

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

**Arthur Neves de Paula**

**Contribuições às Técnicas de Planejamento da Expansão da Transmissão de Energia  
Elétrica Considerando Incertezas**

Juiz de Fora

2021

**Arthur Neves de Paula**

**Contribuições às Técnicas de Planejamento da Expansão da Transmissão de Energia Elétrica Considerando Incertezas**

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: Edimar José de Oliveira

Coorientador: Leonardo Willer de Oliveira

Juiz de Fora

2021

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

de Paula, Arthur Neves.

Contribuições às Técnicas de Planejamento da Expansão da Transmissão de Energia Elétrica Considerando Incertezas / Arthur Neves de Paula. -- 2021.

142 f.

Orientador: Edimar José de Oliveira

Coorientador: Leonardo Willer de Oliveira

Tese (doutorado) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2021.

1. Planejamento da expansão da transmissão de energia elétrica. 2. Planejamento sob incertezas. 3. Algoritmos de agrupamento. 4. Confiabilidade de sistemas de transmissão. 5. Dispositivos de armazenamento de energia. I. de Oliveira, Edimar José, orient. II. de Oliveira, Leonardo Willer, coorient. III. Título.

**Arthur Neves de Paula**

**Contribuições às Técnicas de Planejamento da Expansão da Transmissão de Energia Elétrica Considerando Incertezas**

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: 20/08/2021

**BANCA EXAMINADORA**




---

Prof. Dr. Edimar José de Oliveira - Orientador  
Universidade Federal de Juiz de Fora - UFJF



---

Prof. Dr. Leonardo Willer de Oliveira - Coorientador  
Universidade Federal de Juiz de Fora - UFJF



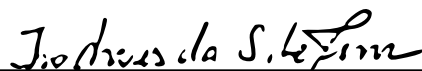
---

Prof. Dr. Edmarcio Antonio Belati  
Universidade Federal do ABC - UFABC



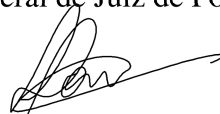
---

Prof. Dr. Raphael Paulo Braga Poubel  
Centro Federal de Educação Tecnológica de Minas Gerais -  
CEFET/MG



---

Prof. Dr. Ivo Chaves da Silva Junior  
Universidade Federal de Juiz de Fora - UFJF



---

Prof. Dr. Leonardo de Mello Honório  
Universidade Federal de Juiz de Fora - UFJF

## **AGRADECIMENTOS**

Agradeço ao meu professor e orientador Edimar José de Oliveira, por todos os ensinamentos ao longo destes últimos anos. Às contribuições dos professores Leonardo Willer de Oliveira, Leonardo de Mello Honório, José Roberto Sanches Mantovani e Edmarcio Antonio Belati e colegas de trabalho Camile Aredes, Ana Flávia Procópio, Lucas Nepomuceno, Gabriel Schreider, Marcos Tadeu, Elisa Oliveira e Jhonatan Sanches. À minha família, por apoiar meus estudos. À minha companheira Nívea Zanitti, pelo apoio. Aos meus amigos Marcos Abdalla e Victor Franco, pelos ensinamentos e companheirismo.

Ao suporte financeiro fornecido pela CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil. Ao CNPq - Conselho Nacional de Desenvolvimento Científico e Tecnológico - Brasil. Ao INERGE - Instituto Nacional de Energia Elétrica. À FAPEMIG - Fundação de Amparo à Pesquisa no Estado de Minas Gerais. À Universidade Federal de Juiz de Fora - UFJF.

## RESUMO

Esta tese de doutorado apresenta contribuições para a solução do problema de Planejamento da Expansão da Transmissão de Energia Elétrica (PET) considerando incertezas e alocação ótima de Dispositivos de Armazenamento de Energia (DAE), dentre estes: (i) uma metodologia para solucionar o PET de forma robusta em relação aos cenários de despacho de geração eólica e contingência, satisfazendo o critério de segurança N-1; (ii) uma metodologia para solucionar o PET considerando um horizonte de planejamento dinâmico e restrições de confiabilidade e de uso adequado da energia eólica disponível; (iii) dois algoritmos de agrupamento de séries históricas, o modified Iterative Self-Organizing Data Analysis Technique Algorithm (m-ISODATA) e o Algoritmo de Agrupamento de Períodos Representativos (AAPR), propostos para obter os cenários representativos para problemas de planejamento e operação de sistemas de energia que levam em conta incertezas a curto prazo, respectivamente para problemas não-cronológicos e cronológicos; (iv) uma metodologia para solucionar o problema de PET e alocação ótima de DAEs de forma desacoplada, permitindo a solução simultânea de cada cenário cronológico.

Palavras-chave: Planejamento da expansão da transmissão de energia elétrica. Planejamento sob incertezas. Algoritmos de agrupamento. Confiabilidade de sistemas de transmissão. Dispositivos de armazenamento de energia. Decomposição de Benders. Simulação Monte Carlo.

## ABSTRACT

This doctoral thesis presents contributions to solve the transmission network expansion planning problem considering uncertainties and optimal allocation of energy storage devices: (i) a methodology to solve the robust transmission network expansion planning problem considering wind generation and contingency dispatch scenarios, meeting the N-1 security criterion; (ii) a methodology to solve the transmission network expansion planning problem considering a dynamic planning horizon and constraints on reliability and use of available wind energy; (iii) two clustering algorithms, the modified Iterative Self-Organizing Data Analysis Technique Algorithm (m-ISODATA) and the Representative Period Clustering Algorithm (AAPR), proposed to obtain representative scenarios from historical series for application in planning and operation of power systems; (iv) a methodology to solve the transmission network expansion planning problem and optimal allocation of energy storage devices in a decoupled way, allowing the simultaneous solution of each chronological scenario.

**Keywords:** Transmission network expansion planning. Planning under uncertainty. Clustering algorithms. Reliability of transmission systems. Energy storage devices. Benders' decomposition. Monte Carlo simulation.

## LISTA DE FIGURAS

Figura 1 – Taxonomia do PET. . . . .	21
Figura 2 – Estrutura matricial de um problema de programação genérico que pode ser dividido em $S$ subproblemas com a decomposição de Benders. . . . .	34
Figura 3 – Fluxograma da metodologia proposta. . . . .	41
Figura 4 – Fluxograma do esquema em dois níveis. . . . .	50
Figura 5 – Abordagem a dois estágios. . . . .	54
Figura 6 – Índices do sistema com e sem investimentos (ver tabela 5) e limites estabelecidos. . . . .	57
Figura 7 – Custos de investimento <i>versus</i> FOR. . . . .	58
Figura 8 – Custos de investimento do RCTNEP <i>versus</i> capacidade de geração das usinas eólicas. . . . .	58
Figura 9 – Primeira semana operativa das séries históricas de despacho de energia eólica. . . . .	62
Figura 10 – Pontos de duas séries históricas correlacionadas de despacho de energia eólica: (a) gráfico de dispersão; (b) gráfico de densidade. . . . .	63
Figura 11 – Dois conjuntos de dados agrupados como cenários representativos de geração eólica. . . . .	64
Figura 12 – Fluxograma do algoritmo m-ISODATA. . . . .	65
Figura 13 – Visualização do Fator de Correção Dimensional (FCD) em: (a) uma dimensão; (b) duas dimensões; (c) três dimensões. . . . .	66
Figura 14 – Gráfico de dispersão da série histórica bidimensional:: (a) como um único cenário; (b) como dois cenários. . . . .	68
Figura 15 – Os 39 cenários obtidos com: (a) m-ISODATA; (b) k-means; (c) HAC. . . . .	72
Figura 16 – Os 101 cenários obtidos com: (a) m-ISODATA; (b) k-means; (c) HAC. . . . .	72
Figura 17 – Grupos obtidos a partir de diferentes técnicas para: (a) 39 cenários; (b) 101 cenários. . . . .	73
Figura 18 – Erro relativo obtido ao considerar os algoritmos m-ISODATA, k-means, HAC e SMC e coeficiente de convergência $\beta$ da SMC. . . . .	76
Figura 19 – Planejamento da expansão para os cenários ( $S$ ) e séries históricas completas ( $F$ ). . . . .	78
Figura 20 – Índices DIC e AUS frente variações de $d_{min}^0$ . . . . .	80
Figura 21 – Número de cenários obtidos com m-ISODATA frente variações de $d_{min}^0$ com FCD (linhas sólidas) e sem FCD (linhas pontilhadas). . . . .	81
Figura 22 – CQE <i>versus</i> $d_{min}^0$ com FCD (linhas sólidas) e sem FCD (linhas tracejadas). . . . .	82
Figura 23 – Índice de erro calculado $E_C$ para diferentes algoritmos de agrupamento e números de cenários. . . . .	83



Figura 24 – Índice de perda de correlação relativa <i>corrloss</i> para diferentes algoritmos de agrupamento e números de cenários. . . . .	84
Figura 25 – Estrutura matricial do PET considerando DAEs, dividida em $S$ subproblemas. . . . .	93
Figura 26 – Estrutura matricial do PET considerando DAEs, dividida em $ns$ subproblemas, reorganizada de forma apropriada para aplicar a decomposição de Benders. . . . .	95
Figura 27 – Sistema teste de duas barras. . . . .	99
Figura 28 – Curva de potência da torre eólica GE1.5sle. . . . .	101
Figura 29 – Média móvel com janela semanal das séries históricas de demanda e despacho das usinas eólica e solar. . . . .	102
Figura 30 – Trigésima primeira semana das séries históricas de demanda e despacho das usinas eólica e solar em resolução horária. . . . .	103
Figura 31 – Investimento na capacidade de transmissão do corredor para os casos de simulação. . . . .	104
Figura 32 – Capacidades instaladas no sistema para o CS-3. . . . .	104
Figura 33 – Custos de operação e investimento para os casos de simulação. . . . .	105
Figura 34 – Trigésima primeira semana operativa do sistema. . . . .	105
Figura 35 – Média móvel com janela semanal da operação do sistema. . . . .	106
Figura 36 – Operação do DAE durante a trigésima primeira semana. . . . .	107
Figura 37 – Primeira semana operativa das séries históricas de carga e despacho de geração eólica, antes e após a aplicação do algoritmo AAPR considerando $d_{min} = 0, 1$ . . . . .	108
Figura 38 – Primeira semana operativa das séries históricas de carga e despacho de geração eólica, antes e após a aplicação do algoritmo AAPR, considerando $d_{min} = 0, 3$ . . . . .	108

## LISTA DE TABELAS

Tabela 1 – Cenários de despacho eólico utilizados para o sistema RTS-WIND. . .	43
Tabela 2 – Soluções obtidas para o sistema IEEE-RTS. . . . .	43
Tabela 3 – Cenários de despacho eólico utilizados para o sistema BS-WIND. . . .	44
Tabela 4 – Soluções obtidas para o sistema BS. . . . .	44
Tabela 5 – Solução do D-PET para o sistema RTS-WIND. . . . .	56
Tabela 6 – Solução do D-PET para o sistema IEEE-118. . . . .	58
Tabela 7 – Índices da primeira e última iteração. . . . .	59
Tabela 8 – Variáveis <i>default</i> do m-ISODATA. . . . .	65
Tabela 9 – Número máximo/mínimo de pontos e desvio padrão ( $\sigma$ ) dos grupos obtidos pelo m-ISODATA, k-means e HAC. . . . .	73
Tabela 10 – Custos operacionais e de investimento utilizados no PEG. . . . .	78
Tabela 11 – Custo computacional para solucionar o PEG utilizando a série histórica completa e os cenários obtidos via m-ISODATA. . . . .	79
Tabela 12 – Taxonomia das publicações recentes que propõe metodologias para solução do co-planejamento da transmissão e DAEs. Onde HP indica Horizonte de Planejamento. . . . .	88
Tabela 13 – Custos de operação e investimento do sistema teste de duas barras. . .	100
Tabela 14 – Resultados das simulações para o sistema Garver considerando diversos parâmetros do AAPR. . . . .	109
Tabela 15 – Comparação do tamanho dos problemas e consumo de memória das formulações clássica e paralelizável. . . . .	109

## LISTA DE ABREVIATURAS E SIGLAS

AAPR	Algoritmo de Agrupamento de Períodos Representativos
CS	Caso de Simulação
DAE	Dispositivo de Armazenamento de Energia
DB	Decomposição de Benders
D-PET	PET Dinâmico
EWES	Expectativa de desperdício de energia eólica, do inglês <i>Expectation of Wind Energy Spilled</i>
FACTS	<i>Flexible AC Transmission Systems</i>
FCD	Fator de Correção Dimensional
FOR	Taxa de saída forçada, do inglês <i>Forced Outage Rate</i>
FPOP	Fluxo de Potência Ótimo Probabilístico
HAC	<i>Hierarchical Agglomerative Clustering</i>
ISODATA	<i>Iterative Self-Organizing Data Analysis Technique Algorithm</i>
LOLE	Expectativa de perda de carga, do inglês <i>Loss of Load Expectation</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>
m-ISODATA	<i>ISODATA modificado</i>
SMC	Simulação Monte Carlo
SMCC	Simulação Monte Carlo Cronológica
SMCNC	Simulação Monte Carlo não-Cronológica
PEG	Planejamento da Expansão da Geração
PET	Planejamento da Expansão da Transmissão de Energia Elétrica
PL	Programação Linear
PLIM	Programação Linear Inteira Mista
PNLIM	Programação Não-Linear Inteira Mista
RCTNEP	PET com restrição de confiabilidade, do inglês <i>Reliability-Constrained Transmission Network Expansion Planning</i>
S-PET	PET Estático.
TOAT	Arranjos Ortogonais de Teste do Taguchi, do inglês <i>Taguchi's Orthogonal Array Testing</i>

## LISTA DE SÍMBOLOS

### Subscritos

$b$	barra do sistema;
$k$	linha de transmissão;
$ij$	barras $i$ e $j$ adjacentes à linha $k$ ;
$y$	DAE;
$s$	cenário;
$c$	centroide de um grupo;
$\delta$	dimensão do conjunto de dados;

### Conjuntos

$B$	barras do sistema de transmissão;
$B^R$	barras com geração renovável;
$B^D$	barras com demanda;
$F$	observações da série histórica;
$G$	geradores controláveis;
$G_b$	geradores controláveis conectados à barra $b$ ;
$R$	geradores não-controláveis;
$R_b$	geradores não-controláveis conectados à barra $b$ ;
$Y$	DAEs;
$Y_b$	DAEs conectadas à barra $b$ ;
$K$	linhas de transmissão;
$K_b$	linhas de transmissão conectadas à barra $b$ ;
$K^E$	linhas de transmissão existentes na rede base;
$K^C$	linhas de transmissão candidatas à expansão;
$S$	cenários;
$\chi$	variáveis de otimização;
$X_c$	dados associados ao grupo $c$ .

### Variáveis

$pg_{b,s}$	potência ativa fornecida pelos geradores controláveis na barra $b$ e cenário $s$ , <b>MW</b> ;
$py_{y,s}^{ch}$	potência ativa consumida pelo DAE $y$ durante o carregamento no cenário $s$ , <b>MW</b> ;
$py_{y,s}^{dis}$	potência ativa fornecida pelo DAE $y$ durante o descarregamento no cenário $s$ , <b>MW</b> ;
$e_{y,s}$	energia armazenada no DAE $y$ e cenário $s$ , <b>MWh</b> ;
$hd_{b,s}$	deficit de potência ativa na barra $b$ e cenário $s$ , <b>MW</b> ;
$hr_{b,s}$	excedente de potência ativa na barra $b$ e cenário $s$ , <b>MW</b> ;
$\theta_{ij,s}$	diferença angular entre as barras terminais $i$ e $j$ , no cenário $s$ , <b>rad</b> ;
$f_{k,s}$	fluxo de potência ativa na linha existente $k$ e cenário $s$ , <b>MW</b> ;

$\pi_{k,s}^T$	índice de sensibilidade para a linha $k$ no cenário $s$ , \$;
$C_{inv}$	custo de investimento, \$;
$C_{ope}^{[s]}$	custo associado à solução do problema de otimização no cenário $s$ , \$;
$C_{total}$	custo total da decisão de expansão (investimento e operação), \$;
$C_{sp}$	custo total da decisão de expansão (investimento e operação) de um subproblema, \$;
$I_r^R$	variável de decisão de investimento em capacidade de geração do gerador não-controlável $r$ , <b>MW</b> ;
$I_g^G$	variável de decisão de investimento em capacidade de geração do gerador controlável $g$ , <b>MW</b> ;
$I_k^T$	variável binária de decisão de reforço na linha candidata $k$ ;
$I_y^{YP}$	variável de decisão de investimento em potência no DAE $y$ ;
$I_y^{YR}$	variável de decisão de investimento em capacidade de energia no DAE $y$ ;
$L_{k,s}$	perda de potência ativa na linha $k$ e cenário $s$ ;
$\lambda_{i,s}$	multiplicador de Lagrange referente à restrição de balanço de potência na barra $b$ e cenário $s$ , \$/MW;
$\lambda_{y,s}^e$	multiplicador de Lagrange referente à variável de nível de energia no DAE $y$ e cenário $s$ , \$/MW;
$\lambda_{y,s}^{YP}$	multiplicador de Lagrange referente à variável de investimento em potência no DAE $y$ e cenário $s$ , \$/MW;
$LOLP_b$	LOLP na barra $b$ ;
$LOWP_b$	LOWP na barra $b$ ;
$F_{b,s}^{LOLP}$	função teste da variável $LOLP_b$ no cenário $s$ ;
$F_{b,s}^{LOWP}$	função teste da variável $LOWP_b$ no cenário $s$ ;
$I^R$	vetor de variáveis de decisão de investimento em capacidade de geração do gerador não-controlável $r$ , <b>MW</b> ;
$I^G$	vetor de variáveis de decisão de investimento em capacidade de geração do gerador controlável $g$ , <b>MW</b> ;
$I^T$	vetor de variáveis binárias de decisão de reforço em linhas de transmissão;
$I^{YP}$	vetor de variáveis de decisão de investimento em potência de DAEs, <b>MW</b> ;
$I^{YE}$	vetor de variáveis de decisão de investimento em capacidade de armazenamento de DAEs, <b>MWh</b> ;
$pg$	vetor de variáveis de potência ativa gerada, <b>MW</b> ;
$\theta$	vetor de variáveis de ângulos das tensões nodais, <b>rad</b> ;
$hd$	vetor de variáveis de corte de cargas, <b>MW</b> ;
$hr$	vetor de variáveis de corte de renováveis, <b>MW</b> ;
$hy$	vetor de variáveis de folga de DAEs, <b>MW</b> ;
$py^{ch}$	vetor de potências entregues por DAEs, <b>MW</b> ;
$py^{dis}$	vetor de potências absorvidas por DAEs, <b>MW</b> ;
$v$	iteração da Decomposição de Benders;
$\sigma_c$	desvio padrão do grupo $c$ ;
$\vec{m}_c$	localização do centroide $c$ ;

$\vec{m}_{cf}^{(+)}, \vec{m}_{cf}^{(-)}$	previsão das localizações dos centroides gerados ao dividir o grupo $c$ via função <i>split</i> ;
$\vec{m}_{cf}$	previsão da localização do centroid obtido ao agrupar dois grupos via função <i>merge</i> ;
$\vec{m}_{ca}, \vec{m}_{cb}$	centroids genéricos 'a' e 'b';
$d(\vec{m}_{ca}, \vec{m}_{cb})$	distância Euclideana entre os centroides $\vec{m}_{ca}$ e $\vec{m}_{cb}$ ;
$Q_c$	matriz de covariância do grupo $c$ ;
$q_{\delta, \delta}$	$\delta$ -ésimo elemento da diagonal da matriz de covariância $Q_c$ ;
$\vec{\lambda}$	autovetor associado ao maior autovalor de $Q_c$ ;
$\vec{x}$	observação do conjunto de dados;
$X_c^N$	número de dados pertencentes ao grupo $c$ ;
$p_s$	probabilidade de ocorrência do cenário $s$ associado ao grupo $c$ .
$\beta$	coeficiente de variação da SMC;

#### Parâmetros

$\overline{pg}_g$	capacidade instalada de potência ativa do gerador $g$ , <b>MW</b> ;
$pr_{r,s}$	despacho de geração renovável para o gerador $r$ no cenário $s$ , <b>MW</b> ;
$a_{r,s}$	disponibilidade de geração renovável para o gerador $r$ no cenário $s$ ;
$d_{b,s}$	demanda de potência ativa na barra $b$ no cenário $s$ , <b>MW</b> ;
$b_k$	susceptância da linha $k$ , $\Omega^{-1}$ ;
$FOR_k$	taxa de saída forçada da linha $k$ ;
$\tilde{f}_k$	capacidade de transmissão de potência ativa da linha $k$ no cenário $s$ , <b>MW</b> ;
$C_r^R$	custo de investimento em capacidade de geração do gerador não-controlável $r$ , \$;
$C_g^G$	custo de investimento em capacidade de geração do gerador controlável $g$ , \$;
$C_k^T$	custo de investimento da linha $k$ , \$;
$C_y^{YP}$	custo de investimento em potência do DAE $y$ , \$;
$C_y^{YE}$	custo de investimento em capacidade de energia do DAE $y$ , \$;
$co_g$	custo de operação do gerador $g$ , \$;
$eg_g$	emissão de carbono do gerador $g$ , <b>ton/MWh</b> ;
$cc$	taxa de carbono, <b>\$/ton</b> ;
$ch$	penalidade para uso de variáveis de folga $b$ , \$;
$\eta_y^{ch}, \eta_y^{dis}, \eta_y^{self}$	eficiência de carregamento, eficiência de descarregamento e taxa de descarregamento do DAE $y$ ;
$\Delta t$	duração do intervalo de tempo entre os cenário $s$ e $s + 1$ , <b>h</b> ;
$\pi_{k,s}^T$	índice de sensibilidade no cenário $s$ , <b>\$/MW</b> ;
$cdh$	custo de corte de carga, <b>\$/MW</b> ;
$crh$	custo de corte de vento, <b>\$/MW</b> ;
$NS$	número de estados amostrados pela SMCNC;
$d_{min}^0, d_{min}$	respectivamente a distância mínima entre dois centroides antes e depois do FCD;

$\sigma_{max}^0, \sigma_{max}$	respectivamente o desvio padrão máximo de um grupo antes e depois do FCD;
$N_{iter}$	número máximo de iterações;
$k_0$	número inicial de grupos;
$D$	dimensão ou número de séries históricas do conjunto de dados;
$E_A$	erro aceitável;

#### Índices de desempenho

$EENS$	EENS do sistema, <b>GWh</b> ;
$EWES$	EWES do sistema, <b>GWh</b> ;
$ER$	erro relativo;
$US_S$	número de cenários ineficazes para o conjunto $S$ ;
$TS_S$	número total de cenários no conjunto $S$ ;
$AUS$	quantidade de cenários ineficazes;
$DIC$	diferença no custo de investimento;
$E_C$	erro calculado;
$CQE$	erro quadrático compensado;
$corrloss$	perda de correlação relativa.
$\rho_{\delta_i\delta_j}, \tilde{\rho}_{\delta_i\delta_j}$	elementos das matrizes de coeficientes de correlação, respectivamente para os conjuntos $F$ e $S$ .

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>17</b>
1.1	CONSIDERAÇÕES INICIAIS E CARACTERIZAÇÃO DO PROBLEMA .	17
1.2	MOTIVAÇÃO DO TRABALHO . . . . .	19
1.3	REVISÃO BIBLIOGRÁFICA . . . . .	20
1.3.1	Modelagem da rede . . . . .	20
1.3.2	Horizonte de planejamento . . . . .	22
1.3.3	Incertezas . . . . .	23
1.3.4	Algoritmos de agrupamento . . . . .	25
1.3.5	Consideração da confiabilidade . . . . .	26
1.3.6	Co-planejamento de sistemas de energia e alocação ótima de dispositivos de armazenamento de energia . . . . .	28
1.4	OBJETIVOS DA TESE . . . . .	30
1.5	TRABALHOS PUBLICADOS . . . . .	30
1.6	ESTRUTURA DO TRABALHO . . . . .	31
<b>2</b>	<b>S-PET SOB INCERTEZAS E CRITÉRIO DE SEGURANÇA N-1 . . .</b>	<b>33</b>
2.1	CONSIDERAÇÕES INICIAIS . . . . .	33
2.2	DECOMPOSIÇÃO DE BENDERS (DB) . . . . .	33
2.2.1	DB tradicional . . . . .	34
2.2.2	DB multicut . . . . .	35
2.3	FORMULAÇÃO MATEMÁTICA DO S-PET ROBUSTO . . . . .	36
2.3.1	Formulação completa . . . . .	36
2.3.2	FPO iterativo modificado . . . . .	38
2.3.3	Formulação em dois níveis . . . . .	39
2.3.4	Geração de cenários . . . . .	40
2.4	RESULTADOS . . . . .	41
2.4.1	Sistema IEEE-RTS . . . . .	42
2.4.2	Sistema BS . . . . .	43
2.5	CONCLUSÕES PARCIAIS . . . . .	45
<b>3</b>	<b>D-PET RESTRITO POR CONFIABILIDADE . . . . .</b>	<b>46</b>
3.1	CONSIDERAÇÕES INICIAIS . . . . .	46
3.2	FORMULAÇÃO DO RCTNEP . . . . .	47
3.2.1	Problema mestre (Passo 2) . . . . .	49
3.2.2	Definição do estado operativo do sistema (Passo 3) . . . . .	51
3.2.3	Formulação do FPO (Passo 4) . . . . .	51
3.2.4	Avaliação da confiabilidade e de desempenho (Passo 7) . . . . .	53
3.3	ABORDAGEM EM DOIS ESTÁGIOS . . . . .	53
3.4	RESULTADOS . . . . .	54



3.4.1	Sistema RTS-WIND . . . . .	55
3.4.2	Sistema IEEE-118 . . . . .	57
3.4.3	Impacto da energia renovável . . . . .	58
3.5	CONCLUSÕES PARCIAIS . . . . .	59
<b>4</b>	<b>ALGORITMO m-ISODATA: GERAÇÃO DE CENÁRIOS REPRESENTATIVOS NÃO-CRONOLÓGICOS . . . . .</b>	<b>60</b>
4.1	CONSIDERAÇÕES INICIAIS . . . . .	60
4.2	CENÁRIOS REPRESENTATIVOS NÃO-CRONOLÓGICOS . . . . .	62
4.3	FORMULAÇÃO DO m-ISODATA . . . . .	63
4.3.1	Passo 1 - Definição dos parâmetros . . . . .	64
4.3.2	Passo 2 - Fator de correção dimensional . . . . .	65
4.3.3	Passo 3 - Definição dos centroides iniciais . . . . .	66
4.3.4	Passo 4 - Critérios de parada . . . . .	66
4.3.5	Passo 5 - Função <i>split</i> . . . . .	66
4.3.6	Passo 6 - Função <i>merge</i> . . . . .	68
4.3.7	Passo 7 - Agrupando dados . . . . .	69
4.3.8	Comentários gerais . . . . .	69
4.4	RESULTADOS . . . . .	70
4.4.1	Definição dos valores <i>default</i> . . . . .	70
4.4.2	Desempenho do m-ISODATA em um espaço bidimensional . . . . .	71
4.4.3	Problema teste 1: Fluxo de Potência Ótimo Probabilístico (FPOP) . . . . .	73
4.4.3.1	<i>Formulação do FPOP</i> . . . . .	74
4.4.3.2	<i>Resultados</i> . . . . .	75
4.4.4	Problema teste 2: Planejamento da Expansão da Geração (PEG) . . . . .	76
4.4.4.1	<i>Formulação do PEG</i> . . . . .	76
4.4.4.2	<i>Casos de simulação</i> . . . . .	77
4.4.4.3	<i>Análises de sensibilidade - Parte 1</i> . . . . .	79
4.4.4.4	<i>Análises de sensibilidade - Parte 2</i> . . . . .	80
4.4.4.5	<i>Comparação entre os algoritmos</i> . . . . .	82
4.4.4.6	<i>Perda de correlação dos cenários</i> . . . . .	82
4.4.4.7	<i>Comparação com a literatura</i> . . . . .	84
4.5	CONCLUSÕES PARCIAIS . . . . .	85
<b>5</b>	<b>PLANEJAMENTO DA EXPANSÃO DA TRANSMISSÃO CONSIDERANDO A ALOCAÇÃO ÓTIMA DE DISPOSITIVOS DE ARMAZENAMENTO DE ENERGIA VIA COMPUTAÇÃO PARALELA . . . . .</b>	<b>87</b>
5.1	CONSIDERAÇÕES INICIAIS . . . . .	87
5.2	FORMULAÇÃO COMPLETA (NÃO-LINEAR) . . . . .	89
5.3	FORMULAÇÃO DECOMPOSTA CLÁSSICA (NÃO PARALELIZÁVEL) . . . . .	92
5.3.1	Problema mestre . . . . .	93

5.3.2	Subproblema . . . . .	94
5.3.3	Geração do corte de Benders . . . . .	94
5.4	FORMULAÇÃO DECOMPOSTA PARALELIZÁVEL . . . . .	94
5.4.1	Problema mestre . . . . .	95
5.4.2	Subproblemas . . . . .	96
5.4.3	Geração de corte de Benders . . . . .	97
5.5	ALGORITMO AAPR . . . . .	97
5.6	RESULTADOS . . . . .	98
5.6.1	Estudos de caso no sistema de duas barras - Tutorial . . . . .	99
5.6.2	Sistema Garver . . . . .	106
5.7	CONCLUSÕES PARCIAIS . . . . .	110
<b>6</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS . . . . .</b>	<b>111</b>
6.1	CONCLUSÕES . . . . .	111
6.2	TRABALHOS FUTUROS . . . . .	111
	<b>REFERÊNCIAS . . . . .</b>	<b>113</b>
	<b>APÊNDICE A – Dados do sistema IEEE-RTS . . . . .</b>	<b>124</b>
	<b>APÊNDICE B – Dados do sistema BS . . . . .</b>	<b>128</b>
	<b>APÊNDICE C – Dados do sistema IEEE-118 . . . . .</b>	<b>134</b>

# 1 INTRODUÇÃO

Neste capítulo busca-se caracterizar o problema de Planejamento da Expansão da Transmissão de Energia Elétrica (PET), apresentar uma revisão bibliográfica com o intuito de definir o atual estado da arte da formulação e solução do problema e apresentar as motivações que levaram às propostas que serão detalhadas nos capítulos posteriores.

## 1.1 CONSIDERAÇÕES INICIAIS E CARACTERIZAÇÃO DO PROBLEMA

O problema de PET busca definir uma topologia de rede futura que garanta o melhor serviço de energia elétrica aos consumidores com mínimo investimento considerando critérios técnicos, ambientais e sociais. A cerca de cinco décadas atrás, foi proposto em (GARVER, 1970) uma das primeiras abordagens automáticas para solucionar o PET através de uma abordagem de otimização heurística que adiciona reforços em ramos sobrecarregados, utilizando como base a solução de um problema de Fluxo de Potência Ótimo (FPO) modelado como um problema de Programação Linear (PL). A partir deste trabalho, o PET vem sendo sistematicamente estudado e aprimorado conforme discutido e apresentado nos trabalhos de revisão bibliográficas e classificação na área (HEMMATI; HOOSHMAND; KHODABAKHSHIAN, 2013; LUMBRERAS; RAMOS, 2016; MAHDAVI et al., 2019; GOMES; SARAIVA, 2019; GIDEON UDE; YSKANDAR; CONETH GRAHAM, 2019). Através dos *reviews* pode-se identificar muitas abordagens a serem desenvolvidas para acomodar modelagens mais precisas e técnicas de solução com tempos computacionais adequados. Dentre os desafios para o PET, pode-se citar: desregulamentação dos mercados de energia; penetração massiva de fontes renováveis de energia; projetos de geração em larga escala; integração dos mercados; consideração de novas tecnologias, como sistemas de corrente contínua em alta tensão (XIE; BIE; LI, 2019; DOMINGUEZ et al., 2017); FACTS (*Flexible AC Transmission Systems*) (RAHMANI et al., 2013; ZHANG; TOMSOVIC; DIMITROVSKI, 2017); veículos elétricos (RATHORE; ROY, 2016; NAGHDIZADEGAN JAHROMI; ASKARZADEH; ABDOLLAHI, 2017) e Dispositivos de Armazenamento de Energia (DAEs) (ZHANG; HU; SONG, 2013; HAMIDPOUR et al., 2019; JABR; DŽAFIĆ; PAL, 2015).

Dada a busca por uma matriz energética diversificada atrelada à necessidade de reduzir a emissão de gases de efeito estufa, o uso de fontes renováveis de energia vem crescendo (QAZI et al., 2019). Dentre as fontes de energia renovável, a solar e a eólica tem ganhado destaque. Por exemplo, o plano decenal de expansão de energia 2021-2030 (Ministério de Minas e Energia (MME); Empresa de Pesquisa Energética (EPE), 2021) prevê uma expansão de 16,5 GW em energia eólica e 5,5 GW em energia solar. Por fim, é esperado que 92% da produção elétrica do país provenha de fontes renováveis de energia. Porém, as fontes de energia solar e eólica agregam muitas incertezas ao planejamento e à operação do sistema elétrico devido à baixa previsibilidade, ao comportamento intermitente da disponibilidade de geração e à baixa controlabilidade. Assim, a integração de recursos renováveis aumenta a complexidade do PET, dificultando a manutenção

de índices de confiabilidade aceitáveis.

Quando geradores eólicos são conectados a uma região com baixa capacidade de transmissão do sistema, reforços podem ser necessários (BILLINTON; WANGDEE, 2007; BILLINTON et al., 2012). Um sistema de transmissão pode encontrar limitações de capacidade quando recebe grandes penetrações de geração de energia renovável, levando a um aumento nos níveis de corte de renováveis. Neste documento, o termo corte de renovável será utilizado para referir ao uso de menos energia eólica ou solar do que está potencialmente disponível em um determinado cenário ou instante de tempo, ou seja, ao desperdício da energia renovável disponível. O aumento da participação de renováveis com baixa controlabilidade pode forçar o operador do sistema a aceitar menos energia proveniente de fontes renováveis do que disponível. Portanto, para incorporar um grande montante de geração renovável planejada, podem ser necessárias mudanças operacionais e estruturais. De fato, reduzir o corte de renováveis envolve aumentar a flexibilidade do sistema. Com relação às mudanças estruturais, pode-se incluir o investimento em linhas de transmissão, FACTS e DAEs. Porém, o acesso a novos mercados e políticas de exportação/importação, melhorias em métodos de previsão e despacho econômico também são capazes de trazer mais flexibilidade à operação do sistema (BIRD et al., 2016).

Congestionamento na transmissão é uma razão comum para ocorrência de corte de renováveis (GU; XIE, 2014). Para evitar o desbalanço de potência, os operadores acionam geradores controláveis com custos operacionais maiores do que aqueles com fontes renováveis que não levam em conta custos com combustíveis. Pode ser mais eficiente desperdiçar energia de fontes renováveis periodicamente em sistemas que apresentam congestionamentos pouco frequentes, sendo economicamente mais viável arcar com os custos de combustíveis ao invés de expandir o sistema de transmissão.

Com isto, a grande maioria dos trabalhos atuais da literatura relacionados ao PET considera incertezas relacionadas à carga, geração, preços de combustíveis, custos de investimento, confiabilidade e recursos renováveis com o intuito de refletir melhor a realidade e produzir planos de expansão de baixo custo e operacionalidade confiável.

Matematicamente, o PET se configura como um problema de programação probabilístico com múltiplos objetivos, com um espaço de busca de grande porte, inteiro-misto, não-convexo e não-linear. Estas características levam a um número explosivo de possíveis soluções e cenários que requer alto esforço computacional para obtenção do ótimo global do problema, sendo impraticável avaliar todas as possíveis soluções em tempos aceitáveis mesmo para problemas de pequeno porte. Desta forma, estudos têm sido conduzidos na literatura para prover soluções eficientes do problema PET.

Os métodos de solução do PET são classificados como: abordagens de otimização matemática, algoritmos heurísticos construtivos e meta-heurísticas. Os métodos de otimização matemática solucionam o problema através de: *solvers* de problema de Programação Linear Inteira Mista (PLIM) ou *solvers* de problema de Programação Não-Linear Inteiro-Misto (PN-

LIM) (AKBARI; TAVAKOLI BINA, 2016); técnicas de decomposição como decomposição de Benders (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013), *branch-and-cut* (HUANG; DINAHAHI, 2019) e *progressive hedging* (MAJIDI-QADIKOLAI; BALDICK, 2018); ou *branch-and-bound* (JAESEOK CHOI et al., 2005). Métodos heurísticos construtivos utilizam funções de sensibilidade especializadas para reforçarem a rede de forma iterativa (SILVA et al., 2012). Apesar de não garantirem o ótimo global, são rápidos e comumente utilizadas para reduzir o espaço de busca, gerando um conjunto reduzido de linhas candidatas a expansão que melhora o desempenho de técnicas utilizadas para refinar a solução (MENDONÇA et al., 2016). As meta-heurísticas determinam soluções de alta qualidade sem garantir o ótimo global. Muitas dessas são baseadas em abordagens populacionais capazes de avaliar múltiplas regiões do espaço de busca, evitando problemas associados às não-linearidades. Aplicadas ao PET, podem-se citar as metas-heurísticas: *genetic algorithm* (MAHDAVI; MONSEF; ROMERO, 2017), *ant colony algorithm* (SILVA et al., 2010), *differential evolution* (ALHAMROUNI et al., 2014), *frog leaping algorithm* (ALAEI; HOOSMAND; HEMMATI, 2016), *harmony search algorithm* (VERMA; PANIGRAHI; BIJWE, 2010), *particle swarm optimization* (HUANG; DINAHAHI, 2017), *bat algorithm* (OLIVEIRA et al., 2018), *grey wolf optimization* (KHANDELWAL et al., 2018), *cuckoo search* (NAGHDIZADEGAN JAHROMI; ASKARZADEH; ABDOLLAHI, 2017).

## 1.2 MOTIVAÇÃO DO TRABALHO

O presente trabalho é motivado por três lacunas identificadas na literatura:

- A primeira diz respeito à falta de trabalhos que levam em consideração as diferenças entre a avaliação da confiabilidade local do sistema como um todo. Ou seja, na literatura encontram-se trabalhos que avaliam a confiabilidade do sistema, com isto, busca-se o custo-benefício ótimo entre confiabilidade e investimento ou respeitar um limite mínimo de confiabilidade. Todavia, regiões de baixo consumo de energia e/ou baixo custo de corte de carga não influenciam nos índices utilizados para realizar o custo-benefício. Ao negligenciar a confiabilidade local pode-se obter redes que apresentem regiões com baixa qualidade no fornecimento de energia elétrica.
- A segunda lacuna identificada na literatura diz respeito à representação do horizonte de planejamento cronológico, pouco abordado em ferramentas de solução do PET. Para agregar a crescente participação dos DAEs nos sistemas elétricos, os modelos de PET devem considerar o comportamento de carregamento e descarregamento destes dispositivos que são modelados por uma equação de balanço de energia dependentes do tempo. Além disso, para reduzir o comportamento intermitente dos geradores solares e eólicos, o modelo precisa levar em conta uma alta resolução temporal, normalmente horária. No entanto, a resolução horária eleva consideravelmente o número de variáveis dos modelos, aumentando o custo computacional. A fim de tornar o problema computacionalmente viável, o autor

utiliza dias representativos para verificar o impacto dos DAEs no PET. Entretanto, os dias representativos não são capazes de caracterizar o comportamento dos ventos, que não apresenta similaridades diárias conforme discutido em (YANG; NEHORAI, 2014).

- A terceira lacuna encontra-se no uso de algoritmos tracionais de agrupamento para agrupar séries históricas em cenários representativos. Os cenários são amplamente utilizados para redução do custo computacional em ferramentas de planejamento de sistemas de energia. Discutido em (MERRICK, 2016), esses algoritmos apresentam a desvantagem de exigir o número de grupos/cenários como parâmetro de entrada. Além de ser um número difícil de ser arbitrado, o autor do estudo observou que o número adequado de cenários necessários para representar uma série histórica se altera conforme características das próprias séries históricas e o número de séries consideradas, tornando impraticável recomendar números de cenários para cada problema. Com isto, verifica-se a necessidade de idealizar algoritmos capazes de obter os cenários a partir do agrupamento de séries históricas sem a necessidade de definir o número de cenários como parâmetro de entrada.

### 1.3 REVISÃO BIBLIOGRÁFICA

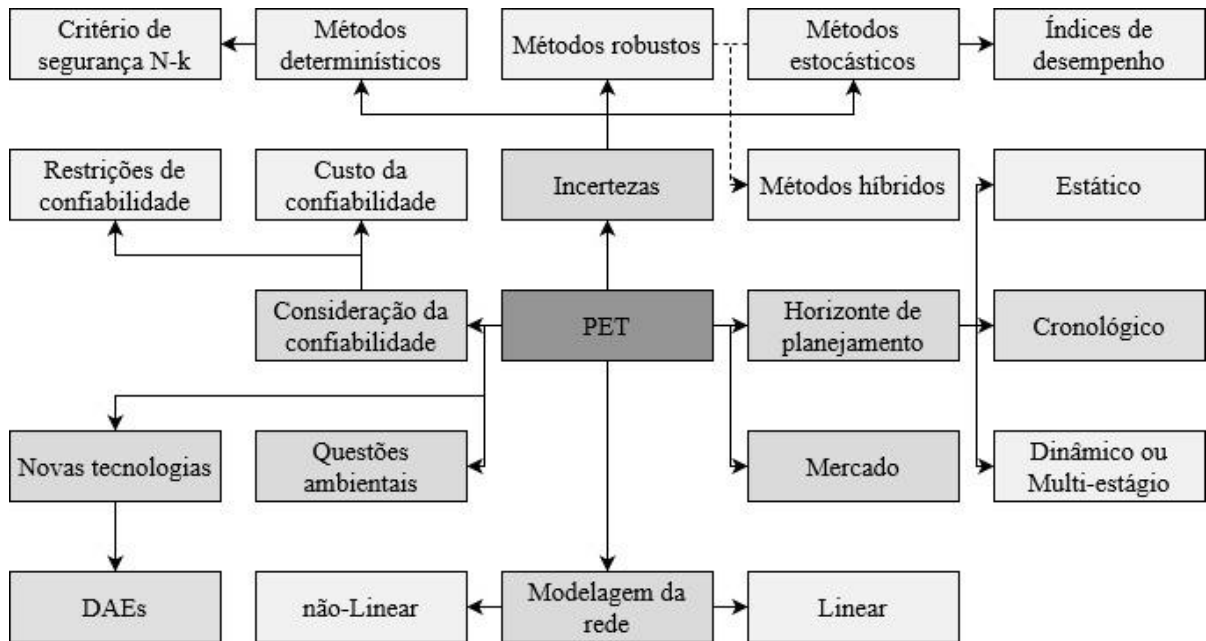
Nesta revisão bibliográfica busca-se apresentar alguns dos principais trabalhos desenvolvidos na área de planejamento da expansão de sistemas elétricos que demonstram a necessidade de criar as metodologias propostas nesta tese. Para melhor organizar a revisão e apresentar o atual estado da arte do PET, as principais variáveis que afetam o problema são organizadas na Figura 1 e discutidas nas próximas subseções deste capítulo. Na Figura 1, extraem-se 7 variáveis principais (em lilás) que são encontradas na literatura para solução do PET: modelagem da rede; horizonte de planejamento; incertezas; consideração da confiabilidade; mercado; questões ambientais e novas tecnologias. Em amarelo são apresentadas algumas subdivisões das variáveis que serão aprofundadas nesta revisão e, em verde, destacam-se aquelas que serão aprofundadas nas contribuições deste trabalho.

