

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

BIBIANA MAITÊ PETRY FERRAZ

**MODELO LINEARIZADO PARA
PROBLEMAS DE PLANEJAMENTO DA
OPERAÇÃO DE SISTEMAS DE
DISTRIBUIÇÃO CONSIDERANDO
INCERTEZAS**

Porto Alegre
2020

BIBIANA MAITÊ PETRY FERRAZ

**MODELO LINEARIZADO PARA
PROBLEMAS DE PLANEJAMENTO DA
OPERAÇÃO DE SISTEMAS DE
DISTRIBUIÇÃO CONSIDERANDO
INCERTEZAS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Doutor em Engenharia Elétrica.

Área de concentração: Energia

ORIENTADOR: Prof. Dr. Sérgio Haffner

CO-ORIENTADOR: Prof. Dr. Flávio Antônio
Becon Lemos

Porto Alegre
2020

CIP - Catalogação na Publicação

Ferraz, Bibiana Maitê Petry
Modelo linearizado para problemas de planejamento da operação de sistemas de distribuição considerando incertezas / Bibiana Maitê Petry Ferraz. -- 2020. 148 f.
Orientador: Sérgio Luis Haffner.

Coorientador: Flávio Antônio Becon Lemos.

Tese (Doutorado) -- Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Programa de Pós-Graduação em Engenharia Elétrica, Porto Alegre, BR-RS, 2020.

1. Planejamento da operação de sistemas de distribuição. 2. Programação linear inteira mista. 3. Incertezas. 4. Controle volt-var. 5. K-means clustering. I. Haffner, Sérgio Luis, orient. II. Lemos, Flávio Antônio Becon, coorient. III. Título.

BIBIANA MAITÊ PETRY FERRAZ

**MODELO LINEARIZADO PARA
PROBLEMAS DE PLANEJAMENTO DA
OPERAÇÃO DE SISTEMAS DE
DISTRIBUIÇÃO CONSIDERANDO
INCERTEZAS**

Esta tese foi julgada adequada para a obtenção do título de Doutor em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____
Prof. Dr. Sérgio Haffner, UFRGS
Doutor pela Universidade Estadual de Campinas – Campinas, Brasil

Banca Examinadora:

Prof. Dr. Carlos Alberto de Castro Júnior, PUC-CAMPINAS
Doutor pela Arizona State University – Tempe, Estados Unidos

Prof. Dr. Osvaldo Ronald Saavedra Mendez, UFMA
Doutor pela Universidade Estadual de Campinas – Campinas, Brasil

Prof. Dr. Mauricio Sperandio, UFSM
Doutor pela Universidade Federal de Santa Catarina – Florianópolis, Brasil

Prof. Dr. Alexandre Sanfelice Bazanella, UFRGS
Doutor pela Universidade Federal de Santa Catarina – Florianópolis, Brasil

Prof. Dr. Roberto Chouhy Leborgne, UFRGS
Doutor pela Chalmers University Of Technology – Göteborg, Suécia

Coordenador do PPGEE: _____
Prof. Dr. Sérgio Haffner

Porto Alegre, novembro de 2020.

DEDICATÓRIA

Ao Renato Ferraz e à pequena Duda.

AGRADECIMENTOS

Ao meu país, em reconhecimento a todos os cidadãos brasileiros que contribuem para a manutenção do ensino superior público, como fator de desenvolvimento científico e tecnológico, apesar de todas as desigualdades sociais e econômicas.

Ao meu marido Renato Gonçalves Ferraz pelo carinho, paciência e incondicional apoio, viabilizando a minha passagem pelo sinuoso da caminho da Pós-Graduação, com seus conselhos e críticas, estimulando constantemente a busca pela excelência na formação acadêmica.

À minha filha amada, Maria Eduarda, que mesmo tão pequena, compreendeu a minha ausência, me proporcionou inúmeras alegrias e me motiva diariamente a ser uma pessoa melhor.

Ao Prof. Sérgio Haffner, por todo o apoio disponibilizado ao longo do Curso de Doutorado, pelos anos de convívio e parceira profissional que construímos desde 2014. Ao Prof. Flávio Antônio Becon Lemos pelo suporte e incentivo desde a graduação.

Desde o plano de pesquisa até a conclusão da tese, a pequena Duda viveu 4 dos seus 5 primeiros anos de vida. Para tornar isso possível, uma extensa lista de pessoas fez parte de uma fundamental rede de apoio, me auxiliando das mais variadas formas. Por isso, muito obrigada. Em especial aos meus pais, Jorge e Terezinha Petry, e à minha sogra, Leontina Ferraz, pela torcida e pelo suporte fundamental com a minha pequena Duda.

Aos colegas do Laboratório de Sistemas Elétricos de Potência (LASEP), onde sempre fui muito bem acolhida ao longo dos últimos 7 anos. Em especial à Mariana Resener, pela ímpar dedicação e disponibilidade no decorrer desta tese. Ao Prof. Roberto Leborgne, que me recebeu na UFRGS ainda no início do mestrado e me acompanhou por todos esses anos de Pós-Graduação. Ao Prof. Alexandre Balbinot pela disponibilidade e importante apoio na consolidação da metodologia de cálculo das incertezas.

À querida amiga Liama Azambuja Pacheco por todos os anos de amizade e carinho.

Agradeço também ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) pela oportunidade de realização de estudos em minha área de pesquisa e à Miriam Rosek, pelo importante trabalho realizado junto ao PPGEE. Por fim, à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro e por tornar viável a minha dedicação em tempo integral ao Curso de Pós-Graduação.

RESUMO

Este trabalho apresenta um modelo linearizado para o problema de planejamento da operação de sistemas de distribuição de energia elétrica (SDEE) considerando incertezas. Com o objetivo de minimizar o custo de operação de SDEE com inserção de recursos energéticos distribuídos (REDs), o modelo contempla estratégias de controle descentralizado de volt-var com bancos de capacitores e reguladores de tensão. Tais estratégias foram escolhidas visando reduzir perdas, corrigir o fator de potência, melhorar o perfil de tensão e aumentar o fator de carga do SDEE. De acordo com a formulação proposta, os dispositivos de regulação tornam-se sensíveis a variações de carga a jusante, uma vez que o modelo contempla variáveis explícitas de corrente para controlar bancos de capacitores automáticos, e compensar quedas de tensão ao longo da linha no controle de reguladores de tensão. As incertezas inerentes à presença de REDs e à demanda de energia elétrica são representadas por cenários de operação, selecionados com o algoritmo *K-means clustering*, visando preservar a cronologia dos dados históricos, bem como considerar a simultaneidade entre diferentes cargas e unidades de geração, com um número reduzido de avaliações necessárias para simular a operação da rede. Além disso, a abordagem proposta contempla o efeito de propagação das incertezas nos custos de operação, os quais estão associados às perdas ativas e penalidades pela violação dos limites de tensão. O ponto de operação em regime permanente do sistema é calculado por meio de um modelo linearizado da rede. Desta forma, o modelo de otimização proposto utiliza função objetivo linear, restrições lineares e variáveis contínuas e binárias, e pode ser representado por um problema de programação linear inteira mista, que pode ser resolvido por intermédio de métodos exatos, com garantia de otimalidade. O modelo é validado por meio da comparação dos resultados obtidos em inúmeros testes de dois sistemas e os resultados do fluxo de carga convencional. Os resultados do modelo linearizado apresentam uma boa precisão em relação ao método do fluxo de potência não-linear. Além disso, os resultados evidenciam a importância da modelagem da cronologia da operação, permitindo representar diferentes níveis de cargas e REDs, mantendo a validade e o desempenho do modelo proposto, além permitir a avaliação do efeito da propagação das incertezas dos cenários nos custos de operação de sistemas de distribuição.

Palavras-chave: Planejamento da operação de sistemas de distribuição, Programação linear inteira mista, Incertezas, Controle volt-var, *K-means clustering*.

ABSTRACT

This work presents a linearized model that can be applied to the planning of the operation of power distribution systems (PDS) considering uncertainties. To minimize the operation costs of distribution systems containing distributed energy resources (DERs), the model includes decentralized strategies for volt-var control which include capacitor banks (CBs) and voltage regulators (VRs). These strategies aim to reduce the power losses and also increase the power factor, thus improving the voltage levels and the PDS load factor. According to the proposed formulation, regulation devices become sensitive to downstream load variations, since inside each control strategy of VRs, the model uses explicit current variables to handle the operation of automatic CBs, and since it includes means to compensate voltage drops along distribution lines. Further, the inherent uncertainties of DERs and load demand are represented through typical operational scenarios, selected using the K-means clustering algorithm. In this way, the simultaneity and chronological combination of different loads and DERs are preserved through a set of K scenarios, which simplifies the PDS operation analysis, given that a reduced number of possible states are required. Besides, the proposed approach considers the effect of the propagation of uncertainties on the operating costs, energy losses, and violation of voltage limits. Further, the steady-state operation point is calculated through a linearized model of the network. Thus, the optimization model proposed to solve these problems uses a linear objective function, along with linear constraints, binary and continuous variables. Therefore, the optimization model can be represented as a mixed-integer linear programming problem (MILP), which in addition to guaranteed optimality of a given feasible solution allows the use of classical optimization methods to find the solution. The model is validated by comparing the results obtained during several tests of two typical cases with those obtained through nonlinear power flow. The results obtained with the linearized model are in good agreement with those obtained with the power flow method. Moreover, the results show that the use of typical scenarios allows representing different levels of loads and DERs while keeping the validity and performance of the proposed model. Finally, the use of typical scenarios also allows evaluating the effect of the propagation of uncertainties on the costs of PDS operation.

Keywords: Distribution system operation planning, Mixed-integer linear programming, Uncertainties, volt-var Control, K-means clustering.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Diagrama ilustrativo das características da abordagem proposta. . . .	25
Figura 2 –	Níveis de carregamento propostos por Haffner <i>et al.</i> (2009) e Resener (2016).	37
Figura 3 –	Comportamento estatístico da demanda agregada no alimentador. . .	39
Figura 4 –	Curvas de carga de um consumidor residencial representadas por: (a) 365 dias (dados históricos), e (b) 3 cenários (selecionados com <i>K-means clustering</i>).	42
Figura 5 –	Agregação de séries temporais (eixo x: dias do ano; eixo y: hora do dia).	45
Figura 6 –	Pseudocódigo da análise de variâncias.	50
Figura 7 –	Proposição de contribuição científica da tese.	57
Figura 8 –	Ilustração das principais etapas da modelagem da cronologia de operação: (a) leitura do histórico de dados (não-tratados); (b) processamento dos dados; (c) seleção de cenários; (d) geração de amostras independentes e aleatórias.	61
Figura 9 –	Representação matricial dos dados para modelagem da cronologia de operação do SDEE.	62
Figura 10 –	Controle de corrente de BCs automáticos: (a) sistema com BC instalado no nó m ; (b) histerese de controle de corrente.	67
Figura 11 –	Exemplo da aproximação linear por partes proposta: (a) visualização em três dimensões do modelo de combinação convexa; (b) visualização em duas dimensões dos planos adotados.	70
Figura 12 –	Circuito simplificado que representa a operação do tap de um RT com compensação por queda de tensão na linha.	72
Figura 13 –	Controle da operação do tap do RT: (a) abordagem sem saturação do controle; (b) abordagem proposta considerando região de saturação. .	74
Figura 14 –	Abordagem proposta para solução do modelo de planejamento da operação de sistemas de distribuição.	79
Figura 15 –	Sistema de 23 nós.	81
Figura 16 –	Avaliação da precisão dos cenários a partir da distância da soma dos quadrados (SS), considerando: (a) 1 a 365 cenários; (b) 1 a 5 cenários.	85
Figura 17 –	Curva de carga da demanda ativa (P^D) e reativa (Q^D), agregadas na subestação do sistema de 23 nós ($S_{base} = 4$ MVA) durante: (a) cenário 1; (b) cenário 2; e (c) cenário 3.	87

Figura 18 – Diagrama de caixa com variação horária das demandas ativas e reativas de todas as cargas instaladas no sistema de 23 nós, considerando: (a)–(b) dados do Cenário 1; (c)–(d) dados do Cenário 2; e (e)–(f) dados do Cenário 3.	88
Figura 19 – Cenários de operação do RED instalado no nó 14 do sistema de 23 nós.	89
Figura 20 – Resultados de ajuste do BC automático instalado no nó 8 do sistema de 23 nós para o Caso BC: (a)–(c) perfil da corrente calculado para o ramo a jusante do BC durante os cenários 1, 2 e 3; (d)–(f) estado horário de operação do BC durante os cenários 1, 2 e 3.	92
Figura 21 – Resultados de ajuste do RT instalado no nó 5 do sistema de 23 nós para o Caso RT: (a)–(c) perfil de tensão calculado para o nó remoto 6 durante os cenários 1, 2 e 3; (d)–(f) posição horária do tap durante os cenários 1, 2 e 3.	93
Figura 22 – Histerese de controle do RT instalado no nó 5 do sistema de 23 nós, resultante do Caso RT considerando: (a) PLIM proposto; (b) fluxo de carga convencional com tensão $V_m^{set,RT}$ definida; e (c) fluxo de carga convencional com taps definidos.	94
Figura 23 – Histerese de controle do RT instalado no nó 5 do sistema de 23 nós, resultante do Caso BC + RT considerando: (a) PLIM proposto; (b) fluxo de carga convencional com tensão $V_m^{set,RT}$ definida; e (c) fluxo de carga convencional com taps definidos.	95
Figura 24 – Avaliação da precisão dos cenários a partir da distância da soma dos quadrados (SS), considerando 30 amostras e: (a) 1 a 5 cenários; (b) 2 a 5 cenários.	96
Figura 25 – Avaliação da potência estatística baseada no tamanho amostral considerando dados históricos de 1 ano de operação (grau de confiança = 95%).	99
Figura 26 – Teste de igualdade de variâncias considerando dados históricos de 1 ano de operação (grau de confiança = 95%).	100
Figura 27 – Teste de normalidade dos resíduos considerando dados históricos de 1 ano de operação (grau de confiança = 95%).	100
Figura 28 – Avaliação da potência estatística baseada no tamanho amostral considerando dados históricos de 3 anos de operação (grau de confiança = 95%).	102
Figura 29 – Teste de igualdade de variâncias considerando dados históricos de 3 anos de operação (grau de confiança = 95%).	103
Figura 30 – Teste de normalidade dos resíduos considerando dados históricos de 3 anos de operação (grau de confiança = 95%).	103
Figura 31 – Resultados de ajuste do BC automático instalado no nó 8 do sistema de 23 nós considerando 30 amostras para o Caso BC, onde: (a)–(c) diagrama de caixa com variação horária da corrente calculada para o ramo à jusante do BC durante os Cenários 1,2 e 3; (d)–(f) somatório do estado de operação do BC durante os Cenários 1, 2 e 3, respectivamente.	109

Figura 32 – Resultados de ajuste do RT instalado no nó 5 do sistema de 23 nós para o Caso RT: (a)–(c) perfis de tensão do nó 6, calculados para todas amostras, durante os Cenários 1, 2 e 3, respectivamente; (d)–(f) variabilidade da posição horária do tap RT, calculado para todas amostras, durante os Cenários 1, 2 e 3, respectivamente.	110
Figura 33 – Resultados de ajuste do RT instalado no nó 5 do sistema de 23 nós para o Caso BC + RT: (a)–(c) perfis de tensão do nó 6, calculados para todas amostras, durante os Cenários 1, 2 e 3, respectivamente; (d)–(f) variabilidade da posição horária do tap RT, calculado para todas amostras, durante os Cenários 1, 2 e 3, respectivamente.	111
Figura 34 – Histerese de controle do RT instalado no nó 5 do sistema de 23 nós, resultante da operação considerando incertezas dos casos: (a) RT; (b) BC + RT.	112
Figura 35 – Topologia do sistema de 69 nós.	112
Figura 36 – Curva de carga da demanda ativa (P^D) e reativa (Q^D), agregadas na subestação do sistema de 69 nós ($S_{base} = 4$ MVA) durante: (a) cenário 1; (b) cenário 2; e (c) cenário 3.	114
Figura 37 – Resultados de ajuste do BC automático instalado no nó 50 do sistema de 23 nós para o Caso BC + RT + RED: (a)–(c) perfil da corrente calculado para o ramo à jusante do BC durante os cenários 1, 2 e 3; (d)–(f) estado horário de operação do BC durante os cenários 1, 2 e 3.	116
Figura 38 – Histerese de controle do RT instalado no nó 43 do sistema de 69 nós, resultante do Caso BC + RT + RED considerando: (a) PLIM proposto; (b) fluxo de carga convencional com tensão $V_m^{set,RT}$ definida; e (c) fluxo de carga convencional com taps definidos.	117
Figura 39 – Curva de potência ativa <i>versus</i> tensão.	131
Figura 40 – Sistema de duas barras.	134
Figura 41 – Função de representação da violação dos limite de tensão - limites móveis.	136
Figura 42 – Restrições lineares utilizadas para aproximar as perdas ativas nas linhas.	137

LISTA DE TABELAS

Tabela 1 –	Histórico de soluções de otimização volt-var.	28
Tabela 2 –	Erro quadrático médio [%] entre os dados históricos (originais) e 4 cenários representativos considerando diferentes técnicas de agregação de séries temporais.	44
Tabela 3 –	Caracterização das abordagens correlatas.	53
Tabela 4 –	Definições sobre a modelagem da cronologia de operação proposta.	59
Tabela 5 –	Resumo dos aspectos que envolvem a avaliação e a expressão das incertezas.	77
Tabela 6 –	Equipamentos existentes no sistema de 23 nós em cada caso.	83
Tabela 7 –	Resultados anuais de desempenho do sistema de 23 nós variando o número de cenários.	86
Tabela 8 –	Duração de cada cenário adotado nos casos do sistema de 23 nós.	87
Tabela 9 –	Resultados do PLIM relativos à operação determinística do sistema de 23 nós.	90
Tabela 10 –	Resultados de ajuste ótimo do controle volt-var do sistema de 23 nós.	91
Tabela 11 –	Matriz experimental considerando dados históricos de 1 ano de operação.	98
Tabela 12 –	Análise de variância (ANOVA) considerando dados históricos de 1 ano de operação.	98
Tabela 13 –	Matriz experimental considerando dados históricos de 3 anos de operação.	101
Tabela 14 –	Análise de variância (ANOVA) considerando dados históricos de 3 anos de operação.	102
Tabela 15 –	Resultados de ajuste ótimo do controle volt-var do sistema de 23 nós, obtidos para a melhor amostra.	105
Tabela 16 –	Resultados do PLIM relativos à operação do sistema de 23 nós considerando a melhor amostra.	106
Tabela 17 –	Resultados do PLIM relativos à operação considerando incertezas do sistema de 23 nós (grau de confiança = 95%).	107
Tabela 18 –	Custo de operação e quantidade de dias agrupados em cada cenário do Caso BC + RT + RED.	108
Tabela 19 –	Equipamentos existentes no sistema de 69 nós em cada caso.	113
Tabela 20 –	Duração de cada cenário adotado nos casos do sistema de 69 nós.	113
Tabela 21 –	Resultados do PLIM relativos à operação determinística do sistema de 69 nós.	115
Tabela 22 –	Resultados de ajuste ótimo do controle volt-var do sistema de 69 nós.	115
Tabela 23 –	Limites segundo o modelo de operação dos geradores.	134

Tabela 24 – Valores de demanda ativa [kW] dos nós 2 à 12.	138
Tabela 25 – Valores de demanda ativa [kW] dos nós 13 à 23.	140
Tabela 26 – Valores de demanda reativa [kvar] dos nós 2 à 12.	141
Tabela 27 – Valores de demanda reativa [kvar] dos nós 13 à 23.	143
Tabela 28 – Valores de injeção de potência ativa do RED [kW].	145

LISTA DE ABREVIATURAS

ANEEL	Agência Nacional de Energia Elétrica
ANOVA	Análise de Variâncias
BC	Banco de Capacitor
CVR	<i>Conservation Voltage Reduction</i>
LDC	<i>Line Drop Compensation</i>
FC	Fluxo de Carga Convencional
FCD	Fluxo de Carga Determinístico
FCP	Fluxo de Carga Probabilístico
OLTC	<i>On-Load Tap Changer</i>
PDF	<i>Probability Density Function</i>
PLIM	Programação Linear Inteira-Mista
PNLIM	Programação Não-Linear Inteira-Mista
PWL	<i>Piecewise Linearization</i>
RED	Recurso Energético Distribuído
RT	Regulador de Tensão
SCADA	Supervisório de Controle e Aquisição de Dados
SDEE	Sistemas de Distribuição de Energia Elétrica
SGD	Sistema de Gerenciamento da Distribuição
SMC	Simulação de Monte Carlo
VE	Veículo Elétrico

LISTA DE SÍMBOLOS

Conjuntos:

ψ^N, N	Conjunto e cardinalidade de todos os nós da rede.
ψ^R, R	Conjunto e cardinalidade de todos os ramos da rede.
ψ^D, D	Conjunto e cardinalidade de todos os nós da rede nos quais existe demanda de potência, nos quais a tensão necessita ser regulada.
ψ^G, G	Conjunto e cardinalidade de todos os nós da rede nos quais existe capacidade de injeção de potência, nos quais a tensão necessita ser regulada.
ψ^{BC}, BC	Conjunto e cardinalidade de todos os nós da rede nos quais existe banco de capacitores instalado.
ψ^F, F	Conjunto e cardinalidade dos tipos de bancos de capacitores fixos existentes na rede.
ψ^A, A	Conjunto e cardinalidade dos tipos de bancos de capacitores automáticos existentes na rede.
ψ^J, J	Conjunto e cardinalidade das 24 horas que são consideradas em cada cenário para descrever um dia de operação.
ψ_s^K, K	Conjunto e cardinalidade de cenários diários de operação a ser considerado, pertencente à amostra s .
ψ^S, S	Conjunto e cardinalidade de amostras a ser considerado.
$\mathcal{V}(\rho)$	Conjunto de vértices do plano ρ .
\mathcal{P}	Conjunto de n_ρ planos.

Variáveis Inteiras e Binárias:

$y_{m,j,sc,s}^{AI}$	Variável binária que indica que o banco de capacitores automático do tipo I instalado no nó m está ligada durante a hora j do cenário sc pertencente à amostra s .
$h_{mn,j,sc,s}^{\rho}$	Variável binária que ativa ou não os planos.
$w_{m,j,sc,s}^{AI}$	Variável binária que indica manobra do banco de capacitores automático do tipo I instalado no nó m .
$t_{m,j,sc,s}^{RT}$	Variável inteira que representa a posição do tap do regulador de tensão, instalado no nó m , durante a hora j do cenário sc pertencente à amostra s .
$r_{i,m,j,sc,s}$	Variável binária utilizada no cálculo do tap do regulador de tensão instalado no nó m durante a hora j do cenário sc pertencente à amostra s , onde $i = 1, 2, \dots, 6$.

Variáveis Contínuas:

C_s^{oper}	Custo anual de operação da amostra s [\$/ano].
$C_{sc,s}^{\text{oper}}$	Custo diário de operação do cenário sc pertencente à amostra s [\$/dia].
$C_{sc,s}^{\text{loss}}$	Custo diário das perdas de energia ativa do cenário sc pertencente à amostra s [\$/dia].
$C_{sc,s}^{\text{vio}}$	Penalidade diária das violações dos limites de tensão do cenário sc pertencente à amostra s [\$/dia].
$P_{km,j,sc,s}^{\text{loss}}$	Perdas ativas diárias ocorridas no ramo km durante a hora j do cenário sc pertencente à amostra s [pu/dia].
$z_{m,j,sc,s}$	Violação diárias ocorridas nos limites de tensão do nó m durante a hora j do cenário sc pertencente à amostra s [pu/dia].
$\mathbf{q}_{j,sc,s}^F, \mathbf{q}_{j,sc,s}^A$	Vetores com injeções de corrente relacionadas a operação de capacitores fixos e automáticos durante a hora j do cenário sc pertencente à amostra s [pu].
$\mathbf{f}_{j,sc,s}^{\text{Re}}, \mathbf{f}_{j,sc,s}^{\text{Im}}$	Vetores das partes real e imaginária das correntes nos ramos durante a hora j do cenário sc pertencente à amostra s [pu].
\mathbf{S}	Matriz incidência nó-ramo da rede.

$\mathbf{g}_{j,sc,s}^{\text{Re}}, \mathbf{g}_{j,sc,s}^{\text{Im}}$	Vetores das partes real e imaginária da injeções nodais de corrente relacionadas à operação dos REDs, durante a hora j do cenário sc pertencente à amostra s [pu].
$\mathbf{d}_{j,sc,s}^{\text{Re}}, \mathbf{d}_{j,sc,s}^{\text{Im}}$	Vetores das partes real e imaginária das correntes de carga durante a hora j do cenário sc pertencente à amostra s [pu].
$\Delta \mathbf{f}_{j,sc,s}^{\text{Re}}, \Delta \mathbf{f}_{j,sc,s}^{\text{Im}}$	Vetores com as alterações nas partes real e imaginária no fluxo de corrente a montante dos RTs [pu].
$f_{km,j,sc,s}^{\text{Re}}$	Parte real da corrente no ramo km durante a hora j do cenário sc pertencente à amostra s [pu].
$f_{km,j,sc,s}^{\text{Im}}$	Parte imaginária da corrente no ramo km durante a hora j do cenário sc pertencente à amostra s [pu].
$f_{km,j,sc,s}^{2\text{Re}}, f_{km,j,sc,s}^{2\text{Im}}$	Aproximações dos quadrados das partes real e imaginária da corrente no ramo km durante a hora j do cenário sc pertencente à amostra s .
$\mathbf{V}_{j,sc,s}$	Vetor de magnitudes da tensão durante a hora j do cenário sc pertencente à amostra s [pu].
$\Delta V_{m,j,sc,s}$	alteração da tensão no nó m durante a hora j do cenário sc pertencente à amostra s [pu].
$I_{m,j,sc,s}^{\text{trs},AI}$	Valor de corrente de transição durante a hora j do cenário sc pertencente à amostra s [pu].
$I_m^{\text{on},AI}$	Valor de corrente para ligar o BC automático do tipo I instalado no nó m [pu].
$I_m^{\text{off},AI}$	Valor de corrente para desligar o BC automático do tipo I instalado no nó m [pu].
$c^{\text{Re}}(v), c^{\text{Im}}(v), c^f(v)$	Vértices do plano ρ [pu].
$f_{mn,j,sc,s}^{\text{Re}}, f_{mn,j,sc,s}^{\text{Im}}$	Parcela real e imaginária da corrente do ramo mn durante a hora j do cenário sc pertencente à amostra s [pu].
$ f_{mn,j,sc,s} $	Magnitude da corrente do ramo mn durante a hora j do cenário sc pertencente à amostra s [pu].
$\alpha_{mn,j,sc,s}^{\rho v}$	Variáveis contínuas que parametrizam as combinações convexas dos vértices.
$V_m^{\text{set},RT}$	Variável contínua que representa o ajuste ótimo da tensão de referência do RT instalado no nó m [pu].

$V_{n,j,sc,s}$	Tensão no nó remoto n durante a hora j do cenário sc pertencente à amostra s [pu].
$a_{m,j,sc,s}$	Relação de transformação do RT, instalado no nó m , durante a hora j do cenário sc pertencente à amostra s .
$\bar{V}_{m,j,sc}$	Fasor de tensão no nó m durante a hora j do cenário sc pertencente à amostra s .
$V_{m,j,sc}$	Magnitude da tensão no nó m durante a hora j do cenário sc pertencente à amostra s [pu].
$\bar{\Delta T}_{sc}$	Valor médio da duração do cenário sc [dias/ano].
\bar{C}_{sc}^{oper}	valor médio do custo de operação do cenário sc [\$/dia].
\bar{C}^{oper}	Valor médio do custo de operação anual [\$/ano].
\bar{e}^{loss}	Valor médio das perdas de energia anuais [MWh/ano].
\bar{z}	Valor médio das violações anuais dos limites de tensão [pu/ano].
\bar{P}_{sc}^{loss}	Valor médio das perdas ativas diárias do cenário sc [MWh/dia].
\bar{z}_{sc}	Valor médio das violação diárias dos limites de tensão do cenário sc [pu/dia].
$S(c_k)$	Erro quadrático.
u_k	Média empírica de um <i>cluster</i> .
SS	Soma do quadrado das distâncias entre os pontos x_i e os centroides u_k .
$u_A^{x_i}$	Incerteza-padrão tipo A calculada para estimativa da variável x_i considerando o conjunto de amostras.
$s_P^{x_i}$	Desvio-padrão baseado em n_s amostras independentes da variável x_i .
u_c^y	Incerteza-padrão combinada, calculada para estimativa da grandeza de saída y .
x_i, x_{ii}	Estimativas das grandezas de entrada.
$\frac{\partial f}{\partial x_i}, \frac{\partial f}{\partial x_{ii}}$	Derivadas parciais, frequentemente denominadas coeficientes de sensibilidade, que descrevem a variação da estimativa de saída y em relação às alterações nos valores das estimativas de entrada x_1, x_2, \dots, x_C .
$u^{x_i, x_{ii}}$	Covariância estimada associada com x_i e x_{ii} .

$u_A^{x_i}$	Incerteza-padrão tipo A, calculada para estimativa da grandeza de entrada x_i .
$u_A^{x_{ii}}$	Incerteza-padrão tipo A, calculada para estimativa da grandeza de entrada x_{ii} .
$r^{x_i, x_{ii}}$	Grau de correlação estimado entre as grandezas de entrada x_i e x_{ii} .
$(s_p^{x_i})^2$	Variância estimada, ou desvio quadrático em torno da estimativa, da variável aleatória x_i .
$(s_p^{x_{ii}})^2$	Variância estimada, ou desvio quadrático em torno da estimativa, da variável aleatória x_{ii} .
$cov^{x_i, x_{ii}}$	Covariância de duas variáveis aleatórias x_i e x_{ii} .
U^y	Incerteza expandida para a estimativa da grandeza de saída y .
u_c^y	Incerteza padrão combinada para a estimativa da grandeza de saída y .

Parâmetros e Índices:

$\Delta T_{sc,s}$	Duração anual do cenário sc pertencente à amostra s [dias/ano].
C^{MWh}	Custo da energia elétrica [\$/MWh].
S_{base}	Potência base do sistema [MVA].
CV	Fator de penalidade pela violação dos limites de tensão [\$/pu].
$K_{km,j,sc,s}$	Fator de ajuste para o cálculo da queda de tensão no trecho km durante a hora j do cenário sc pertencente à amostra s [pu].
R_{km}	Resistência do trecho de rede km [pu].
X_{km}	Reatância do trecho de rede km [pu].
S	Matriz incidência nó-ramo da rede,
ΔI	Largura de banda de corrente [pu].
f^{\max}	Valor máximo que a variável pode assumir na linearização [pu].
n_ρ	Número total de planos.
n_s	Número de amostras.
$W_{m,sc,s}^{\max, AI}$	Limite de manobras do BC automático do tipo I para o cenário sc pertencente à amostra s .
β	Insensibilidade do RT [pu].
C	Número de coeficientes de sensibilidade.

α	Grau de confiança.
c_k	<i>Cluster</i> .
x_i	Pontos d -dimensionais do <i>cluster</i> c_k .
f	Função de medição.
$P_{m,j,sc,s}^D, Q_{m,j,sc,s}^D$	Demandas de potência ativa e reativa no nó m durante a hora j do cenário sc pertencente à amostra s [pu].
$\bar{S}_{m,j,sc,s}^D$	Demanda de potência complexa no nó m durante a hora j do cenário sc pertencente à amostra s [pu].
$g_{m,j,sc,s}^{\min,Re}, g_{m,j,sc,s}^{\max,Re}$	Limites mínimo e máximo de injeção ativa no nó m com capacidade de geração no período de operação j [pu].
$g_{m,j,sc,s}^{\min,Im}, g_{m,j,sc,s}^{\max,Im}$	Limites mínimo e máximo de injeção reativa no nó m com capacidade de geração no período de operação j [pu].
$g_{m,j,sc,s}^{\text{esp,Re}}, g_{m,j,sc,s}^{\text{esp,Im}}$	Valores especificados de injeções ativa e reativa no nó m com capacidade de geração durante a hora j do cenário sc pertencente à amostra s [pu].
Q_m^{BC}	Potência reativa nominal do capacitor instalado no nó m [pu].
Y_m^{BC}	Admitância do capacitor instalado no nó m [pu].
Y_m^{FI}	Admitância do BC fixo do tipo I instalado no nó m [pu].
Y_m^{AI}	Admitância do BC automático do tipo I instalado no nó m [pu].
$\bar{Z}_{km}, R_{km}, X_{km}$	Impedância, resistência e reatância do trecho de rede km [pu].
a_p, b_p	Constantes utilizadas na aproximação das parcelas $(f_{km,j,sc,s}^{Re})^2$ e $(f_{km,j,sc,s}^{Im})^2$ para o cálculo das perdas.
M	Número grande utilizado nas inequações das restrições disjuntivas.
k_p	Fator de abrangência.
m	Índice utilizado para percorrer os nós da rede.
km	Índice utilizado para percorrer os ramos da rede.
s	Índice utilizado para percorrer as amostras do <i>K-means clustering</i> .
sc	Índice utilizado para percorrer os cenários de operação.
j	Índice utilizado para percorrer as horas dos cenários.

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Objetivos e Contribuição Científica	23
1.2	Estrutura da Tese	26
2	PLANEJAMENTO DA OPERAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO: REVISÃO BIBLIOGRÁFICA	27
2.1	Estratégias de Controle volt-var	27
2.1.1	Principais Características	27
2.1.2	Modelos de Otimização	31
2.2	Cronologia de Operação de Sistemas de Distribuição	37
2.2.1	Curva de Duração	37
2.2.2	Função de Distribuição de Probabilidade	38
2.2.3	Cenários Representativos	40
2.3	Incertezas na Operação de Sistemas de Distribuição	43
2.3.1	Método para Expressão da Incerteza	46
2.3.2	Análise de Variância	49
2.4	Principais Abordagens Correlatas ao Modelo Proposto	52
2.4.1	Resener <i>et al.</i> (2019a)	52
2.4.2	Li, Wang e Xia (2018)	54
2.4.3	Moradijoz, Moghaddam e Haghifam (2018)	55
2.5	Comentários sobre o Estado da Arte e Contribuições da Tese	55
3	MODELO PROPOSTO PARA PLANEJAMENTO DA OPERAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO	58
3.1	Definição do Escopo do Planejamento	58
3.2	Modelagem da Cronologia de Operação	59
3.3	Formulação do Modelo Linearizado	62
3.3.1	Função Objetivo	63
3.3.2	Restrições de Operação da Rede	64
3.3.3	Restrições para Controle volt-var com Bancos de Capacitores	66
3.3.4	Restrições para Controle volt-var com Reguladores de Tensão	71
3.4	Cálculo das Incertezas	75
3.5	Considerações Finais	76
4	ESTUDOS DE CASO E RESULTADOS	78
4.1	Estratégia de Solução do Problema Proposto	78
4.2	Validação do Modelo Proposto	80

4.2.1	Descrição do Sistema de 23 Nós	81
4.2.2	Descrição dos Estudos de Casos	81
4.2.3	Resultados de Cronologia de Operação	83
4.2.4	Resultados de Operação Determinística	89
4.2.5	Resultados da Operação Considerando Incertezas	95
4.3	Exemplo de Aplicação - Sistema de 69 nós	112
5	CONCLUSÃO	118
5.1	Trabalhos Futuros	120
	REFERÊNCIAS	121
6	REPRESENTAÇÃO DOS SISTEMA DE DISTRIBUIÇÃO	131
6.1	Representação dos Componentes de SDEE	131
6.2	Representação das Grandezas de Interesse	135
6.2.1	Desvio da Tensão Nodal	135
6.2.2	Perdas Ativas	136
7	DADOS UTILIZADOS NAS SIMULAÇÕES	138

1 INTRODUÇÃO

Os modelos de otimização propostos para problemas de planejamento de sistemas de distribuição de energia elétrica (SDEE) buscam essencialmente a minimização de custos e otimização da eficiência energética da rede. Novos desafios têm sido impostos para atender aos critérios técnicos, operacionais e de segurança, em meio às incertezas relacionadas à proliferação de recursos energéticos distribuídos (REDs) e ao comportamento estocástico da demanda de energia elétrica.

O objetivo do estudo define o período de tempo que o planejamento irá abranger, como curto (1 dia), médio (algumas semanas a um ano) e longo prazo (2 a 5 anos). O problema de planejamento da operação a curto e médio prazo trata do ajuste ótimo das variáveis de controle disponíveis na rede para melhorar o desempenho do sistema, considerando limites físicos e operacionais dos SDEE. O planejamento da operação a longo prazo, por sua vez, avalia novas configurações da rede de distribuição as quais são definidas em um plano de expansão da rede.

Em geral, as soluções do problema de planejamento da operação requerem a redução de perdas, o controle da tensão e a diminuição de sobrecarga nos condutores e transformadores. Desta forma, para regular as tensões nodais e minimizar as perdas dos SDEE, são propostos ajuste de bancos de capacitores (BCs), fixos e automáticos, reguladores de tensão (RTs) e comutador de tap sob carga, bem como a reconfiguração da rede e a conservação de energia por redução de tensão. Resener *et al.* (2018) destacam que a instalação de BCs é amplamente utilizada para corrigir o fator de potência, reduzindo o fluxo de potência reativa na rede e as perdas de potência ativa. Além disso, a instalação de RTs é uma das técnicas mais utilizadas atualmente para o controle de tensão em regime permanente de SDEE, uma vez que impacta diretamente na melhoria do perfil de tensão, permitindo um ajuste quase contínuo dentro da faixa de operação do RT.

Embora a proposição de estratégias de controle volt-var tenha sido amplamente discutida na literatura, quando consideradas as incertezas no comportamento da carga e dos REDs, definir a melhor estratégia de controle se torna uma tarefa mais complexa, evidenciando a necessidade de modelos e ferramentas computacionais capazes de auxiliar a tomada de decisão pelas equipes das distribuidoras.

A busca por soluções otimizadas para o problema de planejamento considerando as incertezas da operação dos SDEE pode se tornar complexa, considerando que a modelagem matemática deve representar da forma mais aproximada um problema real, e permitir sua resolução por meio de técnicas adequadas e de complexidade computacional razoável. Com o avanço das técnicas de resolução baseadas em algoritmos *branch-and-bound*, nos anos 2000, os *solvers* comerciais tornaram-se extremamente eficientes, em especial os *solvers* de problemas de programação linear inteira mista (PLIM) como o CPLEX (IBM, 2019); porém os métodos que resolvem problemas de programação não-linear inteira mista (PNLIM) não evoluíram com a mesma eficiência (GONÇALVES; FRANCO; RIDER, 2014). Esse fato, associado à capacidade de processamento dos computadores, torna as abordagens baseadas em modelos de PLIM bastante atrativas. Por outro lado, ao se utilizar meta-heurísticas não se tem garantia de otimalidade da solução obtida, o que torna atrativa a utilização de abordagens baseadas em métodos de otimização clássica.

Matematicamente, o problema de otimização voltado ao planejamento da operação de SDEE é combinatorial e altamente complexo, contendo variáveis contínuas e discretas. Por isso, na maioria dos estudos de planejamento de SDEE, os modelos empregados consideram um comportamento simplificado das cargas e dos REDs, nos quais a demanda de energia elétrica segue um padrão definido, como por exemplo curvas típicas de carga/geração, ou um número fixo de níveis de carregamento, ou ainda, cenários extremos (a demanda máxima e a ausência de geração ou a demanda mínima e a geração máxima). Essas abordagens determinísticas desconsideram a natureza estocástica das cargas e dos REDs, de modo que dado um conjunto de entradas, a solução resultará em um único conjunto de saídas. Quando todas as cargas da rede apresentam o mesmo comportamento simultâneo, esta representação pode ser adequada. Entretanto, um cenário mais próximo da realidade deve contemplar situações nas quais o comportamento das cargas é muito diferenciado, o que se intensifica na presença de REDs e requer a transição de modelagens tradicionais determinísticas para probabilísticas (CHEN *et al.*, 2018).

Os métodos probabilísticos apresentam uma ou mais variáveis aleatórias como entrada, conduzindo a um conjunto de estimativas aleatórias de saída. Abordagens probabilísticas voltadas à operação de SDEE fornecem a distribuição de probabilidade (do inglês, *Probability Density Function* – PDF) das tensões dos nós e fluxos das linhas (CAI *et al.*, 2015). Nesse contexto, o fluxo de carga probabilístico (FCP), introduzido por Borkowska (1974), aprimora os resultados do fluxo de carga determinístico (FCD), uma vez que possibilita avaliar não só o impacto de casos extremos de operação, mas determinar a probabilidade de ocorrência destes eventos (LIU *et al.*, 2016). A Simulação Monte Carlo (SMC) é uma abordagem tradicional usada para simular o FCP, a qual executa o FCD repetidamente (por um número significativo de vezes) para representar a PDF das variáveis (KABIR; MISHRA; BANSAL, 2016). Embora a PDF tenha capacidade de refletir a natureza aleatória da carga e REDs, o número elevado de amostras para produzir uma

convergência estatística aceitável da SMC inviabiliza o uso dessa abordagem para a maior parte dos problemas práticos em sistemas elétricos de potência (LI *et al.*, 2017).

Para reduzir a complexidade dos problemas citados, recentemente tem se recomendado a adoção de cenários que representem o histórico de curvas de carga e geração dos REDs existentes no SDEE, como forma de reduzir o número de avaliações necessárias para simular a operação da rede. A principal vantagem dessa abordagem é a possibilidade de representar a operação simultânea de diferentes cargas e REDs, preservando a sequência temporal dos dados com esforço computacional reduzido, especialmente quando comparado à SMC (LI *et al.*, 2017). Todavia, um cenário representativo consiste, usualmente, na média de um grupo de dias, e, portanto, carrega consigo incertezas (MONTGOMERY, 2017). Apesar da literatura dispor de várias metodologias para expressão e validação de incertezas, a escolha depende do tipo de incertezas que serão modeladas e do problema de planejamento sob consideração (EHSAN; YANG, 2019).

Por definição, a incerteza é um parâmetro associado a um resultado e depende de um nível de confiança pré-estabelecido (GUM, 2008). Embora diversas modelagens tenham abordado a inclusão de incertezas, considerando inclusive a correlação das variáveis de entrada em modelos de otimização, ainda é incipiente a proposição de metodologias que calculem as estimativas intervalares das variáveis de resposta de problemas de operação, demonstrando a necessidade de abordagens mais consistentes para lidar com incertezas no planejamento de SDEE (ROSTRON; FEARN; RAMSEY, 2020).

Nesse contexto, torna-se necessária a proposição de um modelo matemático que incorpore de forma explícita as incertezas acerca do comportamento da carga e as variações que ocorrem diariamente em SDEE, de forma a considerar possibilidades operacionais até então ignoradas.

1.1 Objetivos e Contribuição Científica

Embora a solução de problemas de planejamento da operação de SDEE tenha sido amplamente investigada, novas oportunidades e desafios são impostos ao setor elétrico visando abordar o novo papel do consumidor no âmbito das redes elétricas inteligentes, a inserção de recursos energéticos distribuídos, a natureza estocástica da demanda e as incertezas inerentes à intermitência da produção de energia com fontes renováveis. Desta forma, propõe-se desenvolver um modelo de otimização aplicado ao problema de operação de SDEE considerando incertezas da carga e REDs.

O modelo proposto nesta tese objetiva minimizar os custos anuais de operação de SDEE, compostos pela monetização das perdas ativas nos ramos e penalidades pela violação dos limites de tensão nodal, considerando horizonte de tempo de um ano. A otimização volt-var é proposta no modelo de planejamento a partir da operação ótima de bancos de capacitores e reguladores de tensão. A representação da operação do SDEE se

baseia em um modelo linearizado, no qual as cargas e os geradores são representados por injeções de corrente, o que possibilita calcular as correntes nos ramos e as tensões nos nós por meio de expressões lineares (RESENER, 2016). Os BCs são representados por uma injeção dependente do quadrado da tensão (impedância constante). As não-linearidades provenientes das equações que envolvem operação dos BCs e RTs, são evitadas por intermédio de uma formulação linear disjuntiva.

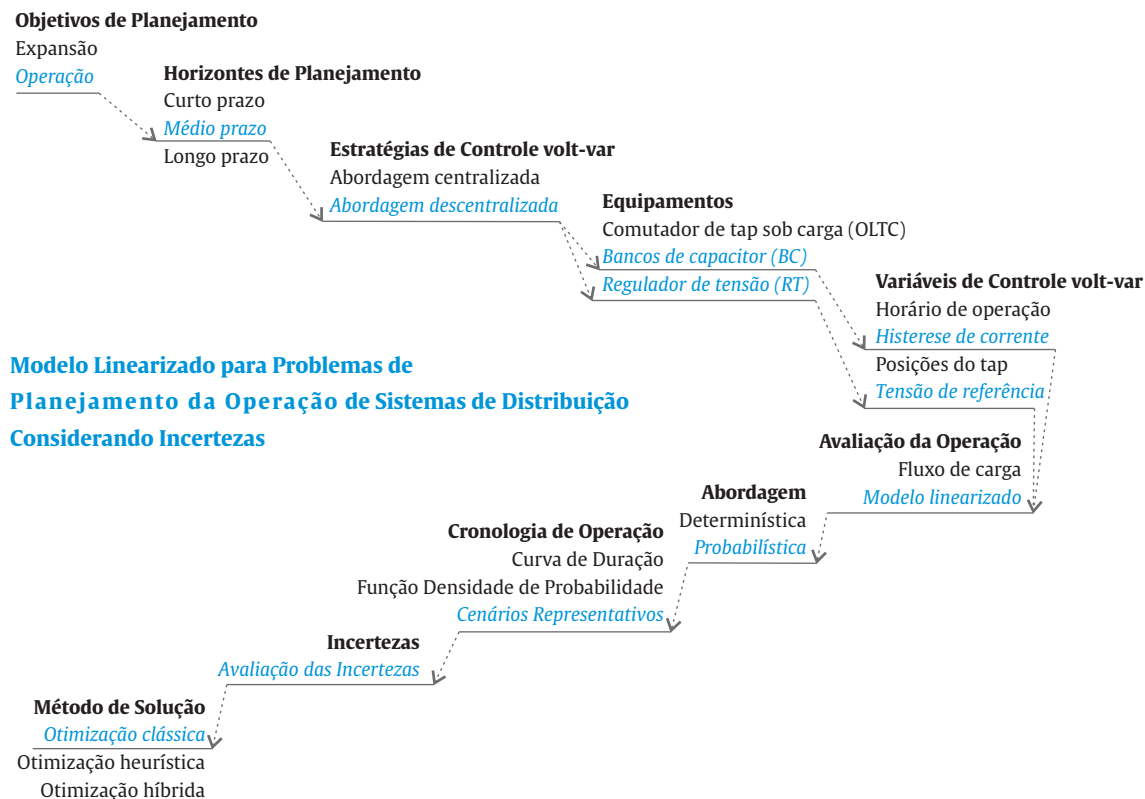
Dentre as bibliografias publicamente disponíveis nesta fase do estudo, nenhum modelo anterior propôs uma abordagem de PLIM com variáveis de controle explícitas para determinar o ajuste ótimo de BCs e RTs. Para evitar não-linearidades, a formulação considera o controle de corrente de BCs automáticos por meio da linearização por partes. Além disso, o modelo considera o RT com compensação por queda de tensão na linha para regular de forma otimizada as tensões de um nó remoto, sendo que o controle é projetado para levar em consideração a possibilidade de saturação sob condições operacionais específicas.

Como extensão ao modelo proposto por Resener (2019a), os principais avanços do presente trabalho são:

- a definição e utilização de um modelo PLIM para otimização volt-var de BCs e RTs considerando a cronologia de operação e simultaneidade inerente de múltiplas cargas e REDs;
- o uso de grandezas elétricas para formular o controle de volt-var viabiliza aplicações práticas em esquemas descentralizados de controle volt-var;
- a possibilidade de expressar as incertezas a partir de estimativas intervalares dos custos de operação de SDEE.

Diante do contexto exposto, a Figura 1 ilustra um diagrama com os principais tópicos discutidos nesta tese. Em resumo, dez aspectos norteiam o escopo deste estudo: objetivos do planejamento; horizonte de planejamento; estratégias de controle volt-var; equipamentos; variáveis de controle volt-var; avaliação da operação; abordagem; cronologia da operação; incertezas; e método de solução. A Figura 1 destaca em azul a abordagem escolhida dentre o conjunto possibilidades encontrado na literatura para cada aspecto.

Figura 1 – Diagrama ilustrativo das características da abordagem proposta.



Fonte: Elaborado pela autora (2020).

Por fim, esta tese contribui para os estudos existentes nos seguintes aspectos:

1. contribuição na extensão de um modelo linearizado, para determinar o ponto de operação em regime permanente de SDEE, baseado em cenários representativos de operação cronológica e simultânea de cargas e REDs;
2. formulação de um modelo abrangente de PLIM para otimização volt-var, o qual restringe as manobras diárias de dispositivos de controle, a partir de: (a) variáveis de controle explícitas para ligar e desligar BCs automáticos; e (b) ajustes explícitos de RTs, incluindo a possibilidade de compensação por queda de tensão na linha;
3. desenvolvimento de uma representação que permite que a operação de BCs automáticos seja sensível à variação da carga a jusante, a partir da proposição de uma histerese de controle de corrente;
4. otimização da faixa de operação do RT a partir de variáveis contínuas, bem como a representação de uma região de saturação do controle dos taps;
5. proposição de uma forma de otimização de controles distribuídos, mas com capacidade de obter a solução ótima para todo o sistema;

6. expressão e avaliação das incertezas relacionadas à operação da rede, permitindo obtenção de resultados probabilísticos.

Para validar a abordagem proposta, os resultados obtidos com o modelo de PLIM são comparados com a solução do fluxo de carga convencional. Além disso, os resultados numéricos de dois sistemas típicos ilustram algumas das aplicações potenciais do modelo proposto.

1.2 Estrutura da Tese

Os demais capítulos desta tese estão assim estruturados:

- no Capítulo 2 é realizada uma revisão bibliográfica, visando expor o estado da arte sobre o assunto e embasar o entendimento das contribuições do presente trabalho. Neste capítulo, constam as principais definições, características, generalidades e modelos representativos dos problemas de planejamento da operação de SDEE. São formalmente apresentadas as estratégias de controle volt-var, as diferentes representações da cronologia da operação de SDEE e o método para expressão e avaliação das incertezas. Por fim, é apresentada uma reflexão acerca do estado da arte e as contribuições da tese;
- no Capítulo 3 é apresentado o modelo para planejamento da operação de SDEE, evidenciando as contribuições da proposta em relação às abordagens correlatas, detalhadas no Capítulo 2;
- no Capítulo 4 é apresentada a estratégia de solução do problema, bem como os resultados dos testes realizados para validar e demonstrar a flexibilidade do modelo proposto para solução do planejamento da operação de SDEE considerando incertezas;
- no Capítulo 5, constam as considerações finais, com base nos testes realizados e respectivas contribuições agregadas, e sugestões para trabalhos futuros;
- no Apêndice A é descrito o modelo linearizado utilizado para representar a operação em regime permanente de SDEE, bem como as adaptações necessárias para inclusão de incertezas;
- no Apêndice B são apresentados os dados dos sistemas de distribuição utilizados nos testes de validação e exemplos de aplicação descritos no Capítulo 4.

2 PLANEJAMENTO DA OPERAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO: REVISÃO BIBLIOGRÁFICA

O presente capítulo apresenta as definições, características e generalidades do planejamento da operação de sistemas de distribuição considerando incertezas. As estratégias de controle volt-var são apresentadas, bem como seus principais modelos representativos. Além disso, a cronologia da operação de sistemas de distribuição é fundamentada e as incertezas de operação são formalmente modeladas.

2.1 Estratégias de Controle volt-var

Controle volt-var é uma das funções mais importantes na operação de sistemas de distribuição, podendo ser definido como uma técnica baseada no uso de dispositivos de regulação de tensão e controle de potência reativa, visando manter os níveis de tensão em regime permanente dentro de faixas aceitáveis ao longo do alimentador, considerando várias condições de carregamento (VÍTOR; ASADA; VIEIRA, 2020). As estratégias de controle volt-var integram soluções para o problema de planejamento da operação de sistemas de distribuição, possibilitando melhorar a eficiência do sistema e reduzir custos operacionais. A seguir, são descritas as principais características de dispositivos de controle volt-var, bem como os modelos de otimização aplicados ao problema de operação.

2.1.1 Principais Características

Os sistemas de distribuição de energia elétrica têm contemplado a inserção progressiva de tecnologias ditas inteligentes, especialmente sob o ponto de vista de infraestrutura e operações. Nos últimos anos, a proliferação de recursos energéticos distribuídos (REDs) e o crescimento da demanda de energia elétrica, aliados ao rápido progresso da ciência de dados, por meio de aprendizagem de máquinas e inteligência artificial, têm transformado gradualmente os SDEE (LI; WANG; XIA, 2018). Consequentemente, inúmeros pesquisadores têm concentrado esforços para desenvolver estratégias de controle volt-var que acompanhem esse avanço tecnológico e científico. Nesse sentido, Manbachi *et al.* (2017) listaram os principais marcos históricos de soluções de otimização volt-var, classificando,

em cinco gerações, atributos como: curva de carga, classificação, controle, equipamentos disponíveis e serviços ancilares; os quais constam listados na Tabela 1.

Tabela 1 – Histórico de soluções de otimização volt-var.

Geração	Atributos				
	Curva de Carga	Topologia	Classificação	Equipamentos	Serviços Ancilares
1ª geração (1980-1990)	Estática	Local	Controle Centralizado	OLTC/RT/BC ⁴	–
2ª geração (1990-1998)	Estática	Local	Controle Centralizado	OLTC/RT/BC	Estudos iniciais CVR ⁵
3ª geração (1998-2008)	Estática	Centralizado via SCADA ³	Controle Centralizado	OLTC/RT/BC	CVR independente
4ª geração (2008-agora)	Tempo quase-real ¹	Distribuído via controle local	Controle Descentralizado	OLTC/RT/BC	CVR integrado
Futuro próximo	Tempo-real ²	Distribuído via agentes inteligentes	Controle Integrado	OLTC/RT/BC VE/RED ⁶	CVR integrado + SGD ⁷

Notas:

¹ Dados obtidos a partir da medição agregada de consumidores.

² Dados obtidos a partir de infraestrutura avançada de medição (do inglês, *Advanced Metering Infrastructure*) desagregada de consumidores.

³ SCADA – Sistema de supervisão e aquisição de dados (do inglês, *Supervisory Control and Data Acquisition*).

⁴ OLTC – Comutador de tap sob carga (do inglês, *On-Load Tap Changer*);

RT – Regulador de tensão;

BC – Banco de capacitores.

⁵ CVR – Conservação de energia por redução de tensão (do inglês – *Conservation Voltage Reduction*).

⁶ VE – Veículo elétrico;

RED – Recurso energético distribuído.

⁷ SGD – Sistema de gerenciamento da distribuição.

Fonte: Adaptado de Manbachi *et al.* (2017).

Tradicionalmente, o sistema de distribuição foi considerado, por muitos anos, uma rede passiva e radial para fornecimento de energia aos usuários finais. Deste modo, o planejamento de SDEE apresentava o conceito de ajustar-e-esquecer (do inglês, *fit-and-forget*), utilizando cenários extremos de operação, os quais implicavam superdimensionamento da rede e lógicas de controle que não precisavam de frequentes atualizações (DOBBE *et al.*, 2020). Por esta razão, as estratégias de controle volt-var até a 3ª geração incluíam soluções baseadas em cargas estáticas, ou também, patamares de carga leve, média e pesada (KABIR; MISHRA; BANSAL, 2016). Mesmo com o advento de sistemas de gerenciamento de distribuição na década 90, onde Roytelman e Shahidehpour (1993) foram pioneiros no uso destes sistemas para soluções volt-var, apenas a partir dos anos 2000 foram registrados grandes esforços para desenvolver novas soluções tecnológicas de otimização volt-var.

Na última década, inúmeras pesquisas sobre aprendizagem de máquinas e inteligência artificial ampliaram a variedade de algoritmos capazes de aprender a partir de dados históricos e/ou medições em tempo real (DOBBE *et al.*, 2020). Desta forma, tornou-se possível propor soluções em diferentes escalas de tempo e, a partir de uma infraestrutura avançada de medições, coletar um expressivo volume de dados (no intervalo de 5, 10 ou 15 minutos) para otimizar em tempo quase-real (MANBACHI *et al.*, 2016). Em um futuro próximo, Manbachi *et al.* (2017) estimam que o controle volt-var possa ser sensível às mudanças da carga em tempo-real. No entanto, há um caminho de pesquisa e desenvolvimento a ser percorrido, para evitar que um possível "tsunami de dados", em decorrência da medição em tempo real, cause falhas de comunicação e monitoramento dos dados.

Em relação à topologia, os modelos propostos na literatura são classificados entre comando local, centralizado e distribuído (CAVRARO; CARLI, 2018). A primeira topologia é baseada em medições locais e impõe zero ou mínima comunicação entre os dispositivos de controle volt-var. A segunda topologia consiste na tomada de decisão centralizada, baseada em fluxo de carga ótimo, resolvido por métodos exatos ou heurísticos. Já a terceira topologia contempla a coordenação distribuída de múltiplos dispositivos, ajustada a partir de algoritmos de otimização. Recentemente, estudos foram publicados com estratégias chamadas hierárquicas, que combinam um componente de tomada de decisão centralizado, um distribuído e um local. Os resultados obtidos por Malekpour, Annaswamy e Shah (2020) demonstraram um desempenho superior da topologia hierárquica em termos de número de operações de tap, redução de perdas e regulação de tensão por intermédio de geração distribuída, se comparado ao desempenho individual de cada topologia.

As estratégias também são classificadas tradicionalmente em controle centralizado e controle descentralizado e sua implementação depende da topologia da rede e da infraestrutura de comunicação disponível (EVANGELOPOULOS; GEORGILAKIS; HATZARGYRIOU, 2016). O controle centralizado se tornou popular na década de 80, em parte

por causa do desenvolvimento de sistemas de rádio-comunicação de baixo custo (JABR, 2019). Posteriormente, o monitoramento e controle de dispositivos volt-var baseado em um sistema SCADA permitiu o ajuste baseado em medições em tempo real (VÍTOR; ASADA; VIEIRA, 2020). Neste caso, a infraestrutura de comunicação é primordial, uma vez que executa a comunicação bidirecional e entre o controlador supervisor e dispositivos remotos (MANBACHI *et al.*, 2017). Para isso, as informações do sistema são enviadas ao controle central, o qual resolve um modelo de otimização para ajustar a operação ótima de cada variável de controle e envia ao controle local dos dispositivos. Por esta razão, o controle centralizado é altamente dependente do sistema de comunicação, o que pode afetar a sua confiabilidade (TAHIR *et al.*, 2016).

A existência de um sistema supervisor para efetuar a monitoração remota dos dispositivos de controle volt-var define a estratégia centralizada como supervisionada. Na inexistência de sistemas de comunicação, as estratégias descentralizadas incluem a possibilidade de operar de forma não-supervisionada, efetuando localmente o controle volt-var. Desta forma, o controle descentralizado objetiva responder em tempo quase-real à variabilidade do fluxo de potência da rede, solucionando localmente o ajuste do controle, o que facilita a integração com o despacho de recursos energéticos distribuídos (ZHANG; XU, 2020). Em um futuro próximo, Manbachi *et al.* (2017) estimam que o controle integrado (ou também chamado, dinâmico) seja uma realidade. Vítor, Asada e Vieira (2020) definem este tipo de controle como uma abordagem avançada de planejamento de operação, uma vez que garante que o controle reflita a configuração atual de operação dos SDEE. Neste caso, a central de controle monitora as grandezas elétricas em tempo-real, executa algoritmos de fluxo de potência ótimo e envia ao controle local os parâmetros de ajuste ótimo dos dispositivos volt-var.

Em relação aos equipamentos, as concessionárias de energia elétrica buscam, simultaneamente, regular as tensões nodais de um sistema de distribuição e minimizar as perdas, por meio de dispositivos de controle volt-var, tais como: comutador de tap sob carga (do inglês, *On-Load Tap Changer* – OLTC), regulador de tensão (RT) e banco de capacitores (BC) fixos e automáticos, entre outros (SAMIMI; KAZEMI, 2016; TAHIR *et al.*, 2016). Conforme mostra a Tabela 1, até a 4ª geração são utilizados OLTC, RT e BCs.

O RT permite regular o nível de tensão da rede em quatro modos distintos: (i) controle do nível de tensão do enrolamento de um transformador, (ii) controle do nível de tensão de um nó qualquer (desde que exista comunicação), (iii) controle do nível de tensão com compensação por queda de tensão na linha, e (iv) regulador operando no modo reverso. O primeiro modo opera controlando o nível de tensão no enrolamento secundário de um transformador, modelando efetivamente um OLTC ou um regulador de linha, quando o transformador monitorado é um autotransformador. O segundo modo difere do primeiro, em relação à medição de tensão, que é obtida com um transformador de potencial conectado a um nó qualquer (ou também chamado, nó remoto) do sistema. O terceiro é

conhecido com compensação por queda de tensão na linha e permite monitorar a tensão em um centro de carga ou em uma carga, alterando o tap conforme a queda de tensão na linha. Para isso, além de conhecer os parâmetros série da linha (resistência e reatância), é necessário instalar um transformador de corrente. O quarto modo permite o RT operar em modo reverso, quando existe inserção de REDs a jusante do equipamento (KERSTING, 2001; VÍTOR; ASADA; VIEIRA, 2020).

O uso de BCs é uma prática comum nas concessionárias de energia, sendo o baixo custo e flexibilidade de instalação e operação as suas maiores vantagens (VÍTOR; ASADA; VIEIRA, 2020). Basicamente, os BCs são instalados em paralelo com as cargas, modificando as características da rede a partir de sua reatância capacitiva. Desta forma, o chaveamento de bancos de capacitores permite reduzir a componente reativa da corrente elétrica que circula em um alimentador, diminuindo o valor absoluto desta corrente e, conseqüentemente, alterando perdas e quedas de tensão. Outras tecnologias como carros elétricos e recursos energéticos distribuídos têm sido propostas como estratégias de controle volt-var e, em um futuro próximo, deverão integrar a lista de equipamentos utilizados normalmente (MANBACHI *et al.*, 2017).

Para efetuar o ajuste dos equipamentos, o modo de controle volt-var pode ser baseado em parâmetros, como por exemplo horários pré-estabelecidos para chavear os bancos de capacitores ou posições de tap dos reguladores de tensão. Ademais, um controle mais sofisticado pode ser baseado em variáveis de controle, ajustadas por soluções de modelos de otimização obtidas a partir de dados históricos ou medições em tempo-real (TAHIR *et al.*, 2016). Este segundo modo de controle pode ser exemplificado por meio do ajuste de operação de bancos de capacitores baseado em corrente, ou ainda, por intermédio do ajuste da tensão de referência de reguladores de tensão.

Finalmente, diferentes abordagens de conservação de energia por redução de tensão marcaram as gerações de serviços ancilares. Desde a década de 90, estudos têm sido desenvolvidos para aprimorar a estratégia de CVR, visando a redução dos níveis de tensão para otimizar a demanda de energia elétrica durante horários de pico. Samimi e Kazemi (2016) ressaltam ainda que, com o aumento da inserção de REDs, é razoável considerar a prestação de serviços ancilares, como demanda e injeção de potência reativa por meio de REDs, possa integrar estratégias de controle volt-var. Ainda, para um futuro próximo, Manbachi *et al.* (2017) estimam mudanças no modelo atual, movidas pela integração com sistemas de gerenciamento de distribuição (SGD) e de armazenamento de energia.

2.1.2 Modelos de Otimização

Modelos de otimização voltados ao problema de planejamento da operação de SDEE têm como objetivo principal otimizar a parametrização de equipamentos de controle existentes na rede, de acordo com metas pré-estabelecidas. Esta modelagem contempla um

conjunto abrangente de expressões matemáticas que relacionam a descrição física da rede de distribuição, os equipamentos disponíveis e o histórico de comportamento de cargas e recursos energéticos distribuídos. Dentre os principais objetivos de modelos de otimização voltados à operação de SDEE, destacam-se: (i) minimização das perdas, (ii) minimização da violação dos limites de tensão, (iii) minimização dos custos de operação, e (iv) maximização da conservação de energia por redução de tensão (VÍTOR; ASADA; VIEIRA, 2020).

Em relação à otimização volt-var, usualmente a formulação pode incluir a comutação de tap de transformadores, operação de reguladores de tensão, chaveamento de bancos de capacitores, reconfiguração de redes e operação integrada com REDs. O principal desafio consiste na convergência do modelo de otimização, de maneira a parametrizar o controle ótimo de dispositivos volt-var por meio de algoritmos robustos (BOARDMAN, 2019).

Nesse contexto, o método de variar volt-ampère reativo (var) a partir da instalação de bancos de capacitores nas subestações de SDEE é reconhecido desde a década de 40 (SAMBALIAH; JAYABARATHI, 2020). A tendência de instalar os BCs próximos às cargas, entretanto, foi iniciada a partir da década de 50. Neagle e Samson (1956) foram os pioneiros na proposição de um modelo para calcular a localização e capacidade de BCs fixos visando a minimização das perdas. Tendo em vista que o modelo de Neagle e Samson (1956) considerava um único nível de carregamento, Cook (1959) apresentou uma análise dos efeitos de capacitores fixos em redes de distribuição, considerando variação de carga. A proposta de alocação de capacitores fixos e chaveados surgiu nos estudos de Cook (1961) e Schmill (1965), considerando cargas uniformemente distribuídas e aleatoriamente distribuídas ao longo do alimentador para minimização das perdas sem regulação de tensão. Dura (1968) desenvolveu um método que identificava a relação custo-benefício de instalação de capacitores e Bae (1978) propôs um método analítico para otimizar os níveis de compensação reativa e maximizar a redução das perdas anuais dos SDEE. No entanto, os métodos analíticos propostos nesses estudos consideravam a potência nominal do BC como variável contínua, sendo necessário o arredondamento para se obter uma solução viável, o que pode resultar em diferenças significativas no valor da função objetivo (RESENER *et al.*, 2018).

Em 1981, Grainger e Lee desconsideraram algumas hipóteses de pesquisas anteriores, como por exemplo a regra dos 2/3 (que define potência nominal do capacitor igual a 2/3 da potência reativa total do alimentador, bem como aloca o capacitor a 2/3 da distância entre a subestação e o final de rede) proposta por Neagle e Samson (1956). Também generalizaram o método proposto por Cook (1959; 1961) para um sistema radial considerando diferentes condutores e cargas não uniformemente distribuídas. Para solucionar a alocação ótima de BCs, Grainger e Lee (1981) utilizaram uma versão relaxada do problema, considerando a capacidade dos capacitores fixos e chaveados, como variáveis contínuas, solucionando por meio de um esquema de solução iterativo e computacionalmente sim-

ples. Posteriormente, Grainger e Lee (1982) propuseram um modelo para considerar o cálculo das tensões nas barras por meio de estudos de fluxo de carga. No entanto, a partir da revisão apresentada por Sambaiah e Jayabarathi (2020), constatou-se que em nenhum dos estudos mencionados até então foram investigados os benefícios para conservação de energia por redução de tensão, tampouco foram considerados: o efeito do crescimento na carga, o fator de carga durante horários de pico de demanda e as sobretensões em horários de baixo consumo. Além disso, nenhuma dessas metodologias identificou o número ideal de capacitores, o tipo (fixo ou chaveado) e a potência nominal padrão, de acordo com modelos comerciais disponíveis. A partir deste momento, vários pesquisadores propuseram métodos exatos e aproximados para resolver o problema de alocação e operação ótima de BCs.

Na década de 80, ocorreu o marco da primeira geração de soluções integradas de controle volt-var, com modelos de otimização voltados à minimização das perdas e melhora dos níveis de tensão. Nesse sentido, Bunch *et al.* 1982 desenvolveram uma estratégia de controle e um algoritmo de processamento digital para melhorar o controle de tensão e a compensação de energia reativa, tanto na subestação de distribuição quanto no nível do alimentador. Neste estudo, os autores desenvolveram um protótipo de pesquisa avançado para integrar controle e proteção de sistemas de distribuição. No ano seguinte, Grainger *et al.* (1983) introduziram a estratégia de compensação reativa com controle centralizado na subestação. A inclusão de reguladores de tensão no problema de controle volt-var foi proposta por Grainger e Civanlar (1985), onde apresentaram uma formulação para o problema de controle de tensão e potência reativa em SDEE radiais.

Civanlar e Grainger (1985a) desenvolveram um modelo para determinar a localização, a capacidade e o controle dos equipamentos, de BCs e RTs de forma desacoplada, visando minimizar a potência de pico e as perdas de energia, mantendo as tensões nas barras dentro de limites especificados sob condições de carga variável. Os autores incluíram no modelo o controle ótimo do tap para um número mínimo de RTs em operação. Em Civanlar e Grainger (1985b) os resultados numéricos foram apresentados, comprovando o efeito da compensação reativa e da regulação de tensão na redução da potência de pico e das perdas de energia.

Com a disponibilidade de recursos computacionais, métodos baseados em programação numérica ganharam destaque no final da década de 80, os quais modelaram o problema para obter a solução por intermédio de operações aritméticas. Nesse sentido, Baran e Wu (1989) utilizaram um modelo de programação não-linear inteira mista (PNLIM) para resolver o problema da alocação de BCs fixos e chaveados, considerando a variação da carga através de curva de duração. O modelo objetivava minimizar as perdas de potência ativa e atender restrições de níveis de tensão, a partir de níveis de carregamento pre-estabelecidos, sendo solucionado a partir de um abordagem multi-níveis, com um problema mestre e um escravo. Esta abordagem é ainda utilizada nos dias atuais,

quando um problema de operação ótima é escravo do problema mestre de planejamento da expansão de SDEE.

A partir da década de 90, as meta-heurísticas para solução de problemas de otimização foram amplamente utilizadas. Isso porque, devido à natureza discreta da operação de taps e chaveamento de BCs, aliada à não linearidade da formulação do fluxo de potência convencional, a maioria dos modelos consistem em PNLIM (JHA *et al.*, 2019). Conforme o levantamento bibliográfico realizado por Resener *et al.* (2018), inúmeros estudos, publicados entre 1993 e 2016, desenvolveram meta-heurísticas voltadas à solução de problemas de alocação e operação ótima de BCs e RTs.

Na literatura mais recente, um algoritmo baseado no mecanismo de caça de lobos cinzas (do inglês, *gray wolf optimization*) foi proposto por Pamshetti, Singh e Singh (2019) para solucionar um PNLIM que envolvia a operação de dispositivos de controle volt-var e reconfiguração de rede, visando minimizar a demanda de energia. Além disso, o estudo contemplava a presença de REDs e o algoritmo incluía operação ótima de inversores de sistemas solar-fotovoltaicos para melhorar a eficiência energética do sistema. Ceylan, Liu e Tomsovic (2018) também utilizaram o método de *gray wolf optimization* para minimizar as violações de tensão de SDEE por meio de RTs e BCs.

Yilmaz e El-Shatshat (2018), por sua vez, propuseram um modelo de otimização multi-objetivo para definir estratégias de controle volt-var em sistemas ativos de distribuição, solucionando o problema a partir da fronteira de Pareto de soluções obtidas com algoritmo genético NSGA-II (do inglês, *Nondominated Sorting Genetic Algorithm*). Embora a meta-heurística seja bastante popular no estado da arte, sua parametrização pode gerar diversos questionamentos, uma vez que tal aspecto afeta drasticamente o seu desempenho.

Uma abordagem interessante para obter soluções ótimas de problemas não-lineares é aplicando a técnica de linearização por partes, PWL (do inglês, *Piecewise Linearization*), para aproximar problemas não-lineares em problemas linearizados, o que viabiliza o uso de PLIM (CAMPONOGARA; DE ALMEIDA; JUNIOR, 2015). A linearização por partes tem sido aplicada com sucesso em problemas não lineares com variáveis inteiras, já que pode ser utilizada para obter soluções com métodos exatos de otimização, os quais podem garantir a convergência para a solução ótima.

Um modelo linearizado inteiro misto foi proposto por Haffner *et al.* (HAFFNER *et al.*, 2009) para alocação de BCs fixos e automáticos em SDEE. Nesse modelo, foram considerados custos de aquisição, instalação, remoção e manutenção das unidades, bem como penalidades por violação dos limites de tensão. Além disto, foi resolvido o ajuste ótimo de operação do tap dos transformadores de distribuição, sendo a variação da carga considerada pela curva de duração. Outro exemplo de aplicação de linearizações é o modelo proposto por Resener *et al.* (2016), o qual teve por objetivo determinar o ponto de operação em regime permanente de SDEE sem utilizar as equações do fluxo de carga não-linear.

Nesse estudo, os autores propuseram a alocação ótima de BCs por meio na minimização de custos operacionais, incluindo violações de tensão e perdas ativas, as quais eram estimadas usando aproximações lineares. Posteriormente, esse estudo foi aprofundado para problemas de planejamento da expansão de SDEE, incluindo alocação ótima de RTs, recondutoramento e presença de geração distribuída (RESENER *et al.*, 2019a,b). Uma vantagem relevante na abordagem proposta por Resener *et al.* (2019a) foi a representação dos limites de tensão utilizando variáveis auxiliares e restrições lineares, o que evitou a imposição de limites rígidos na magnitude de tensão nodal, fazendo com que o problema raramente se tornasse inviável. Como muitos outros trabalhos nesta área, esse trabalho também representa a variação da carga por intermédio da curva de duração.

Ribeiro (2013), por sua vez, apresentou um PLIM e um modelo cônico inteiro misto de segunda ordem para resolver o problema da alocação de BCs fixos e automáticos em SDEE radiais. Um modelo linear para o cálculo do ponto de operação em regime permanente foi proposto, sendo que as cargas foram modeladas como 100% potência constante nas partes ativa e reativa, assim como os modelo linearizados proposto por Franco *et al.* (2013) e Gonçalves, Franco e Rider (2014).

Ahmadi, Martí e Dommel (2014) apresentaram um problema de programação quadrática inteira mista para viabilizar a conservação de energia por redução da tensão (CVR). Para aumentar a precisão da otimização volt-var, os autores consideraram que as cargas eram dependentes da tensão, e que uma redução na tensão ocasionaria uma redução nas demandas ativa e reativa. Kumar, Satsangi e Kumbhar (2019) também propuseram estratégia de controle volt-var com as cargas dependentes da tensão, para o problema de maximização da vida útil de transformadores de distribuição.

Macedo *et al.* (2015) desenvolveram um modelo cônico inteiro misto de segunda ordem para resolver o problema de otimização volt-var com REDs e BCs. Foram consideradas como variáveis de controle as injeções ativa e reativa da geração distribuída, o número de unidades automáticas de BCs em operação, a posição dos taps de RTs e o estado de operação dos sistemas de armazenamento.

Borghetti, Napolitano e Bucci (2015) propuseram um PLIM voltado à operação de sistemas de distribuição desbalanceados. Com o objetivo de minimizar as violações de tensão e fator de potência, os autores modelaram a coordenação de transformadores com OLTC, geração distribuída e BCs automáticos. Adicionalmente, Sabillon-Antunez *et al.* (2017) apresentaram um modelo de PLIM visando minimizar os custos operacionais, a partir do ajuste ótimo BCs, RTs e sistemas de armazenamento, com estações de carga e descarga de veículos elétricos.

A principal desvantagem dos modelos propostos por Sabillon-Antunez *et al.* (2017), Borghetti, Napolitano e Nucci (2015) e Macedo *et al.* (2015) está em considerar que todos os dispositivos de controle volt-var são operados remotamente e de forma centralizada, tornando o resultado obtido pouco aplicável na atual realidade dos SDEE. Além

disso, abordagens determinísticas, para as quais são assumidos os piores cenários, desconsideram as incertezas decorrentes da natureza estocástica tanto das cargas quanto dos REDs.

Uma estratégia local de controle volt-var, considerando os dispositivos volt-var dependentes da tensão, foi elaborada por Turitsyn *et al.* (2011). Nos resultados, os autores avaliaram a resposta do controle local a partir de medições em tempo real, comprovando um aumento da eficiência quando comparado ao modelo dependente da potência. Entretanto, o método contemplava apenas a regulação dos níveis de tensão, desconsiderando a redução de perdas com compensação reativa.

Yeh, Gayme e Low (2012) propuseram uma abordagem multi-objetivo para minimizar as perdas ativas e regular os níveis de tensão, sendo que Dall'Anese, Dhople e Giannakis (2014) ampliaram o escopo com a inserção de geração distribuída com painéis solar-fotovoltaicos. Jabr e Džafić (2016), por sua vez, apresentaram um algoritmo para coordenar BCs, OLTCs e painéis solar-fotovoltaicos visando minimizar as perdas, enquanto eliminavam as violações de tensão. No entanto, a abordagem de controle centralizado não pode de fato garantir que não ocorram violações de tensão durante a operação, um vez que o ajuste foi baseado em estudos de fluxo de potência ótimo desconsiderando as incertezas inerentes à operação de cargas e REDs.

Uma alternativa ao controle centralizado é a estratégia que integra solução puramente local e distribuída. Puramente local, pois visa principalmente garantir que as restrições de tensão sejam satisfeitas a partir de medições locais. Distribuída, porque os agentes estão fisicamente próximos e têm permissão para se comunicar, podendo compartilhar informações para alcançar cooperativamente os objetivos pré-atribuídos. Desta forma, as estratégias distribuídas, além das restrições de tensão local, levam em consideração outros objetivos globais importantes, como a minimização de perdas de energia. Nesse sentido, um crescente número de estratégias para regular as injeções de potência reativa com micro-geração têm sido proposto para lidar com o problema de regulação de tensão (CAVRARO; CARLI, 2018).

Por fim, cabe destacar que o rápido progresso de técnicas de aprendizagem de máquinas e inteligência artificial trouxe atenção renovada à sua aplicabilidade em sistemas de energia para formas modernas de controle que ajudam a lidar com níveis crescentes de incerteza e variabilidade (DOBBE *et al.*, 2020). Nesse sentido, abordagens de otimização volt-var têm sido propostas de maneira a contemplar incertezas inerentes ao comportamento estocástico de cargas e REDs, o que pode implicar elevado processamento computacional. Por esta razão, a seguir são apresentados os principais métodos utilizados para representar a cronologia da operação de SDEE.


2.2 Cronologia de Operação de Sistemas de Distribuição

A cronologia da operação de um sistema de distribuição consiste na modelagem do comportamento de cargas e recursos energéticos distribuídos, em intervalos de tempo pré-definidos. A seguir, são apresentadas as principais definições, características e generalidades de três modelos representativos, encontrados na revisão bibliográfica.

2.2.1 Curva de Duração

A representação da cronologia de operação de SDEE por meio de curvas de carga típicas, obtidas em campanhas de medição, tem sido na prática adotada por muitas concessionárias. Usualmente, as cargas são modeladas por meio de curvas que contemplam patamares de demanda, os quais variam ao longo do tempo, porém são fixos em cada instante, o que caracteriza uma modelagem determinística. Como muitos outros trabalhos, Haffner *et al.* (2009) e Resener (2016) adotaram a curva de duração de carga, tais como a ilustrada pela Figura 2, para avaliar a operação de SDEE e otimizar problemas de planejamento da expansão. Nessa figura, as situações de carga leve, média e pesada foram representadas no seguinte formato: 6 horas diárias com 100% do valor nominal (carga pesada), 10 horas diárias com 70% do valor nominal (carga média) e 8 horas diárias com 30% do valor nominal (carga leve), mantendo o fator de potência constante.

Figura 2 – Níveis de carregamento propostos por Haffner *et al.* (2009) e Resener (2016).



Fonte: Elaborado pela autora (2020).

Os níveis de carregamento, ilustrados pela Figura 2, foram atribuídos igualmente a todas as cargas do sistema. No entanto, a suposição de um comportamento único para cargas desiguais em diferentes nós, implica dependência completa entre as cargas e também pode super-estimar a corrente nas linhas de distribuição. Da mesma forma que ao assumir a independência de todas as cargas instaladas no sistema, poderia acarretar em sub-estimação das correntes (LI *et al.*, 2017).

2.2.2 Função de Distribuição de Probabilidade

A crescente complexidade do sistema elétrico, representada pela inserção de fontes intermitentes de energia, aliada a mudanças nos padrões de consumo e ao fácil acesso a diversas tecnologias eletroeletrônicas, têm contribuído para a inclusão de importantes fontes de incerteza na modelagem de sistemas elétricos (MEHIGAN *et al.*, 2018). A demanda de energia elétrica tem sua natureza estocástica, variando continuamente ao longo do tempo, em parte explicada por sua correlação com condições climáticas e tarifas, e em parte atribuída à característica aleatória (GUPTA; KUMAR, 2017). Por esta razão, em alguns casos, o desvio padrão da demanda apresenta magnitude maior que a demanda média (PAREJA, 2009). Nesse sentido, torna-se essencial a transição de modelagens tradicionais determinísticas para probabilísticas (CHEN *et al.*, 2018).

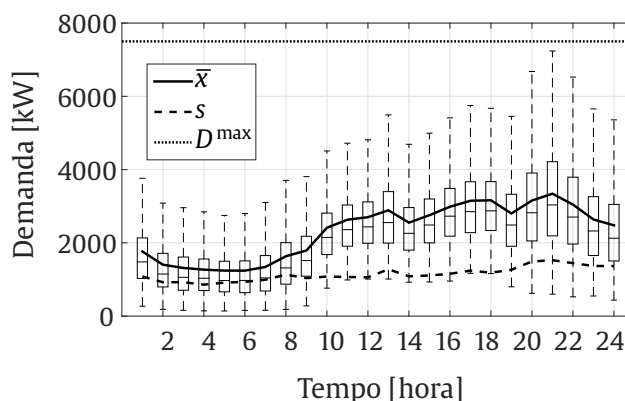
A análise probabilística de sistemas de distribuição de energia elétrica inclui possibilidades operacionais ignoradas em uma abordagem determinística clássica, enriquecendo o estudo. Desde 1974, inúmeras técnicas para solução do fluxo de carga probabilístico têm sido propostas, as quais são classificadas em: (i) métodos numéricos e de amostragem; (ii) métodos analíticos; e (iii) métodos aproximados (PRUSTY; JENA, 2017).

Cada método apresenta prós e contras, mas de maneira geral, os métodos analíticos baseiam-se em técnicas de convolução e apresentam menor esforço computacional se comparados aos métodos de amostragem, no entanto, exigem aproximações inevitáveis e não representam de maneira adequada a correlação entre variáveis de um sistema (SAMMET; KHORSHIDSAVAR, 2018). Já as abordagens aproximadas utilizam métodos de estimação de pontos, o que não requer completo conhecimento sobre a função de distribuição de probabilidade (do inglês, *Probability Density Function* – PDF) das variáveis aleatórias, porém apresenta baixa precisão quando aumenta a correlação entre as variáveis (KABIR; MISHRA; BANSAL, 2016). Por fim, os métodos numéricos, como a Simulação de Monte Carlo, são amplamente utilizados por apresentarem elevada precisão (uma vez que podem lidar com várias condições complexas sem simplificação), mas requerem mais cálculos elevando o esforço computacional (GUPTA; KUMAR, 2017).

A Simulação Monte Carlo é amplamente utilizada para simular curvas de geração eólica e solar, bem como as curvas de carga (HAGH *et al.*, 2018). Para representar as características de alta flutuação e aleatoriedade da velocidade do vento, irradiação solar e demanda de energia elétrica, usualmente são adotadas as distribuições de Weibull, Beta e normal, respectivamente (LI *et al.*, 2017). Com isso, o algoritmo executa o fluxo de carga determinístico repetidamente por um número significativo de vezes para representar todas as variáveis de interesse por funções de densidade de probabilidade (KABIR; MISHRA; BANSAL, 2016). A partir de amostragem aleatória, os possíveis estados de operação do sistema são obtidos e a cada vez que se gera um estado é necessário executar um fluxo de carga determinístico para estabelecer as condições de operação em regime permanente referentes a este estado (HONG; FAN, 2016).

Lautenschleger, Ferraz e Haffner (2018) propuseram um método analítico baseado na Simulação de Monte Carlo para analisar o desempenho de SDEE considerando a natureza incerta da carga. Este estudo exemplifica o nível de detalhamento disponível em uma abordagem probabilística da operação, uma vez que para ampliar as possibilidades operacionais, o comportamento das cargas foi simulado a partir de amostras correlacionadas. A Figura 3 ilustra um diagrama de caixa obtido pelos autores, o qual permitiu visualizar a variabilidade da demanda de energia elétrica ao longo do tempo, a partir do seu comportamento estatístico. De maneira geral, a demanda média (\bar{x} , na figura) é condição que costuma ser avaliada em uma análise determinística. Percebe-se, no entanto, que existe uma expressiva dispersão no entorno do valor médio, sugerindo a necessidade do emprego de um método alternativo para avaliar com maior fidelidade os limites dos indicadores de operação desta rede. Na Figura 3 também é possível visualizar o comportamento do desvio padrão (S) e avaliar o nível de carregamento horário, comparando os registros com a potência nominal do alimentador (representado por D^{max}).

Figura 3 – