872>
- Gazijahani, F. S., Ravadanegh, S. N., & Salehi, J. (2018a). Stochastic multi-objective model for optimal energy exchange optimization of networked microgrids with presence of renewable generation under risk-based strategies. *ISA Transactions*, 73, 100–111. <https://doi.org/10.1016/j.isatra.2017.12.004>
- Gazijahani, F. S., Ravadanegh, S. N., & Salehi, J. (2018b). Stochastic multi-objective model for optimal energy exchange optimization of networked microgrids with presence of renewable generation under risk-based strategies. *ISA Transactions*, 73, 100–111. <https://doi.org/10.1016/j.isatra.2017.12.004>
- Geng, L., Zhao, Y., & Li, W. (2019). Enhanced Cross Entropy Method for Composite Power System Reliability Evaluation. *IEEE Transactions on Power Systems*, 34(4), 3129–3139. <https://doi.org/10.1109/TPWRS.2019.2897384>
- Ghadimi, A. A., Amani, M., Bayat, M., Ahmadi, S., Miveh, M. R., & Jurado, F. (2022a). Stochastic transmission expansion planning in the presence of wind farms considering reliability and N-1 contingency using grey wolf optimization technique. *Electrical Engineering*, 104(2), 727–740. <https://doi.org/10.1007/s00202-021-01339-w>
- Ghadimi, A. A., Amani, M., Bayat, M., Ahmadi, S., Miveh, M. R., & Jurado, F. (2022b). Stochastic transmission expansion planning in the presence of wind farms considering reliability and N-1 contingency using grey wolf optimization technique. *Electrical Engineering*, 104(2), 727–740. <https://doi.org/10.1007/s00202-021-01339-w>
- Gholizadeh-Roshanagh, R., Zare, K., & Marzband, M. (2020). An A-Posteriori Multi-Objective Optimization Method for MILP-Based Distribution Expansion Planning. *IEEE Access*, 8, 60279–60292. <https://doi.org/10.1109/ACCESS.2020.2981943>
- Gomes, P. V., & Saraiva, J. T. (2019). State-of-the-art of transmission expansion planning: A survey from restructuring to renewable and distributed electricity markets. In *International Journal of Electrical Power and Energy Systems* (Vol. 111, p. 411–424). Elsevier Ltd. <https://doi.org/10.1016/j.ijepes.2019.04.035>
- González-fernández, R. a, Leite, A. M., Resende, L. C., & Schilling, M. T. (2013). Composite Systems Reliability Evaluation Based on Monte Carlo Simulation and Cross-Entropy Methods. *IEEE Transactions on Power Systems*, 28(4), 4598–4606.
- Haffner, S., Monticelli, A., Garcia, A., Mantovani, J., & Romero, R. (2000). Branch and bound algorithm for transmission system expansion planning using a transportation model. *IEE Proceedings: Generation, Transmission and Distribution*, 147(3), 149–155. <https://doi.org/10.1049/ip-gtd:20000337>

- Hamidpour, H., Pirouzi, S., Safaee, S., Norouzi, M., & Lehtonen, M. (2021). Multi-objective resilient-constrained generation and transmission expansion planning against natural disasters. *International Journal of Electrical Power and Energy Systems*, 132. <https://doi.org/10.1016/j.ijepes.2021.107193>
- HAYKIN, S. (2001). *Redes neurais: princípios e prática* (2ª Edition). Bookman Editora.
- Huang, S., & Dinavahi, V. (2019). A Branch-and-Cut Benders Decomposition Algorithm for Transmission Expansion Planning. *IEEE Systems Journal*, 13(1), 659–669. <https://doi.org/10.1109/JSYST.2017.2775610>
- J. MacQUEEN. (1967). Some methods for classification and analysis of multivariate observations. Em *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability* (14º ed, Vol. 1, p. 281–297).
- Kamyab, G.-R., Fotuhi-Firuzabad, M., & Rashidinejad, M. (2014). A PSO based approach for multi-stage transmission expansion planning in electricity markets. *International Journal of Electrical Power & Energy Systems*, 54, 91–100. <https://doi.org/10.1016/j.ijepes.2013.06.027>
- Kazemi, M., & Ansari, M. R. (2022). An integrated transmission expansion planning and battery storage systems placement - A security and reliability perspective. *International Journal of Electrical Power and Energy Systems*, 134. <https://doi.org/10.1016/j.ijepes.2021.107329>
- L. C. Resende, A. M. L. da S. and L. A. F. M. (2008). Avaliação da Confiabilidade Convencional e Preventiva de Sistemas de Geração e Transmissão. *XVII Congresso Brasileiro de Automática*.
- Latorre, G., Darío Cruz, R., Areiza, J. M., & Villegas, A. (2003). Classification of publications and models on transmission expansion planning. *IEEE Transactions on Power Systems*, 18(2), 938–946. <https://doi.org/10.1109/TPWRS.2003.811168>
- Lee, C. W., Ng, S. K. K., Zhong, J., & Wu, F. F. (2006). Transmission expansion planning from past to future. *2006 IEEE PES Power Systems Conference and Exposition, PSCE 2006 - Proceedings*, 257–265. <https://doi.org/10.1109/PSCE.2006.296317>
- Lei, Y., Zhang, P., Hou, K., Jia, H., Mu, Y., & Sui, B. (2018). An Incremental Reliability Assessment Approach for Transmission Expansion Planning. *IEEE Transactions on Power Systems*, 33(3), 2597–2609. <https://doi.org/10.1109/TPWRS.2017.2756261>
- Leite, A. P., Falcão, D. M., & Borges, C. L. T. (2006). Modelagem de usinas eólicas para estudos de confiabilidade. *Sba: Controle & Automação Sociedade Brasileira de Automática*, 17(2), 177–188. <https://doi.org/10.1590/S0103-17592006000200006>
- Leite Da Silva, A. M., Da Fonseca Manso, L. A., De Sousa Sales, W., Flavio, S. A., Anders, G. J., & De Resende, L. C. (2012). Chronological power flow for planning transmission systems considering intermittent sources. *IEEE Transactions on Power Systems*, 27(4), 2314–2322. <https://doi.org/10.1109/TPWRS.2012.2203830>
- Leite da Silva, A. M., de Resende, L. C., da Fonseca Manso, L. A., & Miranda, V. (2007). Composite Reliability Assessment Based on Monte Carlo Simulation and Artificial Neural Networks. *IEEE Transactions on Power Systems*, 22(3), 1202–1209. <https://doi.org/10.1109/TPWRS.2007.901302>
- Leite da Silva, A. M., Rezende, L. S., da Fonseca Manso, L. A., & de Resende, L. C. (2010). Reliability worth applied to transmission expansion planning based on ant colony system.

*International Journal of Electrical Power & Energy Systems*, 32(10), 1077–1084.  
<https://doi.org/10.1016/j.ijepes.2010.06.003>

Leite da Silva, A. M., Rezende, L. S., Manso, L. A. F., & Anders, G. J. (2010). Transmission expansion planning: A discussion on reliability and “N-1” security criteria. *2010 IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*, 244–251.  
<https://doi.org/10.1109/PMAPS.2010.5528652>

Li, C., Conejo, A. J., Liu, P., Omell, B. P., Siirola, J. D., & Grossmann, I. E. (2022). Mixed-integer linear programming models and algorithms for generation and transmission expansion planning of power systems. *European Journal of Operational Research*, 297(3), 1071–1082.  
<https://doi.org/10.1016/j.ejor.2021.06.024>

Li, W., & Billinton, R. (1991). Effect of bus load uncertainty and correlation in composite system adequacy evaluation. *IEEE Transactions on Power Systems*, 6(4), 1522–1529.  
<https://doi.org/10.1109/59.116999>

Liu, D., Zhang, S., Cheng, H., Liu, L., Zhang, J., & Zhang, X. (2021). Reducing wind power curtailment by risk-based transmission expansion planning. *International Journal of Electrical Power & Energy Systems*, 124, 106349.  
<https://doi.org/10.1016/j.ijepes.2020.106349>

Lun, I. Y. F., & Lam, J. C. (2000). A study of Weibull parameters using long-term wind observations. *Renewable Energy*, 20(2), 145–153. [https://doi.org/10.1016/S0960-1481\(99\)00103-2](https://doi.org/10.1016/S0960-1481(99)00103-2)

Luo, X., Singh, C., & Patton, A. D. (1999). Loss-of-load state identification using self-organizing map. *199 IEEE Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No.99CH36364)*, 670–675. <https://doi.org/10.1109/PESS.1999.787397>

MacRae, C. A. G., Ernst, A. T., & Ozlen, M. (2016). A Benders decomposition approach to transmission expansion planning considering energy storage. *Energy*, 112, 795–803.  
<https://doi.org/10.1016/j.energy.2016.06.080>

Maghouli, P., Hosseini, S. H., Buygi, M. O., & Shahidehpour, M. (2009). A Multi-Objective Framework for Transmission Expansion Planning in Deregulated Environments. *IEEE Transactions on Power Systems*, 24(2), 1051–1061.  
<https://doi.org/10.1109/TPWRS.2009.2016499>

Maghouli, P., Hosseini, S. H., Oloomi Buygi, M., & Shahidehpour, M. (2011). A scenario-based multi-objective model for multi-stage transmission expansion planning. *IEEE Transactions on Power Systems*, 26(1), 470–478.  
<https://doi.org/10.1109/TPWRS.2010.2048930>

Manso, L. A. F., & Silva, A. M. L. da. (2004). Modelagem de cargas variantes no tempo na avaliação de confiabilidade composta via simulação Monte Carlo não-seqüencial. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, 15(1), 93–100.  
<https://doi.org/10.1590/S0103-17592004000100012>

Marler, R. T., & Arora, J. S. (2004). Survey of multi-objective optimization methods for engineering. *Structural and Multidisciplinary Optimization*, 26(6), 369–395.  
<https://doi.org/10.1007/s00158-003-0368-6>

- Marmidis, G., Lazarou, S., & Pyrgioti, E. (2008). Optimal placement of wind turbines in a wind park using Monte Carlo simulation. *Renewable Energy*, *33*(7), 1455–1460. <https://doi.org/10.1016/j.renene.2007.09.004>
- Melo, A. C. G., Pereira, M. V. F., & Leite da Silva, A. M. (1992). Frequency and duration calculations in composite generation and transmission reliability evaluation. *IEEE Transactions on Power Systems*, *7*(2), 469–476. <https://doi.org/10.1109/59.141748>
- Melo, A. C. G., Pereira, M. V. F., & Leite da Silva, A. M. (1993). A conditional probability approach to the calculation of frequency and duration indices in composite reliability evaluation. *IEEE Transactions on Power Systems*, *8*(3), 1118–1125. <https://doi.org/10.1109/59.260886>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, *69*, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Mirjalili, S., Saremi, S., Mirjalili, S. M., & Coelho, L. dos S. (2016). Multi-objective grey wolf optimizer: A novel algorithm for multi-criterion optimization. *Expert Systems with Applications*, *47*, 106–119. <https://doi.org/10.1016/j.eswa.2015.10.039>
- Moeini-Aghtaie, M., Abbaspour, A., & Fotuhi-Firuzabad, M. (2012). Incorporating Large-Scale Distant Wind Farms in Probabilistic Transmission Expansion Planning—Part I: Theory and Algorithm. *IEEE Transactions on Power Systems*, *27*(3), 1585–1593. <https://doi.org/10.1109/TPWRS.2011.2182363>
- Monticelli, A., Santos, A., Pereira, M. V. F., Cunha, S. H., Parker, B. J., & Praça, J. C. G. (1982). Interactive transmission network planning using a least-effort criterion. *IEEE Transactions on Power Apparatus and Systems*, *PAS-101*(10), 3919–3925. <https://doi.org/10.1109/TPAS.1982.317043>
- Monticelli, A., Santos, A., Pereira, M. V. F., Cunha, S. H., Parker, B. J., Pracoa, J. C. G., Ieee, N.-M., & Ieee, N.-M. (1982). Interactive transmission network planning using a least-effort criterion. Em *IEEE Transactions on Power Apparatus and Systems* (Vol. 101, Número 10).
- Moradi-Sepahvand, M., & Amraee, T. (2021). Hybrid AC/DC Transmission Expansion Planning Considering HVAC to HVDC Conversion Under Renewable Penetration. *IEEE Transactions on Power Systems*, *36*(1), 579–591. <https://doi.org/10.1109/TPWRS.2020.2988195>
- Moraes, C. A., de Oliveira, L. W., de Oliveira, E. J., Botelho, D. F., de Paula, A. N., & Pinto, M. F. (2022). A probabilistic approach to assess the impact of wind power generation in transmission network expansion planning. *Electrical Engineering*, *104*(2), 1029–1040. <https://doi.org/10.1007/s00202-021-01361-y>
- Moutinho, E. L., Borges, C. L. T., Moulin, L. S., & Berizzi, A. (2023). Assessment of most critical project delays on a multi-stage transmission expansion plan using particle swarm optimization. *International Journal of Electrical Power & Energy Systems*, *151*, 109159. <https://doi.org/10.1016/j.ijepes.2023.109159>
- N. Piandoriya, P. Jirutitijaroen, D. Srinivasan, C. S. (2011). Composite Reliability Evaluation Using Monte Carlo Simulation and Least Squares Support Vector Classifier. *IEEE Transactions on Power Systems*, *26*(4), 2483–2490. [https://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=5729852](https://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5729852)

- Naderi, E., Pourakbari-Kasmaei, M., & Lehtonen, M. (2020). Transmission expansion planning integrated with wind farms: A review, comparative study, and a novel profound search approach. *International Journal of Electrical Power & Energy Systems*, *115*, 105460. <https://doi.org/10.1016/j.ijepes.2019.105460>
- ONS. (2024). Plano de Operação Elétrica de Médio Prazo do SIN - Ciclo 2024-2028. *Sumário Executivo PAR/PEL 2023*, 1–50.
- Orfanos, G. A., Georgilakis, P. S., & Hatziargyriou, N. D. (2013). Transmission Expansion Planning of Systems With Increasing Wind Power Integration. *IEEE Transactions on Power Systems*, *28*(2), 1355–1362. <https://doi.org/10.1109/TPWRS.2012.2214242>
- Pan, J.-S., Hu, P., Snášel, V., & Chu, S.-C. (2023). A survey on binary metaheuristic algorithms and their engineering applications. *Artificial Intelligence Review*, *56*(7), 6101–6167. <https://doi.org/10.1007/s10462-022-10328-9>
- Park, H., Baldick, R., & Morton, D. P. (2015). A Stochastic Transmission Planning Model With Dependent Load and Wind Forecasts. *IEEE Transactions on Power Systems*, *30*(6), 3003–3011. <https://doi.org/10.1109/TPWRS.2014.2385861>
- Pereira, M., & Pinto, L. (1985). Application Of Sensitivity Analysis Of Load Supplying Capability To Interactive Transmission Expansion Planning. *IEEE Transactions on Power Apparatus and Systems*, *PAS-104*(2), 381–389. <https://doi.org/10.1109/TPAS.1985.319053>
- Pereira, M. V. F., Balu, N. J., Member, S., Objectives, A., & System, P. (1992). Composite Generation / Transmission Reliability Evaluation. *Proceedings of the IEEE*, *80*(4), 470–491.
- Pisner, D. A., & Schnyer, D. M. (2020). Support vector machine. Em *Machine Learning* (p. 101–121). Elsevier. <https://doi.org/10.1016/B978-0-12-815739-8.00006-7>
- Poubel, R. P. B., de Oliveira, E. J., de Mello Honório, L., de Oliveira, L. W., & da Silva Junior, I. C. (2015). A Coupled Model to Multistage Transmission Expansion Planning. *Journal of Control, Automation and Electrical Systems*, *26*(3), 272–282. <https://doi.org/10.1007/s40313-015-0179-1>
- Praveen, P., Ray, S., Dasl, J., & Bhattacharya, A. (2018). Multi-Objective Power System Expansion Planning with Renewable Intermittency and Considering Reliability. *2018 Internat2018 International Conference on Computation of Power, Energy, Information and Communication (ICCPEIC)ional conference on computation of power, energy, Information and Communication (ICCPEIC)*, 424–429. <https://doi.org/10.1109/ICCPEIC.2018.8525214>
- Rashedi, B., & Askarzadeh, A. (2022). A multi-objective approach for solving transmission expansion planning problem considering wind power uncertainty. *Evolutionary Intelligence*, *15*(1), 497–511. <https://doi.org/10.1007/s12065-020-00525-2>
- Rathore, C., & Roy, R. (2016). Impact of wind uncertainty, plug-in-electric vehicles and demand response program on transmission network expansion planning. *International Journal of Electrical Power and Energy Systems*, *75*, 59–73. <https://doi.org/10.1016/j.ijepes.2015.07.040>
- Rei, A. M., & Schilling, M. T. (2008). Reliability assessment of the Brazilian power system using enumeration and Monte Carlo. *IEEE Transactions on Power Systems*, *23*(3), 1480–1487. <https://doi.org/10.1109/TPWRS.2008.922532>
- Resende, L. C., Manso, L. A. F., Dutra, W. D., & Leite da Silva, A. M. (2015). Support Vector Machine application in composite reliability assessment. *2015 18th International Conference*

on *Intelligent System Application to Power Systems (ISAP)*, 1–6.  
<https://doi.org/10.1109/ISAP.2015.7325580>

Rezende, L. S., Leite da Silva, A. M., & M Honório, L. (2009). *Artificial Immune System Applied to the Multi-stage Transmission Expansion Planning* (p. 178–191).  
[https://doi.org/10.1007/978-3-642-03246-2\\_19](https://doi.org/10.1007/978-3-642-03246-2_19)

Rider, M. J., Garcia, A. V., & Romero, R. (2007). Power system transmission network expansion planning using AC model. *IET Generation, Transmission and Distribution*, 1(5), 731–742. <https://doi.org/10.1049/iet-gtd:20060465>

Roldán, C., García-Bertrand, R., & Mínguez, R. (2020). Robust transmission expansion planning with uncertain generations and loads using full probabilistic information. *Electric Power Systems Research*, 189, 106793. <https://doi.org/10.1016/j.epsr.2020.106793>

Romero, R., Gallego, R. A., & Monticelli, A. ([s.d.]). Transmission system expansion planning by simulated annealing. *Proceedings of Power Industry Computer Applications Conference*, 278–283. <https://doi.org/10.1109/PICA.1995.515195>

Singh, C., Luo, X., & Kim, H. (2006). Power system adequacy and security calculations using Monte Carlo simulation incorporating intelligent system methodology. *2006 9th International Conference on Probabilistic Methods Applied to Power Systems, PMAPS*.  
<https://doi.org/10.1109/PMAPS.2006.360224>

Subcommittee, P. M. (1979). IEEE Reliability Test System. *IEEE Transactions on Power Apparatus and Systems*, PAS-98(6), 2047–2054.

Tome Saraiva, J., Miranda, V., & Pinto, L. M. V. G. (1996). Generation/transmission power system reliability evaluation by Monte-Carlo simulation assuming a fuzzy load description. *IEEE Transactions on Power Systems*, 11(2), 690–695. <https://doi.org/10.1109/59.496140>

Ubeda, J. R., & Allan, R. N. (1992). Sequential simulation applied to composite system reliability evaluation. *IEE Proceedings C Generation, Transmission and Distribution*, 139(2), 81. <https://doi.org/10.1049/ip-c.1992.0014>

Ugranli, F., & Karatepe, E. (2015). Multi-objective transmission expansion planning considering minimization of curtailed wind energy. *International Journal of Electrical Power and Energy Systems*, 65, 348–356. <https://doi.org/10.1016/j.ijepes.2014.10.031>

Urgun, D., & Singh, C. (2019). A Hybrid Monte Carlo Simulation and Multi Label Classification Method for Composite System Reliability Evaluation. *IEEE Transactions on Power Systems*, 34(2), 908–917. <https://doi.org/10.1109/TPWRS.2018.2878535>

Urgun, D., Singh, C., & Vittal, V. (2020). Importance Sampling Using Multilabel Radial Basis Classification for Composite Power System Reliability Evaluation. *IEEE Systems Journal*, 14(2), 2791–2800. <https://doi.org/10.1109/JSYST.2019.2944131>

Vilaça, P., Street, A., & Colmenar, J. M. (2022). A MILP-based heuristic algorithm for transmission expansion planning problems. *Electric Power Systems Research*, 208, 107882. <https://doi.org/10.1016/j.epsr.2022.107882>

Villasana, R., Garver, L. L., & Salon, S. J. (1985). Transmission Network Planning Using Linear Programming. *IEEE Power Engineering Review*, PER-5(2), 36–37.  
<https://doi.org/10.1109/MPER.1985.5528872>



- Wang, L., Ng, A. H. C., & Deb, K. (Orgs.). (2011). *Multi-objective Evolutionary Optimisation for Product Design and Manufacturing*. Springer London.  
<https://doi.org/10.1007/978-0-85729-652-8>
- Y. Lee, S., Hicks, K., & Hnyilicza, E. (1974). Transmission Expansion by Branch-and-Bound Integer Programming with Optimal Cost - Capacity Curves. *IEEE Transactions on Power Apparatus and Systems, PAS-93*(5), 1390–1400. <https://doi.org/10.1109/TPAS.1974.293869>
- Yong, P., Zhang, N., Kang, C., Xia, Q., & Lu, D. (2019). MPLP-Based Fast Power System Reliability Evaluation Using Transmission Line Status Dictionary. *IEEE Transactions on Power Systems, 34*(2), 1630–1640. <https://doi.org/10.1109/TPWRS.2018.2878324>
- Zhang, H., Heydt, G. T., Vittal, V., & Quintero, J. (2013). An Improved Network Model for Transmission Expansion Planning Considering Reactive Power and Network Losses. *IEEE Transactions on Power Systems, 28*(3), 3471–3479.  
<https://doi.org/10.1109/TPWRS.2013.2250318>
- Zhang, X., & Conejo, A. J. (2018). Robust Transmission Expansion Planning Representing Long- and Short-Term Uncertainty. *IEEE Transactions on Power Systems, 33*(2), 1329–1338.  
<https://doi.org/10.1109/TPWRS.2017.2717944>
- Zhao, Y., Tang, Y., Li, W., & Yu, J. (2019). Composite Power System Reliability Evaluation Based on Enhanced Sequential Cross-Entropy Monte Carlo Simulation. *IEEE Transactions on Power Systems, 34*(5), 3891–3901. <https://doi.org/10.1109/TPWRS.2019.2909769>
- Zheng, Q., Ai, X., Fang, J., & Wen, J. (2019). Data-Adaptive Robust Transmission Network Planning Incorporating Post-Contingency Demand Response. *IEEE Access, 7*, 100296–100304. <https://doi.org/10.1109/ACCESS.2019.2928833>
- Zolfaghari Moghaddam, S. (2019). Generation and transmission expansion planning with high penetration of wind farms considering spatial distribution of wind speed. *International Journal of Electrical Power and Energy Systems, 106*, 232–241.  
<https://doi.org/10.1016/j.ijepes.2018.10.007>

## APÊNDICE A - Máquinas de Vetores de Suporte

### A.1 Máquinas de Vetores Suporte Linearmente Separáveis


A classificação binária, problema inicial tratado pela SVM, trata da classificação de duas classes sem perda de generalidade, por meio de um hiperplano ótimo definido a partir de um conjunto de treinamento linearmente separável. Um conjunto de treinamento é dito linearmente separável se for possível separar os padrões de classes diferentes contidos nesse conjunto por pelo menos um hiperplano (Pisner & Schnyer, 2020).

O conjunto de treinamento  $\{\mathbf{x}_i, y_i\}_{i=1}^N$  com entradas  $\mathbf{x}_i \in \mathcal{R}^N$  e saídas correspondentes  $y_i \in \{-1, +1\}$ , representa as classes linearmente separáveis. A equação que separa os padrões através de hiperplanos pode ser definida por:

$$\mathbf{w}^T \cdot \mathbf{x} + b = 0 \quad \text{A.1}$$

onde  $\mathbf{w}^T \cdot \mathbf{x}$  é o produto escalar entre os vetores  $\mathbf{w}$  e  $\mathbf{x}$ , em que  $\mathbf{x}$  é um vetor de entrada que representa os padrões do conjunto de treinamento,  $\mathbf{w}$  é o vetor de pesos ajustáveis e  $b$  é um limiar, conhecido como bias. A Figura 35 representa o hiperplano de separação  $(\mathbf{w}, b)$  em um espaço bidimensional para um conjunto de treinamento linearmente separável.

Figura 35 – Hiperplano de separação  $(\mathbf{w}, b)$  em um espaço bidimensional



Fonte: Elaborado pelo autor (2020)

A Equação A.1 pode ser reescrita por:

$$\begin{cases} \mathbf{w}^T \mathbf{x}_i + b \geq 0 & \Rightarrow y_i = +1 \\ \mathbf{w}^T \mathbf{x}_i + b \leq 0 & \Rightarrow y_i = -1 \end{cases} \quad \text{A.2}$$

A margem de separação, distância entre o hiperplano definido na Equação A.1 e o ponto mais próximo de ambas as classes é representado por  $\rho$ . O objetivo de uma SVM é encontrar um hiperplano que separe o conjunto de treinamento sem erro e maximize a margem de separação. Nesse caso, o hiperplano é definido como hiperplano ótimo, ilustrado na Figura 35.

Considerando que  $\mathbf{w}_o$  e  $b_o$  representam os valores ótimos do vetor peso e bias, respectivamente, a Equação A.1 do hiperplano pode ser reescrita como:

$$\mathbf{w}_o^T \cdot \mathbf{x}_o + b_o = 0 \quad \text{A.3}$$

A função discriminante,

$$g(\mathbf{x}) = \mathbf{w}_o^T \cdot \mathbf{x}_o + b_o \quad \text{A.4}$$

fornece uma medida algébrica de distância  $r$  entre  $\mathbf{x}$  e o hiperplano  $(\mathbf{w}_o, b_o)$  que pode ser representada por:

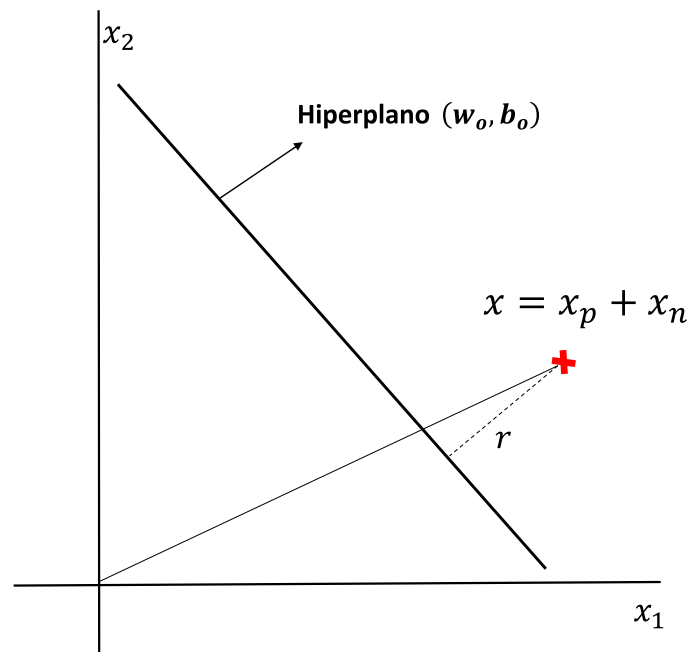
$$\mathbf{x} = \mathbf{x}_p + \mathbf{x}_n \quad \text{A.5}$$

em que  $\mathbf{x}_p$  é a projeção normal de  $\mathbf{x}$  sobre o hiperplano ótimo e  $\mathbf{x}_n$  é o vetor normal com distância  $r$ :

$$\mathbf{x}_n = r \cdot \frac{\mathbf{w}_o}{\|\mathbf{w}_o\|} \quad \text{A.6}$$

A Figura 36 ilustra a distância  $r$  entre  $\mathbf{x}$  e o hiperplano  $(\mathbf{w}_o, b_o)$ , onde  $r$  é positivo se  $\mathbf{x}$  estiver no lado positivo do hiperplano ótimo e negativo para o caso contrário.

Figura 36 – Interpretação gráfica da distância  $x$  até o hiperplano ótimo para o caso bidimensional



Fonte: Elaborado pelo autor (2020)

Considerando  $g(\mathbf{x}_p) = 0$

$$\begin{aligned} g(\mathbf{x}) &= \mathbf{w}_o^T \cdot \mathbf{x}_o + b_o \\ &= r \cdot \|\mathbf{w}_o\| \end{aligned} \quad \text{A.7}$$

A partir da Equação A.7 é possível obter a distância  $r$ :

$$r = \frac{|g(\mathbf{x})|}{\|\mathbf{w}_o\|} \quad \text{A.8}$$

O conjunto de treinamento é dito linearmente separável se  $\mathbf{w}_o$  e  $b_o$  satisfazem a restrição:

$$\begin{cases} \mathbf{w}_o^T \cdot \mathbf{x}_i + b_o \geq +1 & \Rightarrow y_i = +1 \\ \mathbf{w}_o^T \cdot \mathbf{x}_i + b_o \leq -1 & \Rightarrow y_i = -1 \end{cases} \quad \text{A.9}$$

os parâmetros  $\mathbf{w}_o$  e  $b_o$  são obtidos através do conjunto de treinamento. A Equação A.9 pode ser reescrita por:

$$d_i(\mathbf{w}_o^T \cdot \mathbf{x}_i + b_o) \geq 1 \quad \text{A.10}$$

O ponto  $(\mathbf{x}, d)$  em que a Equação A.10 é satisfeita para o sinal de igualdade são denominados vetores suporte, e são esses pontos que influenciam diretamente na localização do hiperplano ótimo de máxima margem, visto que estão mais próximos da superfície de decisão.

Considerando um ponto  $\mathbf{x}^{(s)}$  vetor suporte de classe positiva  $d^{(s)} = +1$ , por definição:

$$g(\mathbf{x}^{(s)}) = \mathbf{w}_o^T \cdot \mathbf{x}^{(s)} + b_o - 1 \Rightarrow y_i = +1 \quad \text{A.11}$$

Da Equação A.8, a distância do vetor suporte  $\mathbf{x}^{(s)}$  até o hiperplano ótimo é dada por:

$$r = \frac{\mathbf{w}_o^T \cdot \mathbf{x}^{(s)} + b_o}{\|\mathbf{w}_o\|} = \begin{cases} +\frac{1}{\|\mathbf{w}_o\|} & \text{se } y^s = +1 \\ -\frac{1}{\|\mathbf{w}_o\|} & \text{se } y^s = -1 \end{cases} \quad \text{A.12}$$

onde o sinal positivo indica que  $\mathbf{x}^{(s)}$  pertence ao lado positivo do hiperplano ótimo, enquanto que o sinal negativo refere-se ao contrário. Considerando  $\rho$  a margem de separação máxima entre duas classes de um conjunto de treinamento, então:

$$\rho = 2r = \frac{2}{\|\mathbf{w}_o\|} \quad \text{A.13}$$

Logo, a Equação A.13 mede a distância entre os hiperplanos da Equação A.10, do mesmo modo que a distância entre os hiperplanos  $\mathbf{w}^T \cdot \mathbf{x} + b = 0$  e  $\mathbf{w}^T \cdot \mathbf{x} + b = 1$  ou  $\mathbf{w}^T \cdot \mathbf{x} + b = -1$  é dada por  $\frac{1}{\|\mathbf{w}_o\|}$ . Como é suposto que a margem de separação é sempre maior que esta última distância, a minimização de  $\|\mathbf{w}\|$  leva a uma maximização da margem.

### Hiperplano ótimo para classes linearmente separáveis

O hiperplano ótimo definido para os parâmetros  $\mathbf{w}$  e  $b$  que satisfaçam as desigualdades da Equação A.10, pode ser reescrito como:

$$d_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1 \quad \text{A.14}$$

O objetivo da SVM é encontrar um procedimento computacional que, utilizando o conjunto de treinamento  $\{\mathbf{x}_i, y_i\}_{i=1}^N$  determine o hiperplano ótimo sujeito às restrições da Equação A.14. Este problema pode ser resolvido através do problema de otimização com restrições, minimizando a função custo  $\Phi$  em relação ao vetor de peso  $\mathbf{w}$  e satisfazendo a Equação A.14. A função custo é dada por:

$$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} \quad \text{A.15}$$

A partir da função custo da Equação A.15 é possível formular o problema de otimização com restrições, denominado problema primal:

$$\begin{aligned} & \text{MINIMIZAR} \quad \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} \\ & \text{SUJEITO A} \quad d_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1, \text{ para } i = 1, \dots, n \end{aligned} \quad \text{A.16}$$

Este é um problema clássico em otimização quadrática sob o aspecto de aprendizado de máquina. O problema de otimização analisado sob o aspecto de otimização da função quadrática pode ser resolvido introduzindo uma função lagrangeana, definida em termos de  $\mathbf{w}$  e  $b$ :

$$J(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i [y_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) - 1] \quad \text{A.17}$$

onde  $\alpha_i$  são denominados multiplicadores de Lagrange não-negativos.

O problema passa a ser então a minimização da Equação A.17 em relação a  $\mathbf{w}$  e  $b$  e de maximização de  $\alpha_i$  com  $\alpha_i \geq 0$ . Os pontos ótimos dessa equação são obtidos a partir da diferenciação da Equação A.17 em relação a  $\mathbf{w}$  e  $b$ , igualando a zero:

$$\text{Condição 1:} \quad \frac{\partial J(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} = 0 \quad \text{A.18}$$

$$\text{Condição 2: } \frac{\partial J(\mathbf{w}, b, \alpha)}{\partial b} = 0$$

A aplicação das condições de A.18 à função lagrangeana da Equação A.17 levam ao resultado:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i y_i \mathbf{x}_i \quad \text{A.19}$$

Substituindo a Equação A.19 em A.17, obtém-se o problema dual de otimização:

$$\text{MAXIMIZAR: } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \quad \text{A.20}$$

Com os multiplicadores de Lagrange obtidos é possível calcular o vetor de peso ótimo  $\mathbf{w}_o$  através da Equação A.19:

$$\mathbf{w}_o = \sum_{i=1}^N \alpha_{o_i} y_i \mathbf{x}_i \quad \text{A.21}$$

O problema dual descrito pela Equação A.20 é formulado totalmente em termos dos padrões de treinamento. Além disso, a equação a ser maximizada depende somente dos padrões de entrada. O hiperplano ótimo depende apenas dos vetores de suporte, considerados os padrões mais significativos do conjunto de treinamento. Os multiplicadores de Lagrange  $\alpha_o > 0$  (diferentes de zero) são justamente os padrões de entrada com margem igual a 1, chamados de vetores de suporte.

Os padrões de entrada que não são vetores de suporte não influenciam na função de decisão da escolha do hiperplano ótimo pela SVM. É importante ressaltar que esse problema de otimização fornece uma solução única, um diferencial de outras técnicas de otimização.

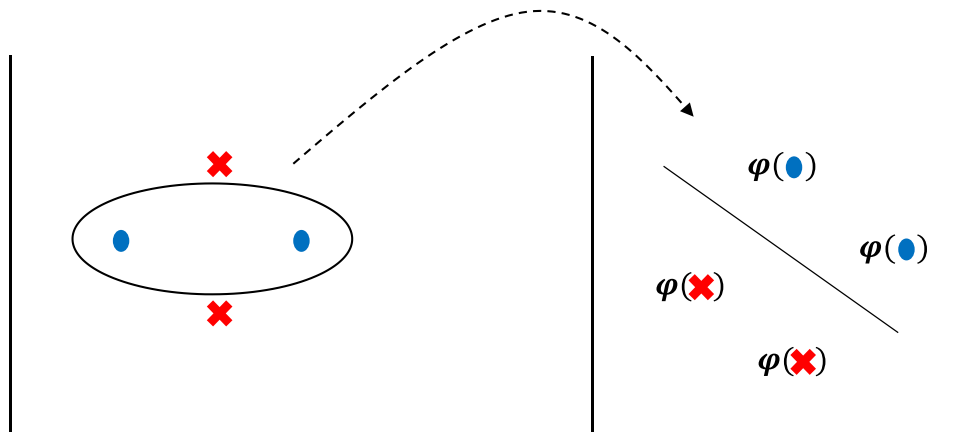
## A.2 Máquinas de Vetores Suporte Não Linearmente Separáveis

O problema de classificação binária em que classes distintas são não linearmente separáveis no espaço original é possível, através de um produto interno *Kernel*,

transformar o espaço original em um espaço de características de maior dimensão linearmente separável no espaço de características.

O espaço de características mencionado, corresponde a uma representação do conjunto de treinamento, mapeamento do espaço de entrada original, em um novo espaço utilizando funções reais  $\varphi_1, \dots, \varphi_M$ . A Figura 37 ilustra um espaço de características.

Figura 37 – Mapeamento de características



Fonte: Elaborado pelo autor (2020)

Para construção da SVM no caso não linear são necessárias duas operações: 1) o mapeamento não linear do vetor de entrada para um espaço de características de alta dimensionalidade, de acordo com o Teorema de Cover (HAYKIN, 2001), em que as funções  $\varphi_i$  são não lineares e a dimensão do espaço é suficientemente alta. 2) a construção de um hiperplano ótimo para separação das características descobertas em 1, uma vez que o Teorema de Cover não realiza a busca desse hiperplano.

### Hiperplano ótimo para classes não linearmente separáveis

Em uma visão geral do problema de classificação onde as classes são não linearmente separáveis, a construção do hiperplano de separação possivelmente gerará erros de classificação, em virtude dos padrões de treinamento. O objetivo da SVM neste caso é encontrar um hiperplano que minimiza a probabilidade de erro de classificação junto ao conjunto de treinamento.

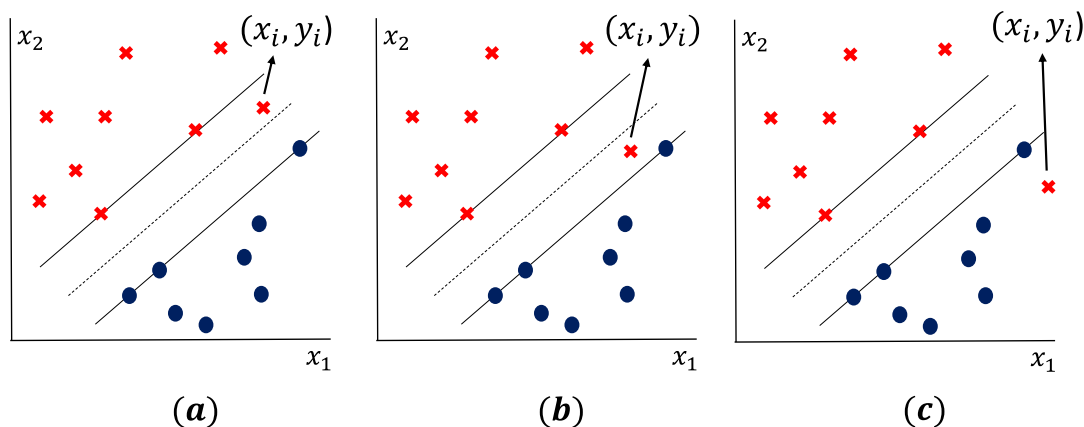
Existem casos em que não é necessário fazer um mapeamento de características no conjunto de treinamento. Esses casos são tratados pela SVM linear com margens de separação entre classes suaves ou flexíveis (soft), pois poderão existir pontos  $(\mathbf{x}_i, y_i)$  que violarão a Equação A.14.



Esta violação pode ocorrer em três diferentes situações:

- O ponto  $(x_i, y_i)$  se encontra dentro da região de separação e no lado correto da superfície de decisão, ilustrado na Figura 38(a). Neste caso houve uma escolha incorreta do hiperplano.
- O ponto  $(x_i, y_i)$  se encontra dentro da região de separação e no lado incorreto da superfície de decisão, ilustrado na Figura 38(b). Neste caso houve uma escolha incorreta do hiperplano de margem maior.
- O ponto  $(x_i, y_i)$  se encontra fora da região de separação e no lado incorreto da superfície de decisão, ilustrado na Figura 38(c).

Figura 38 – (a) O ponto  $(x_i, y_i)$  se encontra na região de separação, do lado correto. (b) O ponto  $(x_i, y_i)$  se encontra na região de separação, do lado incorreto. (c) O ponto de separação  $(x_i, y_i)$  se encontra fora da região de separação, do lado incorreto



Fonte: Elaborado pelo autor (2020)

Para tratar esse problema introduz-se uma variável não negativa  $\{\xi_i\}_{1 \leq i \leq N}$  na definição do hiperplano de separação:

$$y_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1 - \xi_i \quad \text{A.22}$$

As variáveis  $\xi_i$  são denominadas variáveis soltas, e medem os desvios dos pontos  $(x_i, y_i)$  para a condição ideal de separação de classes. Quando  $\xi_i$  satisfizer  $0 \leq \xi_i \leq 1$  o ponto encontra-se dentro da região de separação e do lado correto da superfície de decisão. Se  $\xi_i \geq 1$  o ponto encontra-se do lado incorreto do hiperplano de separação.

Os vetores suporte são os pontos em que o resultado da Equação A.22 é igual a  $1 - \xi_i$ , mesmo que  $\xi_i > 0$ . Ao retirar um padrão do conjunto de treinamento em que  $\xi_i > 0$ , a superfície de decisão tem possibilidade de mudança. No entanto, ao retirar um padrão em que  $\xi_i = 0$  e o resultado da Equação A.22 for maior que 1, a superfície de decisão permanecerá inalterada.

O objetivo é encontrar um hiperplano de separação onde o erro de classificação incorreta seja mínimo diante do conjunto de treinamento, o que pode ser feito minimizando a Equação A.23:

$$\Phi(\xi) = \sum_{i=1}^N I(\xi_i - 1) \quad \text{A.23}$$

sujeita à restrição da Equação A.22 do hiperplano de separação e à restrição sobre  $\mathbf{w}^T \mathbf{w}$ . A função  $I(\xi_i - 1)$  é uma função indicadora, definida por:

$$I(\xi_i - 1) = \begin{cases} 0 & \text{se } I(\xi_i \leq 0 \\ 1 & \text{se } I(\xi_i \geq 0 \end{cases} \quad \text{A.24}$$

A minimização de  $\Phi(\xi)$  é um problema de otimização não convexo de classe NP-completo não determinístico em tempo polinomial. Para tratar este problema, aproxima-se a função  $\Phi(\xi)$  por:

$$\Phi(\xi) = \sum_{i=1}^N \xi_i \quad \text{A.25}$$

Para simplificação de cálculos computacionais, a função a ser minimizada em relação ao vetor peso  $\mathbf{w}$  segue:

$$\Phi(\mathbf{w}, \xi) = \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + C \sum_{i=1}^N \xi_i \quad \text{A.26}$$

onde o parâmetro  $C$  controla a relação entre a complexidade do algoritmo e o número de amostras do conjunto de treinamento classificadas incorretamente, sendo denominado parâmetro de penalização.

A minimização do primeiro termo da Equação A.26 está relacionada à minimização da dimensão da SVM. O segundo termo pode ser visto como um limitante superior para o número de erros no padrão de treinamento apresentados à máquina. O problema de otimização em sua representação primal para encontrar o hiperplano ótimo de separação para classes não linearmente separáveis pode ser escrito como:

$$\begin{aligned} \text{MINIMIZAR: } & \frac{1}{2} \mathbf{w}^T \cdot \mathbf{w} + C \sum_{i=1}^N \xi_i \\ \text{SUJEITO A: } & \begin{cases} y_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1 - \xi_i, \text{ para } i = 1, \dots, N \\ \xi_i \geq 0, \forall i = 1, \dots, N \end{cases} \end{aligned} \quad \text{A.27}$$

Utilizando o método de multiplicadores de Lagrange, é possível formular o problema de otimização primal em seu correspondente problema dual, de maneira similar à descrita na seção A.1.

$$\begin{aligned} \text{MAXIMIZAR: } & \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{SUJEITO A: } & \begin{cases} 0 \leq \alpha_i \leq C, i = 1, \dots, N \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases} \end{aligned} \quad \text{A.28}$$


onde  $C > 0$  é especificado pelo usuário.

A principal diferença entre o caso de classes linearmente separáveis visto na seção 0 e de classes não linearmente separáveis é que a restrição  $\alpha_i \geq 0$  é substituída por  $0 \leq \alpha_i \leq C$ . O vetor de pesos ótimos  $\mathbf{w}_o$  e o bias ótimo  $b$  são calculados da mesma maneira que no caso linearmente separável. Existem casos em que se torna necessário mapear o espaço de entrada não linear para um espaço de características. Para realizar esse mapeamento, as funções *Kernel* são utilizadas.

### A.3 Função *Kernel*

Em muitos casos não é possível dividir de maneira satisfatória os padrões do conjunto de treinamento por meio de um hiperplano, mesmo observando as variáveis flexíveis. Para realização desta tarefa é feito um mapeamento do domínio do espaço de entrada desse conjunto para o espaço de características, usando funções *Kernel*  $\varphi$ . Sua aplicação pode ser ilustrada pela Figura 39:

Figura 39 – Espaço - Entrada x Característica



Fonte: Elaborado pelo autor (2020)

Um *Kernel*  $k$  é uma função que recebe dois pontos  $\mathbf{x}_i$  e  $\mathbf{x}_j$  do espaço de entrada e computa o produto escalar  $\varphi^T(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j)$  no espaço de características.

O termo  $\varphi^T(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j)$  representa o produto interno dos vetores  $\mathbf{x}_i$  e  $\mathbf{x}_j$ , sendo o Kernel representado por:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \varphi^T(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j) \quad \text{A.29}$$

Adaptando a Equação A.21 envolvendo um espaço de características, pode ser reescrito como:

$$\mathbf{w} = \sum_{i,j=1}^N \alpha_i y_i \varphi^T(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j) \quad \text{A.30}$$

onde o vetor de características  $\varphi(\mathbf{x}_i)$  corresponde ao padrão de entrada  $\mathbf{x}_i$ .

Dessa forma, pode-se utilizar o produto interno  $k(\mathbf{x}_i, \mathbf{x}_j)$  para construir um hiperplano ótimo no espaço de características sem ter que considerá-lo de modo explícito:

$$\mathbf{w} = \sum_{i,j=1}^N \alpha_i y_i k(\mathbf{x}_i, \mathbf{x}_j) \quad \text{A.31}$$

As funções  $\varphi$  devem pertencer a um domínio em que seja possível o cálculo de produtos internos. No geral, utiliza-se o teorema de Mercer para satisfazê-las. Segundo o teorema, os *Kernels* devem ser matrizes positivamente definidas, isto é,  $k_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$ . Alguns dos *Kernels* mais utilizados são apresentados na Tabela 19.

Tabela 19 – Funções *Kernel* mais utilizadas em SVM

<b>Kernel</b>	<b>Função <math>k(x_i, x_j)</math></b>	<b>Comentários</b>
<b>Polinomial</b>	$(x_i^T \cdot x_j + 1)^p$	$p$ é especificado a priori pelo usuário
<b>RBF</b>	$e^{(-\frac{1}{2\sigma^2}\ x_i - x_j\ ^2)}$	A largura de $\sigma^2$ é especificada a priori pelo usuário
<b>Sigmoidal</b>	$\tanh(\beta_0 x_i^T \cdot x_j + \beta_1)$	Teorema de Mercer satisfeito para $\beta_0$ e $\beta_1$

Fonte: Elaborado pelo autor (2020)

A obtenção de um classificador por meio de SVM's envolve a escolha de uma função *Kernel* apropriada, além de parâmetros desta função e do algoritmo de determinação do hiperplano ótimo. A escolha do *Kernel* e seus parâmetros afetam o desempenho do classificador através da superfície de decisão.

## APÊNDICE B - Otimização Multiobjetivo

Como sugerido pelo nome, a otimização multiobjetivo tem o objetivo de otimizar vários objetivos de forma simultânea. O problema se torna desafiador quando os objetivos tem características conflitantes entre si, ou seja, o ideal de solução de uma função objetivo é diferente da outra. A solução desses problemas dá origem a um conjunto de soluções popularmente conhecidas como soluções Pareto-ótimas. Em razão da multiplicidade de soluções, esses problemas podem ser adequadamente resolvidos usando algoritmos evolutivos com abordagem populacional em seu procedimento de busca, então denominados algoritmos de otimização evolutiva multiobjetivo (do inglês, *evolutionary multi-objective optimization* – EMO) (Wang et al., 2011).

Um problema de otimização multiobjetivo envolve uma série de funções objetivo que devem ser minimizadas ou maximizadas. Como em um problema de otimização de objetivo único, pode conter uma série de restrições que devem ser satisfeitas por qualquer das soluções viáveis, ou soluções Pareto-ótimas. De forma geral, um problema de otimização multiobjetivo pode ser enunciado como:

$$\text{Minimizar/Maximizar} \quad f_m(\mathbf{x}), \quad m = 1, 2, \dots, M; \quad (\text{B.1})$$

Sujeito a

$$g_j(\mathbf{x}) \geq 0, \quad j = 1, 2, \dots, J; \quad (\text{B.2})$$

$$h_k(\mathbf{x}) = 0, \quad k = 1, 2, \dots, K; \quad (\text{B.3})$$

$$x_i^{(L)} \leq x_i \leq x_i^{(U)}, \quad i = 1, 2, \dots, n. \quad (\text{B.4})$$

A solução  $\mathbf{x} \in \mathbb{R}^n$  é o vetor de variáveis de decisão:  $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$ . As soluções que satisfazem as restrições e limites impostos pelas Equações B.2 a B.4 constituem uma região factível de variáveis de decisão  $S \subset \mathbb{R}^n$ . Uma das diferenças entre a otimização de objetivo único e multiobjetivo é que na otimização multiobjetivo as funções objetivo constituem uma região multidimensional  $Z \subset \mathbb{R}^M$ . Para cada solução  $\mathbf{x}$  na região de decisão, existe um ponto  $z \in \mathbb{R}^M$ , denotado por  $f(\mathbf{x}) = Z = (z_1, z_2, \dots, z_n)^T$ . De forma clara, uma solução é referida como um vetor solução e um “ponto” como vetor objetivo correspondente.

## B.1 Dominância

As soluções ótimas em problemas de otimização multiobjetivo, podem ser definidas a partir de um conceito matemático de ordenação parcial. Na linguagem da EMO, o termo *dominância* é utilizado para esse propósito. A dominância entre duas soluções é definida da seguinte forma (Marler & Arora, 2004; Wang et al., 2011)

Sejam dadas as relações:

- $i > j$  denota que a solução  $i$  é pior do que a solução  $j$  para um determinado objetivo.
- $i < j$  denota que a solução  $i$  é melhor do que a solução  $j$  para um determinado objetivo.
- $i \geq j$  denota que a solução  $i$  é pior ou igual à solução  $j$  para um determinado objetivo. Em outras palavras,  $i$  não é melhor do que  $j$ .
- $i \leq j$  denota que a solução  $i$  é melhor ou igual à solução  $j$  para um determinado objetivo. Em outras palavras,  $i$  não é pior do que  $j$ .

**Definição 1.** Uma solução  $x^{(1)}$  domina outra solução  $x^{(2)}$  se as condições a seguir forem satisfeitas para  $x^{(1)}$  e  $x^{(2)}$  (Deb, 2011):

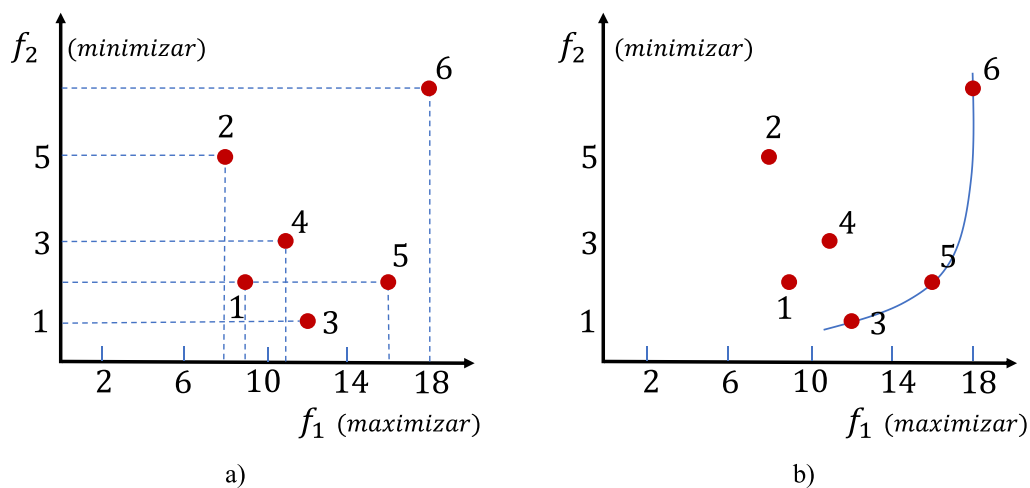
1. A solução  $x^{(1)}$  não é pior do que a solução  $x^{(2)}$  em qualquer objetivo, ou seja,  $f_j(x^{(1)}) \leq f_j(x^{(2)})$  para todo  $j = 1, 2, \dots, k$ .
2. A solução  $x^{(1)}$  é melhor do que a solução  $x^{(2)}$  em pelo menos um objetivo, ou seja,  $f_j(x^{(1)}) < f_j(x^{(2)})$  para pelo menos um  $j \in \{1, 2, \dots, k\}$ .

Se alguma das condições acima forem violadas, então a solução  $x^{(1)}$  não domina a solução  $x^{(2)}$ . Caso contrário,  $x^{(1)} \leq x^{(2)}$ , então pode-se afirmar que:

- $x^{(2)}$  é dominada por  $x^{(1)}$ ;
- $x^{(1)}$  é não dominada por  $x^{(2)}$  ou  $x^{(1)}$  não é inferior a  $x^{(2)}$ .

Para um determinado conjunto de soluções ou pontos correspondentes no espaço objetivo, como ilustrado na Figura 40, uma comparação de pares pode ser feita com base na definição acima para demonstrar o conceito de dominância.

Figura 40 – a) Conjunto soluções; b) Primeira Fronteira de Pareto



Fonte: Elaborado pelo autor (2024)

Todos os pontos que não são dominados por nenhum outro membro do conjunto são chamados de pontos não-dominados da classe um, ou simplesmente pontos não-dominados. Para o conjunto de seis soluções mostradas na Figura 40a), esses pontos são representados por 3, 5 e 6. Uma propriedade de qualquer dois desses pontos é que ocorre um ganho em um objetivo de um ponto a outro somente com sacrifício em pelo menos um outro objetivo. Esta propriedade de compensação entre os pontos não dominados faz com que o decisor se interesse em encontrar uma grande variedade deles antes de fazer uma escolha final. Esses pontos formam uma frente quando são vistos juntos no espaço objetivo, representando a Fronteira Pareto-ótima na Figura 40b).

Como a relação de dominância permite determinar se uma solução é melhor que outra, essa definição é amplamente utilizada nos processos de busca de algoritmos de otimização multiobjetivo.

## B.2 Condições de Otimalidade de Pareto

A definição de dominância permite encontrar um conjunto de soluções factíveis denominado *conjunto não-dominado*. O conjunto de soluções não-dominadas pode ser definido como:

**Definição 2.** Dado um conjunto de soluções  $P$  e seja  $P'$  o conjunto de todas as soluções em  $P$  não-dominadas por qualquer outra solução em  $P$ . O conjunto  $P'$  é chamado de conjunto não-dominado.

Se  $S$  é o conjunto de soluções factíveis para o problema multiobjetivo e  $P = S$ , então  $P'$  é chamado de *conjunto Pareto-ótimo* ou *fronteira Pareto-ótima*. Assim, como

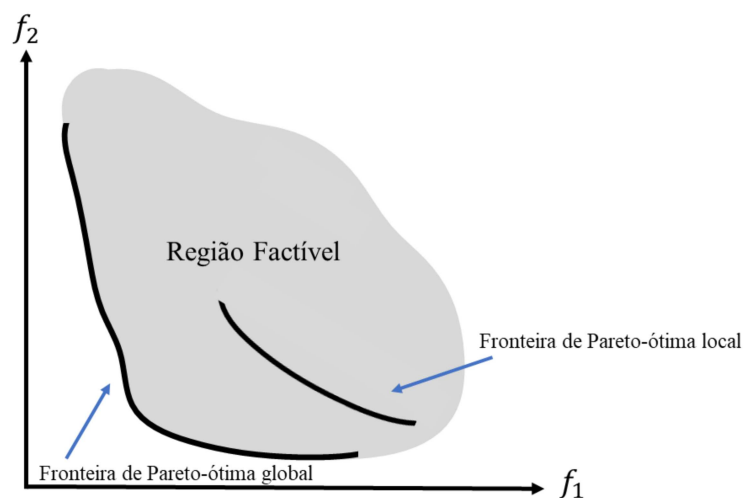


existe um ótimo local e um ótimo global na otimização de objetivo único, há uma fronteira Pareto-ótima local e uma fronteira Pareto-ótima global na otimização multiobjetivo.

**Definição 3.** Se para cada solução  $x$  pertencente ao conjunto  $P$  não há em sua vizinhança nenhuma solução  $y$  ( $\|x - y\| \leq \epsilon$ , onde  $\epsilon$  é um número pequeno e positivo) que domine qualquer solução de  $P$ , então as soluções pertencentes ao conjunto  $P$  formam um conjunto Pareto-ótimo local.

A Figura 41 ilustra de forma gráfica a definição de conjunto Pareto-ótimo local e conjunto Pareto-ótimo global, considerando um problema com funções objetivo  $f_1$  e  $f_2$ .

Figura 41 – Representação da Fronteira de Pareto-ótima local e global



Fonte: Elaborado pelo autor (2024)

### B.3 Ponto Ideal


Normalmente os objetivos na programação multiobjetivo são conflitantes, de modo que se espera uma solução ótima de cada uma das funções objetivo diferente das demais. O ponto  $x^* = [x_1^*, x_2^*, \dots, x_n^*]^T \in \mathbf{x}$  tal que  $x_j^* = \min\{f_j(x) : x \in \mathbf{x}, j = 1, 2, \dots, k\}$  é chamado ponto ideal. Considerando um problema de minimização, o ponto ideal é aquele que minimiza todas as funções objetivo. Em termos reais, não existe um ponto ideal em programação multiobjetivo, Segundo Deb (Deb, 2011), a programação multiobjetivo segue duas metas:

1. Encontrar um conjunto de soluções o mais próximo possível da fronteira Pareto-ótima;
2. Encontrar um conjunto de soluções com a maior diversidade possível.

A primeira meta é comum a qualquer problema de otimização. Comumente são utilizados modelos e ferramentas computacionais na busca de soluções, portanto é

esperado que estas apresentem uma resposta o mais próximo possível de uma solução ótima. Já a segunda meta, diversidade entre soluções, garante que todas as funções objetivo sejam balanceadas entre quaisquer objetivos de forma imparcial. A Figura 42 ilustra a distribuição de soluções em uma fronteira de Pareto, a) soluções bem distribuídas, b) soluções mal distribuídas.

Figura 42 – Distribuição das soluções na Fronteira de Pareto



Fonte: Elaborado pelo autor (2024)

## APÊNDICE C - Grey Wolf Optimizer

### C.1 Grey Wolf Optimizer (GWO)

O *Grey Wolf Optimizer* (GWO) é um algoritmo imita a hierarquia de dominância e o comportamento de caça de lobos cinzentos na natureza. Os lobos cinzentos vivem em um dos grupos naturais mais organizados chamado matilha. Os lobos de uma matilha são divididos em quatro classes: alfa, beta, delta e ômega. O alfa é normalmente o lobo mais forte que lidera a matilha na locomoção e caça. Todos os lobos devem seguir as ordens do lobo alfa. No próximo nível de dominância, os lobos beta ajudam o alfa na tomada de decisões e liderança. Lobos ômega tem menor capacidade de dominação.

Na caça, todos os lobos seguem a ordem do líder alfa. Os lobos cinzentos tendem a primeiro perseguir a presa e circular em torno dela. O trabalho em equipe gradualmente encurrala uma presa. Ao perseguir, cercar e assustar, a presa gradualmente fica cansada. Nesta fase o ataque final é feito para abater a presa. Este comportamento social de inteligência permite que os lobos cinzentos procurem presas maiores do que eles também.

No algoritmo GWO, a hierarquia de poder dos lobos na natureza é imitada salvando as três melhores soluções que este algoritmo encontrou até então. Essas soluções são equivalentes aos lobos alfa, beta e delta. As demais soluções são consideradas como ôegas. Após definir o nível de dominância, a solução deverá ser atualizada. No GWO, assume-se que todo lobo cinzento possui um vetor de posição. Não há vetor velocidade e as soluções são atualizadas pela manipulação direta do vetor posição. A expressão de atualização de posição proposta para as soluções é dada pela Equação C.1:

$$\vec{X}(t + 1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (C.1)$$

onde  $\vec{X}(t + 1)$  é a posição do lobo na iteração  $t + 1$ ,  $\vec{X}_p(t)$  é a posição do lobo na iteração  $t$ ,  $\vec{A}$  é um coeficiente e  $\vec{D}$  é a distância que depende da localização da presa  $\vec{X}_p$ , calculada como:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (C.2)$$

$$\vec{X}(t + 1) = \vec{X}_p(t) - \vec{A} \cdot |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (C.3)$$

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (C.4)$$

$$\vec{C} = 2\vec{r}_2 \quad (\text{C.5})$$

onde os componentes de  $\vec{a}$  decrescem linearmente de 2 a 0 com o desenvolver das iterações e  $\vec{r}_1, \vec{r}_2$  são vetores aleatórios em  $[0,1]$ . Na versão original do algoritmo, valores variantes no tempo são atribuídos para explorar (quando  $0 < a < 1$ ) e então expandir o espaço de busca (quando  $1 < a < 2$ ). A atualização desse parâmetro é dada pela Equação C.6:

$$a = 2 - t \left( \frac{2}{T} \right) \quad (\text{C.6})$$

onde  $t$  é a iteração corrente e  $T$  o número máximo de iterações.

As Equações C.2 a C.5 fornecem a atualização dos lobos e permitem que esses cerquem outras soluções em um espaço de busca  $n$ -dimensional, mimetizando o real comportamento de caça dos lobos à presa em um espaço 3D. Para simular a posição de cada lobo é utilizada a Equação C.7:

$$\vec{X}(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (\text{C.7})$$

onde  $X_1, X_2$  e  $X_3$  são dados calculados conforme Equações C.8 a C.10:

$$X_1 = \vec{X}_\alpha(t) - \vec{A}_1 \cdot \vec{D}_\alpha \quad (\text{C.8})$$

$$X_2 = \vec{X}_\beta(t) - \vec{A}_2 \cdot \vec{D}_\beta \quad (\text{C.9})$$

$$X_3 = \vec{X}_\delta(t) - \vec{A}_3 \cdot \vec{D}_\delta \quad (\text{C.10})$$

$\vec{D}_\alpha, \vec{D}_\beta$  e  $\vec{D}_\delta$  são calculados utilizando as Equações C.11 a C.13:

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}| \quad (\text{C.11})$$

$$\vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}| \quad (\text{C.12})$$

$$\vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (\text{C.13})$$

O algoritmo GWO inicia o processo de otimização usando um grupo de soluções (população inicial). Este grupo é avaliado a partir de uma função objetivo. Após conhecer o *fitness* de cada solução, as três melhores são consideradas alfa, beta e delta. O algoritmo então atualiza iterativamente a posição dos lobos enquanto atualiza os parâmetros que variam no tempo, como  $a$ . A qualquer momento, se uma solução se tornar melhor, os

lobos alfa, beta e delta precisam ser substituídos pela nova solução. O GWO é interrompido após a satisfação de um critério final de parada. Um pseudocódigo para o processo de otimização do GWO é apresentado no Algoritmo C.1 a seguir:

---

**Algoritmo C.1** *Grey Wolf Optimizer (GWO)*

---

- 1 Gerar uma população inicial  $X_i (i = 1, 2, \dots, n)$ ;
  - 2 Inicializar os vetores  $a$ ,  $A$  e  $C$ ;
  - 3 Calcular o valor da função objetivo para cada indivíduo  $X_i$ ;
  - 4  $X_\alpha$  = melhor solução;
  - 5  $X_\beta$  = segunda melhor solução;
  - 6  $X_\delta$  = terceira melhor solução;
  - 7 **enquanto**  $t < T$  **faça**
  - 8     **para**  $i \leftarrow 1$  até  $n$  **faça**
  - 9         Atualizar a posição de cada indivíduo
  - 10     **fim para**
  - 11 Atualizar os vetores  $a$ ,  $A$  e  $C$ ;
  - 12 Calcular o valor da função objetivo para cada indivíduo  $X_i$ ;
  - 13 Atualizar os valores de  $X_\alpha$ ,  $X_\beta$  e  $X_\delta$ ;
  - 14  $t = t + 1$ ;
  - 15 **fim enquanto**
  - 16 Retornar o valor de  $X_\alpha$ .
- 

Fonte: Elaborado pelo autor (2024)

**C.2 Multi-objective Grey Wolf Optimizer (MOGWO)**

De modo a tratar as soluções por uma fronteira de Pareto, essa versão multi-objetivo do algoritmo GWO emprega um arquivo para armazenar as melhores soluções não dominadas durante todo o processo de otimização. O armazenamento de soluções não dominadas no arquivo deve ser feito usando as seguintes regras:

- Se o arquivo estiver vazio e houver um indivíduo não dominado, esse deve ser adicionado ao arquivo.
- Se uma solução no arquivo for dominada em relação a uma solução fora do arquivo, o indivíduo correspondente à essa solução deve ser substituído imediatamente pelas novas soluções.

- Se uma solução não for dominada em comparação com as soluções no arquivo e há espaço suficiente, a solução deve ser adicionada ao arquivo.
- Se uma solução não for dominada em comparação com as soluções no arquivo e não há espaço suficiente, encontra-se os segmentos mais lotados e omite-se uma de suas soluções. Em seguida, a nova solução é inserida no segmento menos congestionado de modo a melhorar a diversidade das soluções Pareto-ótimas.

O mecanismo de arquivo tem um tamanho máximo e deverá ter dois operadores: manutenção de arquivo e seleção de líderes. Na manutenção de arquivo, soluções de segmentos lotados devem ser removidas quando o arquivo estiver completo. Em um espaço de busca multiobjetivo, as soluções não podem ser facilmente comparadas devido aos conceitos de otimalidade de Pareto. O mecanismo de seleção de líderes foi projetado para lidar com esse problema. Como mencionado acima, existe um arquivo das melhores soluções não-dominadas obtidas ao longo do processo de convergência. O componente de seleção de líder escolhe os segmentos menos lotados do espaço de busca e oferece uma de suas soluções não-dominadas como lobos alfa, beta ou delta. A seleção é feita pelo método de roleta com a seguinte probabilidade para cada segmento:

$$p_i = \frac{c}{n_i} \quad (\text{C.14})$$

onde  $n_i$  indica o número de soluções não-dominadas no  $i$ -ésimo segmento e  $c$  é uma constante maior que 1. Pode-se observar pela Equação C.14 que segmentos menos lotados têm maior probabilidade de sugerir novos líderes. A probabilidade de escolha de um segmento para selecionar líderes aumenta quando o número de soluções obtidas diminui nesse segmento. Um pseudocódigo para o processo de otimização do MOGWO é apresentado no Algoritmo C.2 a seguir:

---

**Algoritmo C.2** Multi-objective *Grey Wolf Optimizer* (MOGWO)

---

- 1 Gerar uma população inicial  $X_i (i = 1, 2, \dots, n)$ ;
- 2 Inicializar os vetores  $a$ ,  $A$  e  $C$ ;
- 3 Calcular o valor da função objetivo para cada indivíduo  $X_i$ ;
- 4 Buscar as soluções não-dominadas e inicializar o arquivo com essas soluções;
- 5  $X_\alpha$  = seleção do líder do arquivo;
- 6 Excluir temporariamente o alfa do arquivo para evitar seleção do mesmo líder;
- 7  $X_\beta$  = seleção do líder do arquivo;

---

**Algoritmo C.2** Multi-objective *Grey Wolf Optimizer* (MOGWO)

---

```
8  Excluir temporariamente o beta do arquivo para evitar seleção do mesmo líder;
9   $X_\delta$  = seleção do líder do arquivo;
10 Adicionar alfa e beta de volta ao arquivo;
11 enquanto  $t < T$  faça
12   para  $i \leftarrow 1$  até  $n$  faça
13     Atualizar a posição de cada indivíduo
14   fim para
15   Atualizar os vetores  $a$ ,  $A$  e  $C$ ;
16   Calcular o valor da função objetivo para cada indivíduo  $X_i$ ;
17   Encontrar as soluções não-dominadas;
18   Atualizar o arquivo com a inclusão de soluções não-dominadas encontradas;
19   se arquivo está cheio então
20     Reorganizar o arquivo para omitir um dos membros do arquivo atual;
21     Adicionar a nova solução ao arquivo
22   fim se
23   se algumas das soluções não-dominadas encontradas estão fora do arquivo então
24     Atualizar o arquivo para adicionar as novas soluções;
25   fim se
26   Repetir os passos 5 a 10;
27    $t = t + 1$ ;
28 fim enquanto
29 Retornar o arquivo.
```

---

Fonte: Elaborado pelo autor (2024)

## APÊNDICE D - Método *Fuzzy* de Tomada de Decisão

Em problemas de otimização multiobjetivo não é possível atribuir uma única solução como ótima, uma vez que a Fronteira de Pareto fornece um conjunto de soluções não-dominadas em razão dos objetivos avaliados. Após a determinação do conjunto não-dominado, é desejável obter uma solução flexível e realista que represente um equilíbrio entre diferentes objetivos (Maghouli et al., 2009). Considerando a natureza imprecisa no processo de tomada de decisão em problemas de otimização multiobjetivo, é natural que o decisor leve em consideração critérios baseados em expertise para determinar a escolha provável de solução do problema.

A abordagem a partir de conjuntos *Fuzzy* é de grande interesse em processos decisórios por sua simplicidade e semelhança com o raciocínio humano. Os conjuntos *Fuzzy* são definidos por funções que representam o grau de pertinência em um conjunto *Fuzzy* usando valores de 0 a 1. O valor de pertinência “0” indica incompatibilidade com o conjunto, enquanto “1” significa compatibilidade total. No método *Fuzzy* de tomada de decisão, uma função de pertinência estritamente monotônica decrescente e contínua é atribuída a cada objetivo. A função de associação atribuída é 1 no mínimo objetivo e 0 em seu máximo. O valor da função de pertinência indica até que ponto uma solução satisfaz o objetivo  $f_i$ . O tomador de decisão é totalmente satisfeito com o valor de  $f_i(X)$  se  $\mu_{f_i}(X) = 1$  e não satisfeito se  $\mu_{f_i}(X) = 0$ . Há alguns tipos de funções estritamente monotônicas decrescentes e contínuas que podem ser usadas como funções de pertinência, como tipos lineares, exponenciais convexas e hiperbólicas (Maghouli et al., 2009). Nesta tese o tipo linear é utilizado para os objetivos e formulada conforme Equação D.1:


$$\mu_{f_i}(X) = \begin{cases} 0, & f_i(X) > f_i^{max} \\ \frac{f_i^{max} - f_i(X)}{f_i^{max} - f_i^{min}}, & f_i^{min} < f_i(X) \leq f_i^{max} \\ 1, & f_i(X) \leq f_i^{min} \end{cases} \quad (D.1)$$

A Figura 43 ilustra o gráfico para esta função de pertinência. É importante destacar que tipos diferentes para a função de pertinência podem influenciar a solução final. Por exemplo, usar uma função exponencial convexa para um dos objetivos fornecerá uma prioridade para minimizar esse objetivo em detrimento aos outros pois tal função irá



atribuir uma função de pertinência menor nas proximidades de  $f_i^{max}$  se comparada com a função linear.

Figura 43 – Função de pertinência linear



Fonte: Elaborado pelo autor (2024)

Após a definição das funções de pertinência, o tomador de decisão define o nível desejado para realização de cada objetivo. Os níveis desejados são denominados níveis de referência, denodados por  $\mu_{r_i}$ . Por fim, a solução final pode ser obtida utilizando uma técnica de análise de decisão como o critério “minimax” (Gholizadeh-Roshanagh et al., 2020), a partir da formulação na Equação D.2:

$$\min_{X \in \Phi} \left( \max_i |\mu_{r_i} - \mu_{f_i}(X)| \right) \quad (D.2)$$

## APÊNDICE E – Dados dos sistemas

### E.1 Sistema IEEE – RTS 24 barras

Tabela 20 – Dados de barra para o sistema IEEE – RTS 24 barras

Barra	Carga (MW)	Geração térmica (MW)
1	324	576
2	291	576
3	540	-
4	222	-
5	213	-
6	408	-
7	375	900
8	513	-
9	525	-
10	585	-
11	-	-
12	-	-
13	795	1773
14	582	-
15	951	645
16	300	465
17	-	-
18	999	1200
19	543	-
20	384	-
21	-	1200
22	-	900
23	-	1980
24	-	-

Fonte: Elaborado pelo autor (2024)

Tabela 21 – Dados de barra para o sistema RTS - WIND

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
1	324	120	1572
2	291	576	-
3	540	-	-
4	222	-	-
5	213	-	-
6	408	-	-
7	375	900	-
8	513	-	-
9	525	-	-
10	585	-	-

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
11	-	-	-
12	-	-	-
13	795	1773	-
14	582	-	-
15	951	180	1188
16	300	465	-
17	-	-	-
18	999	1200	-
19	543	-	-
20	384	-	-
21	-	1200	-
22	-	900	-
23	-	1980	-
24	-	-	-

Fonte: Elaborado pelo autor (2024)

Tabela 22 – Dados de linhas existentes para os sistemas IEEE – RTS 24 barras e RTS - WIND

De	Para	R (pu)	X (pu)	Cap (MW)	$\lambda$ (f/ano)	MTTR (h)
1	2	0,26	1,39	175	0,24	16
1	3	5,46	21,12	175	0,51	10
1	5	2,18	8,45	175	0,33	10
2	4	3,28	12,67	175	0,39	10
2	6	4,97	19,2	175	0,48	10
3	9	3,08	11,9	175	0,38	10
3	24	0,23	8,39	400	0,02	768
4	9	2,68	10,37	175	0,36	10
5	10	2,28	8,83	175	0,34	10
6	10	1,39	6,05	175	0,33	35
7	8	1,59	6,14	175	0,3	10
8	9	4,27	16,51	175	0,44	10
8	10	4,27	16,51	175	0,44	10
9	11	0,23	8,39	400	0,02	768
9	12	0,23	8,39	400	0,02	768
10	11	0,23	8,39	400	0,02	768
10	12	0,23	8,39	400	0,02	768
11	13	0,61	4,76	500	0,4	11
11	14	0,54	4,18	500	0,39	11
12	13	0,61	4,76	500	0,4	11
12	23	1,24	9,66	500	0,52	11
13	23	1,11	8,65	500	0,49	11
14	16	0,5	3,89	500	0,38	11

De	Para	R (pu)	X (pu)	Cap (MW)	$\lambda$ (f/ano)	MTTR (h)
15	16	0,22	1,73	500	0,33	11
15	21	0,63	4,9	500	0,41	11
15	21	0,63	4,9	500	0,41	11
15	24	0,67	5,19	500	0,41	11
16	17	0,33	2,59	500	0,35	11
16	19	0,3	2,31	500	0,34	11
17	18	0,18	1,44	500	0,32	11
17	22	1,35	10,53	500	0,54	11
18	21	0,33	2,59	500	0,35	11
18	21	0,33	2,59	500	0,35	11
19	20	0,51	3,96	500	0,38	11
19	20	0,51	3,96	500	0,38	11
20	23	0,28	2,16	500	0,34	11
20	23	0,28	2,16	500	0,34	11
21	22	0,87	6,78	500	0,45	11

Fonte: Elaborado pelo autor (2024)

Tabela 23 – Dados de linhas candidatas para os sistemas IEEE – RTS 24 barras e RTS - WIND

De	Para	R (pu)	X (pu)	Cap (MW)	Custo (\$10 <sup>4</sup> )	$\lambda$ (f/ano)	MTTR (h)
1	2	0,26	1,39	175	3	0,24	16
1	3	5,46	21,12	175	55	0,51	10
1	5	2,18	8,45	175	22	0,33	10
2	4	3,28	12,67	175	33	0,39	10
2	6	4,97	19,2	175	50	0,48	10
3	9	3,08	11,9	175	31	0,38	10
3	24	0,23	8,39	400	50	0,02	768
4	9	2,68	10,37	175	27	0,36	10
5	10	2,28	8,83	175	23	0,34	10
6	10	1,39	6,05	175	16	0,33	35
7	8	1,59	6,14	175	16	0,3	10
8	9	4,27	16,51	175	43	0,44	10
8	10	4,27	16,51	175	43	0,44	10
9	11	0,23	8,39	400	50	0,02	768
9	12	0,23	8,39	400	50	0,02	768
10	11	0,23	8,39	400	50	0,02	768
10	12	0,23	8,39	400	50	0,02	768
11	13	0,61	4,76	500	66	0,4	11
11	14	0,54	4,18	500	58	0,39	11
12	13	0,61	4,76	500	66	0,4	11
12	23	1,24	9,66	500	134	0,52	11
13	23	1,11	8,65	500	120	0,49	11

De	Para	R (pu)	X (pu)	Cap (MW)	Custo (\$10 <sup>4</sup> )	$\lambda$ (f/ano)	MTTR (h)
14	16	0,5	3,89	500	54	0,38	11
15	16	0,22	1,73	500	24	0,33	11
15	21	0,63	4,9	500	68	0,41	11
15	24	0,67	5,19	500	72	0,41	11
16	17	0,33	2,59	500	36	0,35	11
16	19	0,3	2,31	500	32	0,34	11
17	18	0,18	1,44	500	20	0,32	11
17	22	1,35	10,53	500	146	0,54	11
18	21	0,33	2,59	500	36	0,35	11
19	20	0,51	3,96	500	55	0,38	11
20	23	0,28	2,16	500	30	0,34	11
21	22	0,87	6,78	500	94	0,45	11

Fonte: Elaborado pelo autor (2024)

## E.2 Sistema brasileiro Sul equivalente (BSS)

Tabela 24 – Dados de barra para o sistema BSS

Barra	Carga (MW)	Geração térmica (MW)
1	-	-
2	443,1	-
3	-	-
4	300,7	-
5	238,0	-
6	-	-
7	-	-
8	72,2	-
9	-	-
10	-	-
11	-	-
12	511,9	-
13	185,8	-
14	-	1257
15	-	-
16	-	2000
17	-	1050
18	-	-
19	-	1670
20	1091,2	-
21	-	-
22	81,9	-
23	458,1	-
24	478,2	-

Barra	Carga (MW)	Geração térmica (MW)
25	-	-
26	231,9	-
27	-	220
28	-	800
29	-	-
30	-	-
31	-	700
32	-	500
33	229,1	-
34	-	748
35	216,0	-
36	90,1	-
37	-	300
38	216,0	-
39	-	600
40	262,1	-
41	-	-
42	1607,9	-
43	-	-
44	79,1	-
45	86,7	-
46	-	700

Fonte: Elaborado pelo autor (2024)

Tabela 25 – Dados de barra para o sistema BSS - WIND

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
1	-	-	700
2	443,1	-	-
3	-	-	-
4	300,7	-	-
5	238,0	-	-
6	-	-	-
7	-	-	-
8	72,2	-	-
9	-	-	-
10	-	-	-
11	-	-	-
12	511,9	-	-
13	185,8	-	-
14	-	1257	-
15	-	-	-
16	-	2000	-

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
17	-	1050	-
18	-	-	-
19	-	1670	-
20	1091,2	-	-
21	-	-	700
22	81,9	-	-
23	458,1	-	-
24	478,2	-	-
25	-	-	-
26	231,9	-	-
27	-	220	-
28	-	800	-
29	-	-	-
30	-	-	-
31	-	700	-
32	-	500	-
33	229,1	-	-
34	-	748	-
35	216,0	-	-
36	90,1	-	-
37	-	300	-
38	216,0	-	-
39	-	600	-
40	262,1	-	-
41	-	-	-
42	1607,9	-	-
43	-	-	700
44	79,1	-	-
45	86,7	-	-
46	-	700	-

Fonte: Elaborado pelo autor (2024)

Tabela 26 – Dados de linhas existentes para os sistemas BSS e BSS - WIND

De	Para	R (pu)	X (pu)	Cap (MW)	$\lambda$ (f/ano)	MTTR (h)
1	7	0,616	6,16	270	3,878	2,958
1	2	1,065	10,65	270	6,705	2,958
1	2	1,065	10,65	270	6,705	2,958
4	9	0,924	9,24	270	5,817	2,958
5	9	1,173	11,73	270	7,384	2,958
5	8	1,132	11,32	270	7,126	2,958
7	8	1,023	10,23	270	6,440	2,958
4	5	0,566	5,66	270	3,563	2,958

De	Para	R (pu)	X (pu)	Cap (MW)	$\lambda$ (f/ano)	MTTR (h)
4	5	0,566	5,66	270	3,563	2,958
2	5	0,324	3,24	270	2,040	2,958
2	5	0,324	3,24	270	2,040	2,958
8	13	1,348	13,48	240	8,486	2,958
9	14	1,756	17,56	220	11,055	2,958
9	14	1,756	17,56	220	11,055	2,958
12	14	0,74	7,4	270	4,659	2,958
12	14	0,74	7,4	270	4,659	2,958
14	18	1,514	15,14	240	9,531	2,958
14	18	1,514	15,14	240	9,531	2,958
13	18	1,805	18,05	220	11,363	2,958
13	20	1,073	10,73	270	6,755	2,958
18	20	1,997	19,97	200	12,572	2,958
19	21	0,278	2,78	1500	1,750	2,958
16	17	0,078	0,78	2000	0,491	2,958
17	19	0,061	0,61	2000	0,130	1,521
14	26	1,614	16,14	220	10,161	2,958
14	22	0,84	8,4	270	5,288	2,958
22	26	0,79	7,9	270	4,973	2,958
20	23	0,932	9,32	270	5,867	2,958
20	23	0,932	9,32	270	5,867	2,958
23	24	0,774	7,74	270	4,873	2,958
23	24	0,774	7,74	270	4,873	2,958
26	27	0,832	8,32	270	5,238	2,958
26	27	0,832	8,32	270	5,238	2,958
24	34	1,647	16,47	220	10,368	2,958
24	33	1,448	14,48	240	9,116	2,958
33	34	1,265	12,65	270	7,964	2,958
27	36	0,915	9,15	270	5,760	2,958
27	38	2,008	20,08	200	12,641	2,958
27	38	2,008	20,08	200	12,641	2,958
36	37	1,057	10,57	270	6,654	2,958
34	35	0,491	4,91	270	3,091	2,958
34	35	0,491	4,91	270	3,091	2,958
35	38	1,98	19,8	200	12,465	2,958
37	39	0,283	2,83	270	1,782	2,958
37	40	1,281	12,81	270	8,064	2,958
37	42	2,105	21,05	200	13,252	2,958
39	42	2,03	20,3	200	12,780	2,958
39	42	2,03	20,3	200	12,780	2,958
39	42	2,03	20,3	200	12,780	2,958
40	42	0,932	9,32	200	5,867	2,958
38	42	0,907	9,07	270	5,710	2,958



De	Para	R (pu)	X (pu)	Cap (MW)	$\lambda$ (f/ano)	MTTR (h)
38	42	0,907	9,07	270	5,710	2,958
38	42	0,907	9,07	270	5,710	2,958
32	43	0,309	3,09	1400	0,657	1,521
42	44	1,206	12,06	270	7,592	2,958
44	45	1,864	18,64	200	11,735	2,958
19	32	0,195	1,95	1800	0,415	1,521
46	19	0,222	2,22	1800	0,472	1,521
46	16	0,203	2,03	1800	0,432	1,521
18	19	0,125	1,25	600	0,787	2,958
20	21	0,125	1,25	600	0,787	2,958
42	43	0,125	1,25	600	0,787	2,958

Fonte: Elaborado pelo autor (2024)

Tabela 27 – Dados de linhas candidatas para os sistemas BSS e BSS - WIND

De	Para	R (pu)	X (pu)	Cap (MW)	Custo (\$10 <sup>4</sup> )	$\lambda$ (f/ano)	MTTR (h)
1	7	0,616	6,16	270	4,349	3,878	2,958
1	2	1,065	10,65	270	7,076	6,705	2,958
4	9	0,924	9,24	270	6,217	5,817	2,958
5	9	1,173	11,73	270	7,732	7,384	2,958
5	8	1,132	11,32	270	7,48	7,126	2,958
7	8	1,023	10,23	270	6,823	6,440	2,958
4	5	0,566	5,66	270	4,046	3,563	2,958
2	5	0,324	3,24	270	2,581	2,040	2,958
8	13	1,348	13,48	240	8,793	8,486	2,958
9	14	1,756	17,56	220	11,267	11,055	2,958
12	14	0,74	7,4	270	5,106	4,659	2,958
14	18	1,514	15,14	240	9,803	9,531	2,958
13	18	1,805	18,05	220	11,57	11,363	2,958
13	20	1,073	10,73	270	7,126	6,755	2,958
18	20	1,997	19,97	200	12,732	12,572	2,958
19	21	0,278	2,78	1500	32,632	0,591	1,521
16	17	0,078	0,78	2000	10,505	0,166	1,521
17	19	0,061	0,61	2000	8,715	0,130	1,521
14	26	1,614	16,14	220	10,409	10,161	2,958
14	22	0,84	8,4	270	5,712	5,288	2,958
22	26	0,79	7,9	270	5,409	4,973	2,958
20	23	0,932	9,32	270	6,268	5,867	2,958
23	24	0,774	7,74	270	5,308	4,873	2,958
26	27	0,832	8,32	270	5,662	5,238	2,958
24	34	1,647	16,47	220	10,611	10,368	2,958
24	33	1,448	14,48	240	9,399	9,116	2,958
33	34	1,265	12,65	270	8,288	7,964	2,958

De	Para	R (pu)	X (pu)	Cap (MW)	Custo (\$10 <sup>4</sup> )	$\lambda$ (f/ano)	MTTR (h)
27	36	0,915	9,15	270	6,167	5,760	2,958
27	38	2,08	20,8	200	13,237	13,094	2,958
36	37	1,057	10,57	270	7,025	6,654	2,958
34	35	0,491	4,91	270	3,591	3,091	2,958
35	38	1,98	19,8	200	12,631	12,465	2,958
37	39	0,283	2,83	270	2,329	1,782	2,958
37	40	1,281	12,81	270	8,389	8,064	2,958
37	42	2,105	21,05	200	13,388	13,252	2,958
39	42	2,03	20,3	200	12,934	12,780	2,958
40	42	0,932	9,32	200	6,268	5,867	2,958
38	42	0,907	9,07	270	6,116	5,710	2,958
32	43	0,309	3,09	1400	35,957	0,657	1,521
42	44	1,206	12,06	270	7,934	7,592	2,958
44	45	1,864	18,64	200	11,924	11,735	2,958
19	32	0,195	1,95	1800	23,423	0,415	1,521
46	19	0,222	2,22	1800	26,365	0,472	1,521
46	16	0,203	2,03	1800	24,319	0,432	1,521
18	19	0,125	1,25	600	8,178	0,787	2,958
20	21	0,125	1,25	600	8,178	0,787	2,958
20	21	0,125	1,25	600	8,178	0,787	2,958
42	43	0,125	1,25	600	8,178	0,787	2,958
2	4	0,882	8,82	270	5,965	5,553	2,958
14	15	0,374	3,74	270	2,884	2,354	2,958
46	10	0,081	0,81	2000	10,889	0,172	1,521
4	11	2,246	22,46	240	14,247	14,139	2,958
5	11	0,915	9,15	270	6,167	5,760	2,958
46	6	0,128	1,28	2000	16,005	0,272	1,521
46	3	0,203	2,03	1800	24,319	0,432	1,521
16	28	0,222	2,22	1800	26,365	0,472	1,521
16	32	0,311	3,11	1400	36,213	0,661	1,521
17	32	0,232	2,32	1700	27,516	0,493	1,521
19	25	0,325	3,25	1400	37,748	0,691	1,521
21	25	0,174	1,74	2000	21,121	0,370	1,521
25	32	0,319	3,19	1400	37,109	0,678	1,521
31	32	0,046	0,46	2000	7,052	0,098	1,521
28	31	0,053	0,53	2000	7,819	0,113	1,521
28	30	0,058	0,58	2000	8,331	0,123	1,521
27	29	0,998	9,98	270	6,672	6,283	2,958
26	29	0,541	5,41	270	3,894	3,406	2,958
28	41	0,339	3,39	1300	39,283	0,721	1,521
28	43	0,406	4,06	1200	46,701	0,863	1,521
31	41	0,278	2,78	1500	32,632	0,591	1,521

De	Para	R (pu)	X (pu)	Cap (MW)	Custo (\$10 <sup>4</sup> )	$\lambda$ (f/ano)	MTTR (h)
32	41	0,309	3,09	1400	35,957	0,657	1,521
41	43	0,139	1,39	2000	17,284	0,296	1,521
40	45	2,205	22,05	180	13,994	13,881	2,958
15	16	0,125	1,25	600	8,179	0,787	2,958
46	11	0,125	1,25	600	8,179	0,787	2,958
24	25	0,125	1,25	600	8,179	0,787	2,958
29	30	0,125	1,25	600	8,179	0,787	2,958
40	41	0,125	1,25	600	8,179	0,787	2,958
2	3	0,125	1,25	600	8,179	0,787	2,958
5	6	0,125	1,25	600	8,178	0,787	2,958
9	10	0,125	1,25	600	8,178	0,787	2,958

Fonte: Elaborado pelo autor (2024)