#### 1.3.1 Modelagem da rede

A restrição física mais básica do PET está relacionada com a representação da rede de transmissão, que é modelada por variações de problemas de FPO. Em sua forma completa, conhecido como FPO em corrente alternada, o problema é intrinsecamente não-linear, sendo capaz de considerar perfil de tensão, restrições de estabilidade, limites de potência reativa e perdas na transmissão. Porém, o elevado custo computacional torna o FPO em corrente alternada impraticável para ser aplicado no PET devido ao elevado número de planos de expansão e estados de redes a serem avaliados, além do mais, a natureza não-convexa do problema pode limitar a garantia da obtenção do ótimo global (ASADAMONGKOL; EUA-ARPORN, 2013).

Alguns trabalhos buscam maneiras de utilizar a rede CA no PET. Em (RIDER; GARCIA; ROMERO, 2007), é apresentado um trabalho para considerar a rede CA no PET através de

Figura 1 – Taxonomia do PET.



Fonte: do autor.

um algoritmo heurístico construtivo. Em (ZHANG et al., 2013), os autores apresentam um modelo linear capaz de representar potência reativa, perfil de tensão e perdas na transmissão. De maneira similar, o problema PET com rede CA é modelada como um problema de PLIM em (AKBARI; TAVAKOLI BINA, 2016). Em (HAGHIGHAT; ZENG, 2018), a rede é modelada via programação cônica de segunda ordem, permitindo representar de maneira relativamente mais realística o perfil de tensão e reativos no problema PET; a modelagem apresentada é passível de substituir o modelo de PLIM e garante o ótimo global via *solvers* especializados. Em (GOMES; SILVA; SARAIVA, 2016), o D-PET em corrente alternada é solucionado através da meta-heurística *Non-Dominative Hill-Climbing Genetic Algorithm*.

Por outro lado, o problema PET em corrente alternada é comumente relaxado através de abordagens baseadas no modelo em corrente contínua para evitar não-linearidades através da linearização da segunda lei de Kirchhoff (ZIAEE; ALIZADEH-MOUSAVI; CHOUBINEH, 2018; LEI et al., 2018), porém, a abordagem linear não inclui perdas na transmissão, potência reativa e perfil de tensão. Nesta tese, o FPO em corrente contínua será tratado apenas como FPO.

Em (DOS SANTOS; DINIZ, 2011), os autores apresentam um modelo linear dinâmico por partes para representar as perdas na transmissão durante o processo de otimização do FPO. Assim, os autores comparam o modelo linear dinâmico por partes com um processo clássico iterativo que realimenta o FPO para obter as perdas nas linhas. O processo iterativo é mais rápido que o modelo linear dinâmico por partes e amplamente utilizado nos problemas PET (ASSIS et al., 2018; POUBEL et al., 2015), porém, quando o processo iterativo é considerado, a solução ótima global do FPO não pode 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 demandam um elevado custo computacional. Além disso, nem o modelo linear dinâmico por partes nem o processo iterativo comumente utilizado na literatura respeitam a restrição de limite de potência nos dois sentidos de fluxo de uma linha de transmissão de forma adequada. Em (DE LA TORRE; CONEJO; CONTRERAS, 2008), é modelado um problema de PLIM considerando as perdas ativas na transmissão, porém, o modelo também apresenta o problema associado ao limite de fluxo em ambas as direções.

O modelo de transporte, utilizado pela primeira vez em (GARVER, 1970), é mais simplificado que o modelo CC uma vez que desconsidera a segunda lei de Kirchhoff para calcular o fluxo de potência. Desta forma, a rede é modelada como um problema de transporte onde apenas o balanço de potência em cada barramento precisa ser satisfeito. Atualmente, esta modelagem é utilizada em Problemas da Expansão da Geração (PEGs) para reduzir o custo computacional (PINEDA; MORALES, 2018) e/ou para considerar a rede elétrica apenas para fins de exportação/importação de montantes de energia entre regiões distintas (CHEN et al., 2018). Em (CHOI; MOUNT; THOMAS, 2007), o modelo de transportes foi aplicado ao PET com o intuito de incluir o critério de segurança N-1 utilizando uma formulação de PLIM.

### 1.3.2 Horizonte de planejamento

O PET pode ser abordado de forma estática (S-PET) ou dinâmica (D-PET). O S-PET define uma lista de novas linhas que precisam ser instaladas ao fim do horizonte de planejamento com o intuito de satisfazer as restrições técnicas e econômicas. No entanto, a questão de "*quando*" investir na linha é uma informação fundamental para o planejador e pode ser obtido através do D-PET, que permite obter uma visão holística de todo o horizonte de planejamento ao custo de um alto esforço computacional para ser solucionado diretamente. Recentemente, a literatura apresenta um crescente número de artigos com metodologias inovadoras para solucionar o D-PET (POUBEL et al., 2015; ZHANG et al., 2018).

Recentemente, com a inserção dos DAEs no sistema de transmissão, o PET vem sendo realizado com um horizonte de planejamento cronológico, capaz de representar o comportamento horário da operação do sistema, permitindo a modelagem do carregamento e o descarregamento dos DAEs. Nesta tese, são classificadas como cronológicas as metodologias que utilizam resolução temporal menor que um ano.

Em (RABY et al., 2009), uma abordagem cronológica é introduzida para solucionar o PET considerando geração eólica em sistemas hidrotérmicos. A resolução temporal considerada é de aproximadamente 3,3 dias, segundo os autores, é possível representar a variabilidade de blocos de energia entregues pelas eólicas de modo a tornar a análise realística. Em (SILVA et al., 2012), é proposto o Fluxo de Potência Cronológico (fluxo de potência cronológico), utilizado para solucionar o problema de PET de forma heurística, baseando-se em índices de sensibilidade que buscam determinar o conjunto de linhas a serem investidas que apresentam



o melhor custo-benefício para reduzir o corte de vento. A heurística investe nas linhas mais sobrecarregadas levando em conta cenários cronológicos de vento. Para solucionar o problema, foram consideradas séries históricas de carga e despacho eólico com resolução horária. Em (WU et al., 2018), a resolução horária e o fluxo de potência cronológico também foram utilizados para considerar a cronologia e as incertezas a curto prazo associadas à geração eólica na solução do problema PET através de uma técnica heurística baseada em dois índices de sensibilidade. O trabalho leva em conta saídas forçadas de equipamentos durante a avaliação do fluxo de potência cronológico, com isto, os autores levam em conta as restrições associadas às rampas de geração em geradores convencionais. Os resultados apontaram que o fluxo de potência cronológico apresentado obteve um desempenho superior ao proposto em (SILVA et al., 2012).

### 1.3.3 Incertezas

Incertezas têm sido consideradas em problemas de PET com o intuito de modelar: aumentos da demanda; acréscimos da capacidade de produção; disponibilidade de equipamentos e combustíveis; e variabilidade de demanda e geração de fontes renováveis. As incertezas são consideradas através de três classes de métodos: determinísticos, estocásticos e robustos.

Abordagens determinísticas são incapazes de lidar com incertezas uma vez que todos os parâmetros dos modelos são valores conhecidos. Atualmente, abordagens determinísticas são utilizadas para introduzir novas técnicas de solução aplicadas ao PET (CAMPONOGARA; DE ALMEIDA; HARDT, 2015; HUANG; DINAHAHI, 2017), ou a inclusão de novas variáveis no PET, como: inclusão de DAEs (ZHANG; HU; SONG, 2013); consideração de mercado (POZO; SAUMA; CONTRERAS, 2013; JIN; RYAN, 2014a; JIN; RYAN, 2014b); consideração da rede CA (RIDER; GARCIA; ROMERO, 2007; ZHANG et al., 2013; AKBARI; TAVAKOLI BINA, 2016; WIEST; RUDION; PROBST, 2018); critério de segurança (HUANG; DINAHAHI, 2019).

Abordagens estocásticas obtêm planos de expansão que alcançam o ótimo médio de todos os cenários amostrados utilizando distribuições de probabilidade. Diferentes métodos como programação estocástica (PARK; BALDICK; MORTON, 2015), Simulação Monte Carlo (SMC) (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013), e Técnica de Estimção de Estado (MOEINI-AGHTAIE; ABBASPOUR; FOTUHI-FIRUZABAD, 2012a; MOEINI-AGHTAIE; ABBASPOUR; FOTUHI-FIRUZABAD, 2012b; SABERI; MONSEF; AMRAEE, 2017) são utilizadas para lidar com as incertezas no PET. Em (PARK; BALDICK; MORTON, 2015), um modelo de programação estocástica em dois estágios é desenvolvido para considerar as incertezas associadas à geração eólica. Em (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013), os autores uniram a decomposição de Benders e a SMC para solucionar o PET considerando amostragem de: saída forçada de linhas de transmissão; cenários futuros de carga; e despacho correlacionado de geração eólica. Em (MOEINI-AGHTAIE; ABBASPOUR; FOTUHI-FIRUZABAD, 2012a; MOEINI-AGHTAIE; ABBASPOUR; FOTUHI-FIRUZABAD, 2012b), as incertezas associadas à demanda e à geração eólica são incorporadas ao modelo matemático

utilizando a técnica de estimação de estados. Em (AKBARI; RAHIMIKIAN; KAZEMI, 2011), um D-PET estocástico é formulado considerando a capacidade de transferência disponível, incertezas na carga e questões de mercado e o critério de segurança N-1.

Abordagens robustas (também conhecidas como não-determinísticas ou incertas), têm a vantagem de considerar as incertezas através de simples conjuntos de incertezas polinomiais (ou conjuntos robustos). Assim, as incertezas são modeladas de forma simplificada e não necessitam do conhecimento prévio das distribuições de probabilidade de cada variável aleatória. A otimização robusta é um ramo de formulações de otimização que lida com problemas que buscam uma solução com um dado nível de robustez. Exemplos de abordagens baseadas em otimização robusta aplicadas ao PET podem ser encontradas em (GARCÍA-BERTRAND; MÍNGUEZ, 2017; JABR, 2013; ZHANG; CONEJO, 2018b; DEHGHAN; AMJADY; CONEJO, 2018).

Em (MOREIRA; STREET; ARROYO, 2015), um PET robusto com restrições de contingência sob geração conjunta generalizada e critério de segurança N-k da transmissão é proposto e abordado por uma metodologia em três níveis baseada em decomposição de Benders, mas não considera incertezas de carga ou vento. O critério de segurança determinístico N-k, garante uma operação adequada do sistema mesmo sob a interrupção simultânea de  $k$  equipamentos. O critério de segurança N-1 é normalmente utilizado nos modelos de PET e garante a operação do sistema sob a saída de um equipamento qualquer (ALIZADEH-MOUSAVI; ZIMA-BOČKARJOVA, 2016; SILVA et al., 2017). Um método híbrido é proposto em (BARINGO; BARINGO, 2018), onde os autores apresentaram uma abordagem de otimização estocástica adaptativa e robusta para solucionar o problema de PET. Assim, as incertezas de curto prazo são modeladas de maneira estocástica, ou seja, a variabilidade de demanda e produção intermitente das unidades geradoras por fontes renováveis. Já as incertezas de longo prazo são modeladas de maneira robusta, que compreende a demanda futura e o custo futuro da geração.

Os autores em (YU; CHUNG; WONG, 2011) e (LI et al., 2016) propuseram PET robustos sem utilizar conceitos de otimização robusta (GOMES; SARAIVA, 2019) ou o modelo de otimização min-max-min comumente utilizado e introduzido em (JABR, 2013). Nestes trabalhos, a robustez da rede é verificada através da SMC, para estressar a rede com uma elevada quantidade de cenários. Em (YU; CHUNG; WONG, 2011), é apresentado um PET robusto que utiliza cenários de vento e carga gerados via TOAT (*Taguchi's Orthogonal Array Testing*), tais cenários são extremistas e não consideram a correlação entre as variáveis incertas. Para superar este problema, um PET robusto baseado em cenários é apresentado em (LI et al., 2016) utilizando o método *Heuristic Moment Matching* para gerar potências de geração eólica correlacionadas que apresentaram melhor desempenho no custo benefício entre robustez e custo de investimento.

### 1.3.4 Algoritmos de agrupamento

O agrupamento de dados (do inglês *data clustering*) compreende um conjunto de técnicas de aprendizagem não-supervisionada utilizadas para agrupar dados com características semelhantes de acordo com alguns critérios pré-determinados, como por exemplo a distância euclidiana entre dois pontos (DUAN et al., 2015). Uma revisão recente (MITTAL et al., 2019) classificou os algoritmos de agrupamento em seis grupos: baseados em particionamento, baseados em grade, baseados em modelo, baseados em densidade, baseados em hierarquia e baseados em lógica *fuzzy*. Para gerar cenários a partir do agrupamento de séries históricas em sistemas de energia, os algoritmos baseados em particionamento e em hierarquia são amplamente aplicados (MERRICK, 2016). Já os demais algoritmos de agrupamento não são aplicados, uma vez que: algoritmos baseados em densidade têm difícil aplicação quando os grupos não estão bem separados no espaço de observações, o que é o caso de dados contínuos como séries históricas de vento, solar e demanda; algoritmos baseados em grade são projetados principalmente para dados em duas dimensões, como identificação de padrões em fotografias (SHEIKHOESLAMI; CHATTERJEE; ZHANG, 2000); e há uma falta de pesquisas utilizando algoritmos baseados em lógica *fuzzy* para indicar se introduzir graus de pertinência entre os grupos na tarefa de geração de cenários seria ou não vantajoso.

Algoritmos baseados em hierarquia localizam grupos aninhados de maneira recursiva por meio de uma estrutura hierárquica conhecida como dendograma. Já os algoritmos baseados em partição localizam todos os grupos simultaneamente ao dividir os dados. Aplicados a séries históricas, os algoritmos de agrupamento geram cenários representativos que podem ser não-cronológicos, associados à probabilidades de ocorrência, ou podem formar períodos representativos associados às suas durações (SUN et al., 2019).

Entre os algoritmos de agrupamento baseados em particionamento, o k-means (MACQUEEN, 1967) é o mais popular, devido sua simplicidade de implementação. Porém, o k-means é altamente dependente do conjunto inicial de grupos (DUAN et al., 2015; HONÓRIO; SILVA; BARBOSA, 2012) e requer o número de grupos como parâmetro de entrada. Apesar disso, na última década, o k-means tem sido aplicados em problemas de sistemas de potência para: reconhecer e identificar padrões de queda de tensão (DUAN et al., 2015); determinar zonas de falha em sistemas de transmissão (ROMERO; GALLEGO; PAVAS, 2012); extrair dados históricos de sistemas de controle (LIU; HE; LIU, 2010; HONÓRIO et al., 2018); modelar níveis de carga de sistemas de potência (WOGGIN et al., 2014); e para capturar cenários representativos de despacho de energia eólica de séries históricas (ASSIS et al., 2018; MORAES et al., 2020; POUBEL et al., 2017).

Os algoritmos de agrupamento baseados em densidade têm a capacidade de identificar agrupamentos de formatos arbitrários modelados em diferentes regiões de densidade. Nestes métodos, os grupos são representados por regiões densas de pontos no espaço. Assim, regiões de baixa densidade podem filtrar pontos discrepantes. Tais métodos têm sido usados para

reduzir os picos de preços de geração de energia e para analisar o perfil de consumo dos clientes finais (WANG; XIAO; SHI, 2014; YANG et al., 2018). Em (ESTER et al., 1996), os autores apresentam um algoritmo baseado em densidade denominado *Density-Based Spatial Clustering of Application with Noise* (DBSCAN), que é capaz de identificar grupos de formatos arbitrários em dados multidimensionais. No entanto, algoritmos baseados em densidade são ineficazes na definição de cenários a partir de séries históricas, uma vez que apresentam dificuldade para determinar o raio de uma área de densidade necessária para definir limiares entre os grupos.

A aplicação de algoritmos de agrupamento hierárquicos em problemas de sistemas elétricos de potência tem sido proposta para: extrair padrões de consumo para geração fotovoltaica (HINO et al., 2013); avaliar a alocação da turbina eólica (WANG et al., 2016); identificar padrões de falha monofásica em esquemas de proteção (WANG et al., 2013); capturar cenários de demanda de carga para planejamento de expansão de sistemas de distribuição (DUPAČOVÁ; GRÖWE-KUSKA; RÖMISCH, 2003).

### 1.3.5 Consideração da confiabilidade

A avaliação da confiabilidade possibilita garantir o desempenho futuro adequado frente às incertezas inerentes à operação dos sistemas elétricos no PET no que tange à disponibilidade dos equipamentos, mesmo quando as renováveis são consideradas. Apesar da importância, a maioria das ferramentas computacionais apresentadas na literatura não asseguram o nível de confiabilidade de entrega da energia devido ao elevado custo computacional exigido para avaliar os índices de confiabilidade.

O critério de segurança determinístico N-k é comumente utilizado para solucionar o PET com restrições de segurança (HUANG; DINAHAHI, 2019; ZHENG et al., 2019; XIE; BIE; LI, 2019). Quando considerado, a rede expandida deve operar adequadamente sob a saída de k equipamentos simultâneos. Porém, o critério de segurança N-1 é o mais utilizado, devido ao seu custo computacional reduzido.

Em contraste ao critério de segurança N-k, a confiabilidade da rede pode ser melhor considerada através de índices de confiabilidade. Em (SILVA et al., 2010), é proposto um PET considerando o custo da confiabilidade na função objetivo pelo índice LOLC (Custo de Perda de Carga, do inglês, *Loss of Load Cost*). Para considerar as não-linearidades impostas pela saída forçada dos equipamentos na transmissão, o problema é abordado pelo algoritmo meta-heurístico *Ant Colony System*. Similarmente, o custo da confiabilidade é considerado em (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013), porém, os autores combinam a SMC Não-Cronológica (SMCNC) com a decomposição de Benders para solucionar o problema, levando em conta incertezas de vento, disponibilidade de equipamentos e nível de demanda. Os objetivos de investimento e confiabilidade são conflitantes por natureza, assim, a minimização do custo total do plano de expansão requer a definição do custo da energia indisponível, ou *Unit Cost* (WACKER; BILLINTON, 1989), em inglês. Assim, um *Unit Cost* preciso pode levar o

planejamento ao custo mínimo de investimento e confiabilidade, garantindo o retorno financeiro aos investidores. Além da LOLC, outros índices de confiabilidade como expectativa de energia não suprida (EENS, do inglês *Expectation of Energy not Supplied*) e probabilidade de perda de carga (LOLP, do inglês *Loss of Load Probability*) são considerados na literatura (GOMES; SARAIVA, 2018; HAMIDPOUR et al., 2019; LEI et al., 2018). Alguns trabalhos consideram a confiabilidade como uma restrição do PET, o que resulta em uma rede futura que garante um dado nível de confiabilidade exigido ao invés de realizar um balanço ótimo entre os custos de investimento e confiabilidade (TAHERKHANI; HOSSEINI, 2013; QIU, 2018; DEHGHAN; AMJADY; CONEJO, 2016; ALIZADEH; JADID, 2011).

Abordagens híbridas considerando aspectos robustos e estocásticos têm sido propostas na literatura para solucionar o PET (ZHANG; CONEJO, 2018b; BARINGO; BARINGO, 2018). Nestes trabalhos, variáveis incertas são modeladas por: conjuntos robustos, para incertezas a longo prazo como nível de demanda futuro, custo de combustível futuro, capacidade instalada de fontes renováveis; conjunto de cenários, para incertezas a curto prazo como disponibilidade de recursos renováveis intermitentes, saídas forçadas de equipamentos e variabilidade da demanda. Em (DEHGHAN; AMJADY; CONEJO, 2016), é apresentado um planejamento da expansão de geração e transmissão (PEG&T) utilizando otimização robusta e restrição de confiabilidade. As saídas das linhas são modeladas através de distribuições de probabilidade ao passo que os níveis futuros a longo prazo de demanda e geração eólica são modelados por conjuntos robustos. No entanto, a consideração do índice de confiabilidade EENS impõe não-linearidades ao modelo, para mitigar seus efeitos, os autores propõem o uso de diversos conjuntos robustos obtidos pelo método de agrupamento k-means de modo a avaliar melhor o espaço de busca.

Em (SILVA et al., 2010), apenas um conjunto dos planos de expansão mais econômicos obtidos pela solução determinística do PET tem o valor da confiabilidade avaliado. Esta metodologia é conhecida como avaliação da confiabilidade *a posteriori* e o plano que apresenta menor custo total, isto é, investimento e LOLC, é avaliado como o melhor plano. O mesmo custo total é obtido em (CHOI et al., 2004) através de uma abordagem heurística que investiga um conjunto de planos de expansão obtidos com mínimo investimento, porém, que satisfaçam o critério determinístico de confiabilidade *Bus Reserve Rate*. Entretanto, para obter o plano ótimo, muitos planos de expansão com diferentes parâmetros precisam ser avaliados, elevando consideravelmente o custo computacional. Métodos em que a confiabilidade *a posteriori* não garantem nem um nível de confiabilidade adequado nem um custo-benefício otimizado entre custos de investimento e confiabilidade.

Por outro lado, trabalhos que avaliam a confiabilidade durante o procedimento de busca, isto é, *a priori*, podem garantir as metas de confiabilidade e/ou o balanço ótimo entre os custos de confiabilidade de forma ótima. Em (JAESEOK CHOI et al., 2005), um método probabilístico baseado em *branch-and-bound* é proposto para obter um PET com restrições de confiabilidade. Contudo, o método parece conduzir a um conjunto combinatório explosivo de alternativas de

expansão e é testado apenas em um sistema de 5 barras. Em (TAHERKHANI; HOSSEINI, 2013), uma abordagem baseada na decomposição de Benders é proposta para obter um custo benefício ótimo entre investimento e confiabilidade levando em conta a integração de usinas eólicas. Assim, o modelo proposto busca encontrar um plano que satisfaça níveis específicos de confiabilidade e corte de vento com mínimo investimento.

#### 1.3.6 Co-planejamento de sistemas de energia e alocação ótima de dispositivos de armazenamento de energia

A recente participação massiva das energias renováveis não-controláveis, solar e eólica, e a busca pela redução da emissão de gases do efeito estufa nas matrizes energéticas, tornou necessária a avaliação por medidas capazes de reduzir o corte de renováveis. Com isto, a busca por ferramentas capazes de realizar o PET juntamente com a alocação ótima de DAE aumentou nos últimos anos. Os trabalhos avaliados destacam que o co-planejamento reduz o custo de investimento global uma vez que os DAEs ampliam o uso das energias não-controláveis, armazenando energia em momentos de maior geração e menor demanda, e utilizando esta energia armazenada em momentos de menor geração e maior demanda. Além disso, se bem alocados na rede, os DAEs podem evitar o congestionamento de linhas de transmissão. Todos os benefícios proporcionados pelos DAEs permitem reduzir os investimentos necessários em transmissão e/ou os custos de operação.

Em (HU; ZHANG; LI, 2012; ZHANG; HU; SONG, 2013), o co-planejamento de transmissão e DAEs é modelado como um problema de PLIM. Entretanto, esses trabalhos não levam em conta o balanço de energia e cenários cronológicos, o que reduz a precisão das análises pois ignora o comportamento dinâmico dos DAEs, da demanda e de fontes primárias de energia como sol e vento. Já em (MAZAHERI et al., 2021), o co-planejamento é como um problema de PLIM, levando em conta a restrição de balanço de energia e o critério de segurança N-1. A restrição de balanço de energia aumenta consideravelmente a dimensão do problema de PLIM, uma vez que todas as restrições relacionadas à operação do sistema são replicadas para cada cenário operativo da janela temporal considerada, limitando o tamanho da janela uma vez que o custo computacional e uso de memória pode se tornar intratável a depender do tamanho do sistema considerado.

Em (DIAZ; INZUNZA; MORENO, 2019), foram avaliadas diferentes formulações baseadas na complexidade da modelagem do sistema elétrico: resolução temporal, flexibilidade da operação e incertezas nos preços dos combustíveis. A partir dos estudos propostos para o co-planejamento do sistema de geração e DAEs, desconsiderando a rede de transmissão, os autores concluem que quanto maior a complexidade da modelagem, maiores são os benefícios obtidos com a inclusão de DAEs. Isso é dado pelo motivo que os DAEs participam não só da maximização do uso das energias, mas também participam da flexibilidade da operação. O estudo aponta a importância de incluir as restrições de *Unit Commitment* no planejamento.

Em (QIU et al., 2017), os autores propõem um co-planejamento dinâmico da transmissão e DAEs levando em conta cenários de vento e carga através de dias representativos. Na formulação incorporam-se requerimentos de reserva do *Unit Commitment*, alocação ótima dos DAEs e inclui uma modelagem para considerar a degradação das baterias ao longo do planejamento dinâmico, com horizonte de planejamento de 25 anos com épocas de 1 ano.

Em (ZHANG; CONEJO, 2018a), é proposto um método de solução híbrido que leva em conta incertezas a longo prazo, modeladas via conjuntos robustos, e incertezas a curto prazo, modeladas por dias representativos. De maneira similar, (NIKOOBAKHT; AGHAEI, 2019) propõe uma abordagem estocástica e robusta para o problema de co-planejamento de transmissão e DAEs e modela as séries cronológicas através de polinômios de Bernstein de modo a considerar um tempo contínuo ao invés da representação horária discretizada. De forma similar, (NIKOOBAKHT et al., 2020) utiliza os polinômios de Bernstein para demonstrar as vantagens de se considerar o tempo contínuo na otimização de alocação e dimensionamento de DAEs de ação rápida, que auxiliam com suas altas taxas de rampa. No entanto, o estudo não considera o investimento em transmissão.

Em (DVORKIN et al., 2018), os autores formulam uma metodologia de co-planejamento através do método *Column-and-Constraint Generation* para solucionar o modelo de PLIM levando em conta questões mercadológicas. A operação da rede (DVORKIN et al., 2018) é modelada como um grande problema de PLIM, demandando muita memória computacional para representar longas janelas temporais.

Em (FALUGI; KONSTANTELOS; STRBAC, 2018), os autores propõem o *Nested Benders Decomposition*, um esquema de decomposição para solucionar o co-planejamento de transmissão e DAEs com multi-estágios para considerar incertezas a longo prazo e diferentes tipos de opções de investimento de DAEs, com diferentes tempos de construção e linhas de transmissão.

Em (GAN et al., 2019), o problema de co-otimização entre transmissão e DAEs é modelado como um problema de PLIM solucionado via decomposição de Benders. Os autores levam em conta o critério de segurança N-1 e avaliam o impacto positivo da inclusão dos DAEs nos cenários sob contingência. Em (WANG; GENG; JIANG, 2019), o co-planejamento em DAE e transmissão é solucionado considerando conjuntos robustos via algoritmo *Column-and-Constraint Generation*. Os autores consideram variáveis binárias para modelar o status de carregamento e descarregamento dos DAEs, resultando em um problema de PLIM com uma quantidade massiva de variáveis binárias.

Em (LUBURIĆ; PANDŽIĆ; CARRIÓN, 2020), um problema de PLIM é formulado para modelar um problema de co-planejamento em DAE, *thyristor-controlled series compensators* e transmissão considerando uma rede AC linearizada. Através dos *thyristor-controlled series compensators*, a formulação permite considerar o fornecimento de reativo com os DAEs. O problema de PLIM é solucionado com decomposição de Benders.

Em (GONZALEZ-ROMERO; WOGGRIN; GOMEZ, 2019), dias representativos são utilizados para modelar o comportamento do vento enquanto os autores estudam o comportamento da relação entre agentes de geração e operadores da transmissão no problema de co-otimização entre geração, transmissão e DAEs. Em (BHATTACHARJEE; SIOSHANSI; ZAREIPOUR, 2021), os autores solucionam um problema de co-planejamento para determinar a capacidade ótima de um DAE acoplado à usina eólica e a capacidade da transmissão que a conecta à rede. A análise é realizada considerando o ponto de vista de um agente de geração, que leva em conta a perspectiva do mercado e incertezas de geração levando em conta cenários através da decomposição de Benders.

#### 1.4 OBJETIVOS DA TESE

Esta tese tem por objetivo apresentar novas contribuições ao estado da arte do problema PET no quesito de consideração de incertezas a curto prazo através de séries históricas de demanda e geração renovável. Para isto, são propostos três modelos para solucionar o PET: (i) de forma robusta baseada nos cenários; (ii) considerando restrições de confiabilidade e desperdício de energias renováveis; e (iii) considerando a alocação ótima de DAEs. Além disso, para reduzir o custo computacional dos modelos, são utilizados cenários representativos a partir do agrupamento das séries históricas consideradas. Com isto, são propostos dois algoritmos de agrupamento para obter os cenários: o m-ISODATA, utilizado para obtenção de cenários não-cronológicos; e o Algoritmo de Agrupamento de Períodos Representativos (AAPR), utilizado para obtenção de cenários cronológicos.

#### 1.5 TRABALHOS PUBLICADOS

Durante o desenvolvimento desta tese, foram publicados em periódicos internacionais os seguintes trabalhos relacionados ao tema:

- <https://doi.org/10.1007/s40313-019-00556-w>. A. N. de Paula, E. J. de Oliveira, L. W. de Oliveira e L. M. Honório, “Robust static transmission expansion planning considering contingency and wind power generation”, em *Journal of Control, Automation and Electrical Systems*, vol. 31, no. 2, pp. 461–470, 2020.

Este trabalho apresenta uma formulação baseada na decomposição de Benders para solucionar o PET de forma robusta e baseada em cenários obtidos a partir do agrupamento de séries históricas através do algoritmo de agrupamento k-means. O modelo proposto busca minimizar os custos de investimento ao mesmo tempo que penaliza o corte de vento.

- <https://doi.org/10.1007/s00202-020-01054-y>. A. N. de Paula, E. J. de Oliveira, L. W. de Oliveira e C. A. Moraes, “Reliability-Constrained Dynamic Transmission Expansion Planning Considering Wind Power Generation”, em *Electrical Engineering*, vol. 102, pp. 2583–2593, 2020.



Este trabalho propõe uma formulação em dois estágios para solucionar o D-PET restrito a confiabilidade e índices de desempenho que garantam um nível mínimo desejado de uso da energia eólica disponível. O modelo utiliza a decomposição de Benders para realizar os investimentos na rede de transmissão e a simulação Monte Carlo para avaliar o desempenho das decisões de investimento.

- <https://doi.org/10.1002/2050-7038.13005>. A. N. de Paula, E. J. de Oliveira, L. M. Honório, L. W. de Oliveira, and C. A. Moraes, “m-ISODATA: unsupervised clustering algorithm to capture representative scenarios in power systems”, em *International Transactions on Electrical Energy Systems*, 2021.

Este trabalho apresenta o algoritmo m-ISODATA para gerar cenários de demanda e geração renovável através do agrupamento de séries históricas. O algoritmo se mostrou eficaz em obter os cenários representativos da série histórica sem a necessidade do usuário definir o número de grupos, o que consiste em uma tarefa árdua para algoritmos tradicionalmente utilizados na literatura, como o k-means. O código-fonte do m-ISODATA está disponível no repositório *Code Ocean* em <https://doi.org/10.24433/CO.1264423.v1>.

## 1.6 ESTRUTURA DO TRABALHO

Esta tese de doutorado está organizada em 5 capítulos além deste capítulo.

O Capítulo 2 detalha as principais ferramentas utilizadas ao longo da tese, como a decomposição de Benders e o FPO. Além disso, é proposta uma abordagem de solução robusta do PET de modo que a decisão de investimento deve satisfazer todos os cenários de demanda e geração de energia renovável.

O Capítulo 3 apresenta uma formulação de PET restrito à confiabilidade e índices de desempenho que garantam um patamar estipulado de confiabilidade e de uso adequado de energia renovável disponível.

O Capítulo 4 detalha o algoritmo de agrupamento m-ISODATA, especializado para realizar o agrupamento de séries históricas de demanda e geração renovável para aplicações em problemas de sistemas de energia. Para avaliar o desempenho do m-ISODATA, são descritos dois modelos para teste: (i) Fluxo de Potência Ótimo Probabilístico (FPOP); e (ii) Planejamento da Expansão da Geração (PEG).

O Capítulo 5 apresenta um modelo de PET considerando a alocação ótima de DAEs. Para solucionar o modelo, são propostas duas formulações baseadas na decomposição de Benders onde: (i) o problema é decomposto de forma clássica, de modo que a avaliação dos cenários cronológicos, necessários para considerar as ações de carregamento e descarregamento dos DAEs, é realizada uma única vez por iteração; (ii) o problema é decomposto de tal forma que cada cenário pode ser avaliado simultaneamente através de técnicas de computação paralela.

Além disso, o capítulo apresenta o algoritmo AAPR, utilizado para gerar cenários cronológicos a partir do agrupamento de séries históricas de demanda e geração renovável.

O Capítulo 6 apresenta as conclusões finais da tese e propostas de trabalho futuro.

## 2 S-PET SOB INCERTEZAS E CRITÉRIO DE SEGURANÇA N-1

### 2.1 CONSIDERAÇÕES INICIAIS

Neste capítulo apresentam-se em detalhes a Decomposição de Benders (DB), o método de solução dos modelos propostos nesta tese e uma modelagem para solucionar o PET estático (S-PET) de forma robusta considerando cenários de contingência e disponibilidade de geração eólica. Por fim, é introduzido um novo método iterativo para solucionar o FPO considerando perdas na transmissão.

### 2.2 DECOMPOSIÇÃO DE BENDERS (DB)

A DB é uma técnica aplicada em problemas estruturados com variáveis complicantes, que são variáveis que tornam o problema difícil de ser solucionado, e, se fixadas, simplifica o problema ou possibilita sua decomposição em subproblemas. Comumente, em problemas de planejamentos de expansão de sistemas de energia, as variáveis complicantes são as variáveis relacionadas ao investimento de novos dispositivos. Um problema genérico com variáveis complicantes (CONEJO et al., 2006) é apresentado em (2.1)-(2.4), e será utilizado como exemplo para detalhar as formulações utilizando DB.

$$\min_{x_1, \dots, x_n; y_1, \dots, y_m} \left( \sum_{i=1}^n c_i x_i + \sum_{j=1}^m d_j y_j \right) \quad (2.1)$$

sujeito a:

$$\sum_{i=1}^n a_{li} x_i + \sum_{j=1}^m e_{lj} y_j \leq b_l; \quad l = 1, \dots, q \quad (2.2)$$


$$0 \leq x_i \leq x_i^{up}; \quad i = 1, \dots, n \quad (2.3)$$

$$0 \leq y_j \leq y_j^{up}; \quad j = 1, \dots, m, \quad (2.4)$$

onde:  $x_i$  é a  $i$ -ésima variável complicante;  $n$  é o número de variáveis complicantes;  $c_i$  é o custo associado a  $x_i$ ;  $x_i^{up}$  é o limite superior de  $x_i$ ;  $y_j$  é a  $j$ -ésima variável não-complicante;  $m$  é o número de variáveis não-complicante;  $d_j$  é o custo associado a  $y_j$ ;  $y_j^{up}$  é o limite superior de  $y_j$ ;  $a_{li}$  e  $e_{lj}$  são coeficientes associados à restrição  $l$ ;  $b_l$  é o termo independente da restrição  $l$ ;

A estrutura matricial de um problema de programação linear com variáveis complicantes está ilustrada na Figura 2, onde  $A^{[s]}$  e  $E^{[s]}$  representam regiões não-nulas da matriz de restrições, compostas respectivamente pelos elementos  $a_{li}$  e  $e_{lj}$ . Note que a estrutura apresenta um problema que pode ser decomposto em  $S$  subproblemas caso as  $n$  variáveis complicantes  $x$  sejam fixadas, uma vez que os subproblemas representados pelas matrizes  $E^{[s]}$  possuem conjuntos de variáveis  $y^{[s]}$  independentes.

Figura 2 – Estrutura matricial de um problema de programação genérico que pode ser dividido em  $S$  subproblemas com a decomposição de Benders.



Fonte: adaptado de (CONEJO et al., 2006).

Na Seção 2.2.1 apresenta-se a formulação tradicional. Na Seção 2.2.2 é detalhada a DB multicut.

### 2.2.1 DB tradicional

A DB tradicional (BENDERS, 1962) consiste em um processo iterativo que divide o problema (2.1)-(2.4) em um problema mestre e  $S$  subproblemas conforme descrito nos passos a seguir.

**Passo 1: inicialização.** Inicialize o contador de iteração,  $v = 1$ . Solucione o problema mestre inicial (com o conjunto de cortes de Benders vazio) conforme (2.5).

$$\min_{x_1, \dots, x_n; \alpha} = \sum_{i=1}^n c_i x_i + \alpha \quad (2.5)$$

sujeito a (2.3) e:

$$\alpha \geq \alpha_{down} \quad (2.6)$$

onde:  $\alpha$  é uma variável contínua; e  $\alpha_{down}$  é o limite inferior definido para  $\alpha$ , que pode ser obtido a partir de considerações físicas e econômicas relacionadas ao problema. Normalmente define-se  $\alpha_{down} = 0$  para problemas de investimento, uma vez que as variáveis de decisão de investimento são as variáveis complicantes e sempre apresentam custos não-negativos.

A solução do problema mestre inicial é trivial e retorna:  $\alpha^{(1)} = \alpha_{down}$ ;  $x_i^{(1)} = 0$ , se  $c_i \geq 0$ ; e  $x_i^{(1)} = x_i^{up}$ , se  $c_i < 0$ . Para o caso particular de expansão de sistemas de energia, em

que as variáveis complicantes são as decisões de investimento, o problema mestre inicial retorna a solução trivial de não investir, e os investimentos ocorrem conforme as restrições impostas pelos cortes de Benders, calculados no Passo 4.

**Passo 2: solução dos subproblemas.** Os  $S$  subproblemas são modelados conforme (2.7)-(2.9) e, uma vez que são independentes, podem ser solucionados de forma simultânea a partir de técnicas computacionais.

$$\min_{y^{[s]}} = \sum_{j=1}^{m^{[s]}} d_j^{[s]} y_j^{[s]} \quad (2.7)$$

sujeito a (2.8), (2.9) e:

$$x_i = x_i^{(v)} : \lambda_{i,s}^{(v)}; i = 1, \dots, n \quad (2.8)$$

$$0 \leq y_j^{[s]} \leq \bar{y}_j; j = 1, \dots, m^{[s]}, \quad (2.9)$$

onde:  $x_i^{(v)}$  é o valor de  $x_i$  obtido com a solução do problema mestre na  $v$ -ésima iteração;  $\lambda_{i,s}^{(v)}, \dots, \lambda_{n,s}^{(v)}$  são as variáveis duais associadas à restrição (2.8);  $m^{[s]}$  é o número de variáveis não-complicantes pertencentes ao subproblema  $s$ .

A solução do subproblema  $s$  retorna  $y_j^{[s](v)}, \dots, y_{m^{[s]}}^{[s](v)}$ . Estes valores são utilizados para verificar o critério de parada e para gerar os cortes de Benders.

**Passo 3: Critério de parada.** A convergência do processo iterativo da decomposição de Benders ocorre quando  $z_{up}^{(v)} - z_{down}^{(v)} < e$ , sendo:  $e$ , o *gap* aceitável; e  $z_{up}^{(v)}$  e  $z_{down}^{(v)}$  são calculados, respectivamente em (2.10) e (2.11).

$$z_{up}^{(v)} = \sum_{i=1}^n c_i x_i^{(v)} + \sum_{s=1}^S \sum_{j=1}^{m^{[s]}} d_j^{[s]} y_j^{[s](v)} \quad (2.10)$$

$$z_{down}^{(v)} = \sum_{i=1}^n c_i x_i^{(v)} + \alpha^{(v)} \quad (2.11)$$

**Passo 4: Solução do problema mestre.** Atualize o contador de iterações  $v = v + 1$  e solucione o problema mestre em (2.5), sujeito a (2.3), (2.6) e ao conjunto de cortes de Benders gerados conforme (2.12):

$$\sum_{s=1}^S \left[ \sum_{j=1}^{m^{[s]}} d_j^{[s]} y_j^{[s](k)} + \sum_{i=1}^n \lambda_{i,s}^{(k)} (x_i - x_i^{(k)}) \right] \leq \alpha; k = 1, \dots, v - 1, \quad (2.12)$$

### 2.2.2 DB multicut

O conjunto de cortes de Benders definido em (2.12) é obtido com a geração de um corte de Benders por iteração. Uma alternativa a (2.12), conhecida como DB multicut (do inglês, *multicut Benders decomposition*), pode se mostrar vantajosa em alguns casos e consiste em gerar  $S$  cortes de Benders a cada iteração (YOU; GROSSMANN, 2013). Tal alternativa pode

causar uma aceleração na convergência da DB, reduzindo o número de iterações, ao custo de aumentar o tamanho do conjunto de corte de Benders, tornando o problema mestre mais difícil de ser solucionado. Para considerar o DB multicut, basta utilizar o problema mestre definido em (2.13)-(2.15).

$$\min_{x_1, \dots, x_n; \alpha_1, \dots, \alpha_S} = \sum_{i=1}^n c_i x_i + \sum_{s=1}^S \alpha_s \quad (2.13)$$

sujeito a (2.3) e:

$$\alpha_s \geq \alpha_{down}, \quad \forall s \quad (2.14)$$

$$\sum_{j=1}^{m[s]} d_j^{[s]} y_j^{[s](k)} + \sum_{i=1}^n \lambda_{i,s}^{(k)} (x_i - x_i^{(k)}) \leq \alpha_s; \quad \forall s; k = 1, \dots, v-1 \quad (2.15)$$

A variável  $\alpha^{(v)}$ , utilizada para definir o  $z_{down}^{(v)}$  em (2.11) é calculada através de (2.16).

$$\alpha^{(v)} = \sum_{s=1}^S \alpha_s^{(v)} \quad (2.16)$$

## 2.3 FORMULAÇÃO MATEMÁTICA DO S-PET ROBUSTO

A formulação proposta para solucionar o PET considerando cenários e o critério de segurança N-1 é apresentado nesta seção. Primeiramente, é apresentada a formulação completa na Subseção 2.3.1, que consiste em um problema PNLIM de difícil solução. Para linearizar e solucionar o problema, são apresentados nas subseções 2.3.2 e 2.3.3 um algoritmo iterativo para o cálculo das perdas nas linhas de transmissão e a formulação utilizada para aplicar a DB.

### 2.3.1 Formulação completa

A formulação na forma completa para solução do S-PET é apresentada nas equações (2.17)-(2.25) e resumida em (2.26). A função objetivo (2.17) busca eliminar os cortes de carga e vento para todos os cenários de vento e contingência representados pelo conjunto  $S$ . A abordagem busca adequar a rede aos níveis de energia eólica do sistema, assim, o corte de vento causados pela deficiência na capacidade de transmissão é considerado na função objetivo.

$$\min_{\chi} \left[ \sum_{k \in K^C} C_k^T I_k^T + ch \sum_{s \in S} \left( \sum_{b \in B^D} hd_{b,s} + \sum_{b \in B^R} hr_{b,s} \right) \right] \quad (2.17)$$

sendo  $\chi = \{I^T, pg, \theta, hd, hr\}$

onde:  $C_k^T$  é o custo de investimento da linha  $k$ ;  $I_k^T$  é a variável binária de decisão em investimento na linha  $k$ ;  $K^C$  é o conjunto de linhas candidatas à expansão;  $hd_{b,s}$  é o corte de carga na barra  $b$  e cenário  $s$ ;  $ch$  é a penalidade associada aos cortes de carga e de geração renovável;  $hr_{b,s}$  é o corte

de geração renovável na barra  $b$  e cenário  $s$ ;  $B^D$  é o conjunto de barras com demanda;  $B^R$  é o conjunto de barras com geração renovável;  $S$  é o conjunto de cenários;  $I^T$ ,  $pg$ ,  $\theta$ ,  $hd$  e  $hr$  são os vetores das variáveis do problema.

A restrição de balanço de potência na barra  $b$  é modelada em (2.18) e está relacionada à primeira lei de Kirchhoff. A variável dual  $\lambda_{i,s}$  associada a (2.18) é obtida na solução do FPO considerado e será utilizada pelo método de decomposição proposto baseado na DB.

$$\sum_{g \in G_b} pg_{g,s} - \sum_{k \in K_b} f_{k,s} + hd_{b,s} - hr_{b,s} = d_{b,s} - \sum_{r \in R_b} pr_{r,s} [\lambda_{b,s}], \forall b \in B, s \in S \quad (2.18)$$

onde:  $pg_{g,s}$  é a potência gerada pelo gerador  $g$  e cenário  $s$ ;  $pr_{r,s}$  é o despacho de geração renovável no cenário  $s$  para o gerador  $g$ ;  $G_b$  e  $R_b$  são, respectivamente, os conjuntos de geradores convencionais e renováveis alocados na barra  $b$ ;  $f_{k,s}$  é o fluxo de potência que flui no circuito  $k$ , no cenário  $s$ , no sentido da barra  $b$  para a barra  $j$ , sendo  $i$  e  $j$ , respectivamente, as barras de envio e recepção da linha  $k$ ;  $K_b$  é o conjunto de barras conectadas fisicamente à barra  $k$ ;  $d_b$  é a demanda na barra  $b$ .

O fluxo de potência ativa nas linhas para cada condição  $s$  é avaliado em (2.19) e é limitado em (2.20).

$$f_{k,s} = I_k^T \left( -b_k \theta_{ij,s} + g_k \frac{(\theta_{ij,s})^2}{2} \right), \forall k \in K, s \in S \quad (2.19)$$

$$|f_{k,s}| \leq \bar{f}_k \cdot u_{k,s}, \forall k \in K, s \in S \quad (2.20)$$

onde:  $b_k$  é a susceptância série da linha  $k$ ;  $\theta_{ij,s}$  é a diferença angular dos ângulos de tensão das barras  $i$  e  $j$  no cenário  $s$ ;  $\bar{f}_k$  é a capacidade de transmissão da linha  $k$ ;  $u_{k,s}$  é a disponibilidade da linha  $k$  no cenário  $s$ ;  $g_k$  é a condutância série da linha  $k$ ; para mais detalhes acerca de  $b_k$ ,  $g_k$  e  $\theta_{ij,s}$ , ver (MONTICELLI, 1983).

A potência ativa gerada na barra  $b$  por geradores convencionais é limitada pela restrição em (2.21). O corte de carga na barra  $b$  é representada por uma unidade de geração fictícia cuja capacidade é limitada pela demanda  $d_{b,s}$  em (2.22). O corte de vento é restrito em (2.23) e é representado por uma demanda fictícia que consome o excedente de geração eólica.

$$0 \leq pg_{g,s} \leq \overline{pg}_g, \forall g \in G, s \in S \quad (2.21)$$

$$0 \leq hd_{b,s} \leq d_{b,s}, \forall b \in B^D, s \in S \quad (2.22)$$

$$0 \leq hr_{b,s} \leq \sum_{r \in R_b} pr_{r,s}, \forall r \in R, s \in S \quad (2.23)$$

onde:  $\overline{pg}_g$  é a capacidade de geração do gerador  $g$ .

A restrição (2.24) modela a variável de investimento como binária para toda linha  $k$  candidata à expansão. Ao passo que a restrição (2.25) mantém a variável fixada em 1 para todas as linhas existentes na rede base.

$$I_k^T \in \{0, 1\}, \forall k \in K^C \quad (2.24)$$

$$I_k^T = 1, \forall k \in K^E \quad (2.25)$$

onde:  $K^E$  é o conjunto de linhas existentes na rede básica.

De forma resumida, a formulação completa do S-PET é descrita pelo problema de otimização em (2.26). Assim, considerando os cenários de vento e critério de segurança N-1, o S-PET descrito consiste em um problema MINLP de grandes dimensões.

$$\min (2.17)$$

$$\text{Sujeito a:} \quad (2.26)$$

$$(2.18)-(2.25)$$

Considerando a dificuldade de solucionar tal problema como um todo, aplica-se a DB para dividir o problema em dois modelos matemáticos interconectados. E ainda, para evitar as não-linearidades impostas pela consideração das perdas nas linhas, é introduzido o FPO iterativo modificado.

### 2.3.2 FPO iterativo modificado

O FPO iterativo modificado, apresentado em (2.27), busca minimizar o corte de carga e o corte de vento na rede através do despacho dos geradores controláveis dado um cenário  $s$ . O problema de otimização é repetido a cada iteração  $v$  até que a diferença entre  $\theta_{ij,u}^{(v)}$  e  $\theta_{ij,u}^{(v-1)}$  seja pequena o suficiente para todos os pares de barras  $ij$  fisicamente conectados no sistema.

$$C_{ope}^{[s]} = \min_{\chi} \left( \sum_{b \in B^D} ch \cdot hd_{b,s} + \sum_{b \in B^R} ch \cdot hr_{b,s} \right) \quad (2.27)$$

$$\text{sendo } \chi = \{pg, \theta, hd, hr\}$$

sujeito a (2.18), (2.21)-(2.23) e:

$$L_{k,s} = g_k \cdot \theta_{ij,u}^{(v)} \cdot \theta_{ij,u}^{(v-1)}, \forall k \in K \quad (2.28)$$

$$f_{k,s} = I_k^{T*} \left( -b_k \cdot \theta_{ij,u}^{(v)} + 0.5 \cdot L_{k,s} \right), \forall k \in K \quad (2.29)$$

$$f_{k,s} \leq \bar{f}_k, \forall k \in K, s \in S \quad (2.30)$$



$$-f_{k,s} + I_k^{T*} \cdot L_{k,s} \leq \bar{f}_k, \forall k \in K, s \in S \quad (2.31)$$

onde:  $L_{k,s}$  é a perda de potência ativa na linha  $k$  e cenário  $s$ ;  $I_k^{T*}$  é a decisão de investimento na linha  $k$  previamente calculado pelo problema mestre conforme será discutido na Seção 2.3.3.

A principal vantagem do uso do FPO iterativo consiste em considerar a capacidade de transmissão das linhas de maneira adequada e evitar as não-linearidades causadas por (2.19). A perda de potência ativa na linha  $k$  é calculada pela restrição linear em (2.28), obtida pela multiplicação entre a variável  $\theta_{ij,u}^v$  e o parâmetro  $\theta_{ij,u}^{(v-1)}$ , obtido na iteração anterior. Assim, o fluxo de potência ativo na linha  $k$  é calculado em (2.29) e limitado por (2.30)-(2.31).

### 2.3.3 Formulação em dois níveis

A Decomposição de Benders (DB) (BENDERS, 1962; RAHMANIANI et al., 2017) tem sido utilizada para dividir o PET em dois problemas interconectados: o problema mestre, representando o estágio de planejamento; e um conjunto de subproblemas, correspondente ao desempenho de operação da rede sob cada cenário. Assim, a solução do PET envolve um procedimento iterativo no qual o problema mestre define um plano de expansão que é avaliado pelo conjunto de subproblemas, que por sua vez realimenta o problema mestre com restrições lineares, conhecidas como cortes de Benders. Vários trabalhos propõe melhorias na técnica de DB para o problema de PET: em (MAJIDI-QADIKOLAI; BALDICK, 2018), uma técnica de decomposição é proposta para coordenar a DB e o método de decomposição *progressive hedging* para considerar o critério N-1; em (ALIZADEH-MOUSAVI; ZIMA-BOČKARJOVA, 2016), novos cortes de Benders são propostos para reduzir o tempo computacional e melhorar a solução considerando o critério de segurança N-1; e em (LUMBRERAS; RAMOS, 2016), várias técnicas de aceleração propostas para a DB são revisadas e testadas. Este trabalho utiliza uma abordagem baseada na DB multicut que divide o problema MINLP, apresentado em (2.26), gerando um problema mestre e um conjunto de subproblemas. Porém, o problema decomposto evita as não-linearidades ao utilizar o FPO iterativo modificado descrito, permitindo que as perdas elétricas sejam consideradas.

O problema mestre é responsável por determinar as decisões de reforços que formam o plano de expansão. O problema é modelado pela função objetivo em (2.32), restrita por (2.24), (2.25) e pelo conjunto de cortes de Benders, obtidos depois de avaliado o conjunto de subproblemas. Cada subproblema otimiza o estado operativo do plano de expansão definido pelo problema mestre para um dado cenário através da solução do FPO descrito na Subseção 2.3.2.

$$C_{inv} = \min_{I^T} \sum_{k \in K^C} C_k^T I_k^T + \alpha_s \quad (2.32)$$

Com o intuito de interligar o problema mestre e o conjunto de subproblemas, gera-se um corte de Benders, através de (2.33), para cada solução de um FPO que apresente corte de vento

ou de carga. Onde  $\pi_{k,s}^T$  é um índice de sensibilidade calculado por (2.34) ou (2.35).

$$C_{ope}^{[s]} - \sum_{k \in K^C} \pi_{k,s}^T (I_k^T - I_k^{T*}) \leq \alpha_s \quad (2.33)$$

O cálculo do índice de sensibilidade varia de acordo com as características da linha  $k$  seguindo uma heurística apresentada em (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013). A princípio o índice de sensibilidade é calculado por (2.34). Porém, é calculado por (2.35) caso a linha  $k$  esteja conectando uma barra isolada do sistema. Nesta metodologia, as barras isoladas são conectadas por uma rede fictícia formada por pseudo-linhas. Por esta razão, o ângulo de tensão da barra isolada não tem relação física com o sistema elétrico e não pode ser utilizado.

$$\pi_{k,s}^T = |\theta_{i,j,s} (b_k \cdot \lambda_{i,s} - \lambda_{j,u})| \quad (2.34)$$

$$\pi_{k,s}^T = \bar{f}_k |\lambda_{i,s} - \lambda_{j,u}| \quad (2.35)$$

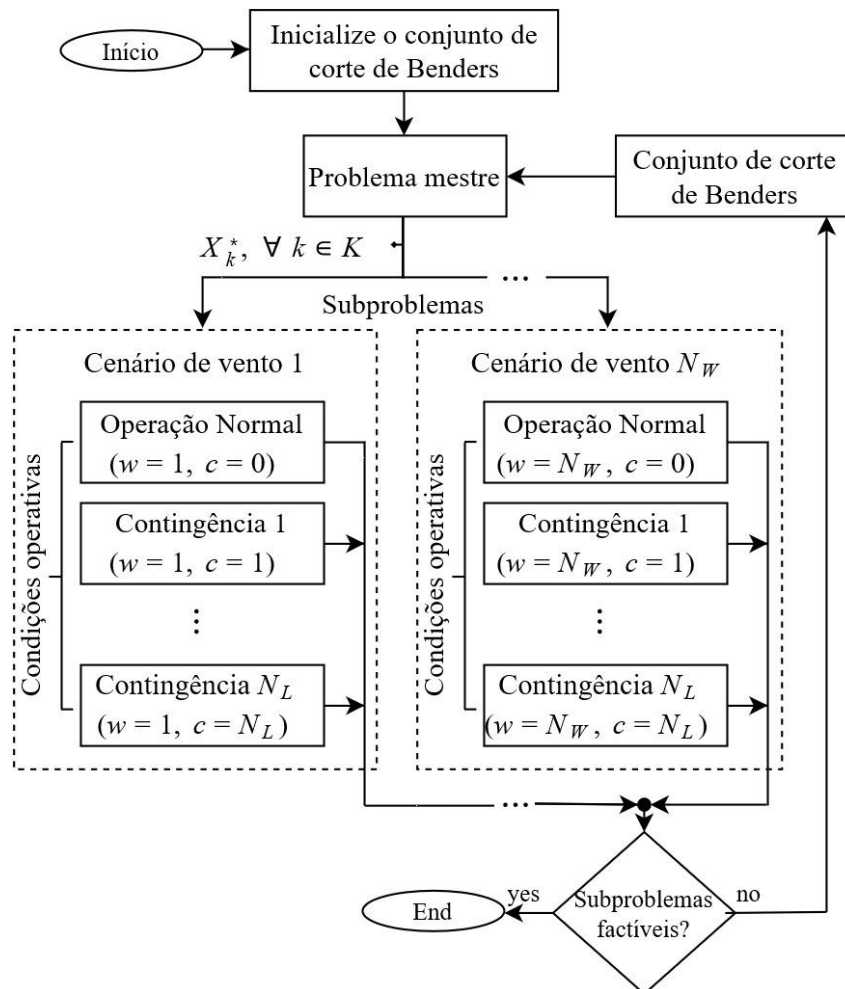
A metodologia proposta é ilustrada na Figura 3. Cada subproblema que apresenta corte de carga ou de vento resulta em um corte de Benders e é agregado ao conjunto de cortes de Benders. Este conjunto restringe o problema mestre, produzindo uma metodologia que obtém um plano de expansão robusto que não apresenta corte de carga ou renovável para nenhum cenário de vento considerado ou contingência simples.

#### 2.3.4 Geração de cenários

A formulação emprega cenários de vento obtidos de séries agrupadas de despacho eólico através do uso do algoritmo k-means conforme realizado em (ASSIS et al., 2018). O k-mean (MACQUEEN, 1967) é um método heurístico de otimização que divide um conjunto de observações em grupos de modo que cada observação pertença ao grupo cujo centroide seja o mais próximo. Desta forma, observações semelhantes são agrupadas e representadas por uma observação média do grupo, reduzindo o número de avaliações da rede necessário para observar seu comportamento frente aos diferentes cenários de vento.

Como resultado, cada grupo representa um conjunto de observações de despacho eólico que possuem características similares. O número de observações pertencentes a um grupo define a probabilidade de ocorrer um cenário eólico e a média das observações de um grupo define o despacho eólico do cenário. O uso do k-means se torna interessante quando há mais de uma série histórica simultânea, de modo a possibilitar a representação da correlação dos despachos de regiões geograficamente distintas (SILVA et al., 2012). Assim, o k-means tem a vantagem de reproduzir a correlação entre as regiões com grande diversidade em suas séries históricas de despacho através de um número baixo de cenários. Essa representação permite que a rede de transmissão obtida tenha capacidade de transferir o excedente de uma região para outra a depender das características do cenário eólico. Como desvantagem, o k-means demanda o

Figura 3 – Fluxograma da metodologia proposta.



Fonte: do autor.

número de grupos como parâmetro de entrada. Desta forma, o usuário precisa saber de antemão qual o número de cenários representa as séries históricas de forma adequada.

Uma vez que os cenários de vento gerados pelo algoritmo k-means não cobrem todas as possibilidades possíveis de vento, a solução obtida pela metodologia proposta é verificada para confirmar sua robustez. Conforme realizado em (YU; CHUNG; WONG, 2011), o método de confirmação consiste em amostrar um número considerável de pontos da série histórica original, e para cada ponto amostrado, a solução de expansão é avaliada para todas as contingências consideradas no critério de segurança N-1. A robustez é então calculada pela razão entre o número de observações que satisfazem o critério de segurança N-1 e o total de observações avaliadas.

## 2.4 RESULTADOS

Nesta seção apresentam-se os resultados da metodologia para os sistemas IEEE-RTS e sul brasileiro equivalente. Destes sistemas, derivam-se quatro: IEEE-RTS (baseado no IEEE-RTS

original (SUBCOMMITTEE, 1979)), RTS-WIND (IEEE-RTS modificado para conter usinas eólicas); BS (sistema equivalente do sul brasileiro original (MONTICELLI et al., 1982)); e BS-WIND (sistema equivalente do sul brasileiro modificado para conter usinas eólicas). Os seguintes Casos de Simulação (CSs) são desempenhados:

**CS-A:** S-PET sem cenários de contingências e sem geração eólica;

**CS-B:** S-PET com cenários de contingências, porém sem geração eólica;

**CS-C:** S-PET sem cenários de contingências, porém com geração eólica;

**CS-D:** S-PET com cenários de contingências e com geração eólica;

Todas as contingências simples das linhas existentes são consideradas nos sistemas testes. Para cada contingência é permitida uma sobre carga de até 10% nas linhas de transmissão para flexibilidade do sistema. Cada ramo com circuitos candidatos pode receber até três novas linhas de transmissão. É considerado um S-PET com horizonte de planejamento de 10 anos.

A metodologia foi implementada no ambiente de computação numérica MATLAB<sup>®</sup>. Os tempos de processamento se referem a um processador AMD Ryzen<sup>™</sup> 5 2400G com 3.6GHz. O problema mestre é solucionado pelo algoritmo *Branch-and-Bound* do pacote de otimização CPLEX 12.9.0 (Copyright<sup>©</sup> IBM Corp.) em paralelo utilizando 6 *threads*. O FPO iterativo é solucionado via método dos pontos interiores através da função *linprog* do *Optimization Toolbox* do MATLAB.

#### 2.4.1 Sistema IEEE-RTS

O sistema IEEE-RTS possui 24 barras e 34 ramos contendo linhas existentes e candidatas. O sistema recebe uma modificação amplamente utilizada na literatura que consiste em dobrar a demanda e a capacidade de geração no intuito de reduzir sua confiabilidade e aumentar a dificuldade do problema de PET. Ao final do horizonte de planejamento de 10 anos, todas as cargas e capacidades de geração ainda recebem um aumento de 50%. Uma segunda modificação deriva o sistema RTS-WIND onde são instalados usinas eólicas nas barras 1 e 15, conforme realizado em (ASSIS et al., 2018). Para o sistema RTS-WIND, são utilizados os cenários de geração eólica dados na Tabela 1. Os despachos e suas probabilidades foram obtidos aplicando-se o algoritmo k-means nas séries históricas de despacho apresentadas em (SILVA et al., 2012). Os dados dos sistemas IEEE-RTS e RTS-WIND estão disponíveis no Apêndice A.

As soluções obtidas pela metodologia proposta para o sistema IEEE-RTS são apresentadas na Tabela 2, onde são apresentados o custo total de investimento obtidos através de (2.32). A Tabela 2 mostra que o critério de segurança N-1 exige sobre-investimentos de 116,2% e 58,5% respectivamente para os sistemas IEEE-RTS e RTS-WIND. A métrica de robustez dos planos para o CS-C e CS-D são 85,9% e 99,4%, respectivamente. Uma desvantagem dos métodos

Tabela 1 – Cenários de despacho eólico utilizados para o sistema RTS-WIND.

Cenário	Despacho eólico (%)		Probabilidade (%)
	Barra 1	Barra 15	
1	5,320	6,990	24,75
2	9,680	18,88	16,44
3	13,32	33,06	11,05
4	22,32	48,89	9,160
5	51,09	74,16	8,230
6	33,06	66,47	6,670
7	65,95	88,68	6,500
8	27,82	32,61	6,410
9	41,23	52,44	6,020
10	88,05	97,82	4,720
Capacidade de Geração	1.572 MW	1.188 MW	

Fonte: do autor.

de otimização robusta baseados em cenários é a não-garantia do grau de robustez dos planos. Porém, métodos que utilizam conjuntos robustos podem levar a sobre-investimentos para garantir a factibilidade de rede em cenários com baixa probabilidade de ocorrência. Além disso, as métricas de robustez obtidas pela abordagem proposta, acima de 85%, mostram que o k-means é uma boa técnica para gerar cenários para abordagens de otimização robusta baseada em cenários.

Tabela 2 – Soluções obtidas para o sistema IEEE-RTS.

CS	Sistema	Circuitos adicionados	Custo (10 <sup>6</sup> \$)	Tempo (min)
A	IEEE-RTS	6-10, 3(7-8), 10-12, 14-16, 16-17	2,04	0,6
B	IEEE-RTS	1-5, 3-24, 4-9, 2(6-10), 2(7-8), 10-12, 12-13, 14-16, 15-24, 16-17	4,41	0,5
C	RTS-WIND	2(1-2), 2(1-5), 3-24, 5-10, 2(6-10), 2(7-8), 9-12, 10-12, 12-13, 14-16, 16-17, 20-23	4,73	2,8
D	RTS-WIND	2(1-2), 1-5, 2-4, 3-24, 2(6-10), 2(7-8), 9-11, 2(10-12), 12-13, 2(14-16), 15-21, 15-24, 16-17, 20-23	7,50	4,3

Fonte: do autor.

#### 2.4.2 Sistema BS

O sistema contém 73 linhas e 46 barras, sendo 11 inicialmente isoladas, destas, 2 contêm geradores e 9 são barras apenas de transmissão (barras de passagem). A modificação que deriva o sistema teste BS-WIND adiciona três usinas eólicas de 700 MW contendo 250 turbinas eólicas 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 cenários de despacho das eólicas com suas respectivas probabilidades são dados na Tabela 3. As capacidades de despacho foram obtidas fazendo o uso do algoritmo k-means nas mesmas séries utilizadas para o sistema IEEE-RTS. Os planos de

expansão obtidos são apresentados na Tabela 4. Os dados dos sistemas BS e BS-WIND estão disponíveis no Apêndice B.

Tabela 3 – Cenários de despacho eólico utilizados para o sistema BS-WIND.

Cenário	Despacho eólico (%)			Probabilidade (%)
	Barra 1	Barra 21	Barra 43	
1	8,230	7,840	5,630	27,23
2	25,71	11,27	12,30	14,11
3	43,82	17,71	23,94	11,06
4	19,34	32,35	11,05	9,150
5	43,33	45,27	24,80	8,470
6	64,77	27,28	41,51	8,060
7	65,55	59,08	40,28	7,400
8	84,46	73,49	59,69	5,730
9	97,69	87,78	85,52	4,620
10	86,31	40,48	68,51	4,110
Capacidade de Geração	700 MW	700 MW	700 MW	

Fonte: do autor.

Tabela 4 – Soluções obtidas para o sistema BS.

CS	Sistema	Circuitos adicionados	Custo (10 <sup>6</sup> \$)	Tempo (min)
A	BS	2(5-6), 18-20, 2(20-21), 20-23, 42-43, 46-6	0,759	0,7
B	BS	2-5, 2(5-6), 12-14, 19-21, 3(20-21), 2(20-23), 31-32, 32-43, 40-42, 40-45, 2(42-43), 46-6	1,895	47,8
C	BS-WIND	2(5-6), 18-20, 2(20-21), 20-23, 42-43, 46-6	0,759	1,5
D	BS-WIND	1-2, 2-5, 2(5-6), 12-14, 19-21, 3(20-21), 2(20-23), 24-25, 31-32, 32-43, 40-42, 40-45, 2(42-43), 46-6	2,047	667

Fonte: do autor.

No sistema BS-WIND foram adicionados 2,1 GW de usinas eólicas em barras sem demanda ou geração, sem reduzir a capacidade de geração não-renovável. Como as linhas de transmissão conectadas às barras que receberam a geração renovável apresentam capacidade de transmissão suficiente para receber a nova geração, os casos CS-A e CS-C levam ao mesmo plano de expansão, como mostra a Tabela 4. Porém, quando o critério de segurança N-1 é considerado, o caso CS-D leva a um sobre-investimento de 10% em comparação com o CS-B para acomodar a capacidade de geração renovável. A métrica de robustez dos planos de expansão em CS-C e CS-D são, respectivamente, 96,6% e 100%. Para confirmar o valor de 100%, os limites do conjunto robusto foram testados, utilizando as TOATs (*Taguchi's orthogonal array testing*) (YU; CHUNG; WONG, 2011), e o plano de expansão obtido em CS-D mostrou ser factível para qualquer saída simples de equipamentos em qualquer cenário de vento.

## 2.5 CONCLUSÕES PARCIAIS

O capítulo apresentou uma metodologia eficiente para obter um S-PET robusto, considerando restrições de segurança e incertezas de disponibilidade de vento. Para os resultados, alguns pontos podem ser enfatizados:

- A restrição de segurança e a geração eólica alocadas nas barras isoladas introduziram maiores necessidades de investimento ao S-PET;
- O FPO iterativo modificado proposto mostrou ser adequado para encontrar planos de expansão robustos.

### 3 D-PET RESTRITO POR CONFIABILIDADE

#### 3.1 CONSIDERAÇÕES INICIAIS

Este capítulo apresenta uma metodologia em dois estágios para solucionar o problema D-PET, chamada RCTNEP (do inglês *Reliability-Constrained Transmission Network Expansion Planning*), que garante níveis de confiabilidade e corte de vento durante todo o horizonte de planejamento.

A formulação do RCTNEP é dividida em dois estágios. No primeiro estágio, um S-PET é solucionado para definir o conjunto de novas linhas que precisam estar instaladas no fim do horizonte de planejamento. No segundo estágio, um procedimento a multi-estágios é desenvolvido para solucionar o D-PET com o intuito de determinar o momento em que cada linha deve ser construída. A metodologia é testada em versões modificadas dos sistemas IEEE-RTS e do sistema teste de 118 barras do IEEE (IEEE-118).

Ambos S-PET e D-PET são decompostos em dois problemas interconectados através de um esquema em dois níveis baseado na DB: decisão de investimento e avaliação de desempenho. Neste esquema, a confiabilidade é avaliada *a priori*, ou seja, durante o processo de planejamento. Os índices de confiabilidade e desempenho são obtidos através de uma Simulação Monte Carlo não-Cronológica (SMCNC) considerando: falhas aleatórias no sistema de transmissão, flutuação de carga e variabilidade do vento. Neste capítulo, um novo índice de desempenho é proposto, chamado de *Loss of Wind Probability* (LOWP), que avalia localmente a probabilidade de desperdiçar energia eólica em um determinado barramento do sistema e é utilizado para evitar que usinas eólicas sejam subutilizadas. Para ter uma avaliação global do desperdício de vento, é utilizado o índice *Expected Wind Energy Spilled* (EWES), proposto em (SILVA et al., 2012).

Com relação à confiabilidade da rede de transmissão, os índices *Loss of Load Probability* (LOLP) e *Expected Energy no Supplied* (EENS) são utilizados para a respectiva avaliação local e global e são amplamente utilizados pela literatura (LEITE DA SILVA et al., 2000). Apesar da avaliação *a priori* ser computacionalmente pesada, os resultados demonstram que o RCTNEP proposto encontra a solução avaliando um baixo número de alternativas.

Procedimentos similares foram propostos na literatura. Em (BILLINTON; WANGDEE, 2007), três opções para a expansão da transmissão são verificadas para comportar a conexão de uma nova usina eólica de grande porte. Apesar da abordagem levar em conta a confiabilidade da rede, a estratégia é heurística e não é automática. Além disso, não considera a possibilidade de corte de vento. Em (UGRANLI; KARATEPE, 2014), uma metodologia é proposta para minimizar o custo de investimento, reduzindo o corte de vento considerando cenários de variabilidade de vento e critério de segurança N-1. De forma similar, uma abordagem robusta é proposta em (MOREIRA et al., 2017) para minimizar o custo associado ao corte de vento no pior caso do critério de segurança N-1.



O RCTNEP contribui ao incluir a avaliação da confiabilidade e da incerteza de corte de vento durante o processo de planeamento, obtendo um PET que satisfaz limites impostos pelo planeador de corte de carga e vento médios de maneira estocástica. As principais contribuições deste capítulo são listadas abaixo:

- A introdução de um PET restrito por confiabilidade considerando 4 índices de desempenho, garantindo flexibilidade para as análises do planeador;
- A introdução do índice de desempenho LOWP, o qual representa a probabilidade de desperdiçar vento, utilizado para forçar a ferramenta de expansão da transmissão a conectar novas usinas eólicas à rede com mínimo desperdício de energia eólica;
- Desenvolvimento de uma abordagem em dois estágios que soluciona o D-PET em multi-estágios para definir *quando* os investimentos precisam estar efetuados e respeitar os múltiplos índices de confiabilidade e desempenho para todos os anos do horizonte de planeamento.

### 3.2 FORMULAÇÃO DO RCTNEP

O RCTNEP é formulado conforme (3.1)-(3.7) e busca garantir os níveis esperados de confiabilidade e corte de vento. A função objetivo em (3.1) minimiza o custo de investimento na transmissão. A restrição (3.2) modela a variável de investimento como binária para as linhas de transmissão candidatas à expansão, ao passo que a restrição (3.3) mantém as linhas existentes na rede base sempre instaladas. Os parâmetros  $\overline{LOLP}_b$ ,  $\overline{LOWP}_b$ ,  $\overline{EENS}$  and  $\overline{EWES}$  impõe um limite mínimo para os índices de confiabilidade e desempenho em (3.4)-(3.7).

$$C_{inv} = \min_{\chi} \sum_{k \in K} C_k^T I_k^T \quad (3.1)$$

$$\text{sendo } \chi = \{I^T, pg, \theta, hd, hr\}$$

sujeito a:

$$I_k^T \in \{0, 1\}, \forall k \in K^C \quad (3.2)$$

$$I_k^T = 1, \forall k \in K^E \quad (3.3)$$

$$LOLP_b \leq \overline{LOLP}_b, \forall b \in B^D \quad (3.4)$$

$$LOWP_b \leq \overline{LOWP}_b, \forall b \in B^R \quad (3.5)$$

$$EENS \leq \overline{EENS} \quad (3.6)$$

$$EWES \leq \overline{EWES} \quad (3.7)$$

onde:  $LOLP_b$  e  $LOWP_b$  são índices locais, que representam a LOLP e a LOWP da barra  $b$ . Ao passo que  $EENS$  e  $EWES$  são índices globais que representam a EENS e EWES do sistema como um todo. O índice LOWP é introduzido neste trabalho como complemento ao índice EWES, e é calculado como o total de tempo que ocorre o corte de vento dividido pela duração do horizonte de planejamento. Assim, o LOWP representa a probabilidade de ocorrência de corte de vento em cada barra de injeção de energia eólica do sistema. O índice EWES quantifica o montante de energia eólica que não foi entregue à rede elétrica por falta de demanda e/ou incapacidade de transferência da rede. De maneira similar, o índice LOLP quantifica a probabilidade de ocorrência de corte de carga em cada barra do sistema, complementando o índice EENS que avalia o montante de energia que não foi atendida no sistema.

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. Além disso, o RCTNEP proposto busca obter um PET que permite que todas as barras tenham uma pequena probabilidade de ocorrência de corte de carga e vento, evitando um sobre-investimento necessário para tornar a rede robusta o suficiente para não permitir cortes em situações de contingência. Deve-se enfatizar que o corte de vento não leva o sistema a um estado de falha na prática, porém, precisa ser evitado para maximizar o uso disponível de energia eólica.

Os índices são avaliados por um algoritmo de SMCNC. Esta escolha é motivada pelo fato da Simulação Monte Carlo (SMC) ser mais atrativa que métodos de enumeração de estados para sistema de grande escala (SILVA et al., 2016). Além disso, abordagens cronológicas baseadas em SMC são computacionalmente caras para serem utilizadas no PET.

Um esquema de dois níveis baseados na DB é proposto para solucionar o problema de RCTNEP definido em (3.1)-(3.7). O problema mestre é responsável por ações de investimento e o subproblema é responsável por avaliar a confiabilidade e o desempenho da rede. Se infactível, o subproblema retorna um corte de Benders para o problema mestre no intuito de obter uma nova decisão de investimento. Esse processo iterativo é repetido até que as restrições (3.4)-(3.7) sejam satisfeita. A cada iteração, a média dos cortes de Benders gerados para cada estado da rede avaliado durante a SMC é adicionada ao problema mestre (ver Seção 3.2.1). Esta estratégia é motivada pela não-linearidade imposta pelas saídas de circuito durante a avaliação dos índices.

A Figura 4 ilustra o fluxograma do esquema em dois níveis proposto. Como pode ser observado, há dois laços principais no fluxograma, o laço externo está relacionado com as iterações da DB (interconexão do problema mestre com o subproblema). Já o laço interno compreende os passos para do algoritmo de SMCNC e geração dos cortes de Benders. As explicações seguintes visam facilitar a compreensão do algoritmo apresentado na Figura 4.

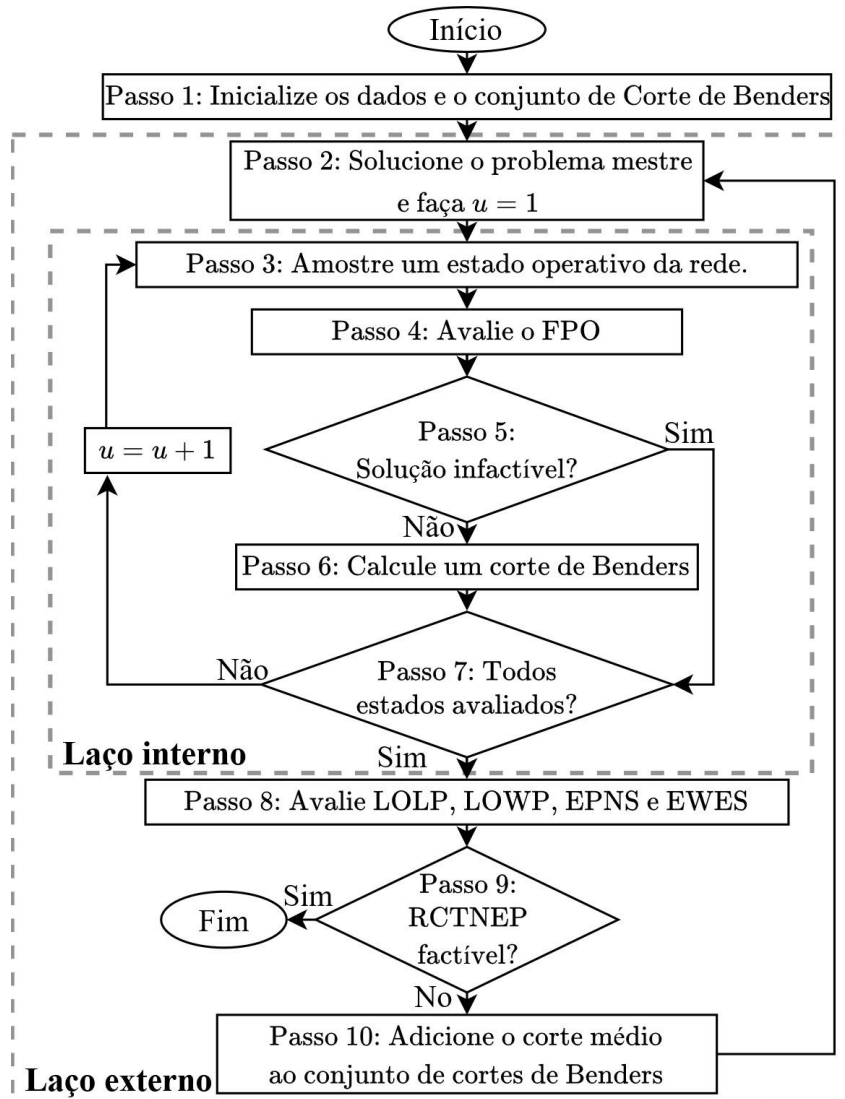
- Passo 1:** Inicialize os dados e o conjunto de corte de Benders;
- Passo 2:** Solucione o problema mestre para obter uma decisão de investimento na transmissão sujeita aos cortes de Benders como descrito na Subseção 3.2.1; inicialize o contador de estados amostrados  $s$ ;
- Passo 3:** Amostre o nível de carga, o despacho das usinas eólicas e o estado operativo das linhas de transmissão. Este passo é melhor descrito na Subseção 3.2.2;
- Passo 4:** Avalie o FPO utilizando (3.9)-(3.16), o qual é detalhado na Subseção 3.2.3;
- Passo 5:** Se não ocorrer corte de carga ou vento, vá para o Passo 7. Caso contrário, vá para o Passo 6;
- Passo 6:** Como o FPO é tido como inactível, um corte de Benders é derivado de (2.33)-(2.35), conforme detalhado na Subseção 2.3.3;
- Passo 7:** Verifique se o número definido de amostras foi alcançado. Se sim, vá para o Passo 8. Caso contrário, incremente o contador e retorne ao Passo 3;
- Passo 8:** Obtenha os índices através de (3.17)-(3.22), conforme descrito na Subseção 3.2.4;
- Passo 9:** Verifique se os índices obtidos satisfazem as restrições (3.4)-(3.7). Se sim, o investimento ótimo na transmissão foi alcançado e o esquema proposto é finalizado. Caso contrário, vá para o passo 10;
- Passo 10:** Determine a média de todos os cortes de Benders gerados no Passo 6 e adicione este plano de corte médio ao problema mestre. O corte de Benders médio é utilizado na formulação probabilística uma vez que o valor médio dos cortes de vento e carga substituem a formulação determinística (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013). Seguindo, retorne ao Passo 2.

### 3.2.1 Problema mestre (Passo 2)

Matematicamente, o problema mestre é definido como um problema de PLIM. No esquema em dois níveis proposto, a função objetivo do problema mestre é definida em (3.1). Deve-se enfatizar que o problema mestre não leva em conta o nível de confiabilidade e desempenho da rede de forma direta, estando sujeito apenas aos cortes de Benders (ver Subseção 2.3.3) e às restrições (3.2) e (3.3), que definem as variáveis binárias de decisão de investimentos e a rede base, respectivamente.

A solução do problema mestre retorna um plano de expansão, formado pelo vetor  $I^T$  que representa os reforços na transmissão. Note que  $I^T$  é uma variável apenas no problema mestre e se torna um parâmetro no subproblema, isto é, é mantido fixo no valor obtido pelo Passo 2.

Figura 4 – Fluxograma do esquema em dois níveis.



Fonte: do autor.

Na primeira iteração, o conjunto de cortes de Benders é definido como vazio pelo Passo 1 do fluxograma da Figura 4. Assim, o problema mestre retorna a solução trivial, um plano de expansão sem reforços, uma vez que o problema contém apenas as restrições (3.2) e (3.3), tornando-o irrestrito nos termos de confiabilidade e desempenho. A cada iteração, um corte de Benders é adicionado para cada cenário infactível, aumentando o custo de investimento ( $C_{inv}$ ) até que os critérios de desempenho sejam satisfeitos.

Os dados necessários para o modelo proposto incluem i) carga; ii) geração; iii) rede de transmissão. Estes dados estão disponíveis em (DE PAULA, 2020).

### 3.2.2 Definição do estado operativo do sistema (Passo 3)

O plano de expansão definido pela solução do problema mestre é avaliado pela SMCNC, a qual consiste em realizar repetidas amostragens aleatórias para obter os índices de desempenho através da média de funções testes. Um estado operativo do sistema (cenário  $s$ ) é definido por três condições:

**Condição 1:** Estados operativos das linhas de transmissão;

**Condição 2:** Nível de demanda;

**Condição 3:** Despacho dos geradores não-controláveis (geradores eólicos).

O estado operativo de uma linha de transmissão é amostrado através de um gerador de números aleatórios com distribuição uniforme. O número aleatório é comparado com a taxa de saída forçada (FOR, do inglês, *Forced Outage Rate*) da linha  $k$  ( $FOR_k$ ). Assim, para um cenário  $s$ , a saída da linha  $k$ , representada pela variável  $u_{k,s}$  ocorre quando o número amostrado for menor que  $FOR_k$ . Logo, dois estados operativos são possíveis para cada linha de transmissão, conforme (3.8).

$$u_{k,s} = \begin{cases} 0, & \text{se a linha está fora de operação;} \\ 1, & \text{se a linha está operando.} \end{cases} \quad (3.8)$$

Os dados de carga são obtidos na literatura para definir o nível de carga em resolução horária para o horizonte de planejamento, consistindo em curvas de carga anuais. A disponibilidade dos geradores eólicos, os quais permitem representar o comportamento intermitente do vento e reproduzir a correlação do despacho de usinas entre regiões geograficamente distintas (SILVA et al., 2012). Neste trabalho, os despachos horários dos geradores não-controláveis são dados em função de suas respectivas capacidades instaladas.

### 3.2.3 Formulação do FPO (Passo 4)

Cada estado operativo amostrado do sistema é avaliado pelo FPO, formulado em (3.9)-(3.16). O FPO, modelado como um problema PL que despacha os geradores controláveis com o intuito de minimizar os cortes de carga e vento. Os custos operacionais (por exemplo, custos de combustíveis e perdas na transmissão) não são considerados no objetivo do FPO uma vez que a consideração dos mesmos precisam ser realizadas sob outras questões de mercados desregulados, como discutido em (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013).

$$C_{ope}^{[s]} = \min_{\chi} \left( \sum_{b \in B^D} cdh \cdot hd_{b,s} + \sum_{b \in B^R} crh \cdot hr_{b,s} \right) \quad (3.9)$$

sendo  $\chi = \{pg, \theta, hd, hr\}$

subject to:

$$\sum_{g \in G_b} pg_{g,s} - \sum_{k \in K_b} f_{k,s} + hd_{b,s} - hr_{b,s} = d_{b,s} - \sum_{r \in R_b} pr_{r,s} [\lambda_{b,s}], \forall b \in B \quad (3.10)$$

$$f_{k,s} = u_{k,s} (-b_k \theta_{i,j,s}), \forall k \in K^E \quad (3.11)$$

$$f_{k,s} = I_k^{T*} (-b_k \theta_{i,j,s}), \forall k \in K^C \quad (3.12)$$

$$|f_{k,s}| \leq \bar{f}_k, \forall k \in K \quad (3.13)$$

$$0 \leq pg_{g,s} \leq \overline{pg}_g, \forall g \in G, s \in S \quad (3.14)$$

$$0 \leq hd_{b,s} \leq d_{b,s}, \forall b \in B^D \quad (3.15)$$

$$0 \leq hr_{b,s} \leq \sum_{r \in R_b} pr_{r,s}, \forall r \in R \quad (3.16)$$

onde:  $cdh$  e  $crh$  são, respectivamente, os custos de corte de carga e de vento.

A função objetivo em (3.9) busca minimizar o corte de carga e vento para o estado amostrado  $s$ . Deve-se notar que um valor não-nulo de  $C_{ope}^{[s]}$  significa que o estado operativo é infactível, ao passo que  $C_{ope}^{[s]} = 0$  implica em um estado factível. Assim, o corte do vento é tratado como infactibilidade para maximizar o uso da energia eólica, como considerado em (YU; CHUNG; WONG, 2011), porém, na prática o corte de vento não leva o sistema a um estado de falha. A restrição de balanço de potência ativa na barra  $b$  é descrita em (3.10) e está relacionada à primeira lei de Kirchhoff, nesta, tanto o nível de carga quanto o despacho de geração eólica são amostrados de forma aleatória através de séries históricas anuais com resolução horária. A variável dual  $\lambda_{i,s}$  é obtida na solução do FPO. O fluxo ativo na linha  $k$ , existente na rede base, é calculado em (3.11), o qual depende do estado operativo da mesma ( $u_{k,s}$ ). Já o fluxo ativo na linha  $k$ , candidata a expansão, é avaliado em (3.12) e depende da decisão de investimento corrente ( $I_k^{T*}$ ). Deve-se ficar claro que as linhas candidatas não estão sujeitas a falhas, isto é adotado para maximizar o benefício das novas linhas nos índices de confiabilidade e desempenho. A restrição (3.13) limita o fluxo de potência ativo na linha  $k$ . As potências ativas dos geradores convencionais da barra  $b$  são limitadas em (3.14). Em (3.15), o corte de carga na barra  $b$  é limitado pela demanda ativa  $d_{b,s}$ . De forma similar, o corte de vento é limitado pelo despacho eólico amostrado em (3.16).

### 3.2.4 Avaliação da confiabilidade e de desempenho (Passo 7)

Os índices são calculados através de funções teste específicas. Assim, LOLP e LOWP da barra  $b$  são calculados por (3.17)-(3.20) e são obtidos pela média dos estados amostrados que causam corte de carga e vento.

$$LOLP_b = \frac{1}{NS} \sum_{s=1}^{NS} F_{b,s}^{LOLP} \quad (3.17)$$

$$F_{b,s}^{LOLP} = \begin{cases} 1, & \text{se há corte de carga;} \\ 0, & \text{caso contrário.} \end{cases} \quad (3.18)$$

$$LOWP_b = \frac{1}{NS} \sum_{s=1}^{NS} F_{b,s}^{LOWP} \quad (3.19)$$

$$F_{b,s}^{LOWP} = \begin{cases} 1, & \text{se há corte de vento;} \\ 0, & \text{caso contrário.} \end{cases} \quad (3.20)$$

onde:  $NS$  é o número de estados amostrados pela SMCNC;  $F_{b,s}^{LOLP}$  e  $F_{b,s}^{LOWP}$  são as funções testes avaliadas para o estado amostrado  $s$  na barra  $b$ .

Os índices EENS e EWES são calculados, respectivamente, em (3.21) e (3.22). Estes índices são dados em  $MWh/year$  uma vez que são obtidos pela potência esperada, dada em  $MW$ , multiplicada pela duração de 1 ano em horas, isto é,  $8760 h/year$ .

$$EENS = \frac{8760}{NS} \sum_{s=1}^{NS} \sum_{b \in B} hd_{b,s} \quad (3.21)$$

$$EWES = \frac{8760}{NS} \sum_{s=1}^{NS} \sum_{b \in B} hr_{b,s} \quad (3.22)$$

## 3.3 ABORDAGEM EM DOIS ESTÁGIOS

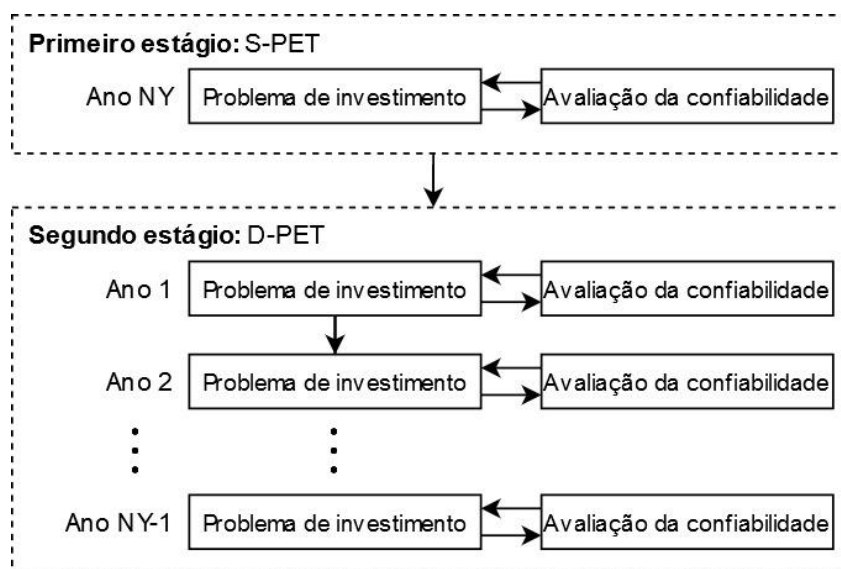
A abordagem em dois estágios torna o RCTNEP capaz de obter um plano de expansão que garante um nível adequado de confiabilidade e desempenho ao longo de todo o horizonte de planejamento. Assim, o esquema em dois níveis proposto em 3.2 é estendido conforme ilustrado na Figura 5, onde “NY” é o número de anos no horizonte de planejamento.

O primeiro estágio avalia o RCTNEP num ponto de vista estático (S-PET) para os valores previsto de capacidade de geração e demanda ao final do horizonte de planejamento. Desta forma, o S-PET com mínimo custo é obtido, porém, sem a informação de “quando” os reforços deverão estar instalados. Como consequência, os reforços obtidos no primeiro estágio são definidos como linhas candidatas para o planejamento do segundo estágio. Para definir o melhor momento para instalar as linhas, o segundo estágio realiza uma sequência de RCTNEPs para cada ano do planejamento, do primeiro para o penúltimo, conforme Figura 5.

Para acoplar os planos, uma linha candidata selecionada para estar instalada em um dado ano é mantida instalada para todos os anos subsequentes. Além disso, os reforços selecionados para um dado ano  $y$  são removidos da lista de candidatas para os anos subsequentes ( $y + 1$  to  $NY$ ). A solução em dois estágios determina a solução do D-PET, garantindo uma visão holística do horizonte de planejamento.

O primeiro estágio pode ser visto como uma abordagem de redução de espaço de busca e uma estratégia utilizada para assegurar encontrar o plano mais econômico ao final do horizonte de planejamento. O S-PET minimiza o custo de investimento garantindo as restrições de confiabilidade para a pior condição de operação da transmissão (maior geração e carga). Assim, o espaço de busca reduzido é suficiente para encontrar planos de expansão para cada ano do problema.

Figura 5 – Abordagem a dois estágios.



Fonte: do autor.

### 3.4 RESULTADOS

Nesta seção apresentam-se os resultados da metodologia proposta aplicada a versões modificadas dos sistemas RTS-WIND e IEEE-118. As seguintes considerações foram adotadas para padronizar as análises:

- Os limites superiores definidos são 5% para LOLP e LOWP; 1% da carga pico para a EENS; e 1% da capacidade total instalada de geração eólica para a EWES;
- A série histórica anual de carga normalizada apresentada em (SUBCOMMITTEE, 1979) é utilizada para modelar as cargas de cada barra;
- As séries históricas anuais de despacho eólico do “Cenário 1” apresentado em (SILVA et al., 2012), são utilizadas para representar a natureza intermitente do vento;



- Sob cada contingência, uma sobrecarga de 10% em cada linha é permitida para trazer flexibilidade para a operação, como em (OLIVEIRA et al., 2018);
- Cada ramo candidato à expansão do sistema pode receber um máximo de três reforços;
- Um planejamento de expansão a longo prazo de 10 anos é considerado; ao fim do horizonte de planejamento, todas as demandas e capacidades de geração aumentam 50% em relação ao ano base, o que consiste em uma taxa de aumento de 4,14% ao ano, como considerado em (AKBARI; RAHIMIKIAN; KAZEMI, 2011);
- O parâmetro relacionado ao número de amostras,  $NS$ , é ajustado para 10000 amostras, como em (ROLDÁN et al., 2019);
- Cada SMCNC é executada com a mesma semente do gerador aleatório, conforme realizado em (SILVA et al., 2012).

A metodologia foi implementada no ambiente de computação numérica MATLAB<sup>®</sup>. Os tempos de processamento se referem a um processador AMD Ryzen<sup>™</sup> 5 2400G com 3.6GHz. O problema mestre é solucionado pelo algoritmo *Branch-and-Bound* do pacote de otimização CPLEX 12.9.0 (Copyright<sup>©</sup> IBM Corp.). O FPO é solucionado via método dos pontos interiores através da função *linprog* do *Optimization Toolbox* do MATLAB<sup>®</sup>.

#### 3.4.1 Sistema RTS-WIND

O sistema RTS-WIND de 24 barras, descrito na Subseção 2.4.1, possui 34 ramos candidatos à expansão. Os custos de investimentos foram obtidos de (FANG; HILL, 2003). Assim, ao final do horizonte de planejamento, o sistema modificado apresenta: 9294 MW de capacidade de geração térmica; 2760 MW de capacidade eólica; e 8500 MW de carga pico. A FOR de todas as linhas de transmissão é ajustada para 1%, como em (ORFANOS; GEORGILAKIS; HATZIARGYRIOU, 2013).

O S-PET obtido para o RTS-WIND apresenta um custo de investimento de \$1.62 milhões. O plano de expansão encontrado consiste nos seguintes investimentos: um reforço nos ramos 1-5, 2-4, 3-2 e 6-10; dois no ramo 7-8; e três no ramo 1-2. A lista de linhas selecionadas no S-PET é utilizada como o conjunto de linhas candidatas à expansão no D-PET, cuja solução é apresentada na Tabela 5. Para o ano 1, há 6452 MW de capacidade de geração térmica, 1916 MW de capacidade eólica instalada e 5936 MW de carga pico. Para esta condição, a abordagem proposta define o plano de expansão formado por três linhas no ramo 1-2, como pode ser observado na Tabela 5. Para o segundo ano, onde os valores de capacidade de geração térmica e eólica, bem como a demanda, são acrescidos em 4,14%, é definido um plano de expansão formado por uma linha no ramo 1-5. Os planos de expansão para os seguintes anos são exibidos na Tabela 5. Pode-se observar que nos anos 4, 5, 7 e 9, nenhum reforço é definido.

Tabela 5 – Solução do D-PET para o sistema RTS-WIND.

Ano	Linhas	Ano	Linhas
1	3(1-2)	6	7-8
2	1-5	7	-
3	6-10	8	2-4, 7-8
4	-	9	-
5	-	10	3-24

Fonte: do autor.

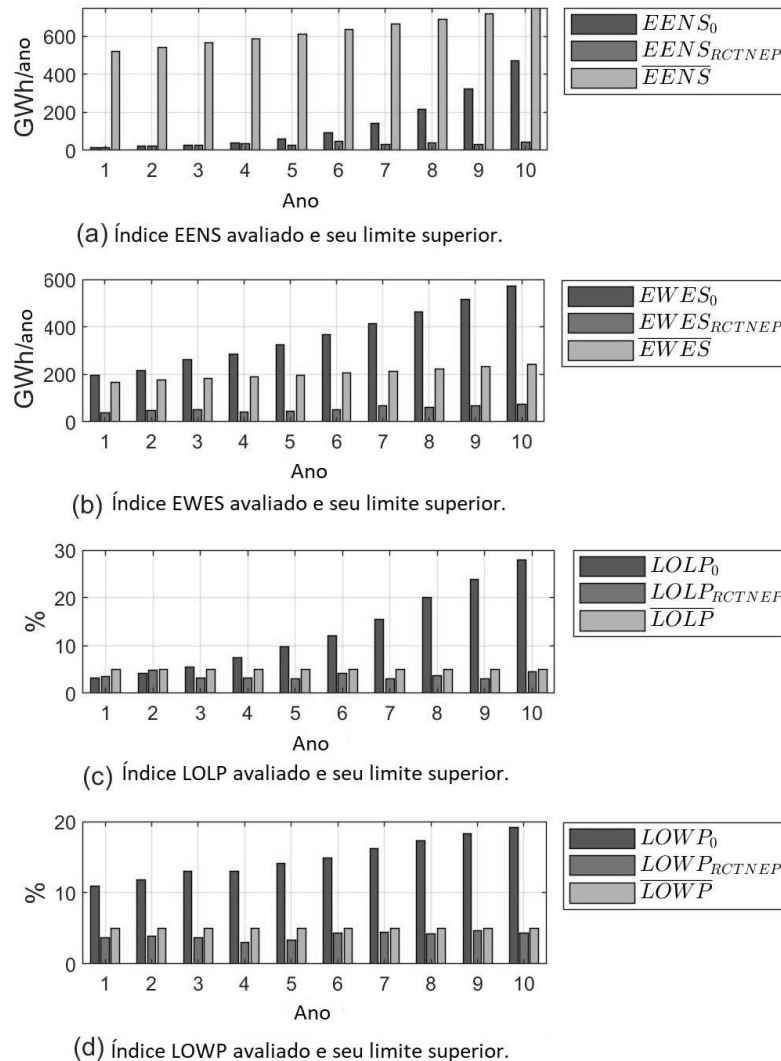
Quanto ao esforço computacional, o RCTNEP levou 1,9 horas para solucionar o primeiro estágio e 46 minutos para solucionar o segundo. O tempo para solução do problema no segundo estágio é menor devido à redução do espaço de busca.

Os índices avaliados ao longo do horizonte de planejamento são apresentados na Figura 6, onde apenas o maior valor de LOLP e LOWP obtido nos nós são apresentados para representar os índices do sistema. Para justificar o plano de expansão, a Figura 6 ainda apresenta: os valores dos índices obtidos para o sistema sem investimentos, representados pelos índices com o subscrito “0”; e os limites superiores definidos para cada índice, descritos na Seção 3.4. Pode-se observar que nem os índices de confiabilidade ou os índices associados ao corte de vento do cenário sem investimento satisfazem os limites de desempenho estabelecidos. Além disso, como esperado, os índices pioram com o aumento da demanda e da capacidade de geração, uma vez que o sistema de transmissão vai sendo sobrecarregado ao longo do horizonte de planejamento. Quando a solução do D-PET é considerada, pode-se verificar que os níveis de desempenho desejados são alcançados para todos os anos. Na Figura 6, os índices obtidos pela solução do D-PET estão representados pelo subscrito “*RCTNEP*”.

Com o intuito de verificar o impacto da FOR, na Figura 7 apresenta-se o comportamento do RCTNEP em termos do custo de investimento. Pode-se observar que o custo de investimento aumenta com o acréscimo da FOR. Na Figura 7 apresenta-se o custo de investimento relacionado com a FOR nula, representando a hipótese de o sistema ser imune às falhas. Com isto, obtém-se o investimento necessário apenas para satisfazer o aumento de carga e capacidade de geração e as incertezas a curto prazo de nível de carga e despacho eólico.

Para verificar o impacto da injeção de renováveis no RCTNEP, a capacidade da geração eólica foi alterada de zero para 140% do valor nominal (100%). Os custos de investimento obtido para estes cenários estão apresentado na Figura 8. Pode-se observar que o custo de investimento, sem geração eólica, é de \$1.39 milhões. Com o acréscimo de até 60% na capacidade de geração eólica, o custo de investimento decresce até alcançar um valor mínimo de \$1.04 milhões. Este ponto indica o valor ótimo de capacidade eólica para a topologia de rede e séries eólicas consideradas. Porém, como o aumento desta capacidade acima de 60%, há um aumento considerável nos custos de investimento. Isto ocorre devido às restrições de corte de vento, o que implica que o sistema precisa de investimento em transmissão para acomodar a quantidade de penetração de renovável.

Figura 6 – Índices do sistema com e sem investimentos (ver tabela 5) e limites estabelecidos.




Fonte: do autor.


### 3.4.2 Sistema IEEE-118

O segundo estudo de caso é realizado no sistema IEEE-118 modificado. O sistema é composto por 40 geradores convencionais, 40 usinas eólicas, 91 pontos de demanda, e 179 ramos com linhas candidatas à expansão. Os dados utilizados foram adaptados de (ROLDÁN et al., 2019) e estão disponíveis no Apêndice C. No final do horizonte de planejamento o sistema apresenta um total de 18,05 MW de capacidade de geração convencional, 7,74 MW de capacidade de geração eólica e 15,73 de demanda nos momentos de carga pico.

O S-PET obtido para o sistema IEEE-118 tem um custo de investimento de €3.43 milhões. O plano de expansão define os investimentos de: um reforço nos ramos 5-6, 8-5, 17-18 e 8-30; e dois no ramo 19-34. A lista de linhas selecionadas no S-PET é utilizada no segundo estágio do RCTNEP que retorna o D-PET apresentado na Tabela 6. Para o IEEE-118, levou-se 6 horas para solucionar o primeiro estágio e 1 hora para o segundo. Aproximadamente 2,7 vezes

Figura 7 – Custos de investimento *versus* FOR.

Fonte: do autor.

Figura 8 – Custos de investimento do RCTNEP *versus* capacidade de geração das usinas eólicas.

Fonte: do autor.

Tabela 6 – Solução do D-PET para o sistema IEEE-118.

Ano	Linhas	Ano	Linhas
1	8-30	6	-
2	-	7	17-18
3	8-5	8	19-34
4	-	9	-
5	5-6	10	19-34

Fonte: do autor.

mais que o gasto na simulação do sistema RTS-WIND.

### 3.4.3 Impacto da energia renovável

Os valores dos índices de confiabilidade e de corte de vento obtidos na primeira e última iteração das simulações do S-PET são apresentadas na Tabela 7. Estes índices indicam a contribuição das linhas adicionadas no processo de otimização. Os índices EENS e EWES são apresentados em valores percentuais do pico de carga e da capacidade eólica por ano,

Tabela 7 – Índices da primeira e última iteração.

Índice (%)	RTS-WIND		IEEE-118		Limite (%)
	1ª iteração	Última iteração	1ª iteração	Última iteração	
LOLP	20,86	4,82	46,12	4,66	5
EENS	0,64	0,11	1,60	0,11	1
LOWP	21,47	4,43	2,32	2,05	5
EWES	2,70	0,33	0,08	0,08	1

Fonte: do autor.

respectivamente.

Pela Tabela 7, a primeira iteração da simulação no RTS-WIND, indica que há uma necessidade de melhorar os índices LOLP, LOWP e EWES no final do horizonte de planejamento. Já a última iteração indica que os índices locais LOLP e LOWP foram decisivos para definir o plano de expansão, uma vez que são ligeiramente menores do que os limites superiores definidos. Para a simulação com o sistema IEEE-118, pode-se observar que os índices LOWP e EWES, relacionados ao corte de vento, não contribuem para a primeira iteração. Na última iteração, o índice LOLP é decisivo para definição do plano.

O sistema RTS-WIND tem uma capacidade instalada de geração eólica de 32,5% em relação à carga pico, enquanto a capacidade do IEEE-118 é de 49%, sendo relativamente maior que a do RTS-WIND. Porém, o que se observa é que há um valor esperado de corte de vento muito maior no RTS-WIND, devido ao fato da geração eólica estar distribuída em 26 barras no sistema IEEE-118, enquanto no RTS-WIND, há somente 2 usinas eólicas de grande porte. Deve-se enfatizar que, no sistema IEEE-118, todas as usinas eólicas foram posicionadas em barras sem demanda, forçando a ocorrência de corte de vento.

### 3.5 CONCLUSÕES PARCIAIS

Este capítulo apresentou uma metodologia em dois estágios para solucionar o PET restrito a índices de confiabilidade e desempenho (RCTNEP, do inglês, *Reliability-Constrained Transmission Network Expansion Problem*). Quanto aos resultados, alguns pontos podem ser enfatizados:

- Geradores eólicos bem distribuídos pelo sistema podem reduzir os custos de investimento na transmissão;
- As restrições de desempenho são capazes de garantir o nível de robustez da energia eólica, evitando o desperdício da energia renovável disponível com baixo custo de operação;
- A abordagem proposta é adequada para solucionar o PET dinâmico (D-PET), satisfazendo as restrições impostas em todos os anos do horizonte de planejamento;
- O índice LOWP mostrou-se eficiente para complementar o índice EWES de forma local.

## 4 ALGORITMO m-ISODATA: GERAÇÃO DE CENÁRIOS REPRESENTATIVOS NÃO-CRONOLÓGICOS

### 4.1 CONSIDERAÇÕES INICIAIS

Uma forma de representar o comportamento intermitente de fontes renováveis nas análises numéricas é através de séries históricas de operação, porém, tais séries, normalmente em resolução horária, podem demandar um alto custo computacional. Desta forma, o uso de algoritmos de agrupamento para gerar cenários representativos a partir de séries históricas mostra-se como alternativa para reduzir o custo computacional, agrupando períodos de tempo com características comuns que em contrapartida introduzem algum erro aceitável aos resultados do problema.

Na literatura, os algoritmos k-means e *Hierarchical Agglomerative Clustering* (HAC) têm sido amplamente aplicados para gerar cenários representativos em abordagens probabilísticas. No entanto, esses algoritmos requerem o número de grupos como parâmetro de entrada, o que é difícil de ser definido, como foi intensamente discutido em (MERRICK, 2016). Merrick (MERRICK, 2016) realizou uma análise para encontrar o número de cenários necessários para representar as fontes de variabilidade no problema de Planejamento da Expansão da Geração (PEG), aplicando o HAC a séries históricas relacionadas a três fontes de variabilidade: despacho de energia fotovoltaica e eólica, e demanda. Os resultados apontaram que o número de cenários aumenta com o número de fontes de variabilidade. Porém, o trabalho não responde à questão sobre como obter o número de cenários que seja adequado para representar o comportamento das séries históricas, uma vez que o HAC aplicado não pode detectá-lo automaticamente. Visando contornar esse inconveniente, o presente capítulo apresenta o algoritmo m-ISODATA que extrai o número adequado de cenários de séries históricas.

O m-ISODATA é baseado no algoritmo ISODATA (BALL; HALL, 1965), que consiste em uma técnica de agrupamento que altera o número de grupos dinamicamente durante seu processo iterativo. No entanto, quando aplicado a séries históricas, o ISODATA não consegue encontrar automaticamente o número de cenários, pois requer um número desejado de grupos, que também é difícil de estimar. Em contrapartida, o m-ISODATA é uma versão aprimorada capaz de identificar os cenários (e o número de cenários) a partir de séries históricas de operação de sistemas de potência. Com os estudos discutidos neste trabalho, foram definidos parâmetros *default* para o m-ISODATA que apresentam boa precisão nas aplicações testadas.

Muitos esforços têm sido feitos na literatura para melhorar a qualidade dos algoritmos de agrupamento (MITTAL et al., 2019; RUI XU; WUNSCH, 2005), entretanto, a maioria deles são propostos para aprimorar o agrupamento de dados de imagens aplicado a matrizes bidimensionais. Além de avanços sofisticados, a necessidade de um algoritmo aprimorado específico para agrupar séries históricas para definir cenários justifica a introdução do m-ISODATA. Para obter os cenários sem o número de cenários como parâmetro de entrada, o algoritmo ISODATA tradicional

é o que parece ser mais adequado devido aos seus dois procedimentos: divisão e fusão. No ISODATA tradicional, um grupo é dividido quando seu desvio padrão está acima de um limite pré-especificado; por outro lado, dois grupos são mesclados quando a distância entre seus centroides está abaixo de outro limite. Além disso, o número de grupos não é um parâmetro de entrada no ISODATA, mas um número estimado de grupos é necessário como parâmetro. Em outras palavras, o ISODATA tradicional busca encontrar o número de grupos em um conjunto de dados com base em um número de grupos previamente estipulado. Neste trabalho propõem-se modificações e melhorias no algoritmo ISODATA tradicional para possibilitar a obtenção de cenários a partir de séries históricas sem a informação de quantos grupos as representam.

De forma resumida, o m-ISODATA apresenta as seguintes vantagens

- é capaz de encontrar o número adequado de cenários para representar séries históricas e com diferentes fontes de variabilidade;
- não depende do número de séries históricas (dimensão do conjunto de dados) para determinar os cenários representativos;
- não possui parâmetros obrigatórios a serem definidos pelos usuários e possui apenas um parâmetro opcional para melhorar ou reduzir a representatividade dos cenários;
- é uma abordagem baseada em dados, independente do modelo, permitindo sua utilização em uma alta gama de aplicações.

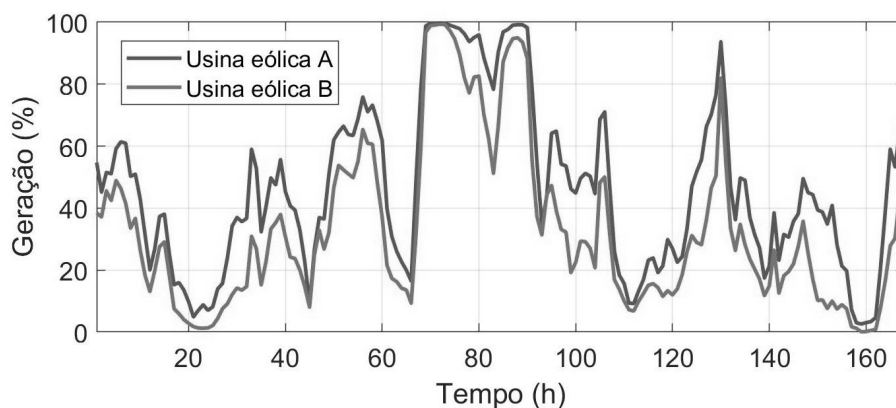
Estudos são realizados para avaliar as vantagens do m-ISODATA sobre os algoritmos SMC, k-means e HAC. Além disso, dois estudos de caso são realizados: (i) Planejamento da Expansão da Geração (PEG); e (ii) Fluxo de Potência Ótimo Probabilístico (FPOP). Por fim, o código-fonte do m-ISODATA está disponível no repositório *Code Ocean* (DE PAULA et al., 2020), onde os melhores parâmetros obtidos nos estudos apresentados são configurados como valores *default* para facilitar sua aplicação em outros problemas. As principais contribuições apresentadas neste capítulo são:

- Desenvolvimento de um algoritmo que extraia os cenários de séries históricas sem o número de cenários como parâmetro de entrada;
- Uma formulação aprimorada que prevê as melhores localizações dos centroides dos novos grupos na função *split*;
- Proposta de um fator de correção dimensional para tornar o m-ISODATA capaz de agrupar diferentes números de séries históricas sem a necessidade de modificação dos parâmetros do algoritmo;
- Apresentação da análise de sensibilidade relacionada aos parâmetros m-ISODATA para facilitar ajustes pelo usuário.

## 4.2 CENÁRIOS REPRESENTATIVOS NÃO-CRONOLÓGICOS

Com o objetivo de apresentar os conceitos básicos acerca da obtenção de cenários representativos a partir do agrupamento de séries históricas, nesta seção discute-se um espaço bidimensional relacionado aos dados de geração de dois parques eólicos correlacionados. A variabilidade da geração eólica é obtida a partir de medições horárias dos parques eólicos, apresentada em porcentagem das respectivas capacidades, conforme mostrado na Figura 9. O conjunto de dados completo contém 8.760 pontos de dados bidimensionais, cobrindo, portanto, 8.760 horas de operação de cada parque eólico. Essas séries históricas podem ser representadas em um gráfico de dispersão bidimensional, conforme ilustrado na Figura 10(a), o que facilita a compreensão do processo de agrupamento dos dados para capturar os cenários por meio do m-ISODATA.

Figura 9 – Primeira semana operativa das séries históricas de despacho de energia eólica.




Fonte: do autor.

A dependência estatística entre as séries é comum em curvas de geração eólica, solar e de demanda e, portanto, deve ser representada nos modelos de sistemas de potência (BARINGO; CONEJO, 2013). Além de representar a variabilidade de curto prazo, os cenários obtidos por algoritmos de agrupamento são capazes de reproduzir a correlação entre séries históricas (SILVA et al., 2012). Na Figura 9, pode-se observar que as séries possuem uma forte correlação que se confirma na concentração de dados em torno da diagonal gráfico de dispersão da Figura 10(a), seguindo a linha tracejada. Em grande parte dos dados, o parque eólico A tem geração ligeiramente maior do que o parque eólico B, resultando na curvatura da linha tracejada.

Também verifica-se na Figura 10(a) que os pontos não cobrem todo o espaço de observação possível, por exemplo, não há um estado operativo onde o parque eólico A tem alta geração enquanto o parque eólico B tem sua geração em nível baixo. Este comportamento é melhor ilustrado na Figura 10(b), onde as bordas amarelas cobrem os pontos das séries e as cores avermelhadas indicam as regiões com maior densidade de dados. Como os dados estão concentrados em uma determinada região, torna-se difícil definir uma quantidade de cenários representativos que cubram esse espaço reduzido. Além disso, é razoável concluir que tal



Figura 10 – Pontos de duas séries históricas correlacionadas de despacho de energia eólica: (a) gráfico de dispersão; (b) gráfico de densidade.



Fonte: do autor.

difficuldade aumenta com o aumento número de séries, ou seja, com a dimensão do conjunto de dados, uma vez que o hiper-espaço coberto pelos dados passa a ser mais abstratos.


Pontos semelhantes do conjunto de dados das séries históricas podem ser agrupados em cenários para reduzir a carga computacional dos métodos de solução. Desta forma, cada cenário consiste em um grupo de dados representado por seu centroide. Para ilustrar este agrupamento, dois grupos e seus respectivos centroides são representados na Figura 11 pelos marcadores “+” e “x”, respectivamente para os grupos 1 e 2. Do grupo 1, pode ser destacado:

1.  $d_{min}$ , parâmetro que define a mínima distância entre os centroides, representado pelo círculo sólido de cor lilás;
2.  $\sigma_{max}$ , parâmetro que define o desvio padrão máximo de cada cenário, representado pelo círculo sólido de cor laranja;
3.  $\sigma_1$ , o desvio padrão calculado para o grupo 1, representado pelo círculo tracejado de cor verde.

#### 4.3 FORMULAÇÃO DO m-ISODATA

O algoritmo m-ISODATA proposto é baseado em duas funções principais: *split* e *merge*. Os principais passos do algoritmo são apresentados no fluxograma da Figura 12 e detalhados nas subseções a seguir.

Figura 11 – Dois conjuntos de dados agrupados como cenários representativos de geração eólica.



Fonte: do autor.

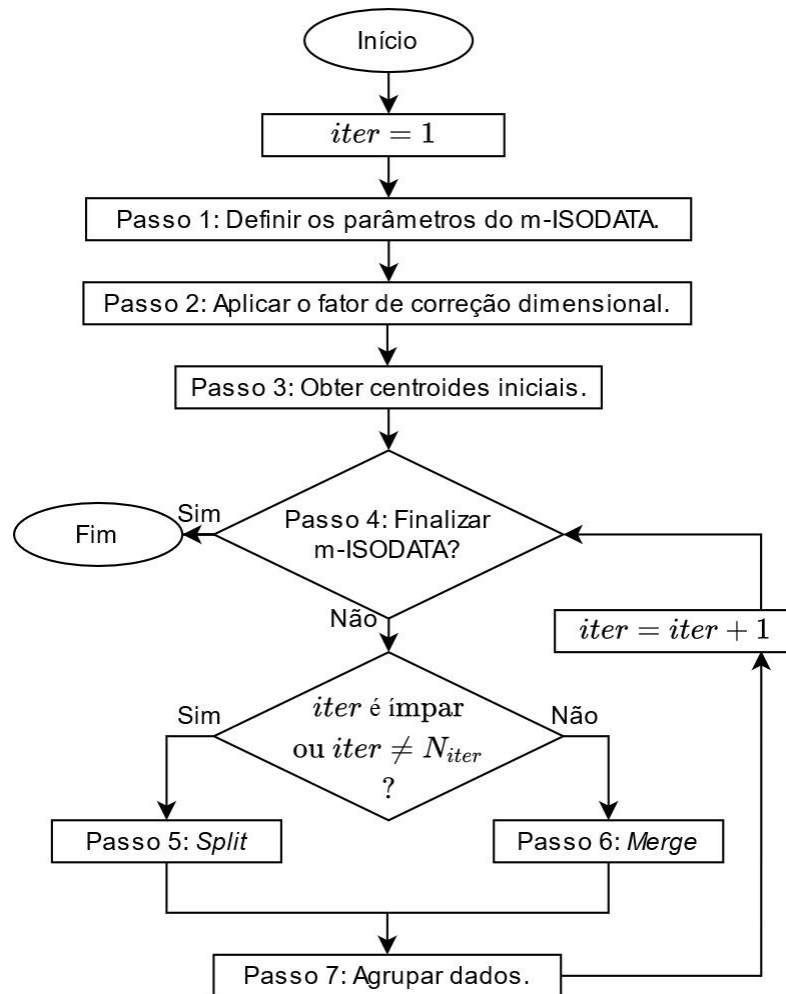
#### 4.3.1 Passo 1 - Definição dos parâmetros

O algoritmo é ajustado pelos quatro parâmetros a seguir:

1.  $d_{min}^0$ , a distância mínima entre dois centroides;
2.  $\sigma_{max}^0$ , o desvio padrão máximo de um grupo;
3.  $N_{iter}$ , o número máximo de iterações;
4.  $k_0$ , o número inicial de grupos.

Embora os parâmetros anteriores possam ser definidos pelo usuário, neste capítulo sugerem-se valores *default* para o m-ISODATA na Tabela 8. Tais parâmetros podem ser utilizados para diferentes números de séries históricas conforme amplamente discutido na Seção 4.4. Além disso, a qualidade dos cenários pode ser ajustada alterando apenas o parâmetro  $d_{min}^0$  conforme discutido nas seções 4.4.4.3 e 4.4.4.4. Na Tabela 8,  $\sigma_{max}^0$  é predefinido como um valor dependente de  $d_{min}^0$ , conforme discutido na Seção 4.4. Esta característica é importante para que o m-ISODATA seja capaz de encontrar o número adequado de cenários para diferentes dimensões das séries históricas. Observe que  $d_{min}^0$  e  $\sigma_{max}^0$  são, respectivamente, os valores iniciais para  $d_{min}$  e  $\sigma_{max}$  apresentados na Figura 11.  $d_{min}$  e  $\sigma_{max}$  são obtidos com auxílio do Fator de Correção Dimensional (FCD), detalhado na Seção 4.3.2.

Figura 12 – Fluxograma do algoritmo m-ISODATA.



Fonte: do autor.

Tabela 8 – Variáveis *default* do m-ISODATA.

Parâmetro	Símbolo	Valor <i>default</i>
Distância mínima entre dois centroides	$d_{min}^0$	0,04
Máximo desvio padrão de um grupo	$\sigma_{max}^0$	$0.55 \cdot d_{min}^0$
Número máximo de iterações	$N_{iter}$	100
Número inicial de grupos	$k_0$	1


Fonte: do autor.

#### 4.3.2 Passo 2 - Fator de correção dimensional

O número adequado de cenários é difícil de ser arbitrado uma vez que este número muda com a dimensão da série utilizada (MERRICK, 2016). Para ilustrar a questão relacionada à dimensionalidade, na Figura 13 apresentam-se três grupos formados por pontos ortogonais em 1, 2 e 3 dimensões. Pode-se observar que a distância entre o centroide (em cor laranja) e um ponto (em cor preta) é aumentada pelo fator  $\sqrt{D}$ , onde  $D$  é a dimensão do conjunto de dados.

Como os parâmetros  $d_{min}$  e  $\sigma_{max}$  são distâncias, eles precisam ser ajustados para cada

Figura 13 – Visualização do Fator de Correção Dimensional (FCD) em: (a) uma dimensão; (b) duas dimensões; (c) três dimensões.



Fonte: do autor.

dimensão da série histórica. Assim, o m-ISODATA compensa automaticamente os parâmetros de entrada  $d_{min}^0$  e  $\sigma_{max}^0$ , conforme formulado em (4.1) e (4.2).

$$d_{min} = d_{min}^0 \cdot \sqrt{D} \quad (4.1)$$

$$\sigma_{max} = \sigma_{max}^0 \cdot \sqrt{D} \quad (4.2)$$

#### 4.3.3 Passo 3 - Definição dos centroides iniciais

Para iniciar o procedimento iterativo,  $k_0$  observações são selecionadas aleatoriamente das séries históricas para representar os centroides iniciais do grupo. As etapas a seguir consideram o valor padrão para  $k_0$ , ou seja,  $k_0 = 1$ . Assim, todos os conjuntos de dados serão considerados um grupo na primeira iteração.

#### 4.3.4 Passo 4 - Critérios de parada

Para reduzir a carga computacional do m-ISODATA, três critérios de parada são definidos para encerrar o processo iterativo. Assim, o algoritmo termina quando pelo menos um dos seguintes critérios é atendido:

1. o número máximo de iterações ( $N_{iter}$ ) é alcançado;
2. as funções implementadas nos passos 5, 6 e 7 do algoritmo não alteram nenhum dos grupos entre iterações sucessivas;
3. o número de cenários começa a oscilar entre dois valores devido a um conflito entre as funções *merge* e *split*.

#### 4.3.5 Passo 5 - Função *split*

Conforme apresentado na Figura 12, a função *split* é executada apenas em iterações ímpares ou quando não é a última iteração. A função *split* é aplicada para garantir um nível

adequado de representatividade do centroide de um grupo. Se o desvio padrão de um grupo for alto, isso significa que seu centroide pode não representar com precisão os dados do cenário. Assim, a função *split* divide o grupo em dois grupos menores que representam melhor seus próprios dados, reduzindo o desvio padrão destes dois novos grupos em relação ao grupo originário.

Antes de aplicar a função *split* a um grupo, é verificado se  $\sigma_c > \sigma_{max}$ , onde  $\sigma_c$  é o desvio padrão do grupo  $c$ , calculado por (4.3)-(4.4). O desvio padrão em (4.3) é calculado como a raiz quadrada da máxima variância em cada dimensão  $\delta$  da série histórica de  $D$  dimensões, onde  $q_{\delta,\delta}$  é o  $\delta$ -ésimo elemento da diagonal principal da matriz de covariância  $Q_c$  do grupo  $c$ , obtido por (4.4). Na função *split*, o centroide  $\vec{m}_c$  é dividido em  $\vec{m}_{cf}^{(+)}$  e  $\vec{m}_{cf}^{(-)}$ , que são posições estimadas para os centroides dos novos dois grupos a serem formados, conforme formulado em (4.5), onde  $\vec{\lambda}_c$  é o autovetor associado ao maior autovalor do grupo  $c$ . Deve-se frisar que  $\vec{\lambda}_c$  aponta na direção em que os dados mais se espalham pelo espaço. As posições previstas para os centroides são utilizadas no Passo 7 (ver 4.3.7) para formar os novos grupos.

$$\sigma_c = \sqrt{\max \{q_{\delta,\delta} \forall \delta = 1, \dots, D\}} \quad (4.3)$$

$$Q_c = \frac{1}{X_c^N} \sum_{\vec{x} \in X_c} (\vec{x} - \vec{m}_c)(\vec{x} - \vec{m}_c)^T \quad (4.4)$$

$$\begin{aligned} \vec{m}_{cf}^{(+)} &= \vec{m}_c + \vec{\lambda}_c \sigma_c \\ \vec{m}_{cf}^{(-)} &= \vec{m}_c - \vec{\lambda}_c \sigma_c \end{aligned} \quad (4.5)$$

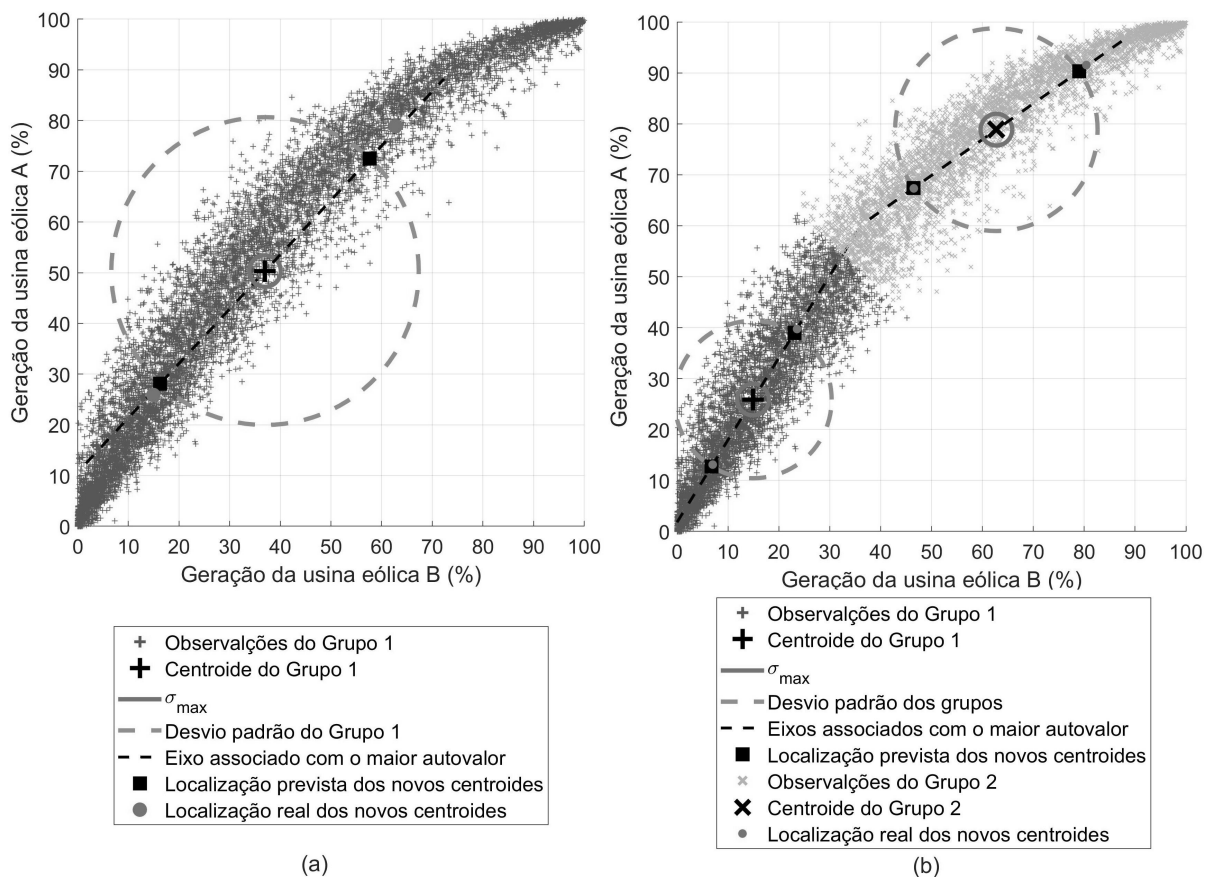
onde:  $\vec{x}$  é uma observação da série histórica;  $X_c$  é o conjunto de dados associados ao grupo  $c$ ;  $X_c^N$  é o número total de dados pertencentes ao grupo  $c$ ; e  $\vec{m}_c$  é o centroide do grupo  $c$ .

Para melhor compreender o funcionamento da função *split*, os primeiros dois processos de *split* são representados na Figura 14. Assim, o Passo 3 do algoritmo m-ISODATA começa a partir da determinação do primeiro centroide com base no conjunto de dados total (considerando  $k_0 = 1$ ), conforme Figura 14(a). Pode-se observar que o desvio padrão dos cenários ( $\sigma_1$ , círculo tracejado de cor verde) é alto pois os dados estão muito espalhados em relação ao centroide e é maior do que seu limite ( $\sigma_{max}$ ) representado pelo círculo sólido de cor laranja, ou seja,  $\sigma_1 > \sigma_{max}$ . Neste caso, a diferença entre  $\sigma_{max}$  e  $\sigma_1$  é em torno de 28% da capacidade total de geração da usina eólica e a função *split* é utilizada para dividir o grupo em dois outros menores. Na Figura 14(a), a semirreta tracejada representa o autovetor  $\vec{\lambda}_c$  cruzando o centroide do grupo  $\vec{m}_c$ . Assim, os dois centroides estimados dos dois futuros grupos  $\vec{m}_{cf}^{(+)}$  e  $\vec{m}_{cf}^{(-)}$ , são obtidos pelo produto entre  $\vec{\lambda}_c$  e  $\sigma_c$ , que é representado na Figura 14(a) pelas marcas quadradas de cor preta, localizadas na interseção entre a semirreta tracejada e o círculo tracejado de cor verde.

A função *split* foi introduzida para estimar as posições dos centroides dos grupos divididos com precisão, reduzindo o número de iterações para convergência do m-ISODATA em

relação ao algoritmo ISODATA tradicional. As posições reais dos centroides dos grupos obtidos após aplicação da função *split* são calculadas no Passo 7 (Seção 4.3.7) e estão representadas na Figura 14(a) pelos pontos vermelhos. Pode-se observar uma alta precisão na estimativa de suas localizações pelo procedimento proposto. Os novos grupos, obtidos ao final da primeira iteração pelo Passo 7, estão representados na Figura 14(b), a qual inclui as localizações reais e previstas para os quatro novos centroides que serão obtidos após uma segunda aplicação da função *split*. Pode-se notar que a precisão dos centroides estimados (distância entre as posições previstas e verdadeiras) foi aprimorada com a redução do tamanho dos grupos.

Figura 14 – Gráfico de dispersão da série histórica bidimensional:: (a) como um único cenário; (b) como dois cenários.



Fonte: do autor.

#### 4.3.6 Passo 6 - Função *merge*

A função *merge* é aplicada para evitar grupos com centroides semelhantes, garantindo a unicidade de cada cenário, conforme mostrado na Figura 12. A função *merge* é aplicada apenas em iterações pares ou na última iteração. Para isto, o m-ISODATA avalia a distância euclidiana  $d(\vec{m}_{ca}, \vec{m}_{cb})$  entre cada par de centroides  $\vec{m}_{ca}$  e  $\vec{m}_{cb}$ . Se a distância não satisfaz a restrição dada por  $d(\vec{m}_{ca}, \vec{m}_{cb}) \geq d_{min}$ , então os grupos são fundidos para obter um grupo maior, através da localização prevista de seu centroide, representado por  $\vec{m}_{cf}$ . Por fim, assim como no Passo 5, a

localização prevista do centroide é utilizada no Passo 7.

$$\vec{m}_{cf} = \frac{\vec{m}_{ca} + \vec{m}_{cb}}{2} \quad (4.6)$$

#### 4.3.7 Passo 7 - Agrupando dados

O algoritmo m-ISODATA é um procedimento heurístico que altera o número e a posição dos centroides através das funções *split* e *merge*. Porém, ambas as funções apenas predizem a posição dos centroides enquanto a posição verdadeira é obtida no Passo 7. Para isto, é necessário associar os dados ao respectivo centroide previsto a cada iteração, visando calcular a posição real do centroide. Neste passo também são calculados o desvio padrão de cada grupo e a probabilidade de ocorrência de cada cenário.

Para calcular a posição real do centroide dos grupos, cada observação da série histórica é associada ao centroide previsto mais próximo e, portanto, incorporado ao respectivo grupo, conforme formulado em (4.7). Portanto, o centroide do grupo  $c$  é calculado conforme (4.8) e, finalmente, a probabilidade do cenário  $s$  que é representado pelo centroide  $\vec{m}_c$  é calculada em (4.9).

$$\vec{x} \in X_c \text{ if } d(\vec{x}, \vec{m}_c) = \min \{d(\vec{x}, \vec{m}_c), \forall c\} \quad (4.7)$$

$$\vec{m}_c = \frac{1}{X_c^N} \sum_{\vec{x} \in X_c} \vec{x} \quad (4.8)$$

$$p_s = \frac{X_c^N}{N} \quad (4.9)$$

onde:  $d(\vec{x}, \vec{m}_c)$  é a distância Euclidiana entre a observação  $\vec{x}$  e o centroide  $\vec{m}_c$ , conforme (4.10).

$$d(\vec{x}, \vec{m}_c) = \|\vec{x} - \vec{m}_c\| \quad (4.10)$$

De forma resumida, um cenário  $s$  é representado pelo respectivo centroide  $\vec{m}_c$ , que é formado por  $X_c^N$  observações da série histórica e que possui uma probabilidade de ocorrência igual a  $p_s$ .

#### 4.3.8 Comentários gerais

Na Seção 4.3.5, o algoritmo m-ISODATA verifica se  $\sigma_c > \sigma_{max}$ , cujo parâmetro  $\sigma_{max}$  é definido para manter o desvio padrão de um grupo em um nível desejado. Porém,  $\sigma_{max}$  não é um parâmetro mandatório, desde que  $\sigma_{max}$  e  $d_{min}$  impõem restrições conflitantes para a formação dos grupos, isto é, quanto menor  $\sigma_{max}$ , menor será a distância entre os centroides de grupos distintos. Assim, o valor de  $\sigma_{max}$  pode ser difícil para ser definido e é fortemente dependente do parâmetro  $d_{min}$ . Ao dividir um grupo utilizando a função *split*, se  $\sigma_{max} \leq 0.5 \cdot d_{min}$ , a distância entre os dois novos centroides tenderá a ser menor do que a especificada por  $d_{min}$ , causando uma oscilação no número de grupos ao aplicar as funções *split* e *merge*, uma vez que a função

*merge* reagrupará estes dados que não satisfazem a restrição imposta por  $d_{min}$ . Por outro lado,  $\sigma_{max} \gg 0.5 \cdot d_{min}$ , a função *split* tende a não ser utilizada, reduzindo a representatividade dos cenários. Pode-se concluir então que um valor para  $\sigma_{max}$  levemente maior que  $0.5 \cdot d_{min}$  é a melhor opção para harmonizar o funcionamento entre as funções *split* e *merge*. Para confirmar isto, são apresentadas análises na Seção 4.4.1 para definir um valor adequado para  $\sigma_{max}$ .

#### 4.4 RESULTADOS

Nesta seção apresentam-se os resultados do m-ISODATA aplicado a séries históricas de demanda e despacho de energia solar e eólica. Os valores *default* para os parâmetros m-ISODATA são apresentados na Seção 4.4.1. Na seção 4.4.2, dados históricos de dois parques eólicos em resolução horária são usados para ilustrar os cenários obtidos do m-ISODATA e para destacar as vantagens sobre os métodos tradicionais de agrupamento da *Statistics and Machine Learning Toolbox* do MATLAB<sup>®</sup> R2019b: k-means e HAC. Na seção 4.4.3, estudos de Fluxo de Potência Ótimo Probabilístico (FPOP) são realizados para comparar o desempenho dos cenários obtidos com m-ISODATA, Simulação de Monte Carlo (SMC) (LEITE DA SILVA et al., 2010), k-means e HAC. Na seção 4.4.4, diferentes conjuntos de fontes de variabilidade são agrupados em cenários representativos pelo m-ISODATA e são usados para reduzir o tamanho de um problema de Planejamento de Expansão da Geração (PEG). Os resultados comprovam a capacidade do m-ISODATA em capturar um número adequado de cenários para diferentes conjuntos de séries históricas sem a necessidade de alterar os parâmetros de entrada do algoritmo.

Todos os resultados apresentados neste capítulo podem ser reproduzidos no repositório Code Ocean (DE PAULA et al., 2020), que contém o m-ISODATA e as simulações apresentadas. O m-ISODATA é estruturado como uma função do software MATLAB<sup>®</sup> e pode ser facilmente aplicado a outras séries históricas e problemas.

##### 4.4.1 Definição dos valores *default*

Os valores *default* para os parâmetros do m-ISODATA são apresentados na Tabela 8. Estes valores foram definidos de forma a melhorar o desempenho do algoritmo proposto. O valor de  $d_{min}^0$  é definido com o apoio das análises desempenhadas nas seções 4.4.3-4.4.4. O valor escolhido para  $N_{iter}$  é suficiente para garantir a convergência de todas as simulações testadas. O algoritmo m-ISODATA é mais rápido para  $k_0 = 1$  e é pouco sensível para alterações em  $k_0$  quando o valor *default* definido para  $\sigma_{max}^0$  é utilizado.

Para definir um valor adequado para  $\sigma_{max}^0$ , um estudo foi realizado para avaliar como diferentes valores para  $\sigma_{max}^0$  e  $d_{min}^0$  impactam na qualidade dos cenários obtidos pelo m-ISODATA para diferentes conjuntos de séries históricas. Com isto, para cada par de parâmetros  $\sigma_{max}^0$  e  $d_{min}^0$ , duas simulações foram realizadas considerando:  $k_0 = 1$  e  $k_0 = N$ . Para  $k_0 = 1$ , o m-ISODATA tende a utilizar mais a função *split* de modo a aumentar o número de grupos, enquanto para  $k_0 = N$ , a função *merge* é mais acessada. Se  $\sigma_{max}^0$  é adequadamente ajustada em função de  $d_{min}^0$ ,



os grupos obtidos em ambas as simulações não irão variar muito. Assim, determinou-se que  $\sigma_{max} = 0.55 \cdot d_{min}$  reduz a variação no número de cenários obtidos ao variar o parâmetro  $k_0$ , o que demonstra uma boa harmonia entre as funções *merge* e *split* e as restrições impostas por  $\sigma_{max}^0$  e  $d_{min}^0$ .

#### 4.4.2 Desempenho do m-ISODATA em um espaço bidimensional

Nesta seção compara-se o desempenho do m-ISODATA com os algoritmos de agrupamento k-means e HAC, considerando o conjunto de dados de despacho de energia eólica bidimensional apresentado anteriormente. Os algoritmos k-means e HAC estão disponíveis em (MATLAB. . . , 2019). As análises a seguir consideram 39 e 101 grupos para todos os algoritmos, onde esses números de grupos são respectivamente obtidos executando o m-ISODATA com  $d_{min}^0 = 0,04$  (valor *default*) e  $d_{min}^0 = 0,027$  (valor personalizado).


Sob os valores *default* para os parâmetros m-ISODATA ( $d_{min}^0 = 0,04$ ), o processo iterativo do algoritmo m-ISODATA converge com 26 iterações. O resultado obtido com 39 cenários é representado na Figura 15(a) por cores diferentes, onde o marcador “o” indica a localização dos centroides de cada grupo. É possível verificar que os centroides estão bem distribuídos no espaço de observação.

Para comparar o desempenho do m-ISODATA proposto, o algoritmo k-means é aplicado considerando a mesma série histórica bidimensional e 39 grupos como parâmetro de entrada e 1000 iterações. Os cenários obtidos são apresentados na Figura 15(b). Pode-se notar que os grupos obtidos tendem a se concentrar na região com baixa geração eólica, que apresenta maior densidade de dados. Por outro lado, regiões de baixa densidade de dados são representadas por menos grupos. Isso implica na redução da singularidade e representatividade dos cenários, criando pequenos grupos semelhantes em regiões com alta densidade de dados e grupos com alto desvio padrão em regiões de baixa densidade.

No algoritmo HAC, os limites para o desvio padrão máximo de cada cenário e a distância mínima entre dois cenários podem ser alcançados através do método de Ward (MURTAGH; LEGENDRE, 2014), considerado nas análises deste capítulo. A Figura 15(c) apresenta os cenários obtidos definindo o número de grupos em 39. Como esperado, o HAC associado ao método Ward fornece grupos muito bem distribuídos, gerando um conjunto de cenários semelhante ao do m-ISODATA.

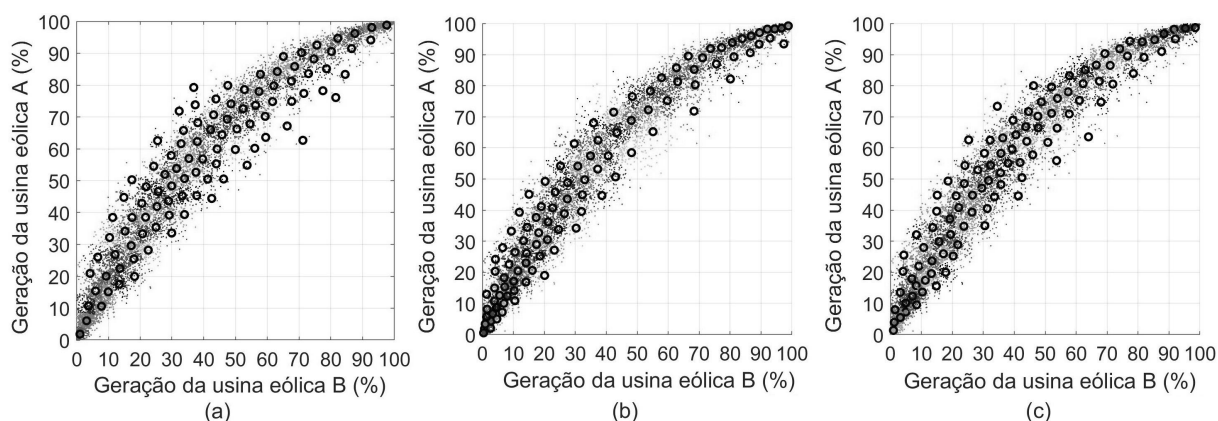
Para enfatizar as desvantagens do k-means, uma segunda análise é realizada executando m-ISODATA com  $d_{min}^0 = 0,027$ . Os resultados obtidos com 101 cenários são representados nas figuras 16(a), (b) e (c), respectivamente para os algoritmos m-ISODATA, k-means e HAC. Na solução do k-means, há uma alta aglomeração de grupos similares nas regiões de alta densidade, o que reduz a unicidade de cada cenário. Apesar da boa distribuição dos cenários obtidos com o HAC, este algoritmo depende do número de cenários como parâmetro de entrada, o que pode ser difícil de se arbitrar por parte do usuário.

Figura 15 – Os 39 cenários obtidos com: (a) m-ISODATA; (b) k-means; (c) HAC.



Fonte: do autor.

Figura 16 – Os 101 cenários obtidos com: (a) m-ISODATA; (b) k-means; (c) HAC.



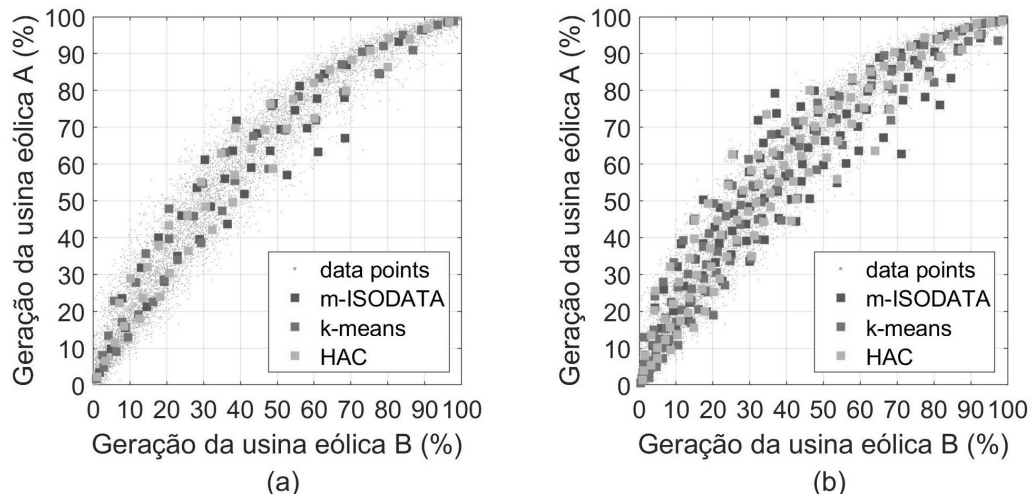
Fonte: do autor.

Para resumir as análises, todos os centroides obtidos a partir dos três algoritmos de agrupamento anteriores são exibidos na Figura 17. Pode-se observar que o m-ISODATA captura cenários mais extremos para melhor distribuir seus clusters. Este comportamento é útil para análises de sistemas de potência, uma vez que cenários extremos, mesmo aqueles com baixa probabilidade, podem ter um alto impacto nos modelos probabilísticos, conforme discutido na Seção 4.4.3.

Pode-se observar que o k-means e o HAC podem refletir melhor a densidade da distribuição dos pontos de dados no espaço de observação. No entanto, refletir a densidade dos pontos de dados não é interessante, pois cenários semelhantes serão gerados, fornecendo resultados redundantes nas aplicações. A densidade das regiões é representada pelo m-ISODATA através da probabilidade de ocorrência dos cenários, ponderando os resultados para cada cenário gerado.

As principais características dos cenários são exibidas na Tabela 9. Pode-se observar que o m-ISODATA apresenta maior razão entre o número máximo e mínimo de pontos e menor razão entre o desvio padrão máximo e mínimo, o que apoia o comportamento visualizado na

Figura 17 – Grupos obtidos a partir de diferentes técnicas para: (a) 39 cenários; (b) 101 cenários.



Fonte: do autor.

Figura 17, demonstrando que o m-ISODATA é capaz de capturar cenários extremos ao mesmo tempo que mantém um desvio padrão razoável para todos os grupos.

Tabela 9 – Número máximo/mínimo de pontos e desvio padrão ( $\sigma$ ) dos grupos obtidos pelo m-ISODATA, k-means e HAC.

Técnica	Número de cenários	mín. de pontos	máx. de pontos	mín. $\sigma$	máx. $\sigma$
m-ISODATA	39	9	617	0,018	0,032
k-means	39	72	329	0,010	0,037
HAC	39	89	496	0,015	0,040
m-ISODATA	101	2	404	0,011	0,020
k-means	101	11	181	0,004	0,041
HAC	101	16	255	0,008	0,040

Fonte: do autor.

#### 4.4.3 Problema teste 1: Fluxo de Potência Ótimo Probabilístico (FPOP)

Nesta seção discute-se o desempenho dos cenários obtidos pelos algoritmos m-ISODATA, SMC (LEITE DA SILVA et al., 2010), k-means e HAC aplicados a um problema FPOP. Para gerar os cenários, foram considerados quatro séries históricas com resolução horária, sendo, três séries de despacho eólico (SILVA et al., 2012) e uma série de demanda baseada nos dados originais do sistema teste IEEE-RTS (SUBCOMMITTEE, 1979).

#### 4.4.3.1 Formulação do FPOP

O FPOP é formulado em (4.11)-(4.17).

$$\sum_{s \in S} \left[ \min_{\chi} \left( \sum_{b \in B} (hd_{b,s} + hr_{b,s}) \cdot p_s \right) \right] \quad (4.11)$$

sendo  $\chi = \{pg, \theta, hd, hr\}$

$$pg_{b,s} - \sum_{k \in K_b} f_{k,s} + hd_{b,s} - hr_{b,s} = d_{b,s} - \sum_{r \in R_b} pr_{r,s}, \quad \forall b \in B \quad (4.12)$$

$$f_{k,s} = -b_k \theta_{ij,s}, \quad \forall k \in K \quad (4.13)$$

$$|f_{k,s}| \leq \bar{f}_k, \quad \forall k \in K \quad (4.14)$$

$$0 \leq pg_{g,s} \leq \overline{pg}_g, \quad \forall g \in G \quad (4.15)$$

$$0 \leq hd_{b,s} \leq d_{b,s}, \quad \forall b \in B^D \quad (4.16)$$

$$0 \leq hr_{b,s} \leq \sum_{r \in R_b} pr_{r,s}, \quad \forall r \in R \quad (4.17)$$

A função objetivo em (4.11) busca minimizar o corte de carga e o corte de renováveis do sistema para o conjunto de cenários representativos  $S$ . Isso implica que a função objetivo proposta busca maximizar o uso da energia eólica, conforme considerado em (YU; CHUNG; WONG, 2011). As variáveis de decisão FPOP são: corte de carga ( $hd$ ), corte de renovável ( $hr$ ), geração em geradores controláveis ( $pg$ ) e ângulo de fase ( $\theta$ ). A restrição em (4.12) modela o balanço de potência ativa na barra  $b$ , relacionada à primeira lei de Kirchhoff, onde o cenário de despacho renovável ( $pr_{r,s}$ ) e nível de carga ( $d_{b,s}$ ) são parâmetros definidos através do agrupamento das séries históricas. O fluxo de potência ativa no circuito  $k$  é calculado por (4.13) e é limitado por (4.14). Em (4.15)-(4.17), as variáveis de decisão para potência gerada em geradores controláveis, corte de carga e corte de renovável são limitadas. O modelo FPOP compreende  $s$  subproblemas, ou seja, cada cenário leva a um subproblema FPOP, formulado como um problema de programação linear (PL) que é resolvido via método dos pontos interiores através da função *linprog* do *Optimization Toolbox* do MATLAB®.

O modelo FPOP é utilizado para avaliar os índices de confiabilidade do sistema Expectativa de perda de carga (LOLE, do inglês *Loss of Load Expectation*) e Expectativa de desperdício de energia eólica, (EWES, do inglês *Expectation of Wind Energy Spilled*), respectivamente formulados em (4.18) e (4.19).

$$LOLE = 8760 \cdot \sum_{s \in S} \left( p_s \cdot \sum_{b \in B^D} hd_{b,s}^* \right) \quad (4.18)$$

$$EWES = 8760 \cdot \sum_{s \in S} \left( p_s \cdot \sum_{b \in B^R} hr_{b,s}^* \right) \quad (4.19)$$

onde  $hr_{b,s}^*$  e  $hd_{b,s}^*$  são, respectivamente, os valores de corte de vento e carga obtidos na solução do FPOP.

#### 4.4.3.2 Resultados

O FPOP é aplicado a uma versão modificada do sistema de teste IEEE-RTS (SUBCOMMITTEE, 1979). A demanda pico e a capacidade de geração foram dobradas para reduzir a confiabilidade da rede e causar cortes de carga e vento sem a necessidade de modelar contingências nos circuitos do sistema. Além disso, três parques eólicos de 900 MW foram adicionados às barras 17, 21 e 22. Por fim, foram removidos os circuitos redundantes da rede localizados nos ramos 15-17, 15-21, 18-21, 19-20 e 20-23, resultando em uma rede composta apenas por circuitos simples.


Para as análises propostas, os índices LOLE e EWES também foram obtidos por uma simulação determinística que executa o problema FPOP para todos os 43.800 pontos de dados horários na série histórica (conjunto de dados de referência), que resultou em uma LOLE de 317,5 GWh/ano e uma EWES de 919,8 GWh/ano. Com o objetivo de avaliar o desempenho das abordagens probabilísticas, o erro relativo ( $ER$ ) introduzido em (4.20) é aplicado à simulação de m-ISODATA, k-means, HAC e Monte Carlo (SMC), onde o sobrescrito  $S$  indica o índice obtido pela abordagem probabilística através dos cenários e o sobrescrito  $F$  refere-se ao *benchmark*, obtido ao avaliar todos os pontos da série histórica. Note que o erro relativo indica o erro máximo entre os dois índices apurados em (4.18) e (4.19) de modo a evidenciar os erros introduzidos pelo uso dos cenários.

$$ER = \max \left( \frac{|LOLE^{(P)} - LOLE^{(B)}|}{LOLE^{(B)}}, \frac{|EWES^{(P)} - EWES^{(B)}|}{EWES^{(B)}} \right) \quad (4.20)$$

Na Figura 18 são apresentados os erros relativos obtidos através de (4.20). Os parâmetros *default* do m-ISODATA foram utilizados, variando-se apenas  $d_{min}^0$  entre 0,01 e 0,1 de modo a obter diversos conjuntos de cenários. O erro relativo obtido com os parâmetros *default* m-ISODATA, para  $d_{min}^0 = 0,04$ , é marcado na Figura 18 por um marcador quadrado. O parâmetro de entrada relacionado ao número de grupos dos algoritmos k-means e HAC foi alterado de 1 a 10.000. Os erros relativos obtidos durante processo iterativo da SMC são mostrados na Figura 18 de modo a demonstrar o comportamento de um FPOP solucionado a partir de amostragens aleatórias. Pode-se observar que o m-ISODATA retorna erros relativos similares às outras abordagens e fornece, através dos parâmetros *default*, uma boa relação entre o número de cenários (associado ao custo computacional) e o erro relativo (precisão). Em relação à SMC, existe uma grande variação no erro relativo ao longo do processo de amostragem aleatória, o erro

relativo da SMC também pode ser estimado pelo coeficiente de variação ( $\beta$ ) (LEITE DA SILVA et al., 2010), representado pela linha tracejada e o eixo das ordenadas do lado direito do gráfico. Na literatura, o coeficiente  $\beta$  é usado como critério de parada para SMC, e valores abaixo de 5% são considerados aceitáveis dependendo da aplicação (SILVA et al., 2013). Considerando o critério de parada  $\beta \leq 5\%$ , o SMC exige a avaliação de 2.418 cenários e obteve um erro relativo de 1,94%. No entanto, as abordagens de agrupamento m-ISODATA, k-médias e HAC, obtêm erros relativos abaixo de 1,94% com menos de 1.000 cenários, o que mostra as vantagens dos algoritmos de agrupamento sobre a amostragem aleatória.

Figura 18 – Erro relativo obtido ao considerar os algoritmos m-ISODATA, k-means, HAC e SMC e coeficiente de convergência  $\beta$  da SMC.



Fonte: do autor.

Apesar da pequena diferença entre os desempenhos dos algoritmos de agrupamento, o número de grupos é difícil de ser definido em k-means e HAC enquanto é automaticamente definido pelo m-ISODATA. Para dados históricos com mais dimensões, a escolha de um número adequado de grupos torna-se ainda mais difícil. Assim, há a necessidade de avaliar o equilíbrio entre custo computacional e precisão quanto ao número de cenários (ZHANG; CONEJO, 2018b), o que pode ser uma tarefa exaustiva.

#### 4.4.4 Problema teste 2: Planejamento da Expansão da Geração (PEG)

Com o objetivo de avaliar a qualidade dos cenários obtidos com o m-ISODATA, nesta seção utiliza-se o problema clássico de Planejamento da Expansão da Geração (PEG). Usando séries históricas de 1, 3 e 11 dimensões, os valores *default* do m-ISODATA demonstraram-se adequados para capturar automaticamente o número apropriado de cenários representativos.

##### 4.4.4.1 Formulação do PEG

O PEG considerando os cenários de demanda e geração eólica e solar é descrito em (4.21)-(4.26). A função objetivo em (4.21) busca minimizar o custo total ( $C_{total}$ ) da decisão de

expansão que envolve os custos de investimento anualizado e os custos de operação e de emissão de carbono para todos os cenários representativos; o balanço de potência é representado em (4.22), observando que a modelagem foi proposta para solucionar um problema simplificado de barra única; (4.23) limita a geração térmica à capacidade instalada; (4.24) limita a geração renovável à capacidade instalada e à disponibilidade de geração segundo o cenário; por fim, as variáveis de geração e investimento são modeladas como não-negativas em (4.25)-(4.26).

$$C_{total} = \min_{\chi} \left( \sum_{g \in G} \left[ C_g^G \cdot I_g^G + 8760 \cdot \sum_{s \in S} p_s \cdot pg_{g,s} (co_g + cc_g \cdot eg_g) \right] + \sum_{r \in R} C_r^R \cdot I_r^R \right) \quad (4.21)$$

sendo  $\chi = \{pg, I^R, I^G\}$

subject to:

$$\sum_{g \in G} pg_{g,s} = d_{b,s} - \sum_{r \in R} pr_{r,s}, \quad \forall s \in S \text{ e } b = 1 \quad (4.22)$$

$$pg_{g,s} \leq I_g^G, \quad \forall g \in G, s \in S \quad (4.23)$$

$$pr_{r,s} = a_{r,s} \cdot I_r^R, \quad \forall r \in R, s \in S \quad (4.24)$$

$$I_g^G, pg_{g,s} \geq 0, \quad \forall g \in G, s \in S \quad (4.25)$$

$$I_r^R, pr_{r,s} \geq 0, \quad \forall r \in R, s \in S \quad (4.26)$$

O PEG definido em (4.21)-(4.26) é um modelo simplificado para mensurar a representatividade dos cenários obtidos pelos algoritmos de agrupamento. Matematicamente, o PEG consiste em um problema de programação linear que é resolvido via método dos pontos interiores através da função *linprog* do *Optimization Toolbox* do MATLAB<sup>®</sup>. A Tabela 10 apresenta os dados de custos de investimento e operação de cinco fontes primárias de energia consideradas no modelo, os valores apresentados foram baseados em (LAZARD, 2018).

Nas análises, não são consideradas usinas existentes e até 11 séries históricas são consideradas, sendo sete séries de despacho de usinas solares, três séries de despacho de usinas eólicas e uma série de demanda (MERRICK, 2016).

#### 4.4.4.2 Casos de simulação

Os casos de simulação consideram os valores *default* para o m-ISODATA, definidos na Tabela 8 onde  $d_{min}^0 = 0,04$ . Três casos de simulação considerando séries históricas com diferentes números de fontes de variabilidade são analisados, sendo:

1.  $R^1$  o caso unidimensional que considera uma série histórica para demanda de carga;

Tabela 10 – Custos operacionais e de investimento utilizados no PEG.


Fonte	Custo de operação (\$/MWh)	Custo de investimento (\$/kW)	Emissão de CO2 (ton/MWh)	Custo de CO2 (\$/ton)
Solar	36	425	0	0
Wind	29	575	0	0
Gas	206	950	0.51	50
Coal	60	3000	0.92	50
Nuclear	112	6500	0	0

Fonte: do autor.

- $R^3$  é o caso tridimensional que considera uma série histórica para demanda de carga, uma para energia eólica e outra para geração solar;
- $R^{11}$  é o caso com 11 dimensões que considera uma série histórica para demanda de carga, três para energia eólica e sete para geração solar.

Na Figura 19 apresentam-se os custos de investimento do PEG considerando os cenários obtidos do m-ISODATA aplicado: aos cenários, representados por  $S$ ; e a série histórica completa, representada por  $F$ . Para calcular o custo de investimento para toda a série histórica, basta considerar  $S = F$  em (4.21)-(4.26). Pode ser observado que os resultados para  $F$  e  $S$  para um mesmo caso de simulação são similares. O caso de simulação  $R^1$  não considera a expansão em fontes renováveis, por tanto, os custos totais são compostos por um misto de investimento em usinas térmicas adequadas para satisfazer a variabilidade da demanda. Por outro lado, os casos de simulação  $R^3$  e  $R^{11}$  que consideram fontes renováveis, apresentam custos totais reduzidos.

Figura 19 – Planejamento da expansão para os cenários ( $S$ ) e séries históricas completas ( $F$ ).



Fonte: do autor.

O uso de cenários introduz erros em relação à simulação considerando toda a série histórica. Apesar da série ser utilizada de maneira determinística para determinar um *benchmark* para as análises, não há uma previsão precisa para o comportamento a curto prazo da variabilidade da geração eólica para problemas de planejamento a longo prazo. Com isto, pode-se considerar aceitáveis determinados níveis de erros introduzidos com o uso dos cenários. Neste trabalho, erros inferiores a 5% serão considerados adequados nas análises probabilísticas. O uso de cenários pode reduzir substancialmente o tempo de resolução dos problemas com um nível de



erro aceitável, conforme mostrado na Tabela 11, que apresenta o número de variáveis, restrições e carga computacional de cada caso de simulação. Os dados foram mensurados utilizando um processador Core i5-5200U de 2,2 GHz e 4 Gb de memória RAM. Esses valores são impactados pela dimensão da série histórica (caso de simulação) e pelo número de observações em cada conjunto de dados ( $F$  ou  $S$ ). Pode-se observar que o m-ISODATA captura 18, 447 e 1519 cenários representativos para, respectivamente, os casos de simulação  $R^1$ ,  $R^3$  e  $R^{11}$ , como pode ser verificado na Figura 21.

Tabela 11 – Custo computacional para solucionar o PEG utilizando a série histórica completa e os cenários obtidos via m-ISODATA.

Caso de Simulação	Conjunto de dados	No. de pontos	No. de variáveis	No. de restrições	Tempo (s)
$R^1$	$F$	8760	26283	17520	1.8
$R^1$	$S$	11	36	22	0.03
$R^3$	$F$	8760	43805	17520	5.0
$R^3$	$S$	320	1605	640	0.05
$R^{11}$	$F$	8760	113893	17520	26.7
$R^{11}$	$S$	1366	17771	2732	1.6

Fonte: do autor.

#### 4.4.4.3 Análises de sensibilidade - Parte 1

A análise presente demonstra a capacidade do m-ISODATA em capturar de forma automática um número adequado de cenários representativos a partir de séries históricas com dimensões diferentes. Para a análise, considera-se uma variação para o parâmetro  $d_{min}^0$  de 0,01 a 0,2, mantendo os demais valores *default* da Tabela 8. Deve-se enfatizar que  $d_{min}^0$  é internamente ajustado pelo FCD, conforme discutido na seção 4.3.2.  $\sigma_{max}^0$  é, por padrão, dependente do parâmetro  $d_{min}^0$ , de modo a ser também atualizado para cada valor avaliado de  $d_{min}^0$ . A análise é realizada sob os seguintes índices de desempenho:

1. *AUS*, a quantidade de cenários infactíveis, do inglês *Amount of Unfeasible Scenarios*. Este índice é calculado em (4.27), onde  $US_S$  e  $TS_S$  representam respectivamente o número de cenários infactíveis e total. Através do índice *AUS*, é possível mensurar a representatividade dos cenários obtidos via m-ISODATA. O índice é obtido ao solucionar o PEG considerando o conjunto de cenários ( $S$ ). Em sequência, a decisão de investimento obtida é avaliada para a série histórica completa ( $S = F$ ) para calcular quais observações da série não satisfazem as restrições (4.22)-(4.26), ou seja, qual a quantidade de informação da série histórica não foi devidamente representada pelos cenários obtidos com o m-ISODATA.
2. *DIC*, a diferença de custos de investimento, do inglês *Difference in the Investment Costs*. Este índice é calculado em (4.28) e representa a diferença relativa entre os custos de

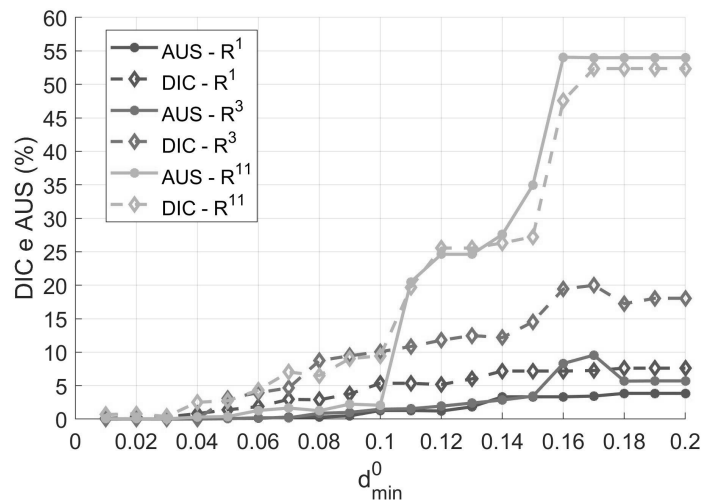
investimento ao solucionar o PEG considerando a série histórica completa ( $TC_F$ ) e os cenários do m-ISODATA ( $TC_S$ ).

$$AUS = \frac{US_S}{TS_S} \cdot 100\% \quad (4.27)$$

$$DIC = \frac{TC_F - TC_S}{TC_F} \cdot 100\% \quad (4.28)$$

Na Figura 20 apresentam-se os índices  $AUS$  e  $DIC$  para os três casos de simulação. Com o aumento de  $d_{min}^0$ , pode-se notar um aumento em  $AUS$  e  $DIC$ , o que significa que a representatividade dos cenários decresce. Para  $d_{min}^0 = 0,04$ , pode-se verificar que tanto  $AUS$  e  $DIC$  ficam abaixo de 5% para todos os casos de simulação. Os erros passam a ser significantes apenas para  $d_{min} > 0,08$ . Além disso, para  $d_{min} \leq 0,08$ , os resultados mostram que  $AUS$  e  $DIC$  são similares apesar das séries históricas terem dimensões diferentes, o que indica que o m-ISODATA é capaz de capturar os cenários representativos para todos os casos de simulação, eliminando a necessidade de definir um número de cenários como é necessário ao utilizar outros algoritmos de agrupamento como k-means e HAC. Desde que qualquer valor entre 0 e 0,08 para o parâmetro  $d_{min}^0$  demonstra uma boa representatividade para os cenários, o valor  $d_{min}^0 = 0,04$  é ajustado como *default*. O que ainda pode ser ajustado pelo usuário.

Figura 20 – Índices DIC e AUS frente variações de  $d_{min}^0$ .




Fonte: do autor.

#### 4.4.4.4 Análises de sensibilidade - Parte 2

Esta análise de sensibilidade avalia o impacto do Fator de Correção Dimensional (FCD) no desempenho do m-ISODATA. O papel do FCD consiste em ajustar  $d_{min}$  e  $\sigma_{max}$  para valores adequados de acordo com a dimensão do conjunto de dados a ser agrupado. Os números de cenários obtidos com e sem o FCD são apresentados na Figura 21. Pode-se observar que o

Figura 21 – Número de cenários obtidos com m-ISODATA frente variações de  $d_{min}^0$  com FCD (linhas sólidas) e sem FCD (linhas pontilhadas).



Fonte: do autor.

número de cenários para um mesmo  $d_{min}^0$  aumenta quando o FCD é desconsiderado. Deve-se enfatizar que para 1 dimensão (caso de simulação  $R^1$ ), os resultados são o mesmo independente da aplicação do FCD. Na Figura 21 destacam-se os números de cenários obtidos pelo m-ISODATA utilizando os parâmetros *default*.

Para mensurar o impacto do FCD no desempenho do m-ISODATA, o índice de erro calculado,  $E_C$ , é introduzido em (4.29). Como o uso de cenários introduz um erro, a função de mérito Erro Quadrático Compensado,  $CQE$  (do inglês *compensated quadratic error*), é definida em (4.30), onde  $E_A$  é um erro aceitável. Assim, valores pequenos de  $CQE$  implicam em uma boa escolha de  $d_{min}^0$ .


$$E_C = \max(AUS, DIC) \quad (4.29)$$

$$CQE = (E_A - E_C)^2 \cdot TS_S \quad (4.30)$$

A Figura 22 apresenta o  $CQE$  obtido ao variar  $d_{min}^0$  com e sem uso do FCD. Neste caso, um erro aceitável ( $E_A$ ) de 3% é adotado. A Figura enfatiza o mínimo  $CQE$  para cada curva. Pode-se notar que os valores mínimos ao considerar o FCD são obtidos ao considerar  $d_{min}^0 = 0,05$ , enquanto para as curvas que desconsideram o FCD, os mínimos valores ocorrem em  $d_{min}^0 = 0,09$  e  $d_{min}^0 = 0,16$ . O fato de obter um mesmo  $d_{min}^0$  que minimiza o  $CQE$  demonstra que aplicar o FCD torna o m-ISODATA adequado para obter um número apropriado de cenários para as séries históricas com diferentes dimensões. Por outro lado, quando o FCD não é utilizado, a experiência do usuário precisa ser levada em conta para definir um valor adequado do parâmetro

$d_{min}^0$  de modo a obter um número de cenários adequado que retorne um valor de erro aceitável.

Figura 22 – CQE versus  $d_{min}^0$  com FCD (linhas sólidas) e sem FCD (linhas tracejadas).



Fonte: do autor.

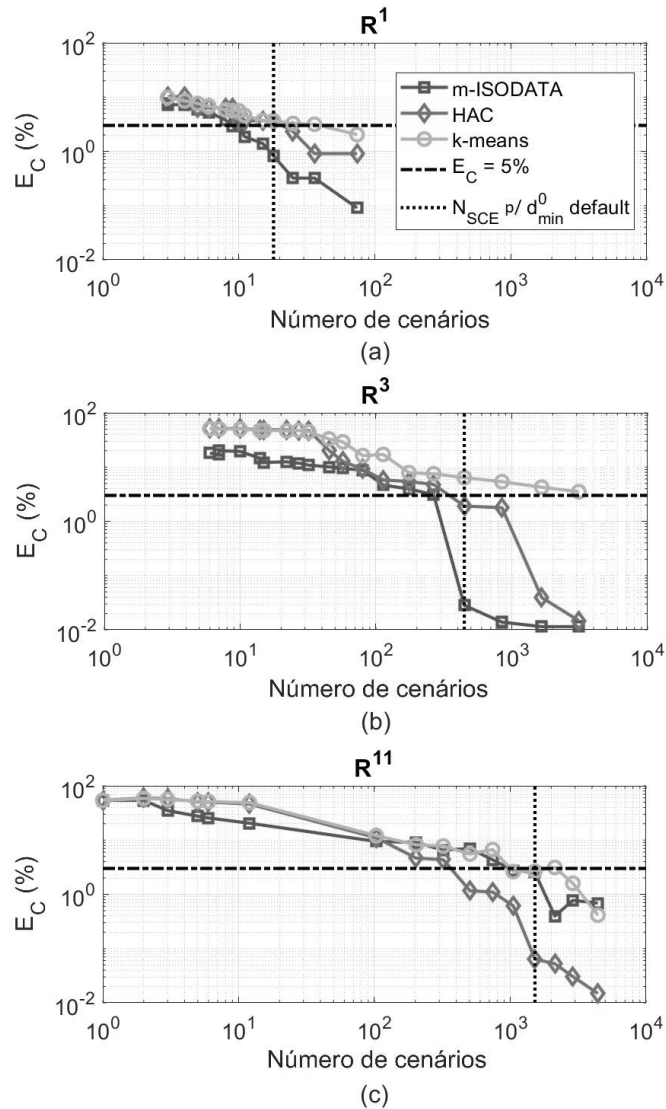
#### 4.4.4.5 Comparação entre os algoritmos

Para comparar o desempenho dos algoritmos, é apresentado na Figura 23 o índice de erro calculado  $E_C$  obtido para os algoritmos k-means, HAC e m-ISODATA para os três casos de simulação. Nos gráficos, as linhas tracejadas horizontais indicam  $E_C = 5\%$ , para orientar a visualização de um erro aceitável, e as linhas verticais indicam o número de cenários obtidos com o m-ISODATA para cada caso de simulação utilizando os parâmetros definidos como *default*. Os demais números de cenários usados para todos os algoritmos foram obtidos através do m-ISODATA variando o parâmetro  $d_{min}^0$  de 0,01 a 0,2 com um passo de 0,01. Pode-se observar que os cenários obtidos pelo m-ISODATA resultaram em erros menores para os casos de simulação  $R^1$  e  $R^3$ . Para o caso de 11 dimensões, os cenários obtidos via HAC apresentaram maior precisão. Esses resultados indicam que o m-ISODATA perde desempenho ao aumentar a quantidade de séries do conjunto de dados. Apesar disso, o m-ISODATA com seus parâmetros *default* encontrou um número de cenários que representam o conjunto de dados com uma precisão maior que 95%, o que pode ser uma tarefa custosa para outras técnicas dependendo do tempo computacional despendido para solução do problema em questão.

#### 4.4.4.6 Perda de correlação dos cenários

No contexto de geração de cenários, o índice de perda de correlação é um parâmetro importante a ser minimizado visando garantir uma verdadeira representação das séries históricas. Neste sentido, é proposto o índice de perda de correlação *corrloss*, inspirado no índice proposto

Figura 23 – Índice de erro calculado  $E_C$  para diferentes algoritmos de agrupamento e números de cenários.



Fonte: do autor.

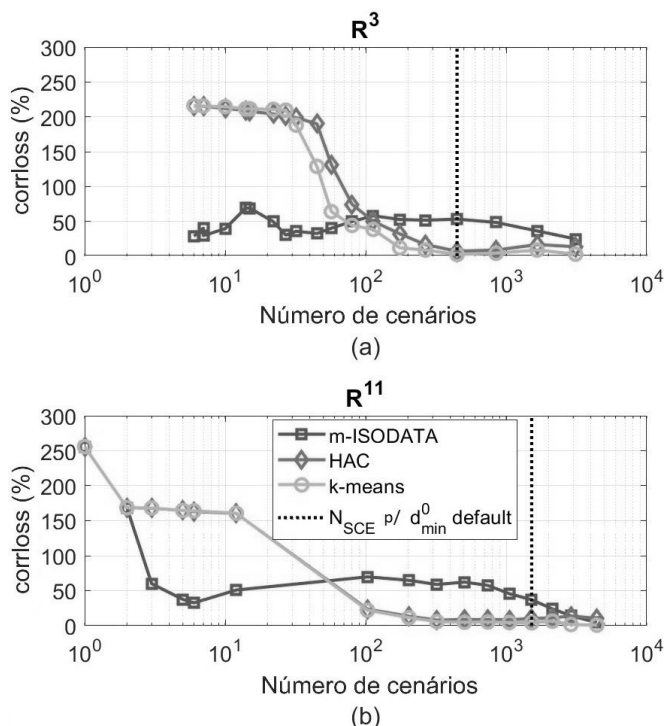
em (HU; LI, 2019). O índice *corrloss* mensura a perda média de correlação dos cenários em comparação com as séries históricas e é calculado em (4.31).

$$corrloss = \sum_{\delta_i=1}^{D-1} \sum_{\delta_j=i+1}^D \frac{|\rho_{\delta_i\delta_j} - \tilde{\rho}_{\delta_i\delta_j}|}{\rho_{\delta_i\delta_j}} \quad (4.31)$$

onde:  $D$  é a dimensão da série histórica;  $\rho_{\delta_i\delta_j}$  e  $\tilde{\rho}_{\delta_i\delta_j}$  são elementos das matrizes de coeficientes de correlação, respectivamente para os conjuntos  $F$  e  $S$ .

A diferença entre o índice proposto e o apresentado em (HU; LI, 2019) consiste na facilidade de avaliar os resultados obtidos, uma vez que *corrloss* é apresentados em valores percentuais, dando uma boa compreensão no quão diferentes estão as correlações entre os

Figura 24 – Índice de perda de correlação relativa *corrloss* para diferentes algoritmos de agrupamento e números de cenários.



Fonte: do autor.

cenários e as séries históricas.

A Figura 24 apresenta o índice *corrloss* obtido para os algoritmos m-ISODATA, k-means e HAC e diferentes números de cenários. Assim como na seção 4.4.4.5, os números de cenários utilizados foram obtidos ao variar o parâmetro  $d_{min}^0$  do m-ISODATA de 0,01 a 0,2 com passo de 0,01 (o que leva aos mesmos números de cenários ilustrados na Figura 21 com o FCD). As Figuras 24(a) e 24(b) apresentam, respectivamente, o *corrloss* obtidos para os casos de simulação com 3 e 11 fontes de variabilidade. De forma resumida, os resultados para ambas as dimensões foram muito semelhantes e podem ser analisados de uma só vez. O *corrloss* para k-means foi ligeiramente melhor do que para HAC enquanto o m-ISODATA teve o pior desempenho. Embora m-ISODATA mude a matriz de coeficientes de correlação em torno de 50%, a aplicação de seus cenários no problema PEG foi adequada conforme apresentado na Figura 23, com a vantagem de determinar o número de cenários.

#### 4.4.4.7 Comparação com a literatura

Tanto os casos de simulação quanto o modelo PEG foram apresentados no estudo proposto por Merrick (MERRICK, 2016), onde o autor busca o número adequado de cenários representativos para diferentes casos utilizando o algoritmo HAC com o método de Ward. No entanto, esse número aumenta com o número de séries, ou seja, com a dimensão do espaço de observações.

O algoritmo ISODATA tradicional (BALL; HALL, 1965) é capaz de obter o número de grupos baseado nas funções *split* e *merge*. No entanto, o algoritmo requer o ajuste do número esperado de grupos como um parâmetro de entrada, o que é difícil de definir uma vez que o número adequado de cenários pode variar de dezenas a milhares dependendo da dimensão da série histórica. Além disso, o algoritmo não inclui o fator de correção dimensional proposto no presente trabalho e, portanto, tem mais dificuldade para capturar os cenários de um conjunto de dados. Por fim, o ISODATA tradicional possui uma técnica menos eficiente para prever a posição de novos centroides pela função *split*, dificultando a convergência do método.

Os resultados apresentados mostram que o m-ISODATA proposto é capaz de manter uma representatividade semelhante dos cenários para diferentes conjuntos de séries históricas, uma vez que a abordagem independe da definição do número de grupos como parâmetro de entrada. Além disso, conforme discutido na Seção 4.4.1, os parâmetros do m-ISODATA são fáceis de ajustar, permitindo a sua aplicação a outros estudos. A formulação, os dados e os modelos implementados no MATLAB<sup>®</sup> estão disponíveis no repositório Code Ocean (DE PAULA et al., 2020).

#### 4.5 CONCLUSÕES PARCIAIS

Este capítulo apresentou o algoritmo de agrupamento m-ISODATA, utilizado para capturar cenários representativos de séries históricas, sem a necessidade de definir o número de grupos como parâmetro de entrada. O algoritmo proposto foi comparado com a simulação de Monte Carlo e os conhecidos algoritmos k-means e *Hierarchical Agglomerative Clustering* usando um problema de Fluxo de Potência Ótimo Probabilístico (FPOP). Além disso, um modelo de Planejamento da Expansão da Geração (PEG) com 11 séries históricas compreendendo dados de demanda e geração eólica e solar foi resolvido para mostrar a eficácia da abordagem proposta. A partir dos resultados, alguns pontos podem ser destacados:

- A função *split* proposta prediz com precisão a posição de novos centroides;
- O Fator de Correção de Dimensão (FCD) proposto torna o m-ISODATA capaz de capturar cenários de séries históricas com diferentes dimensões de forma automática;
- Os erros introduzidos nas análises que consideram cenários são pequenos;
- O m-ISODATA fornece cenários com representatividade uniforme sobre o espaço de observação, o que não se consegue com o uso de k-means;
- O m-ISODATA fornece o número de cenários de forma automática, o que significa uma vantagem sobre k-means ou HAC;
- A Simulação de Monte Carlo (SMC) exige um maior número de cenários para apresentar um nível de erro semelhante aos de qualquer algoritmo de agrupamento testado;

- Dois índices foram introduzidos para verificar a sensibilidade do m-ISODATA com relação à variação de seu parâmetro principal,  $d_{min}^0$ ; além disso, verificou-se que uma ampla faixa de valores para  $d_{min}^0$  garante um grau de erros adequado;
- O índice denominado Erro Quadrático Compensado (*CQE*) foi introduzido para mostrar os benefícios da aplicação do FCD proposto;
- Uma tabela de valores *default* para os parâmetros do m-ISODATA foi apresentada para facilitar sua aplicação em outros problemas e estudos.

Todas as análises realizadas mostraram que o m-ISODATA foi capaz de identificar um número adequado de cenários de forma automática e com boa precisão para diferentes aplicações. Dois problemas de aplicação, FPOP e PEG, e três conjuntos de dados foram avaliados.

Para trabalhos futuros, faz-se necessário melhorar o problema da perda dos coeficientes de correlação com o m-ISODATA e na perda de qualidade quando o número de dimensões aumenta.



## 5 PLANEJAMENTO DA EXPANSÃO DA TRANSMISSÃO CONSIDERANDO A ALOCAÇÃO ÓTIMA DE DISPOSITIVOS DE ARMAZENAMENTO DE ENERGIA VIA COMPUTAÇÃO PARALELA

### 5.1 CONSIDERAÇÕES INICIAIS

Até o presente, a literatura apresenta técnicas para solucionar o Problema de Expansão da Transmissão (PET) considerando os dispositivos de armazenamento na rede de transmissão com janelas limitadas a dias ou semanas operativas para reduzir o tamanho do problema de otimização e torná-lo computacionalmente viável. A modelagem limitada a dias ou semanas operativas pode trazer resultados precisos para Dispositivos de Armazenamento de Energia (DAEs) a bateria, que normalmente apresentam uma baixa relação potência/energia e podem ser carregados e descarregados dentro do intervalo de um dia, ciclicamente. Porém, para integrar as ações dos DAEs nos sistemas de transmissão que apresentam comportamentos mais complexos, como a existência de hidroelétricas e termoeelétricas, ambas podendo ter disponibilidade sazonal de capacidade de geração podem exigir a avaliação cronológica do sistema ao longo de todo o ano operativo, conforme discutido em (ZHUO et al., 2020; TEJADA-ARANGO et al., 2018; DIAZ; INZUNZA; MORENO, 2019) .

Na Tabela 12 apresenta-se um resumo das principais características das publicações mais recentes que propuseram metodologias para a solução do co-planejamento de transmissão e DAE que levam em conta a restrição de balanço de energia. Nas formulações avaliadas, foram identificados dois tipos de investimento em DAEs, contínuo (C) ou binário (B). Os investimentos formulados de forma binária possibilitam a alocação de DAEs com valores de capacidades de potência e energia pré-estabelecidos. Já os investimentos formulados de forma contínua otimizam as capacidades de potência e energia dos DAEs instalados de forma precisa. Neste sentido, destaca-se o uso de uma formulação mista em (WANG; GENG; JIANG, 2019), onde o investimento em um DAE é definido de forma binária, atribuindo um custo fixo enquanto as capacidades de potência e energia são definidas de forma contínua, com custos variáveis.

Quanto ao horizonte de planejamento, apenas duas referências modelaram o problema de forma dinâmica (D), enquanto a grande maioria das publicações levaram em conta apenas o final do horizonte, de forma estática (E). Foram consideradas três tipos de tecnologias nos artigos avaliados, sendo: BESS (Battery Energy Storage Systems), CAES (Compressed Air Energy Systems) e PHES (Pumped Hydro Energy Storage).

Quanto às janelas temporais, utilizadas para avaliar a operação cronológica dos DAEs e considerar séries históricas de geração e demanda, a maioria dos trabalhos utilizaram janelas de 24 horas, apenas as referências (NIKOUBAKHT; AGHAEI, 2019) e (LUBURIĆ; PANDŽIĆ; CARRIÓN, 2020) consideraram janelas maiores, de 48 e 120 horas, respectivamente. Janelas maiores são um gargalo prático das formulações uma vez que geram problemas de programação que demandam alto custo computacional. Nestas formulações, toda a modelagem matemática da

rede de transmissão precisa ser replicada para cada período representativo da janela temporal, essas réplicas são interligadas através da restrição de balanço de energia pelas variáveis de nível de carregamento dos DAEs. Assim, a formulação detalhada neste capítulo contribui ao permitir desacoplar temporalmente as restrições de balanço de energia nos DAEs, possibilitando a solução rápida e simultânea dos problemas de operação para cada cenário de maneira distribuída, reduzindo o custo computacional e uso de memória.

Tabela 12 – Taxonomia das publicações recentes que propõe metodologias para solução do co-planejamento da transmissão e DAEs. Onde HP indica Horizonte de Planejamento.

Referência	Ano	Inv. DAE	Janela temporal	HP	Tecnologia
(QIU et al., 2017)	2017	C	24h	D	BESS
(ZHANG; CONEJO, 2018a)	2018	B	24h	E	PHES
(DVORKIN et al., 2018)	2018	C	24h	E	BESS
(FALUGI; KONSTANTELOS; STRBAC, 2018)	2018	B	24h	D	BESS, CAES e PHES
(NIKOOBAKHT; AGHAEI, 2019)	2019	B	48h	E	BESS
(GAN et al., 2019)	2019	C	24h	E	BESS e PHES
(WANG; GENG; JIANG, 2019)	2019	B e C	24h	E	BESS
(LUBURIĆ; PANDŽIĆ; CARRIÓN, 2020)	2020	C	120h	E	BESS
(MAZAHERI et al., 2021)	2021	C	24h	E	CAES
Proposta	-	C	8760h	E	BESS

Fonte: do autor.

Outros trabalhos da literatura que consideram investimento na transmissão e a existência de DAEs, porém, sem a possibilidade de investimento nos DAES, ou trabalhos que envolvem o co-planejamento da geração e DAEs, importantes para a discussão desta proposta, foram apresentados na Seção 1.3.6.

Apesar de todas as propostas da literatura poderem ser modificadas para considerar todo o ano operativo ao invés de dias representativos, tem-se que o custo computacional crescerá muito com a consideração da restrição de balanço de energia, uma vez que a rede de transmissão passa a ser replicada dentro do modelo para cada período representativo, resultando em problemas de programação computacionalmente difíceis de solucionar.

Neste sentido, neste capítulo propõe-se evitar esse problema ao replicar a rede de transmissão de forma distribuída através da decomposição de Benders e computar cada cenário operativo de forma paralela, desacoplando temporalmente a restrição de balanço de energia. Assim, computadores com diversos núcleos de computação podem resolver de forma simultânea os problemas de programação linear para cada período operativo. Portanto, as contribuições deste capítulo podem ser resumidas em:

- Apresentar uma formulação inovadora para realizar o PET e alocação ótima de DAEs;
- Avaliar a operação dos planos de expansão de forma distribuída, desacoplando as restrições de balanço de energia nos DAEs;

- Introdução de restrições auxiliares ao problema mestre, tornando-o eficiente em definir os níveis de energia nos DAEs para cada cenário;
- Introdução do Algoritmo de Agrupamento de Períodos Representativos (AAPR) para gerar cenários cronológicos sem a necessidade de definir o número de grupos como parâmetro de entrada.

## 5.2 FORMULAÇÃO COMPLETA (NÃO-LINEAR)

A formulação completa do PET, detalhada nas expressões (5.1)-(5.20) consiste em um problema de programação não linear inteiro misto (PNLIM) de difícil solução.

$$\min_{\chi} \left( \sum_{k \in K^C} C_k^T I_k^T + \sum_{y \in Y^C} (C_y^{YP} I_y^{YP} + C_y^{YE} I_y^{YE}) + \sum_{s \in S} \left[ \Delta_s \left( \sum_{g \in G} co_g pg_{g,s} + \sum_{y \in Y} \left[ co_y (py_{y,s}^{ch} + py_{y,s}^{dis}) + ch (hy_{y,s}^{(+)} + hy_{y,s}^{(-)}) \right] + \sum_{b \in B^D} ch \cdot hd_{b,s} \right) \right] \right) \right)$$

sendo  $\chi = \{ I^T, I^{YP}, I^{YE}, pg, \theta, hd, hr, hy, py^{ch}, py^{dis} \}$

(5.1)

onde:

- $C_k^T$  e  $I_k^T$  são o custo e o investimento na capacidade de transmissão do circuito  $k$ ;
- $K^C$  é o conjunto de linhas candidatas à expansão;
- $C_y^{YP}$ ,  $I_y^{YP}$ ,  $C_y^{YE}$  e  $I_y^{YE}$  são os custos e os investimentos, respectivamente, em potência e energia do DAE  $y$ ;
- $Y^C$  é o conjunto de DAEs candidatos à expansão;
- $\Delta$  é a duração do cenário  $s$ ;
- $S$  é o conjunto de cenários;
- $co_g$  é o custo de operação associado ao gerador  $g$ ;
- $pg_{g,s}$  é a potência despachada pelo gerador  $g$  no cenário  $s$ ;
- $G$  é o conjunto de geradores, renováveis ou não;  $co_y$  é o custo de operação associado ao DAE  $y$ ;
- $py_{y,s}^{ch}$  e  $py_{y,s}^{dis}$  são as potências de carregamento e descarregamento do DAE  $s$  no cenário  $s$ ;
- $Y$  é o conjunto de DAEs;  $ch$  é a penalidades associada ao uso das variáveis de folga;

- $B^D$  é o conjunto de barras com demanda;
- $\chi$  agrega os conjuntos de variáveis de decisão do problema de otimização, sendo:  $I^T$ , investimento na transmissão;  $I^{YP}$ , investimento em potência de DAEs;  $I^{YE}$ , investimento em energia de DAEs;  $pg$ , potência despachada por geradores;  $\theta$ , ângulos nodais;  $hd$ , corte de carga;  $hr$ , corte de geração renovável;  $py^{ch}$  carregamento de DAEs;  $py^{dis}$ , descarregamento de DAEs.

Para cada cenário  $s$ , o balanço de potência imposto em (5.2)-(5.4) deve ser satisfeito para cada barra  $b$  do sistema. Assim, a soma da potência gerada pelas unidades geradoras, potências fornecidas pelos DAEs e corte de carga, deve ser igual à soma da demanda, consumo dos DAEs, injeção líquida de fluxo de potência no sistema de transmissão e corte de vento. Para evitar o uso de variáveis binárias para definir o estado de carregamento ou descarregamento de um DAE e, ao mesmo tempo evitar que o *solver* defina estados de carregamento e descarregamento simultâneos, o custo/penalidade de corte de renováveis é desconsiderado e um custo fictício de operação do DAE é introduzido na função objetivo. Deve-se atentar que tanto  $py^{ch}$  quanto  $py^{dis}$  são definidos como variáveis contínuas não-negativas. Note que em (5.4), o produto entre as variáveis  $I^T$  e  $\theta_{ij,s}$  torna o problema não-linear.

$$\sum_{g \in G_b} pg_{g,s} + \sum_{y \in Y_b} \left( py_{y,s}^{ch} - py_{y,s}^{dis} + hy_{y,s}^{(+)} - hy_{y,s}^{(-)} \right) - \sum_{k \in K_b} f_{k,s} + hd_{b,s} - hr_{b,s} = d_{b,s} - \sum_{r \in R_b} pr_{r,s}, \quad \forall b \in B, s \in S \quad [\lambda_{b,s}] \quad (5.2)$$

$$f_{k,s} = -b_k \cdot \theta_{ij,s}, \quad \forall k \in K^E, s \in S \quad (5.3)$$

$$f_{k,s} = -b_k \cdot \theta_{ij,s} \cdot I_k^T, \quad \forall k \in K^C, s \in S \quad (5.4)$$

onde:  $G_b$  é o conjunto de geradores não-renováveis conectados à barra  $b$ ;  $d_{b,s}$  é a demanda da barra  $b$  no cenário  $s$ ;  $hy_{y,s}^{(+)}$  e  $hy_{y,s}^{(-)}$  são as variáveis de folga do DAE  $y$  e cenário  $s$ ;  $hr_{b,s}$  é o corte de renováveis na barra  $b$  e cenário  $s$ ;  $pr_{r,s}$  é a potência ativa injetada pelo gerador renovável  $r$  no cenário  $s$ ;  $R_b$  é o conjunto de geradores renováveis conectados à barra  $b$ ;  $f_{k,s}$  é o fluxo de potência ativo que flui através da linha  $k$ , cujas barras terminais são as barras  $i$  e  $j$ ;  $K_b$  é o conjunto de linhas conectadas à barra  $b$ ;  $b_k$  é a susceptância da linha  $k$ ;  $\theta_{ij,t}$  é a diferença angular entre as barras  $i$  e  $j$  no cenário  $s$ ;  $K^E$  e  $K^C$  são os conjuntos de linhas existentes e candidatas à expansão;  $\lambda_{b,s}$  é a variável dual associada à restrição de balanço de potência.

Cada cenário ainda deve satisfazer o balanço de energia em cada DAE da rede, conforme definido em (5.5)-(5.7). Em (5.5), a energia armazenada no cenário posterior é calculada. Em (5.6) e (5.7) são definidos os valores iniciais e finais de armazenamento de energia para cada DAE. O balanço de energia acopla temporalmente os cenários, uma vez que  $e_{y,s}$  e  $e_{y,s+1}$  são

definidos simultaneamente em (5.5).

$$e_{y,s+1} = \gamma_y^A \cdot e_{y,s} + \Delta_s \left( \eta_y^{ch} \cdot py_{y,s}^{ch} - \frac{1}{\eta_y^{dis}} \cdot py_{y,s}^{dis} \right), \forall y \in Y, s \in S \quad (5.5)$$

$$e_{y,1} = e_y^{inicial}, \forall y \in Y \quad (5.6)$$

$$e_{y,ns+1} = e_y^{final}, \forall y \in Y \quad (5.7)$$

onde:  $e_{y,s+1}$  e  $e_{y,s}$  representam a energia armazenada no DAE  $y$  nos cenários  $s + 1$  e  $s$ ;  $ns$  é o número de cenários;  $\eta_y^{ch}$  e  $\eta_y^{dis}$  são as eficiências de carregamento e descarregamento;  $\gamma_y$  é a taxa horária de auto-descarregamento.

A restrição de limite de geração dos geradores não-renováveis é apresentada em (5.8).

$$0 \leq pg_{g,s} \leq \overline{pg}_g, \forall g \in G, s \in S \quad (5.8)$$

onde:  $\overline{pg}_g$  é a potência nominal do gerador  $g$ ;

Os limites de potência de carregamento e descarregamento e de capacidade de armazenamento dos DAEs são apresentados em (5.9)-(5.12). Já os limites das variáveis de folga dos DAEs são definidos em (5.13)-(5.14)

$$0 \leq py_{y,s}^{ch}, py_{y,s}^{dis} \leq \overline{py}_y, \forall y \in Y^E, s \in S \quad (5.9)$$

$$0 \leq py_{y,s}^{ch}, py_{y,s}^{dis} \leq I_y^{YP}, \forall y \in Y^C, s \in S \quad (5.10)$$

$$0 \leq e_{y,s} \leq \bar{e}_y, \forall y \in Y^E, s \in S \quad (5.11)$$

$$0 \leq e_{y,s} \leq I_y^{YE}, \forall y \in Y^C, s \in S \quad (5.12)$$

$$0 \leq hy_{y,s}^{(+)}, hy_{y,s}^{(-)} \leq \bar{e}_y, \forall y \in Y^E, s \in S \quad (5.13)$$

$$0 \leq hy_{y,s}^{(+)}, hy_{y,s}^{(-)} \leq I_y^{YE}, \forall y \in Y^C, s \in S \quad (5.14)$$

onde:  $\overline{py}_y$  e  $\bar{e}_y$  são, respectivamente, a potência nominal e a capacidade de armazenamento do DAE  $y$ .

O corte de carga de cada barra é limitado pelo nível de demanda no cenário  $s$ , conforme (5.15). Já o corte de renováveis é limitado pela disponibilidade de cada usina eólica no cenário  $s$ , conforme (5.16). A potência ativa injetada pelo gerador renovável  $r$  é definido pela sua capacidade instalada e o despacho definido pelo cenário  $s$  conforme (5.17)-(5.18).

$$0 \leq hd_{b,s} \leq d_{b,s}, \forall b \in B^D, s \in S \quad (5.15)$$

$$hr_{b,s} \leq \sum_{r \in R_b} pr_{r,s}, \forall b \in B^R, s \in S \quad (5.16)$$

$$pr_{r,s} \leq a_{r,s} \cdot \bar{p}r_r, \forall r \in R^E, s \in S \quad (5.17)$$

$$pr_{r,s} \leq a_{r,s} \cdot I_r^R, \forall r \in R^C, s \in S \quad (5.18)$$

onde:  $a_{r,s}$  define o despacho percentual da usina  $r$  em relação à sua capacidade de geração no cenário  $s$ .

Em (5.19) e (5.20) são definidos os limites de fluxos nas linhas da rede.

$$|f_{k,s}| \leq \bar{f}_k, \forall k \in K^E, s \in S \quad (5.19)$$

$$|f_{k,s}| \leq \bar{f}_k \cdot I_k^T, \forall k \in K^C, s \in S \quad (5.20)$$

onde:  $\bar{f}_k$  é a capacidade de transmissão da linha  $k$ .

Os limites no investimento em potência e capacidade de armazenamento dos DAEs são representados respectivamente em (5.21) e (5.22). Em (5.23), o a variável de investimento em transmissão é modelada como inteira, e é limitada em (5.24).

$$0 \leq I_y^{YP} \leq \bar{I}^{YP}_y, \forall y \in Y^C \quad (5.21)$$

$$0 \leq I_y^{YE} \leq \bar{I}^{YE}_y, \forall y \in Y^C \quad (5.22)$$

$$I_k^T \in \mathbb{N}, \forall k \in K^C \quad (5.23)$$


$$0 \leq I_k^T \leq \bar{I}_k^T, \forall k \in K^C \quad (5.24)$$

### 5.3 FORMULAÇÃO DECOMPOSTA CLÁSSICA (NÃO PARALELIZÁVEL)

Organizando os coeficientes das restrições (5.2)-(5.20) de forma harmoniosa, pode-se facilmente observar o arranjo ilustrado na Figura 25. Desta maneira, pela decomposição de Benders, pode-se dividir o problema em um problema mestre, formado pelas variáveis complicantes de investimento (representadas pelas matrizes  $INV^{[s]}$ ) e por um subproblema, formado por todos os períodos operativos (representados pelas matrizes  $OPE^{[s]}$ ) que estão cronologicamente acoplados pelas variáveis de nível de energia nos DAEs nas restrições de balanço de energia, conforme (5.5).

Nas subseções a seguir apresenta-se a formulação que decompõe o problema apresentado na Seção 5.2 em problema mestre e um subproblema através da DB. A decomposição lineariza a

Figura 25 – Estrutura matricial do PET considerando DAEs, dividida em  $S$  subproblemas.



Fonte: do autor.

formulação completa solucionando as variáveis inteiras de investimento em transmissão de forma iterativa no problema mestre, enquanto o subproblema fica responsável por definir os valores das demais variáveis segundo a decisão de expansão em transmissão, incluindo as decisões de investimento em potência e energia nos DAEs.

### 5.3.1 Problema mestre

Responsável por definir a decisão de expansão em transmissão, o problema mestre é formulado em (5.25).

$$C_{inv} = \min_{I^T} \sum_{k \in KC} C_k^T I_k^T + \alpha \quad (5.25)$$

Sujeito a (5.24), aos cortes de Benders (ver Seção 5.3.3) e:

$$\alpha \geq 0 \quad (5.26)$$

onde:  $C_{inv}$  é o custo de investimento definido pelo problema mestre.

### 5.3.2 Subproblema

O subproblema é definido pela formulação apresentada em (5.27) com o objetivo de minimizar os custos de operação, o corte de carga e o uso das variáveis de folga dos DAEs.

$$C_{sp} = \min_{\chi} \left[ \sum_{y \in Y^C} (C_y^{YP} I_y^{YP} + C_y^{YE} I_y^{YE}) + \sum_{s \in S} \Delta_s \left( \sum_{g \in G} c_{og} p g_{g,s} + \sum_{y \in Y} \left[ c_{oy} (p y_{y,s}^{ch} + p y_{y,s}^{dis}) + ch (h y_{y,s}^{(+)} + h y_{y,s}^{(-)}) \right] + \sum_{b \in B^D} ch \cdot h d_{b,s} \right) \right]$$

sendo  $\chi = \{ I^{YP}, I^{YE}, pg, \theta, hd, hr, hy, py^{ch}, py^{dis} \}$

(5.27)

sujeito a (5.2)-(5.3), (5.5)-(5.19) e:

$$f_{k,s} = -b_k \cdot \theta_{ij,s} \cdot I_k^{T*}, \forall k \in K^C$$
(5.28)

$$|f_{k,s}| \leq \bar{f}_k \cdot I_k^{T*}, \forall k \in K^C$$
(5.29)

onde:  $C_{sp}$  é o custo de operação e investimento associado ao subproblema; e os sobrescritos (\*) indicam valores obtidos com a solução do problema mestre.

Note que o cálculo do fluxo de potência nas linhas de transmissão candidatas em (5.28) é linear. A substituição da variável  $I_k^T$  pelo parâmetro  $I_k^{T*}$  remove a não-linearidade da formulação completa (PEREIRA et al., 1985).

### 5.3.3 Geração do corte de Benders

O corte de Benders é gerado através da formulação proposta em (PEREIRA et al., 1985), apresentada em (5.30).

$$C_{sp} - \sum_{s \in S} \sum_{k \in K^C} \pi_{k,s}^T (I_k^T - I_k^{T*}) \leq \alpha$$
(5.30)

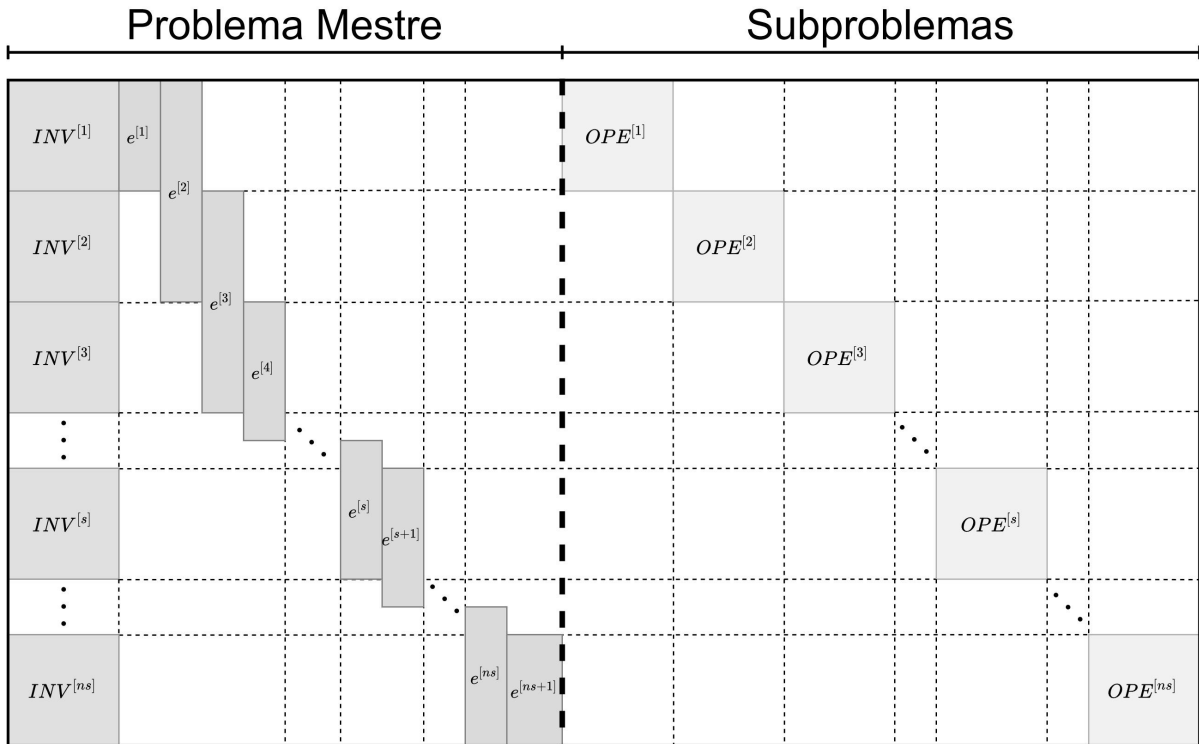
onde:  $\pi_{k,s}^T$  é um índice de sensibilidade relacionado ao investimento na transmissão, calculado por (2.34) ou (2.35) conforme detalhado na Seção 2.3.3.

## 5.4 FORMULAÇÃO DECOMPOSTA PARALELIZÁVEL

Para decompor a formulação completa e torná-la paralelizável, reorganiza-se a estrutura obtida na Figura 25, de modo a obter a estrutura apresentada na Figura 26. Nesta, as variáveis que acoplam os períodos operativos são consideradas como variáveis complicantes do problema. Assim, através da decomposição de Benders, é possível dividir o problema em: um problema mestre, composto pelas variáveis de investimento e níveis de energia dos DAES; e  $S$  subproblemas que podem ser solucionados de forma simultânea uma vez que possuem conjuntos de variáveis independentes e cada subproblema representa um cenário operativo.



Figura 26 – Estrutura matricial do PET considerando DAEs, dividida em  $ns$  subproblemas, reorganizada de forma apropriada para aplicar a decomposição de Benders.



Fonte: do autor.

#### 5.4.1 Problema mestre

Para tornar os subproblemas paralelizáveis, é proposta uma formulação especializada do problema mestre que conta com restrições auxiliares além do conjunto de corte de Benders. Em (5.31) define-se a função objetivo do problema mestre, que consiste em minimizar os custos de investimentos em DAEs e transmissão e definir os níveis de energia dos DAEs.

$$C_{inv} = \min_{\chi} \left( \sum_{k \in KC} C_k^T I_k^T + \sum_{y \in Y^C} (C_y^{YP} I_y^{YP} + C_y^{YE} I_y^{YE}) + \sum_{s \in S} \alpha_s \right) \quad (5.31)$$

$$\text{sendo } \chi = \{e, I^T, I^{YP}, I^{YE}, \alpha\}$$

Sujeito a: cortes de Benders (ver Seção 5.4.3); (5.6)-(5.7), (5.11)-(5.12) e (5.21)-(5.24); e:

$$e_{y,s+1} \geq \gamma_y^{\Delta_s} \cdot e_{y,s} - \Delta_s \frac{\overline{p}_y}{\eta_y^{dis}}, \quad \forall y \in Y^E, s \in S \quad (5.32)$$

$$e_{y,s+1} \geq \gamma_y^{\Delta_s} \cdot e_{y,s} - \Delta_s \frac{I_y^{YP}}{\eta_y^{dis}}, \quad \forall y \in Y^C, s \in S \quad (5.33)$$

$$e_{y,s+1} \leq \gamma_y^{\Delta_s} \cdot e_{y,s} + \Delta_s \cdot \overline{p}_y \cdot \eta_y^{ch}, \quad \forall y \in Y^E, s \in S \quad (5.34)$$

$$e_{y,s+1} \leq \gamma_y^{\Delta_s} \cdot e_{y,s} + \Delta_s \cdot I_y^{YP} \cdot \eta_y^{ch}, \quad \forall y \in Y^C, s \in S \quad (5.35)$$

$$\alpha_s \geq 0 \quad (5.36)$$

onde:  $C_{inv}$  é o custo de investimento definido pelo problema mestre.

A restrição auxiliar (5.11) limita o nível de energia armazenado no DAE  $y$ , existente. A restrição auxiliar, definida por (5.12), informa ao problema mestre que o investimento em capacidade de energia deve ser superior ou igual ao pico de energia armazenada no DAE  $y$  demandado pelos cortes de Benders. Apesar de parecer trivial, na presente formulação, os cortes de Benders só carregam a informação sobre o quanto de potência de DAEs cada subproblema demanda. Como os subproblemas são independentes e desacoplados, eles não retornam nenhuma informação sobre níveis de energias para o problema mestre. Assim, a restrição (5.12) contorna o problema de falta de informação acerca de investimento em capacidade de energia dos DAEs. As restrições auxiliares (5.21) e (5.22) limitam, respectivamente, os investimentos em capacidades de potência e energia no DAE  $y$ .

As demais restrições auxiliares, apresentadas em (5.32)-(5.35) são propostas neste trabalho para acelerar o processo de convergência da decomposição de Benders. Essas restrições impõem limites para o nível energético dos DAEs para cada estágio, acoplando a solução de cada subproblema. Com estas restrições, garante-se uma factibilidade geral para o ano operativo da rede. As restrições (5.32)-(5.35) garantem que a energia armazenada em cada DAE se mantenham em níveis adequados para manter a factibilidade de solução de cada subproblema. A restrição (5.36) define a variável de folga referente ao cenário  $s$  como não-negativa.

Deve-se salientar que na formulação completa do PET, descrita em (5.1)-(5.20), o nível de energia nos DAEs em cada cenário não é uma variável de decisão na formulação MINLP e aparece apenas como uma variável dependente das potências de carregamento e descarregamento. Já na decomposição de Benders proposta nessa seção, o nível de energia dos DAEs é uma variável de decisão do problema mestre e é representado por “ $e$ ” em (5.31), esta alteração garante que os subproblemas possam ser desacoplados de forma adequada. Desta forma, os níveis de energia também devem ser modelados como variáveis de decisão nos subproblemas, porém com valores fixados pré-definidos conforme detalhado na Seção 5.4.2.

#### 5.4.2 Subproblemas

Cada subproblema  $s$  é definido pela formulação apresentada em (5.37) com o objetivo de minimizar os custos de operação, o corte de carga e o uso das variáveis de folga dos DAEs.

$$C_{ope}^{[s]} = \min_{\chi} \Delta_s \left( \sum_{g \in G} co_g pg_{g,s} + \sum_{y \in Y} \left[ co_y \left( py_{y,s}^{ch} + py_{y,s}^{dis} \right) + ch \left( hy_{y,s}^{(+)} + hy_{y,s}^{(-)} \right) \right] + \sum_{b \in B^D} ch \cdot hd_{b,s} \right)$$

sendo  $\chi = \left\{ pg, \theta, hd, hr, hy, py^{ch}, py^{dis}, e, I^T, I^{YP}, I^{YE} \right\}$

(5.37)

sujeito a (5.2)-(5.3) e (5.5)-(5.19), considerando  $S = s$ ; e:

$$e_{y,s} = e_{y,s}^*, \forall y \in Y \quad [\lambda_{y,s}^e] \quad (5.38)$$

$$e_{y,s+1} = e_{y,s+1}^*, \forall y \in Y \quad [\lambda_{y,s+1}^e] \quad (5.39)$$

$$I_y^{YP} = I_y^{YP*}, \forall y \in Y^C \quad [\lambda_{y,s}^{YP}] \quad (5.40)$$

$$I_y^{YE} = I_y^{YE*}, \forall y \in Y^C \quad (5.41)$$

$$f_{k,s} = -b_k \cdot \theta_{ij,s} \cdot I_k^{T*}, \forall k \in K^C \quad (5.42)$$

$$|f_{k,s}| \leq \bar{f}_k \cdot I_k^{T*}, \forall k \in K^C \quad (5.43)$$

onde:  $C_{ope}^{[s]}$  é o custo de operação associado ao subproblema  $s$ ; \* indicam valores obtidos com a solução do problema mestre;  $\lambda_{y,s}^e$  e  $\lambda_{y,s}^{YP}$  são variáveis duais obtidas com a solução do subproblema  $s$ .

### 5.4.3 Geração de corte de Benders

A decomposição de Benders especializada proposta utiliza a formulação multicut (YOU; GROSSMANN, 2013). Assim, para cada subproblema de operação infactível, isto é, que apresenta o uso de alguma variável de folga, é gerado um corte de Benders conforme (5.44).

$$\begin{aligned} C_{ope}^{[s]} - \sum_{y \in Y} [\lambda_{y,s}^e (e_{y,s} - e_{y,s}^*) + \lambda_{y,s+1}^e (e_{y,s+1} - e_{y,s+1}^*)] \\ - \sum_{y \in Y^C} \lambda_{y,s}^{YP} (I_y^{YP} - I_y^{YP*}) - \sum_{k \in K^C} \pi_{k,s}^T (I_k^T - I_k^{T*}) \leq \alpha_s \end{aligned} \quad (5.44)$$

onde:  $\pi_{k,s}^T$  é um índice de sensibilidade relacionado ao investimento na transmissão, calculado por (2.34) ou (2.35) conforme detalhado na Seção 2.3.3.

## 5.5 ALGORITMO AAPR

Nesta seção apresenta-se o algoritmo de agrupamento de períodos representativos (AAPR). O algoritmo é uma heurística eficiente que objetiva agrupar períodos representativos das curvas históricas que apresentam forte similaridade, com o intuito de reduzir o número de cenários a serem avaliados por ferramentas de análise de sistemas de energia. O algoritmo é capaz de agrupar múltiplas séries históricas e é composto pelos 5 passos detalhados a seguir. Para o algoritmo funcionar adequadamente, deve-se considerar séries históricas normalizadas no intervalo  $[0, 1]$ .

**Passo 1: Inicialização.** Defina: um valor para o parâmetro  $d_{min}$ ; e cada observação das séries históricas como um período representativo.

**Passo 2: Agrupamento.** Para cada par adjacente de períodos representativos “A” e “B”, forme um novo período representativo “C”, conforme (5.45)-(5.47).

$$\underline{x}_p^{[\delta]} = \min \left( X_p^{[\delta]} \right), \forall \delta \in D \quad (5.45)$$

$$\bar{x}_p^{[\delta]} = \max \left( X_p^{[\delta]} \right), \forall \delta \in D \quad (5.46)$$

$$X_C = X_A \cup X_B, \text{ se } \left| \underline{x}_A^{[\delta]} - \bar{x}_B^{[\delta]} \right| < d_{min}, \forall \delta \in D \text{ e } \left| \bar{x}_A^{[\delta]} - \underline{x}_B^{[\delta]} \right| < d_{min}, \forall \delta \in D \quad (5.47)$$

onde:  $X_p^{[\delta]}$  é a  $\delta$ -ésima dimensão do conjunto de dados pertencentes ao período representativo  $p$ ; de forma similar,  $X_A^{[\delta]}$  e  $X_B^{[\delta]}$  são respectivamente, a  $\delta$ -ésima dimensão dos conjuntos de dados  $X_A$  e  $X_B$ ; e  $X_C$  é o agrupamento dos dados pertencentes aos períodos representativos “A” e “B”.

**Passo 3: Convergência.** Caso algum par adjacente de períodos representativos tenha sido agrupado, repita o Passo 2. Caso contrário, prossiga para o Passo 4.

**Passo 4: Cálculo do ponto representativo.** Calcule os  $D$  elementos  $m_p^{[\delta]}$  do vetor  $\vec{m}_p$  que representarão o período representativo definido pelo conjunto  $X_p$ , conforme (5.48)-(5.49).

$$m_p^{[\delta]} = x_i^{[\delta]}, \text{ para } i = \underset{i}{\operatorname{argmin}} \left\{ \left| x_i^{[\delta]} - \left( \bar{x}_p^{[\delta]} - \underline{x}_p^{[\delta]} \right) \cdot c_p^{[\delta]} + \underline{x}_p^{[\delta]} \right|, \forall i \in X_p \right\}, \forall \delta \in D \quad (5.48)$$

$$\vec{c}_p = \frac{1}{X_p^{dur}} \sum_{\vec{x} \in X_p} \vec{x} \quad (5.49)$$

onde:  $m_p^{[\delta]}$ , é a  $\delta$ -ésima dimensão de  $\vec{m}_p$ , ou seja, é o ponto representativo da série histórica  $\delta$  pertencente ao período representativo  $p$ ;  $m_i^{[\delta]}$  é o  $i$ -ésimo elemento da dimensão  $\delta$  pertencente ao período representativo definido por  $X_p$ ; sendo  $X_p$  o conjunto de dados pertencentes ao período representativo  $p$ ;  $c_p^{[\delta]}$  é a  $\delta$ -ésima dimensão do centroide  $\vec{c}_p$  dos dados do período representativo  $p$ , calculado conforme (5.49).

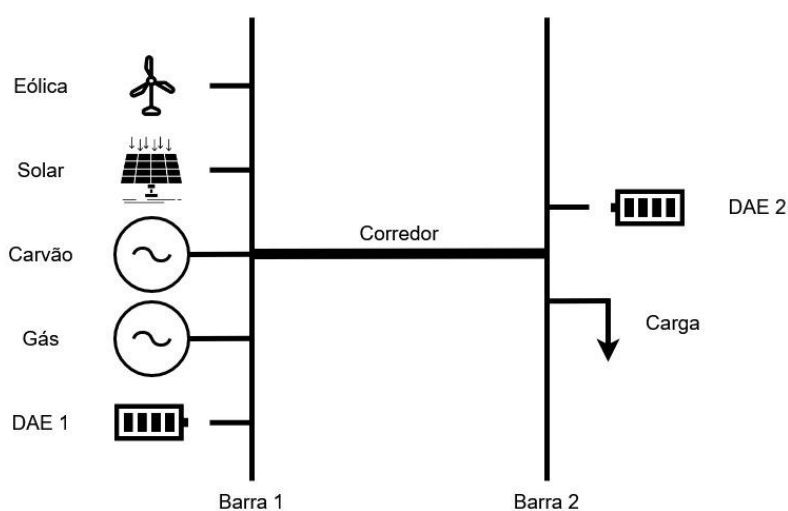
## 5.6 RESULTADOS

Esta seção apresenta a aplicação das metodologias propostas para solução do co-planejamento de transmissão e DAEs em dois sistemas testes. Primeiramente, são realizados estudos de casos em um sistema simplificado de duas barras para expor as vantagens do PET considerando a alocação ótima de DAEs. Logo, as formulações clássica e paralelizável são comparadas através do sistema teste GARVER (GARVER, 1970).

### 5.6.1 Estudos de caso no sistema de duas barras - Tutorial

Com o intuito de avaliar o impacto da alocação de DAEs no PET, é proposto um sistema teste de duas barras, sendo uma de geração e outra de demanda. Nas análises, ambas as barras são candidatas a alocação de DAEs. A barra de geração contém geradores térmicos (controláveis) a gás e a carvão e geradores renováveis (não-controláveis) eólicos e solares. A Figura 27 apresenta o diagrama do sistema. Os tempos computacionais apresentados neste capítulo foram obtidos com um processador AMD Ryzen™ 5 2400G com 3.6GHz e 16 Gb de memória RAM. Foram considerados 4 núcleos de processamento para as simulações que utilizam computação paralela.

Figura 27 – Sistema teste de duas barras.



Fonte: do autor.

Com o único intuito de aprofundar mais nas análises discutidas nesta seção, o investimento na capacidade de transmissão do corredor entre as barras do sistema é modelado por uma variável contínua e a formulação completa apresentada na Seção 5.2 é linearizada através do modelo de transportes (PEREIRA et al., 1985). Para considerar o modelo de transportes relaxam-se as restrições (5.3)-(5.4), relativas ao balanço de potência, e a restrição (5.23), responsável por limitar as variáveis de investimento em transmissão em variáveis inteiras. Por fim, substitui-se as variáveis de decisão  $\theta$  pelas variáveis de decisão de fluxo de potência ativa em cada linha de transmissão. Desta forma, a variável  $\bar{I}_k^T$  que limita o investimento em transmissão na restrição (5.24) deixa de representar o limite de investimento em número de linhas de transmissão e passa a representar o limite de capacidade de transmissão, em **MW**.

Com as alterações propostas, o problema de PET e alocação ótima de DAEs passa a ser um problema de programação linear, cuja solução é realizada via método dos pontos interiores através da função *linprog* do *Optimization Toolbox* do MATLAB. Vale ressaltar que para o sistema de 2 barras proposto, o modelo de transportes seria equivalente aos modelos linearizados propostos nas seções 5.3 e 5.4, se não fosse o investimento em transmissão modelado de forma contínua. Ao simplificar o problema da forma proposta, é possível realizar as análises desta

seção com baixo custo computacional sem prejuízo à precisão dos resultados.

Os custos de operação e investimento do sistema teste são apresentados na Tabela 13. Os custos de operação e emissão de CO<sub>2</sub> são detalhados em (LAZARD, 2018). Os custos de investimento em DAEs foram extraídos de (JABR; DŽAFIĆ; PAL, 2015). Para o investimento em transmissão, considera-se um custo variável de 10 M\$/MW. Os custos de investimentos foram anualizados conforme detalhado em (PANDŽIĆ et al., 2015), considerando-se uma taxa de retorno de 5% e tempos de vida útil de 60 anos para as linhas de transmissão (DVORKIN et al., 2018), 20 anos para os DAEs (BHATTACHARJEE; SIOHANSI; ZAREIPOUR, 2021) e 25 anos para os geradores (CHEN et al., 2018). Para os DAEs, foram consideradas eficiências de 90% de carregamento, descarregamento e auto-d Descarregamento mensal.

Tabela 13 – Custos de operação e investimento do sistema teste de duas barras.

Equipamento	Operação	Investimento		Emissão de CO <sub>2</sub>
	(\$/MWh)	(\$/kW)	(\$/kWh)	(ton/MW)
Usina a gás	41	950	-	0,51
Usina a carvão	36	3000	-	0,92
DAE	-	160	240	-


Fonte: do autor.

O sistema teste conta com três séries históricas de demanda e despacho de geração eólica e solar. As séries de despacho dos geradores renováveis foram obtidas a partir de séries de velocidade de vento e intensidade solar de 2013 obtidas através do *software System Advisor Model*, disponível em (NREL, 2021). Para traduzir as curvas de velocidade de vento em potência de saída, utilizou-se a curva de potência do modelo de torre eólica da GE 1.5sle, conforme apresentada na Figura 28. Para a curva de potência despachada da usina solar, utilizou-se a irradiação direta normal em p.u., o que consiste em uma simplificação para representar a variabilidade a curto prazo da usina fotovoltaica.

Na Figura 29 apresentam-se as médias móveis, com janela semanal, das séries históricas de demanda e geração de fontes renováveis durante o ano para demonstrar a variabilidade das mesmas. Porém, a variabilidade horária que caracteriza o comportamento intermitente das fontes de energia renováveis e a curva diária de consumo de energia elétrica são representados na Figura 30, que faz um recorte da trigésima primeira semana do ano, semana em que ocorre a carga pico de demanda da série histórica.

São analisados 4 casos de simulação (CS). Para todas as análises, consideram-se: uma demanda pico de 100 MW; duas usinas solar e eólica, cada uma com capacidade de geração de 100 MW; e capacidades de geração não-renovável variando de 30 MW a 100 MW, igualmente divididas entre usinas a carvão e a gás. Não há limite para investimento em capacidade de transmissão no corredor. Apesar das capacidades de geração não-renovável serem fixadas em cada análise, os custos de investimento das mesmas são levados em conta de modo a realçar a importância da consideração de DAEs na rede. Desta forma, os casos de simulações a seguir

Figura 28 – Curva de potência da torre eólica GE1.5sle.



Fonte: modificado de (NREL, 2021).

consideram um sistema sem capacidade de transmissão no caso base. Para cada análise são realizados investimentos fixos em geração não-renovável e os demais investimento em DAEs e transmissão são definidos através do problema de programação linear. A seguir, são apresentados os detalhes de cada caso de simulação:

**CS-0:** Não há investimento em DAEs;

**CS-1:** Apenas investimento no DAE 1 (DAE localizado na barra 1);


**CS-2:** Apenas investimento no DAE 2 (DAE localizado na barra 2);

**CS-3:** Investimento em ambos os DAEs.

Na Figura 31 apresentam-se os investimentos realizados na capacidade de transmissão do corredor para os casos de simulação. Na figura foram apresentados apenas os resultados factíveis, ou seja, que não apresentaram nenhum corte de carga para todos os cenários avaliados.

Para o CS-0, sem a possibilidade de investimento em armazenamento, o sistema é factível apenas quando a geração não-renovável é compatível com a carga pico da rede, apesar dos 200 MW disponíveis das usinas solar e eólica. Isto ocorre por uma razão trivial: os geradores controláveis não possuem capacidade de atender a demanda em momentos de baixa geração renovável, exceto quando há 100 MW de capacidade de geração não-renovável. O CS-0 abordado eleva este problema a um nível crítico uma vez que existem apenas 2 usinas renováveis, cujas séries históricas não são complementares e suficientes para manter níveis adequados de geração durante a operação.

Figura 29 – Média móvel com janela semanal das séries históricas de demanda e despacho das usinas eólica e solar.




Fonte: do autor.

Pelos resultados do CS-1, considerando o investimento apenas na barra 1 (região geradora), é exigido do corredor uma capacidade de transmissão idêntica ao valor da demanda pico. Isto ocorre uma vez que o excesso de energia gerados pelas usinas renováveis, em momentos de baixa demanda, são armazenados no DAE 1; e em momentos em que a demanda se eleva, o DAE 1 fornece a potência demandada. Diferentemente do CS-0, o sistema é factível para capacidades de geração não-renovável entre 50 MW e 100 MW. Nas redes obtidas, o DAE entra em operação tanto para evitar o corte de carga, quanto para reduzir os custos operacionais, evitando o uso dos geradores não-renováveis sempre que possível.

Para o CS-2, quando o sistema considera o investimento apenas na DAE 2 (região de demanda), verifica-se que o corredor não precisa mais ter a capacidade de transmissão igual à demanda pico. Para as análises realizadas, o DAE 2 armazena energia durante períodos de operação ociosa da transmissão. Com isto, o DAE na região de demanda aumenta o fator de utilização da rede de transmissão ao longo da variabilidade da demanda e disponibilidade de geração. Na série histórica de demanda utilizada, o dia de maior demanda opera com demanda entre 60 MW e 100 MW, com demanda média de aproximadamente 80 MW. Observa-se que para os casos factíveis do CS-2, que a capacidade de transmissão fica entre 80 MW e 85 MW, o que condiz com o nível médio de demanda nos momentos de maior consumo de energia do sistema.



Figura 30 – Trigésima primeira semana das séries históricas de demanda e despacho das usinas eólica e solar em resolução horária.




Fonte: do autor.

Para o CS-3, em que há a possibilidade de instalação de DAEs em ambas as barras do sistema, tem-se um comportamento similar do investimento em transmissão do caso CS-2. Para complementar a análise do CS-3, são apresentadas, na Figura 32, as capacidades instaladas em potência e energia para capacidade instalada de geração não-renovável. Pode-se observar que houve um investimento muito elevado em potência e energia nos DAEs com o intuito de tornar o sistema factível para níveis de capacidade de geração não-renovável abaixo dos 60 MW. Ainda na Figura 32, verifica-se que há uma redução nos níveis de investimento nos DAEs com o aumento da capacidade de geração não-renovável, chegando a zerar o investimento no DAE 1 a partir de 70 MW de capacidade de geração não-renovável. Este resultado demonstra que, para situações em que o corredor de transmissão de um sistema apresenta períodos de ociosidade, passa a ser mais interessante investir em DAEs nos centros de demanda para maximizar o uso da transmissão existente, reduzindo os níveis de investimento globais.


Os custos totais (operação e investimento) obtidos para os casos de simulação são apresentados na Figura 33, demonstrando que, para o sistema analisado, os custos mínimos permaneceram em valores de capacidade de geração não-renovável entre 60% e 80% da carga pico. Além disso, os resultados demonstram que a possibilidade de investimento em DAEs tanto na região de geração quanto na região de demanda podem reduzir o custo total de operação e investimento para todos os cenários de geração não-renovável avaliados, exceto para o CS-1 na

Figura 31 – Investimento na capacidade de transmissão do corredor para os casos de simulação.



Fonte: do autor.

Figura 32 – Capacidades instaladas no sistema para o CS-3.




Fonte: do autor.

condição em que há 100 MW de capacidade de geração não-renovável.

Uma análise aprofundada dos resultados do caso de simulação CS-3 considerando 60 MW de capacidade de geração não-renovável é realizada através das figuras 34, 35 e 36. A Figura 34 apresenta os resultados obtidos para a trigésima primeira semana operativa da barra 1, semana em que ocorre a carga pico da série histórica. Observa-se que o máximo montante de energia transferido para a barra 2, representado pela linha preta (demanda + exportação), equivale aos quase 80 MW de capacidade de transmissão instalados. É possível observar o DAE 1 fornecendo e absorvendo potência ao longo da série histórica, atuando para suprir a demanda e reduzir a necessidade de utilizar geração não-renovável. Como as capacidades de


Figura 33 – Custos de operação e investimento para os casos de simulação.



Fonte: do autor.

geração renováveis eólica e solar foram fixadas em 100 MW, é possível observar corte de sol e vento mesmo em momentos de maior demanda do sistema. É possível observar a preferência na utilização da usina a gás quando o uso de geração não-renovável se faz necessário, uma vez que essa opção apresenta custo de operação inferior às usinas a carvão.

Figura 34 – Trigésima primeira semana operativa do sistema.

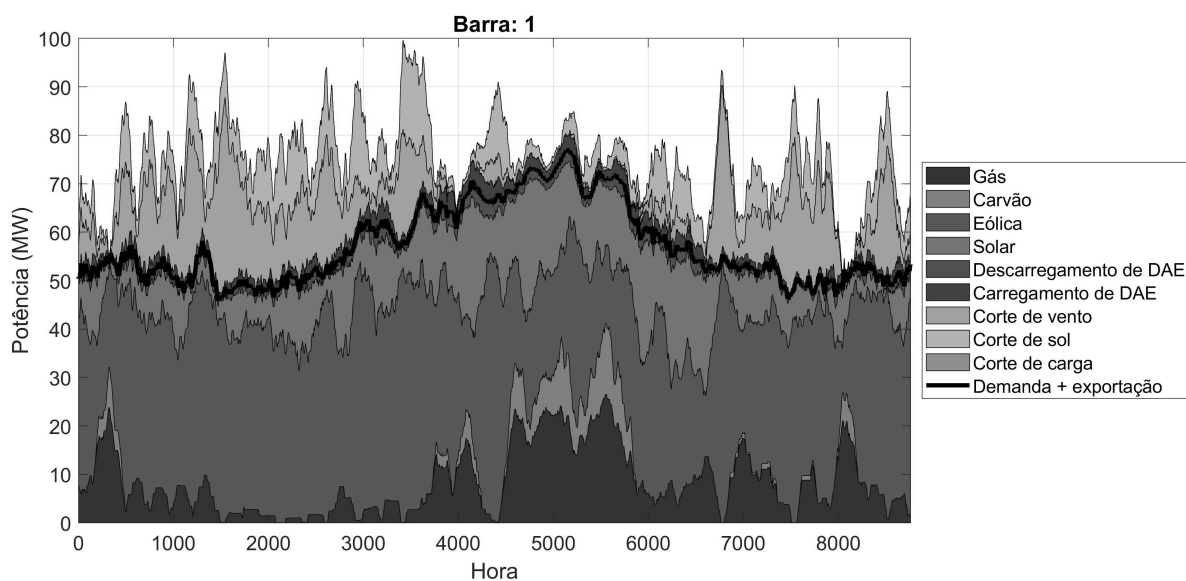


Fonte: do autor.

Uma visão holística da operação ao longo do ano é apresentada na Figura 35, que apresenta a média móvel da operação com janela semanal. Observa-se um forte corte de vento e sol ao longo do ano, reduzido apenas no período de maior demanda. Verifica-se que o uso da

usina a carvão ocorre apenas em períodos de baixa geração renovável e/ou alta demanda, por conta de seu alto custo de operação. Ainda na Figura 35, verifica-se um uso contínuo dos DAEs ao longo do ano, com maior participação nos períodos de maior demanda, demonstrando uma forte participação na rede que, na prática, implica em redução de corte de renováveis e uso de geradores não-renováveis. Deve-se frisar que, em momento algum da série, um DAE carrega e descarrega simultaneamente, conforme observado na Figura 34, este fenômeno aparenta ocorrer ao observar a Figura 35 por conta do uso de média móvel.

Figura 35 – Média móvel com janela semanal da operação do sistema.



Fonte: do autor.


Na Figura 36 apresenta-se a operação do DAE da Barra 1 durante a trigésima primeira semana, semana em que ocorre a demanda pico do sistema. É possível observar na Figura 36 que o montante de energia armazenado em um DAE pode-se manter praticamente constante durante dias de operação. Tais resultados não podem ser obtidos quando utilizados dias representativos, o que indica a possibilidade de que o uso de dias representativos pode levar a planos de expansão subótimos uma vez que a janela temporal das análises é limitada.

### 5.6.2 Sistema Garver

O Sistema Garver, descrito na Seção 5.3 será utilizado para realização das análises de desempenho do AAPR.

O sistema Garver utiliza duas séries históricas com resolução horária e horizonte de um ano, uma de demanda e uma de despacho eólico. A série de demanda (MERRICK, 2016) é definida em valores percentuais da demanda pico do sistema e a variabilidade de geração das usinas eólicas foi representada através da série histórica de velocidade de vento de 2013 da cidade Cape May - N.J., medida a 80 metros de altitude considerando a curva de potência da torre eólica GE 1.5sle, ambos obtidos através do software System Advisor Model(NREL, 2021).

Figura 36 – Operação do DAE durante a trigésima primeira semana.




Fonte: do autor.

Para esta análise, foi considerado um custo de investimento em transmissão de \$2 milhões por milha. Cada DAE candidato à expansão pode ter uma potência de até 100 MW e uma capacidade de armazenamento de até 1 GWh. Consideram-se os custos de operação e investimento de geradores não-renováveis e DAEs conforme Tabela 13. Foram consideradas eficiências de 90% de carregamento, descarregamento e auto-d Descarregamento mensal. Conforme detalhado em (PANDŽIĆ et al., 2015), os custos de investimentos foram anualizados considerando-se um tempo de vida útil de 60 anos para as linhas de transmissão (DVORKIN et al., 2018) e 20 anos para os DAEs (BHATTACHARJEE; SIOSHANSI; ZAREIPOUR, 2021).

As séries obtidas ao aplicar o AAPR na primeira semana operativa das séries históricas de demanda e geração eólica são ilustradas nas figuras 37 e 38 considerando, respectivamente,  $d_{min} = 0,1$  e  $d_{min} = 0,3$ . É possível observar uma alta similaridade entre as séries originais e as séries agrupadas pelo AAPR. As figuras também indicam que, conforme esperado, quanto menor o parâmetro  $d_{min}$ , mais próximas serão as séries históricas agrupadas ao custo de demandarem um número maior de períodos representativos. A Tabela 14 apresenta o número de cenários obtidos e o erro da série, em pu, que consiste no erro médio introduzido pela utilização do AAPR nas duas séries históricas variando o parâmetro  $d_{min}$  de 0 a 0,6. Este erro médio mensura a distância entre o ponto original de cada série original e o ponto representativo do período representativo equivalente obtido pelo AAPR. Ainda na Tabela 14 são apresentados: os erros de custo, que consiste no erro da solução do problema descrito na Seção 5.3 para as séries históricas agrupadas obtidas com o AAPR e a série histórica completa; e o tempo computacional despendido para solucionar os problemas para cada série histórica agrupada obtida com o AAPR.


Os resultados apresentados na Tabela 14 demonstram que a redução do número de

Figura 37 – Primeira semana operativa das séries históricas de carga e despacho de geração eólica, antes e após a aplicação do algoritmo AAPR considerando  $d_{min} = 0,1$ .



Fonte: do autor.

Figura 38 – Primeira semana operativa das séries históricas de carga e despacho de geração eólica, antes e após a aplicação do algoritmo AAPR, considerando  $d_{min} = 0,3$ .



Fonte: do autor.

cenários é imprescindível, pois não apresenta uma relação linear com o custo computacional, tão pouco com o erro de custo introduzido. Por exemplo, ao comparar a série original ( $d_{min} = 0$ ) com a série obtida ao aplicar  $d_{min} = 0,1$ , tem-se uma redução de 56,6% de cenários e um *speed-up* de 17 vezes. Tal ganho computacional introduz um erro relativo de apenas 0,45% uma vez que, em média, tem-se um erro de 0,03 pu na demanda e na geração das usinas eólicas segundo o erro de séries. Os resultados para o sistema Garver demonstram que o uso do AAPR para  $d_{min}$  menor que 0,5 mantém o erro de custo abaixo de 5%, o que pode ser considerado um erro aceitável

Tabela 14 – Resultados das simulações para o sistema Garver considerando diversos parâmetros do AAPR.

$d_{min}$	Erro da série (pu)	Cenários	Tempo (min)	Erro de custo (%)
0	-	8760	170	-
0,1	0,030	3806	10,0	0,45
0,2	0,066	2166	4,47	0,67
0,3	0,098	1427	1,58	2,72
0,4	0,126	994	0,78	3,94
0,5	0,149	739	0,48	4,88
0,6	0,174	527	0,29	5,83

Fonte: do autor.

em problemas probabilísticos. Porém, mais análises precisam ser realizadas para averiguar um patamar seguro de uso do  $d_{min}$ .

Para verificar os resultados obtidos como a formulação decomposta paralelizável são apresentadas na Tabela 15 as dimensões do problema considerando toda a série histórica para o sistema Garver, bem como a memória consumida. Sendo PM e SP os termos utilizados para descrever o problema mestre e o subproblema.

Tabela 15 – Comparação do tamanho dos problemas e consumo de memória das formulações clássica e paralelizável.

Caso	No. de variáveis	No. de restrições	Memória (Mb)
PM - Clássico	16	0*	0,04
PM - Paralelizável	35.061	78.846**	9,06
SP - Clássico	201.483	420.483	30,29
SP - Paralelizável	41	54	0,23

\* Há um acréscimo de 1 restrição por iteração.

\*\* Há um acréscimo de 8.760 restrições por iteração.

Fonte: do autor.

Para o caso do sistema Garver, testes apontam que o problema mestre paralelizável atinge o consumo de memória do subproblema clássico em aproximadamente 7 iterações. Este valor demonstra que, para casos pequenos, a formulação paralelizável não é vantajosa, algo já esperado e comum em métodos que utilizam computação paralela. Estudos precisam ser realizados em sistemas testes maiores para verificar a contribuição que o método proposto traz para a literatura.

Para o sistema Garver considerando as séries originais, o método paralelizável não converge em tempo hábil. Para o caso considerando a série gerada pelo AAPR considerando  $d_{min} = 0,3$ , tem-se que o algoritmo paralelizável converge para a solução idêntica ao algoritmo clássico em: 5,5 minutos, solucionando os subproblemas de forma sequencial; e em 4,7 minutos utilizando computação paralela. Ao passo que o algoritmo decomposto de forma clássica converge em 1,58 minutos.

## 5.7 CONCLUSÕES PARCIAIS

Neste capítulo apresentou-se uma metodologia para realizar o co-planejamento de transmissão e dispositivos de armazenamento de energia (DAEs). A metodologia permite otimizar o tamanho e a localização dos DAEs e considerar uma quantidade massiva de cenários cronológicos uma vez que cada cenário pode ser solucionado de forma simultânea a partir de computação paralela. Para reduzir o esforço computacional, foi introduzido o algoritmo de agrupamento de períodos representativos (AAPR) que reduz o número de cenários de múltiplas séries históricas. Através de análises de sensibilidade, observou-se que o algoritmo AAPR introduziu erros aceitáveis ao problema.

A metodologia consiste em reduzir o custo computacional a partir do uso da computação paralela, porém, observou-se um aumento no número de variáveis e restrições do problema mestre. Uma técnica para dividir o problema mestre em subproblemas também pode ser investigado em trabalhos futuros. Além disso, a metodologia proposta precisa ser testada em sistemas maiores.

A formulação permite utilizar diferentes tipos de tecnologias de armazenamento, o que pode ser investigado em trabalhos futuros.



## 6 CONCLUSÕES E TRABALHOS FUTUROS

### 6.1 CONCLUSÕES

Nesta tese de doutorado são propostas três formulações para a solução do problema de Planejamento da Expansão de Sistemas de Transmissão de Energia Elétrica (PET) e de dois algoritmos de agrupamento de séries históricas, incluindo os seguintes aspectos relevantes ao PET:

- As incertezas de curto prazo relacionadas à geração de energia a partir de fontes renováveis não-controladas foram tratadas através de cenários obtidos via agrupamento de séries históricas;
- Foi proposta uma metodologia capaz de considerar o critério de segurança “N-1” no sistema de transmissão existente e incertezas de demanda e geração de energia eólica;
- Foi proposta uma metodologia restrita em confiabilidade, que garante níveis adequados de corte de carga e de vento a partir da união da decomposição de Benders e a Simulação Monte Carlo (SMC).
- Foi proposto o m-ISODATA, algoritmo que se mostrou capaz de capturar os cenários representativos de forma não-cronológica de séries históricas de operação sem a necessidade de definir o número de grupos como parâmetro de entrada. O código-fonte do m-ISODATA está disponível no repositório *Code Ocean* em <https://doi.org/10.24433/CO.1264423.v1>.
- Foi proposto o AAPR, utilizado para gerar cenários representativos cronológicos. O AAPR não necessita da definição do número de grupos como parâmetro de entrada e se mostrou eficaz em reduzir o número de períodos que representam uma série histórica.
- Foi proposto um algoritmo para solucionar o PET considerando alocação ótima de Dispositivos de Armazenamento de Energia (DAEs) de tal forma que cada cenário possa ser solucionado através de técnicas de computação paralela. O algoritmo se mostrou promissor, porém, mais estudos e testes ainda precisam ser realizados para demonstrar suas contribuições à literatura.

### 6.2 TRABALHOS FUTUROS

Os seguintes tópicos de pesquisa foram identificados para continuidade e melhorias do presente trabalho:

- Os algoritmos m-ISODATA e AAPR são formulados através de heurísticas e podem ser formulados como problemas de otimização, o que precisa ser investigado para melhorar o desempenho de ambos;

- A formulação decomposta paralelizável do problema de PET considerando a alocação ótima de DAEs precisa ser aprimorada para reduzir o tamanho do problema mestre. Para tanto, a redução das variáveis auxiliares e a redução do número de cortes de Benders gerados por iteração devem ser avaliados. Com a redução do problema mestre, haveria uma redução considerável de custo computacional e consumo de memória;
- A avaliação do PET considerando a alocação ótima de DAEs em sistemas mais complexos, que levem em consideração diferentes tecnologias de armazenamento, como hidrelétricas. A possibilidade de considerar os diferentes ciclos operativos de cada tecnologia de DAE é o maior ganho com a representação de todo o ano operativo, possível através da utilização do AAPR e da formulação paralelizável;
- A formulação de um problema de PET que considere a alocação ótima de DAEs e as restrições e/ou custos de confiabilidade. A ideia por trás desta proposta é considerar a cronologia dos eventos a partir de uma simulação pseudo-cronológica (LEITE DA SILVA et al., 2000), gerando-se séries históricas sintéticas similares às obtidas pelo AAPR e solucionando-as de forma paralela e eficiente a partir da formulação paralelizável.

## REFERÊNCIAS

- AKBARI, T.; RAHIMIYAN, A.; KAZEMI, A. A multi-stage stochastic transmission expansion planning method. *Energy Conversion and Management*, v. 52, n. 8, p. 2844 – 2853, 2011.
- AKBARI, T.; TAVAKOLI BINA, M. Approximated milp model for ac transmission expansion planning: global solutions versus local solutions. *IET Generation, Transmission & Distribution*, v. 10, n. 7, p. 1563–1569, 2016. ISSN 1751-8695.
- ALAEI, S.; HOOSMAND, R.; HEMMATI, R. Stochastic transmission expansion planning incorporating reliability solved using sfla meta-heuristic optimization technique. *CSEE Journal of Power and Energy Systems*, v. 2, n. 2, p. 79–86, June 2016. ISSN 2096-0042.
- ALHAMROUNI, I. et al. Transmission expansion planning using ac-based differential evolution algorithm. *IET Generation, Transmission & Distribution*, v. 8, n. 10, p. 1637–1644, October 2014. ISSN 1751-8695.
- ALIZADEH, B.; JADID, S. Reliability constrained coordination of generation and transmission expansion planning in power systems using mixed integer programming. *IET Generation, Transmission & Distribution*, v. 5, n. 9, p. 948–960, Sep. 2011. ISSN 1751-8695.
- ALIZADEH-MOUSAVI, O.; ZIMA-BOČKARJOVA, M. Efficient benders cuts for transmission expansion planning. *Electric Power Systems Research*, v. 131, p. 275 – 284, 2016.
- ASADAMONGKOL, S.; EUA-ARPORN, B. Transmission expansion planning with ac model based on generalized benders decomposition. *International Journal of Electrical Power & Energy Systems*, v. 47, p. 402 – 407, 2013. ISSN 0142-0615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061512006400>>.
- ASSIS, F. A. et al. Transmission expansion planning with wind sources based on constructive metaheuristics. In: *2018 Simpósio Brasileiro de Sistemas Elétricos (SBSE)*. [S.l.: s.n.], 2018. p. 1–6. In Portuguese.
- BALL, G.; HALL, D. *ISODATA, a Novel Method of Data Analysis and Pattern Classification*. Menlo Park: Stanford Research Institute, 1965.
- BARINGO, L.; BARINGO, A. A stochastic adaptive robust optimization approach for the generation and transmission expansion planning. *IEEE Transactions on Power Systems*, v. 33, n. 1, p. 792–802, Jan 2018.
- BARINGO, L.; CONEJO, A. Correlated wind-power production and electric load scenarios for investment decisions. *Applied Energy*, v. 101, p. 475 – 482, 2013. ISSN 0306-2619. Sustainable Development of Energy, Water and Environment Systems.
- BENDERS, J. Partitioning procedures for solving mixed-variables programming problems. *Numerische Mathematik*, Springer, v. 4, p. 238–252, 1962. ISSN 0029-599X.
- BHATTACHARJEE, S.; SIOSHANSI, R.; ZAREIPOUR, H. Benefits of strategically sizing wind-integrated energy storage and transmission. *IEEE Transactions on Power Systems*, v. 36, n. 2, p. 1141–1151, March 2021. ISSN 1558-0679.
- BILLINTON, R. et al. Adequacy assessment considerations in wind integrated power systems. *IEEE Transactions on Power Systems*, v. 27, n. 4, p. 2297–2305, Nov 2012.

BILLINTON, R.; WANGDEE, W. Reliability-based transmission reinforcement planning associated with large-scale wind farms. *IEEE Transactions on Power Systems*, v. 22, n. 1, p. 34–41, Feb 2007.

BIRD, L. et al. Wind and solar energy curtailment: A review of international experience. *Renewable and Sustainable Energy Reviews*, v. 65, p. 577 – 586, 2016. ISSN 1364-0321.

CAMPONOGARA, E.; DE ALMEIDA, K. C.; HARDT, R. Piecewise-linear approximations for a non-linear transmission expansion planning problem. *IET Generation, Transmission & Distribution*, v. 9, n. 12, p. 1235–1244, 2015. ISSN 1751-8695.

CHEN, X. et al. Power system capacity expansion under higher penetration of renewables considering flexibility constraints and low carbon policies. *IEEE Transactions on Power Systems*, v. 33, n. 6, p. 6240–6253, Nov 2018. ISSN 1558-0679.

CHOI, J.; MOUNT, T. D.; THOMAS, R. J. Transmission expansion planning using contingency criteria. *IEEE Transactions on Power Systems*, v. 22, n. 4, p. 2249–2261, Nov 2007. ISSN 1558-0679.

CHOI, J. S. et al. A study on the optimal reliability criteria decision for a transmission system expansion planning. In: *IEEE Power Engineering Society General Meeting, 2004*. [S.l.: s.n.], 2004. p. 607–613 Vol.1.

CONEJO, A. J. et al. *Decomposition Techniques in Mathematical Programming: Engineering and Science Applications*. 1. ed. [S.l.]: Springer, 2006. ISBN 9783540276852,3-540-27685-8.

DE LA TORRE, S.; CONEJO, A. J.; CONTRERAS, J. Transmission expansion planning in electricity markets. *IEEE Transactions on Power Systems*, v. 23, n. 1, p. 238–248, Feb 2008. ISSN 1558-0679.

DE PAULA, A. N. *Data for modified IEEE-118 system*. 2020. Online. Disponível em: <<https://drive.google.com/open?id=1YEiLZ-F1Qo-jx4-IWpyFs4Sbi8M0MUG6>>.

DE PAULA, A. N. et al. *m-ISODATA: unsupervised clustering algorithm to capture representative scenarios in power systems - source code and data*. 2020. <<https://doi.org/10.24433/CO.1264423.v1>>.

DEHGHAN, S.; AMJADY, N.; CONEJO, A. J. Reliability-constrained robust power system expansion planning. *IEEE Transactions on Power Systems*, v. 31, n. 3, p. 2383–2392, May 2016.

DEHGHAN, S.; AMJADY, N.; CONEJO, A. J. A multistage robust transmission expansion planning model based on mixed binary linear decision rules—part I. *IEEE Transactions on Power Systems*, v. 33, n. 5, p. 5341–5350, Sep. 2018.

DIAZ, G.; INZUNZA, A.; MORENO, R. The importance of time resolution, operational flexibility and risk aversion in quantifying the value of energy storage in long-term energy planning studies. *Renewable and Sustainable Energy Reviews*, v. 112, p. 797–812, 2019. ISSN 1364-0321.

DOMINGUEZ, A. H. et al. Multistage security-constrained hvac/hvdc transmission expansion planning with a reduced search space. *IEEE Transactions on Power Systems*, v. 32, n. 6, p. 4805–4817, Nov 2017. ISSN 1558-0679.

- DOS SANTOS, T. N.; DINIZ, A. L. A dynamic piecewise linear model for dc transmission losses in optimal scheduling problems. *IEEE Transactions on Power Systems*, v. 26, n. 2, p. 508–519, May 2011.
- DUAN, R. et al. Data mining & pattern recognition of voltage sag based on k-means clustering algorithm. In: IEEE. *2015 IEEE Power & Energy Society General Meeting*. [S.l.], 2015. p. 1–5.
- DUPAČOVÁ, J.; GRÖWE-KUSKA, N.; RÖMISCH, W. Scenario reduction in stochastic programming. *Mathematical programming*, Springer, v. 95, n. 3, p. 493–511, 2003.
- DVORKIN, Y. et al. Co-planning of investments in transmission and merchant energy storage. *IEEE Transactions on Power Systems*, v. 33, n. 1, p. 245–256, Jan 2018. ISSN 1558-0679.
- ESTER, M. et al. A density-based algorithm for discovering clusters in large spatial databases with noise. In: ESTER, MARTIN AND KRIEGEL, HANS-PETER AND SANDER, JÖRG AND XU, XIAOWEI. *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining*. [S.l.]: AAAI Press, 1996. (KDD'96), p. 226–231.
- FALUGI, P.; KONSTANTELOS, I.; STRBAC, G. Planning with multiple transmission and storage investment options under uncertainty: A nested decomposition approach. *IEEE Transactions on Power Systems*, v. 33, n. 4, p. 3559–3572, July 2018.
- FANG, R.; HILL, D. J. A new strategy for transmission expansion in competitive electricity markets. *IEEE Transactions on Power Systems*, v. 18, n. 1, p. 374–380, Feb 2003.
- GAN, W. et al. Security constrained co-planning of transmission expansion and energy storage. *Applied Energy*, v. 239, p. 383–394, 2019. ISSN 0306-2619.
- GARCÍA-BERTRAND, R.; MÍNGUEZ, R. Dynamic robust transmission expansion planning. *IEEE Transactions on Power Systems*, v. 32, n. 4, p. 2618–2628, July 2017. ISSN 1558-0679.
- GARVER, L. L. Transmission network estimation using linear programming. *IEEE Transactions on Power Apparatus and Systems*, PAS-89, n. 7, p. 1688–1697, Sep. 1970.
- GIDEON UDE, N.; YSKANDAR, H.; CONETH GRAHAM, R. A comprehensive state-of-the-art survey on the transmission network expansion planning optimization algorithms. *IEEE Access*, v. 7, p. 123158–123181, 2019.
- GOMES, P. V.; SARAIVA, J. T. A novel efficient method for multiyear multiobjective dynamic transmission system planning. *International Journal of Electrical Power & Energy Systems*, v. 100, p. 10 – 18, 2018.
- GOMES, P. V.; SARAIVA, J. T. State-of-the-art of transmission expansion planning: A survey from restructuring to renewable and distributed electricity markets. *International Journal of Electrical Power & Energy Systems*, v. 111, p. 411 – 424, 2019. ISSN 0142-0615.
- GOMES, P. V.; SILVA, J. P.; SARAIVA, J. T. Multiyear and multi-criteria ac transmission expansion planning model considering reliability and investment costs. In: *2016 13th International Conference on the European Energy Market (EEM)*. [S.l.: s.n.], 2016. p. 1–5. ISSN 2165-4093.
- GONZALEZ-ROMERO, I.-C.; WOGGRIN, S.; GOMEZ, T. Proactive transmission expansion planning with storage considerations. *Energy Strategy Reviews*, v. 24, p. 154–165, 2019. ISSN 2211-467X.

- GU, Y.; XIE, L. Fast sensitivity analysis approach to assessing congestion induced wind curtailment. *IEEE Transactions on Power Systems*, v. 29, n. 1, p. 101–110, Jan 2014.
- HAGHIGHAT, H.; ZENG, B. Bilevel conic transmission expansion planning. *IEEE Transactions on Power Systems*, v. 33, n. 4, p. 4640–4642, July 2018.
- HAMIDPOUR, H. et al. Flexible, reliable, and renewable power system resource expansion planning considering energy storage systems and demand response programs. *IET Renewable Power Generation*, v. 13, n. 11, p. 1862–1872, 2019. ISSN 1752-1424.
- HEMMATI, R.; HOOSHMAND, R.-A.; KHODABAKHSHIAN, A. State-of-the-art of transmission expansion planning: Comprehensive review. *Renewable and Sustainable Energy Reviews*, v. 23, p. 312 – 319, 2013. ISSN 1364-0321.
- HINO, H. et al. A versatile clustering method for electricity consumption pattern analysis in households. *IEEE Transactions on Smart Grid*, IEEE, v. 4, n. 2, p. 1048–1057, 2013.
- HONÓRIO, L. de M.; SILVA, A. M. L. da; BARBOSA, D. A. A cluster and gradient-based artificial immune system applied in optimization scenarios. *IEEE Transactions on Evolutionary Computation*, IEEE, v. 16, n. 3, p. 301–318, 2012.
- HONÓRIO, L. M. et al. A multiple kernel classification approach based on a quadratic successive geometric segmentation methodology with a fault diagnosis case. *ISA transactions*, Elsevier, v. 74, p. 209–216, 2018.
- HU, J.; LI, H. A new clustering approach for scenario reduction in multi-stochastic variable programming. *IEEE Transactions on Power Systems*, v. 34, n. 5, p. 3813–3825, Sep. 2019. ISSN 1558-0679.
- HU, Z.; ZHANG, F.; LI, B. Transmission expansion planning considering the deployment of energy storage systems. In: ' '. *2012 IEEE Power and Energy Society General Meeting*. [S.l.], 2012. p. 1–6. ISSN 1944-9925.
- HUANG, S.; DINAVAH, V. Multi-group particle swarm optimisation for transmission expansion planning solution based on lu decomposition. *IET Generation, Transmission & Distribution*, v. 11, n. 6, p. 1434–1442, 2017. ISSN 1751-8695.
- HUANG, S.; DINAVAH, V. A branch-and-cut benders decomposition algorithm for transmission expansion planning. *IEEE Systems Journal*, v. 13, n. 1, p. 659–669, March 2019. ISSN 1937-9234.
- JABR, R. A. Robust transmission network expansion planning with uncertain renewable generation and loads. *IEEE Transactions on Power Systems*, v. 28, n. 4, p. 4558–4567, Nov 2013.
- JABR, R. A.; DŽAFIĆ, I.; PAL, B. C. Robust optimization of storage investment on transmission networks. *IEEE Transactions on Power Systems*, v. 30, n. 1, p. 531–539, Jan 2015.
- JAESEOK CHOI et al. A method for transmission system expansion planning considering probabilistic reliability criteria. *IEEE Transactions on Power Systems*, v. 20, n. 3, p. 1606–1615, Aug 2005.

JIN, S.; RYAN, S. M. A tri-level model of centralized transmission and decentralized generation expansion planning for an electricity market—part i. *IEEE Transactions on Power Systems*, v. 29, n. 1, p. 132–141, Jan 2014. ISSN 1558-0679.

JIN, S.; RYAN, S. M. A tri-level model of centralized transmission and decentralized generation expansion planning for an electricity market—part ii. *IEEE Transactions on Power Systems*, v. 29, n. 1, p. 142–148, Jan 2014. ISSN 1558-0679.

KHANDELWAL, A. et al. Modified grey wolf optimization algorithm for transmission network expansion planning problem. *Arabian Journal for Science and Engineering*, v. 43, n. 6, p. 2899–2908, Jun 2018. ISSN 2191-4281.

LAZARD. *Lazard's Levelized Cost of Energy Analysis - Version 12*. 2018. Online.

LEI, Y. et al. An incremental reliability assessment approach for transmission expansion planning. *IEEE Transactions on Power Systems*, v. 33, n. 3, p. 2597–2609, May 2018.

LEITE DA SILVA, A. M. et al. Pseudo-chronological simulation for composite reliability analysis with time varying loads. *IEEE Transactions on Power Systems*, v. 15, n. 1, p. 73–80, Feb 2000.

LEITE DA SILVA, A. M. et al. Reliability assessment of time-dependent systems via quasi-sequential monte carlo simulation. In: ' '. *2010 IEEE 11th International Conference on Probabilistic Methods Applied to Power Systems*. [S.l.], 2010. p. 697–702.

LI, J. et al. A scenario-based robust transmission network expansion planning method for consideration of wind power uncertainties. *CSEE Journal of Power and Energy Systems*, v. 2, n. 1, p. 11–18, March 2016.

LIU, B.; HE, J.; LIU, G. A study on conditions analysis of power plant based on data mining. In: IEEE. *2010 2nd International Asia Conference on Informatics in Control, Automation and Robotics (CAR 2010)*. [S.l.], 2010. v. 3, p. 161–165.

LUBURIĆ, Z.; PANDŽIĆ, H.; CARRIÓN, M. Transmission expansion planning model considering battery energy storage, tscs and lines using ac opf. *IEEE Access*, v. 8, p. 203429–203439, 2020. ISSN 2169-3536.

LUMBRERAS, S.; RAMOS, A. How to solve the transmission expansion planning problem faster: acceleration techniques applied to benders' decomposition. *IET Generation, Transmission & Distribution*, v. 10, n. 10, p. 2351–2359, 2016. ISSN 1751-8695.

LUMBRERAS, S.; RAMOS, A. The new challenges to transmission expansion planning. survey of recent practice and literature review. *Electric Power Systems Research*, v. 134, p. 19 – 29, 2016.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*. Berkeley, Calif.: University of California Press, 1967. p. 281–297.

MAHDAVI, M.; MONSEF, H.; ROMERO, R. Reliability effects of maintenance on tnep considering preventive and corrective repairs. *IEEE Transactions on Power Systems*, v. 32, n. 5, p. 3768–3781, Sep. 2017. ISSN 1558-0679.

MAHDAVI, M. et al. Transmission expansion planning: Literature review and classification. *IEEE Systems Journal*, v. 13, n. 3, p. 3129–3140, Sep. 2019. ISSN 1937-9234.

MAJIDI-QADIKOLAI, M.; BALDICK, R. A generalized decomposition framework for large-scale transmission expansion planning. *IEEE Transactions on Power Systems*, v. 33, n. 2, p. 1635–1649, March 2018. ISSN 1558-0679.

MATLAB Statistics and Machine Learning Toolbox. 2019. Online. The MathWorks, Natick, MA, USA.

MAZAHERI, H. et al. An online method for milp co-planning model of large-scale transmission expansion planning and energy storage systems considering n-1 criterion. *IET Generation, Transmission & Distribution*, v. 15, n. 4, p. 664–677, 2021.

MENDONÇA, I. M. de et al. Identification of relevant routes for static expansion planning of electric power transmission systems. *Electric Power Systems Research*, v. 140, p. 769 – 775, 2016. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779616301638>>.

MERRICK, J. H. On representation of temporal variability in electricity capacity planning models. *Energy Economics*, v. 59, p. 261 – 274, 2016. ISSN 0140-9883.

Ministério de Minas e Energia (MME); Empresa de Pesquisa Energética (EPE). *Plano Decenal de Expansão de Energia 2030*. Brasília, 2021.

MITTAL, M. et al. Clustering approaches for high-dimensional databases: A review. *WIREs Data Mining and Knowledge Discovery*, v. 9, n. 3, p. e1300, 2019.

MOEINI-AGHTAIE, M.; ABBASPOUR, A.; FOTUHI-FIRUZABAD, M. Incorporating large-scale distant wind farms in probabilistic transmission expansion planning—part i: Theory and algorithm. *IEEE Transactions on Power Systems*, v. 27, n. 3, p. 1585–1593, Aug 2012. ISSN 1558-0679.

MOEINI-AGHTAIE, M.; ABBASPOUR, A.; FOTUHI-FIRUZABAD, M. Incorporating large-scale distant wind farms in probabilistic transmission expansion planning—part ii: Case studies. *IEEE Transactions on Power Systems*, v. 27, n. 3, p. 1594–1601, Aug 2012. ISSN 1558-0679.

MONTICELLI, A. et al. Interactive transmission network planning using a least-effort criterion. *IEEE Transactions on Power Apparatus and Systems*, PAS-101, n. 10, p. 3919–3925, Oct 1982. ISSN 0018-9510.

MONTICELLI, A. J. *Fluxo de Carga em Redes de Energia Elétrica*. [S.l.]: Edgard Blucher, 1983.

MORAES, C. A. et al. Wind generation impact in transmission expansion planning. *Journal of Control, Automation and Electrical Systems*, Springer, v. 31, n. 1, p. 247–256, 2020.

MOREIRA, A. et al. Reliable renewable generation and transmission expansion planning: Co-optimizing system's resources for meeting renewable targets. *IEEE Transactions on Power Systems*, v. 32, n. 4, p. 3246–3257, July 2017.



MOREIRA, A.; STREET, A.; ARROYO, J. M. An adjustable robust optimization approach for contingency-constrained transmission expansion planning. *IEEE Transactions on Power Systems*, v. 30, n. 4, p. 2013–2022, July 2015.

MURTAGH, F.; LEGENDRE, P. Ward's hierarchical agglomerative clustering method: Which algorithms implement ward's criterion? *Journal of Classification*, v. 31, n. 3, p. 274–295, Oct 2014. ISSN 1432-1343.

NAGHDIZADEGAN JAHROMI, S.; ASKARZADEH, A.; ABDOLLAHI, A. Modelling probabilistic transmission expansion planning in the presence of plug-in electric vehicles uncertainty by multi-state markov model. *IET Generation, Transmission & Distribution*, v. 11, n. 7, p. 1716–1725, 2017. ISSN 1751-8695.

NIKOOLAKHT, A.; AGHAEI, J. Integrated transmission and storage systems investment planning hosting wind power generation: continuous-time hybrid stochastic/robust optimisation. *IET Generation, Transmission & Distribution*, v. 13, n. 21, p. 4870–4879, 2019.

NIKOOLAKHT, A. et al. Allocation of fast-acting energy storage systems in transmission grids with high renewable generation. *IEEE Transactions on Sustainable Energy*, v. 11, n. 3, p. 1728–1738, July 2020. ISSN 1949-3037.

NREL. *System Advisor Model*. 2021. Online. Version 2020.11.29. Accessed May 17, 2021. <<https://sam.nrel.gov>>.

OLIVEIRA, E. J. D. et al. Efficient hybrid algorithm for transmission expansion planning. *Electrical Engineering*, v. 100, n. 4, p. 2765–2777, Dec 2018.

ORFANOS, G. A.; GEORGILAKIS, P. S.; HATZIARGYRIOU, N. D. Transmission expansion planning of systems with increasing wind power integration. *IEEE Transactions on Power Systems*, v. 28, n. 2, p. 1355–1362, May 2013.

PANDŽIĆ, H. et al. Near-optimal method for siting and sizing of distributed storage in a transmission network. *IEEE Transactions on Power Systems*, v. 30, n. 5, p. 2288–2300, Sep. 2015. ISSN 1558-0679.

PARK, H.; BALDICK, R.; MORTON, D. P. A stochastic transmission planning model with dependent load and wind forecasts. *IEEE Transactions on Power Systems*, v. 30, n. 6, p. 3003–3011, Nov 2015. ISSN 1558-0679.

PEREIRA, M. V. F. et al. A decomposition approach to automated generation/transmission expansion planning. *IEEE Transactions on Power Apparatus and Systems*, PAS-104, n. 11, p. 3074–3083, Nov 1985. ISSN 0018-9510.

PINEDA, S.; MORALES, J. M. Chronological time-period clustering for optimal capacity expansion planning with storage. *IEEE Transactions on Power Systems*, v. 33, n. 6, p. 7162–7170, Nov 2018. ISSN 1558-0679.

POUBEL, R. et al. Tree searching heuristic algorithm for multi-stage transmission planning considering security constraints via genetic algorithm. *Electric Power Systems Research*, Elsevier, v. 142, p. 290–297, 2017.

POUBEL, R. P. B. et al. A coupled model to multistage transmission expansion planning. *Journal of Control, Automation and Electrical Systems*, v. 26, n. 3, p. 272–282, Jun 2015. ISSN 2195-3899.

POZO, D.; SAUMA, E. E.; CONTRERAS, J. A three-level static milp model for generation and transmission expansion planning. *IEEE Transactions on Power Systems*, v. 28, n. 1, p. 202–210, Feb 2013. ISSN 1558-0679.

QAZI, A. et al. Towards sustainable energy: A systematic review of renewable energy sources, technologies, and public opinions. *IEEE Access*, v. 7, p. 63837–63851, 2019.

QIU, J. How to build an electric power transmission network considering demand side management and a risk constraint? *International Journal of Electrical Power & Energy Systems*, v. 94, p. 311 – 320, 2018. ISSN 0142-0615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061517302818>>.

QIU, T. et al. Stochastic multistage coplanning of transmission expansion and energy storage. *IEEE Transactions on Power Systems*, v. 32, n. 1, p. 643–651, Jan 2017. ISSN 1558-0679.

RABY, M. et al. Integrating large wind farms into transmission planning of hydrothermal system. *Journal of Energy Engineering*, v. 135, n. 3, p. 89–97, 2009.

RAHMANI, M. et al. Multistage transmission expansion planning considering fixed series compensation allocation. *IEEE Transactions on Power Systems*, v. 28, n. 4, p. 3795–3805, Nov 2013. ISSN 1558-0679.

RAHMANIANI, R. et al. The benders decomposition algorithm: A literature review. *European Journal of Operational Research*, v. 259, n. 3, p. 801 – 817, 2017. ISSN 0377-2217.

RATHORE, C.; ROY, R. Impact of wind uncertainty, plug-in-electric vehicles and demand response program on transmission network expansion planning. *International Journal of Electrical Power & Energy Systems*, v. 75, p. 59 – 73, 2016. ISSN 0142-0615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061515003415>>.

RIDER, M. J.; GARCIA, A. V.; ROMERO, R. Power system transmission network expansion planning using ac model. *IET Generation, Transmission & Distribution*, v. 1, n. 5, p. 731–742, Sep. 2007. ISSN 1751-8695.

ROLDÁN, C. et al. Robust transmission network expansion planning under correlated uncertainty. *IEEE Transactions on Power Systems*, v. 34, n. 3, p. 2071–2082, May 2019.

ROMERO, M.; GALLEGO, L.; PAVAS, A. Fault zones location on distribution systems based on clustering of voltage sags patterns. In: IEEE. *2012 IEEE 15th International Conference on Harmonics and Quality of Power*. [S.l.], 2012. p. 486–493.

RUI XU; WUNSCH, D. Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, v. 16, n. 3, p. 645–678, May 2005.

SABERI, H.; MONSEF, H.; AMRAEE, T. Probabilistic congestion driven network expansion planning using point estimate technique. *IET Generation, Transmission & Distribution*, v. 11, n. 17, p. 4202–4211, 2017. ISSN 1751-8695.

SHEIKHOESLAMI, G.; CHATTERJEE, S.; ZHANG, A. Wavecluster: a wavelet-based clustering approach for spatial data in very large databases. *The VLDB Journal*, v. 8, n. 3, p. 289–304, Feb 2000. ISSN 0949-877X.

SILVA, A. M. L. da et al. Constructive metaheuristics applied to transmission expansion planning with security constraints. In: *2017 19th International Conference on Intelligent System Application to Power Systems (ISAP)*. [S.l.: s.n.], 2017. p. 1–7.

SILVA, A. M. L. da et al. Transmission expansion planning based on relaxed n-1 criteria and reliability indices. In: *2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*. [S.l.: s.n.], 2016. p. 1–6.

SILVA, A. M. L. da et al. Chronological power flow for planning transmission systems considering intermittent sources. *IEEE Transactions on Power Systems*, v. 27, n. 4, p. 2314–2322, Nov 2012.

SILVA, A. M. L. da et al. Reliability worth applied to transmission expansion planning based on ant colony system. *International Journal of Electrical Power & Energy Systems*, v. 32, n. 10, p. 1077 – 1084, 2010.

SILVA, A. M. Leite da et al. Composite reliability assessment of power systems with large penetration of renewable sources. In: \_\_\_\_\_. *Reliability and Risk Evaluation of Wind Integrated Power Systems*. India: Springer India, 2013. p. 107–128.

SUBCOMMITTEE, P. M. Ieee reliability test system. *IEEE Transactions on Power Apparatus and Systems*, PAS-98, n. 6, p. 2047–2054, Nov 1979. ISSN 0018-9510.

SUN, M. et al. Data-driven representative day selection for investment decisions: A cost-oriented approach. *IEEE Transactions on Power Systems*, v. 34, n. 4, p. 2925–2936, July 2019.

TAHERKHANI, M.; HOSSEINI, S. H. Wind farm optimal connection to transmission systems considering network reinforcement using cost-reliability analysis. *IET Renewable Power Generation*, v. 7, n. 6, p. 603–613, Nov 2013.

TEJADA-ARANGO, D. A. et al. Enhanced representative days and system states modeling for energy storage investment analysis. *IEEE Transactions on Power Systems*, v. 33, n. 6, p. 6534–6544, Nov 2018. ISSN 1558-0679.

UGRANLI, F.; KARATEPE, E. Transmission expansion planning for wind turbine integrated power systems considering contingencies. In: *2014 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings*. [S.l.: s.n.], 2014. p. 350–355.

VERMA, A.; PANIGRAHI, B. K.; BIJWE, P. R. Harmony search algorithm for transmission network expansion planning. *IET Generation, Transmission & Distribution*, v. 4, n. 6, p. 663–673, June 2010. ISSN 1751-8695.

WACKER, G.; BILLINTON, R. Customer cost of electric service interruptions. *Proceedings of the IEEE*, v. 77, n. 6, p. 919–930, June 1989.

WANG, J.; XIAO, L.; SHI, J. The combination forecasting of electricity price based on price spikes processing: A case study in south australia. *Abstract and Applied Analysis*, Hindawi Publishing Corporation, v. 2014, p. 172306, May 2014. ISSN 1085-3375.

WANG, S.; GENG, G.; JIANG, Q. Robust co-planning of energy storage and transmission line with mixed integer recourse. *IEEE Transactions on Power Systems*, v. 34, n. 6, p. 4728–4738, Nov 2019. ISSN 1558-0679.

WANG, Y. et al. Wind power curtailment evaluation based on eof and hierarchical clustering method. In: IEEE. *2016 International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*. [S.l.], 2016. p. 1–6.

WANG, Y. Y. et al. Stator single-phase-to-ground fault protection for bus-connected powerformers based on hierarchical clustering algorithm. *IEEE Transactions on Energy Conversion*, IEEE, v. 28, n. 4, p. 991–998, 2013.

WIEST, P.; RUDION, K.; PROBST, A. Efficient integration of (n-1)-security into probabilistic network expansion planning. *International Journal of Electrical Power & Energy Systems*, v. 94, p. 151 – 159, 2018. ISSN 0142-0615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061517304246>>.

WOGRIN, S. et al. A new approach to model load levels in electric power systems with high renewable penetration. *IEEE Transactions on Power Systems*, IEEE, v. 29, n. 5, p. 2210–2218, 2014.

WU, W. et al. Transmission network expansion planning based on chronological evaluation considering wind power uncertainties. *IEEE Transactions on Power Systems*, v. 33, n. 5, p. 4787–4796, Sep. 2018. ISSN 1558-0679.

XIE, H.; BIE, Z.; LI, G. Reliability-oriented networking planning for meshed vsc-hvdc grids. *IEEE Transactions on Power Systems*, v. 34, n. 2, p. 1342–1351, March 2019. ISSN 1558-0679.

YANG, J. et al. A model of customizing electricity retail prices based on load profile clustering analysis. *IEEE Transactions on Smart Grid*, IEEE, v. 10, n. 3, p. 3374–3386, 2018.

YANG, P.; NEHORAI, A. Joint optimization of hybrid energy storage and generation capacity with renewable energy. *IEEE Transactions on Smart Grid*, v. 5, n. 4, p. 1566–1574, July 2014.

YOU, F.; GROSSMANN, I. E. Multicut benders decomposition algorithm for process supply chain planning under uncertainty. *Annals of Operations Research*, v. 210, n. 1, p. 191–211, Nov 2013. ISSN 1572-9338.

YU, H.; CHUNG, C. Y.; WONG, K. P. Robust transmission network expansion planning method with taguchi's orthogonal array testing. *IEEE Transactions on Power Systems*, v. 26, n. 3, p. 1573–1580, Aug 2011. ISSN 1558-0679.

ZHANG, F.; HU, Z.; SONG, Y. Mixed-integer linear model for transmission expansion planning with line losses and energy storage systems. *IET Generation, Transmission & Distribution*, v. 7, n. 8, p. 919–928, Aug 2013. ISSN 1751-8695.

ZHANG, H. et al. An improved network model for transmission expansion planning considering reactive power and network losses. *IEEE Transactions on Power Systems*, v. 28, n. 3, p. 3471–3479, Aug 2013. ISSN 1558-0679.

ZHANG, X.; CONEJO, A. J. Coordinated investment in transmission and storage systems representing long- and short-term uncertainty. *IEEE Transactions on Power Systems*, v. 33, n. 6, p. 7143–7151, Nov 2018. ISSN 1558-0679.

ZHANG, X.; CONEJO, A. J. Robust transmission expansion planning representing long- and short-term uncertainty. *IEEE Transactions on Power Systems*, v. 33, n. 2, p. 1329–1338, March 2018.

ZHANG, X.; TOMSOVIC, K.; DIMITROVSKI, A. Security constrained multi-stage transmission expansion planning considering a continuously variable series reactor. *IEEE Transactions on Power Systems*, v. 32, n. 6, p. 4442–4450, Nov 2017. ISSN 1558-0679.

ZHANG, Y. et al. An extension of reduced disjunctive model for multi-stage security-constrained transmission expansion planning. *IEEE Transactions on Power Systems*, v. 33, n. 1, p. 1092–1094, Jan 2018. ISSN 1558-0679.

ZHENG, Q. et al. Data-adaptive robust transmission network planning incorporating post-contingency demand response. *IEEE Access*, v. 7, p. 100296–100304, 2019. ISSN 2169-3536.

ZHUO, Z. et al. Incorporating massive scenarios in transmission expansion planning with high renewable energy penetration. *IEEE Transactions on Power Systems*, v. 35, n. 2, p. 1061–1074, March 2020. ISSN 1558-0679.

ZIAEE, O.; ALIZADEH-MOUSAVI, O.; CHOUBINEH, F. F. Co-optimization of transmission expansion planning and tesc placement considering the correlation between wind and demand scenarios. *IEEE Transactions on Power Systems*, v. 33, n. 1, p. 206–215, Jan 2018.

**APÊNDICE A – Dados do sistema IEEE-RTS**

Dados de barra do sistema IEEE-RTS (sem considerar geração eólica).

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: Adaptado de (SUBCOMMITTEE, 1979).

## Dados de barra do 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	-	-
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: Adaptado de (SUBCOMMITTEE, 1979) e (ASSIS et al., 2018).

Dados de linhas existentes dos sistemas IEEE-RTS e RTS-WIND.

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)
01	02	0.2600	01.390	175
01	03	5.4600	21.120	175
01	05	2.1800	08.450	175
02	04	3.2800	12.670	175
02	06	4.9700	19.200	175
03	09	3.0800	11.900	175
03	24	0.2300	08.390	400
04	09	2.6800	10.370	175
05	10	2.2800	08.830	175
06	10	1.3900	06.050	175
07	08	1.5900	06.140	175
08	09	4.2700	16.510	175
08	10	4.2700	16.510	175
09	11	0.2300	08.390	400
09	12	0.2300	08.390	400
10	11	0.2300	08.390	400
10	12	0.2300	08.390	400
11	13	0.6100	04.760	500
11	14	0.5400	04.180	500
12	13	0.6100	04.760	500
12	23	1.2400	09.660	500
13	23	1.1100	08.650	500
14	16	0.5000	03.890	500
15	16	0.2200	01.730	500
15	21	0.6300	04.900	500
15	21	0.6300	04.900	500
15	24	0.6700	05.190	500
16	17	0.3300	02.590	500
16	19	0.3000	02.310	500
17	18	0.1800	01.440	500
17	22	1.3500	10.530	500
18	21	0.3300	02.590	500
18	21	0.3300	02.590	500
19	20	0.5100	03.960	500
19	20	0.5100	03.960	500
20	23	0.2800	02.160	500
20	23	0.2800	02.160	500
21	22	0.8700	06.780	500

Fonte: Adaptado de (SUBCOMMITTEE, 1979).



## Dados de linhas candidatas dos sistemas IEEE-RTS e RTS-WIND.

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
01	02	0.2600	01.390	175	003
01	03	5.4600	21.120	175	055
01	05	2.1800	08.450	175	022
02	04	3.2800	12.670	175	033
02	06	4.9700	19.200	175	050
03	09	3.0800	11.900	175	031
03	24	0.2300	08.390	400	050
04	09	2.6800	10.370	175	027
05	10	2.2800	08.830	175	023
06	10	1.3900	06.050	175	016
07	08	1.5900	06.140	175	016
08	09	4.2700	16.510	175	043
08	10	4.2700	16.510	175	043
09	11	0.2300	08.390	400	050
09	12	0.2300	08.390	400	050
10	11	0.2300	08.390	400	050
10	12	0.2300	08.390	400	050
11	13	0.6100	04.760	500	066
11	14	0.5400	04.180	500	058
12	13	0.6100	04.760	500	066
12	23	1.2400	09.660	500	134
13	23	1.1100	08.650	500	120
14	16	0.5000	03.890	500	054
15	16	0.2200	01.730	500	024
15	21	0.6300	04.900	500	068
15	24	0.6700	05.190	500	072
16	17	0.3300	02.590	500	036
16	19	0.3000	02.310	500	032
17	18	0.1800	01.440	500	020
17	22	1.3500	10.530	500	146
18	21	0.3300	02.590	500	036
19	20	0.5100	03.960	500	055
20	23	0.2800	02.160	500	030
21	22	0.8700	06.780	500	094

Fonte: Adaptado de (SUBCOMMITTEE, 1979) e (FANG; HILL, 2003).

**APÊNDICE B – Dados do sistema BS**

Dados de barra do sistema BS.

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	-
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	-	-

Barra	Carga (MW)	Geração térmica (MW)
44	79.1	-
45	86.7	-
46	-	700

Fonte: Adaptado de (MONTICELLI et al., 1982).

#### Dados de barra do sistema BS-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	-
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	-	-

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
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: Adaptado de (MONTICELLI et al., 1982).

#### Dados de linhas existentes dos sistemas BS e BS-WIND.

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)
1	7	.616	6.16	270
1	2	1.065	10.65	270
1	2	1.065	10.65	270
4	9	.924	9.24	270
5	9	1.173	11.73	270
5	8	1.132	11.32	270
7	8	1.023	10.23	270
4	5	.566	5.66	270
4	5	.566	5.66	270
2	5	.324	3.24	270
2	5	.324	3.24	270
8	13	1.348	13.48	240
9	14	1.756	17.56	220
9	14	1.756	17.56	220
12	14	.740	7.40	270
12	14	.740	7.40	270
14	18	1.514	15.14	240
14	18	1.514	15.14	240
13	18	1.805	18.05	220
13	20	1.073	10.73	270
18	20	1.997	19.97	200
19	21	.278	2.78	1500
16	17	.078	0.78	2000
17	19	.061	0.61	2000
14	26	1.614	16.14	220
14	22	.840	8.40	270
22	26	.790	7.90	270
20	23	.932	9.32	270

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)
20	23	.932	9.32	270
23	24	.774	7.74	270
23	24	.774	7.74	270
26	27	.832	8.32	270
26	27	.832	8.32	270
24	34	1.647	16.47	220
24	33	1.448	14.48	240
33	34	1.265	12.65	270
27	36	.915	9.15	270
27	38	2.008	20.08	200
27	38	2.008	20.08	200
36	37	1.057	10.57	270
34	35	.491	4.91	270
34	35	.491	4.91	270
35	38	1.980	19.80	200
37	39	.283	2.83	270
37	40	1.281	12.81	270
37	42	2.105	21.05	200
39	42	2.030	20.30	200
39	42	2.030	20.30	200
39	42	2.030	20.30	200
40	42	.932	9.32	200
38	42	.907	9.07	270
38	42	.907	9.07	270
38	42	.907	9.07	270
32	43	.309	3.09	1400
42	44	1.206	12.06	270
44	45	1.864	18.64	200
19	32	.195	1.95	1800
46	19	.222	2.22	1800
46	16	.203	2.03	1800
18	19	.125	1.25	600
20	21	.125	1.25	600
42	43	.125	1.25	600

Fonte: Adaptado de (MONTICELLI et al., 1982).

#### Dados de linhas candidatas dos sistemas BS e BS-WIND.

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
1	2	1.065	10.65	270	7.076
1	7	0.616	06.16	270	4.349
2	3	0.125	01.25	600	8.179

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
2	4	0.882	08.82	270	5.965
2	5	0.324	03.24	270	2.581
4	5	0.566	05.66	270	4.046
4	9	0.924	09.24	270	6.217
4	11	2.246	22.46	240	14.247
5	6	0.125	01.25	600	8.178
5	8	1.132	11.32	270	7.480
5	9	1.173	11.73	270	7.732
5	11	0.915	09.15	270	6.167
7	8	1.023	10.23	270	6.823
8	13	1.348	13.48	240	8.793
9	10	0.125	01.25	600	8.179
9	14	1.756	17.56	220	11.267
12	14	0.740	07.40	270	5.106
13	18	1.805	18.05	220	11.570
13	20	1.073	10.73	270	7.120
14	15	0.374	03.74	270	2.884
14	18	1.514	15.14	240	9.803
14	22	.840	8.40	270	5.712
14	26	1.614	16.14	220	10.409
15	16	0.125	01.25	600	8.179
16	17	.078	0.78	2000	10.505
16	28	0.222	02.22	1800	26.365
16	32	0.311	03.11	1400	36.213
17	19	.061	0.61	2000	8.715
17	32	0.232	02.32	1700	27.516
18	19	0.125	01.25	600	8.178
18	20	1.997	19.97	200	12.732
19	21	0.278	02.78	1500	32.632
19	25	0.325	03.25	1400	37.748
19	32	0.195	01.95	1800	23.423
20	21	0.125	01.25	600	8.178
20	23	.932	9.32	270	6.268
21	25	0.174	01.74	2000	21.121
22	26	.790	7.90	270	5.409
23	24	.774	7.74	270	5.308
24	25	0.125	01.25	600	8.179
24	33	1.448	14.48	240	9.399
24	34	1.647	16.47	220	10.611
25	32	0.319	03.19	1400	37.109
26	27	.832	8.32	270	5.662
26	29	0.541	05.41	270	3.894
27	29	0.998	09.98	270	6.672
27	36	0.915	09.15	270	6.167
27	38	2.080	20.80	200	13.237

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
28	30	0.058	00.58	2000	8.331
28	31	0.053	00.53	2000	7.819
28	41	0.339	03.39	1300	39.283
28	43	0.406	04.06	1200	46.701
29	30	0.125	01.25	600	8.179
31	32	0.046	00.46	2000	7.140
31	41	0.278	02.78	1500	32.632
32	43	0.309	03.09	1400	35.957
32	41	0.309	03.09	1400	35.957
36	37	1.057	10.57	270	7.025
34	35	0.491	04.91	270	3.591
35	38	1.980	19.80	200	12.631
33	34	1.265	12.65	270	8.288
37	39	0.283	02.83	270	2.329
37	40	1.281	12.81	270	8.389
37	42	2.105	21.05	200	13.388
38	42	0.907	09.07	270	6.116
39	42	2.030	20.30	200	12.934
40	41	0.125	01.25	600	8.179
40	42	0.932	09.32	200	6.268
40	45	2.205	22.05	180	13.994
41	43	0.139	01.39	2000	17.284
42	43	0.125	01.25	600	8.178
42	44	1.206	12.06	270	7.934
44	45	1.864	18.64	200	11.924
46	03	0.203	02.03	1800	24.319
46	06	0.128	01.28	2000	16.005
46	10	0.081	00.81	2000	10.889
46	11	0.125	01.25	600	8.179
46	16	0.203	02.03	1800	24.319
46	19	0.222	02.22	1800	26.365

Fonte: Adaptado de (MONTICELLI et al., 1982).

**APÊNDICE C – Dados do sistema IEEE-118**

Dados de barra do sistema IEEE-118.

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
1	405.72	-	-
2	167.41	-	-
3	326.58	-	-
4	251.25	-	-
5	-	-	245.0
6	435.41	-	-
7	159.08	-	-
8	-	110.0	245.0
9	-	-	315.0
10	-	1100.0	210.0
11	586.17	-	-
12	393.58	-	-
13	284.66	-	-
14	117.25	-	-
15	753.67	-	-
16	209.33	-	-
17	89.91	-	-
18	502.42	-	-
19	376.83	-	-
20	603.46	-	-
21	117.25	-	-
22	83.75	-	-
23	58.58	-	-
24	-	110.0	611.8
25	-	3300.0	651.0
26	-	-	1426.6
27	519.17	-	-
28	142.42	-	-
29	201.00	-	-
30	-	-	70.0
31	360.08	110.0	-
32	493.99	1172.6	-
33	42.24	-	-
34	108.28	110.0	-
35	60.57	-	-
36	56.91	92.4	-
37	-	-	210.0
38	-	-	-
39	46.69	-	-
40	34.22	110.0	-
41	63.98	-	-
42	63.98	110.0	-
43	31.13	-	-



Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
44	27.66	-	-
45	91.63	-	-
46	48.41	367.4	-
47	58.79	-	-
48	34.57	-	-
49	150.42	457.6	-
50	29.38	-	-
51	29.38	-	-
52	31.13	-	-
53	39.75	-	-
54	195.40	457.6	-
55	108.92	367.4	-
56	145.23	367.4	-
57	20.75	-	-
58	20.75	-	-
59	478.96	244.2	-
60	134.86	-	-
61	-	244.2	186.9
62	133.14	367.4	-
63	-	-	105.0
64	-	-	175.0
65	-	616.0	84.0
66	67.44	616.0	-
67	48.41	-	-
68	-	-	210.0
69	-	275.0	105.0
70	520.61	292.6	-
71	-	-	448.0
72	-	110.0	84.0
73	-	110.0	84.0
74	536.37	550.0	-
75	370.77	-	-
76	117.57	-	-
77	105.48	-	-
78	122.76	-	-
79	67.44	-	-
80	224.77	-	-
81	-	-	784.0
82	205.45	367.4	-
83	76.10	-	-
84	41.84	-	-
85	91.30	110.0	-
86	79.89	-	-
87	-	785.4	150.5
88	182.62	-	-
89	-	-	186.9

Barra	Carga (MW)	Geração térmica (MW)	Geração eólica (MW)
90	296.75	-	-
91	-	182.6	497.0
92	247.29	-	-
93	45.66	-	-
94	114.13	-	-
95	159.79	-	-
96	144.57	-	-
97	259.40	-	-
98	58.79	-	-
99	-	367.4	371.7
100	140.78	1100.0	-
101	83.69	-	-
102	19.01	-	-
103	87.50	72.6	-
104	144.57	732.6	-
105	117.95	732.6	-
106	163.58	-	-
107	105.10	367.4	-
108	7.61	-	-
109	30.44	-	-
110	148.39	182.6	-
111	-	367.4	63.0
112	95.12	367.4	-
113	-	367.4	133.0
114	67.00	-	-
115	184.16	-	-
116	-	182.6	84.0
117	167.50	-	-
118	57.07	-	-

Fonte: Adaptado de (ROLDÁN et al., 2019).

#### Dados de linhas existentes e candidatas do sistema IEEE-118.

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
1	2	3.030	9.990	525	44.99
1	3	1.290	4.240	525	39.24
4	5	0.176	0.798	1500	100.79
3	5	2.410	10.800	525	45.80
5	6	1.190	5.400	525	40.40
6	7	0.459	2.080	525	37.08
8	9	0.244	3.050	1500	103.05
8	5	0.000	2.670	1500	102.67
9	10	0.258	3.220	1500	103.22

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
4	11	2.090	6.880	525	41.88
5	11	2.030	6.820	525	41.82
11	12	0.595	1.960	525	36.96
2	12	1.870	6.160	525	41.16
3	12	4.840	16.000	525	51.00
7	12	0.862	3.400	525	38.40
11	13	2.225	7.310	525	42.31
12	14	2.150	7.070	525	42.07
13	15	7.440	24.440	525	59.44
14	15	5.950	19.500	525	54.50
12	16	2.120	8.340	525	43.34
15	17	1.320	4.370	1500	104.37
16	17	4.540	18.010	525	53.01
17	18	1.230	5.050	525	40.05
18	19	1.119	4.930	525	39.93
19	20	2.520	11.700	525	46.70
15	19	1.200	3.940	525	38.94
20	21	1.830	8.490	525	43.49
21	22	2.090	9.700	525	44.70
22	23	3.420	15.900	525	50.90
23	24	1.350	4.920	525	39.92
23	25	1.560	8.000	1500	108.00
26	25	0.000	3.820	1500	103.82
25	27	3.180	16.300	1500	116.30
27	28	1.913	8.550	525	43.55
28	29	2.370	9.430	525	44.43
30	17	0.000	3.880	1500	103.88
8	30	0.431	5.040	525	40.04
26	30	0.799	8.600	1500	108.60
17	31	4.740	15.630	525	50.63
29	31	1.080	3.310	525	38.31
23	32	3.170	11.530	420	39.53
31	32	2.980	9.850	525	44.85
27	32	2.290	7.550	525	42.55
15	33	3.800	12.440	175	47.44
19	34	7.520	24.700	175	59.70
35	36	0.224	1.020	525	36.02
35	37	1.100	4.970	525	39.97
33	37	4.150	14.200	525	49.20
34	36	0.871	2.680	525	37.68
34	37	0.256	0.940	1500	100.94
38	37	0.000	3.750	1500	103.75
37	39	3.210	10.600	525	45.60
37	40	5.930	16.800	525	51.80
30	38	0.464	5.400	525	40.40

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
39	40	1.840	6.050	525	41.05
40	41	1.450	4.870	525	39.87
40	42	5.550	18.300	525	53.30
41	42	4.100	13.500	525	48.50
43	44	6.080	24.540	525	59.54
34	43	4.130	16.810	525	51.81
44	45	2.240	9.010	525	44.01
45	46	4.000	13.560	525	48.56
46	47	3.800	12.700	525	47.70
46	48	6.010	18.900	525	53.90
47	49	1.910	6.250	525	41.25
42	49	7.150	32.300	525	67.30
42	49	7.150	32.300	525	67.30
45	49	6.840	18.600	525	53.60
48	49	1.790	5.050	525	40.05
49	50	2.670	7.520	525	42.52
49	51	4.860	13.700	525	48.70
51	52	2.030	5.880	525	40.88
52	53	4.050	16.350	525	51.35
53	54	2.630	12.200	525	47.20
49	54	7.300	28.900	525	63.90
49	54	8.690	29.100	525	64.10
54	55	1.690	7.070	525	42.07
54	56	0.275	0.955	525	35.95
55	56	0.488	1.510	525	36.51
56	57	3.430	9.660	525	44.66
50	57	4.740	13.400	525	48.40
56	58	3.430	9.660	525	44.66
51	58	2.550	7.190	525	42.19
54	59	5.030	22.930	525	57.93
56	59	8.250	25.100	525	60.10
56	59	8.030	23.900	525	58.90
55	59	4.739	21.580	525	56.58
59	60	3.170	14.500	525	49.50
59	61	3.280	15.000	525	50.00
60	61	0.264	1.350	1500	101.35
60	62	1.230	5.610	525	40.61
61	62	0.824	3.760	525	38.76
63	59	0.000	3.860	1500	103.86
63	64	0.172	2.000	1500	102.00
64	61	0.000	2.680	1500	102.68
38	65	0.901	9.860	1500	109.86
64	65	0.269	3.020	1500	103.02
49	66	1.800	9.190	1500	109.19
49	66	1.800	9.190	1500	109.19

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
62	66	4.820	21.800	525	56.80
62	67	2.580	11.700	525	46.70
65	66	0.000	3.700	1500	103.70
66	67	2.240	10.150	525	45.15
65	68	0.138	1.600	1500	101.60
47	69	8.440	27.780	525	62.78
49	69	9.850	32.400	525	67.40
68	69	0.000	3.700	1500	103.70
69	70	3.000	12.700	1500	112.70
24	70	0.221	41.150	525	76.15
70	71	0.882	3.550	525	38.55
24	72	4.880	19.600	525	54.60
71	72	4.460	18.000	525	53.00
71	73	0.866	4.540	525	39.54
70	74	4.010	13.230	525	48.23
70	75	4.280	14.100	525	49.10
69	75	4.050	12.200	1500	112.20
74	75	1.230	4.060	525	39.06
76	77	4.440	14.800	525	49.80
69	77	3.090	10.100	525	45.10
75	77	6.010	19.990	525	54.99
77	78	0.376	1.240	525	36.24
78	79	0.546	2.440	525	37.44
77	80	1.700	4.850	1500	104.85
77	80	2.940	10.500	1500	110.50
79	80	1.560	7.040	525	42.04
68	81	0.175	2.020	1500	102.02
81	80	0.000	3.700	1500	103.70
77	82	2.980	8.530	600	48.53
82	83	1.120	3.665	600	43.66
83	84	6.250	13.200	525	48.20
83	85	4.300	14.800	525	49.80
84	85	3.020	6.410	525	41.41
85	86	3.500	12.300	1500	112.30
86	87	2.828	20.740	1500	120.74
85	88	2.000	10.200	525	45.20
85	89	2.390	17.300	525	52.30
88	89	1.390	7.120	1500	107.12
89	90	5.180	18.800	1500	118.80
89	90	2.380	9.970	1500	109.97
90	91	2.540	8.360	525	43.36
89	92	0.990	5.050	1500	105.05
89	92	3.930	15.810	1500	115.81
91	92	3.870	12.720	525	47.72
92	93	2.580	8.480	525	43.48

Barra de	Barra para	Resistência série (pu)	Reatância série (pu)	Capacidade de transmissão (MW)	Custo (\$10 <sup>4</sup> )
92	94	4.810	15.800	525	50.80
93	94	2.230	7.320	525	42.32
94	95	1.320	4.340	525	39.34
80	96	3.560	18.200	525	53.20
82	96	1.620	5.300	525	40.30
94	96	2.690	8.690	525	43.69
80	97	1.830	9.340	525	44.34
80	98	2.380	10.800	525	45.80
80	99	4.540	20.600	600	60.60
92	100	6.480	29.500	525	64.50
94	100	1.780	5.800	525	40.80
95	96	1.710	5.470	525	40.47
96	97	1.730	8.850	525	43.85
98	100	3.970	17.900	525	52.90
99	100	1.800	8.130	525	43.13
100	101	2.770	12.620	525	47.62
92	102	1.230	5.590	525	40.59
101	102	2.460	11.200	525	46.20
100	103	1.600	5.250	1500	105.25
100	104	4.510	20.400	525	55.40
103	104	4.660	15.840	525	50.84
103	105	5.350	16.250	525	51.25
100	106	6.050	22.900	525	57.90
104	105	0.994	3.780	525	38.78
105	106	1.400	5.470	525	40.47
105	107	5.300	18.300	525	53.30
105	108	2.610	7.030	525	42.03
106	107	5.300	18.300	525	53.30
108	109	1.050	2.880	525	37.88
103	110	3.906	18.130	525	53.13
109	110	2.780	7.620	525	42.62
110	111	2.200	7.550	525	42.55
110	112	2.470	6.400	525	41.40
17	113	0.913	3.010	525	38.01
32	113	6.150	20.300	1500	120.30
32	114	1.350	6.120	525	41.12
27	115	1.640	7.410	525	42.41
114	115	0.230	1.040	525	36.04
68	116	0.034	0.405	1500	100.40
12	117	3.290	14.000	525	49.00
75	118	1.450	4.810	525	39.81
76	118	1.640	5.440	525	40.44

Fonte: Adaptado de (ROLDÁN et al., 2019).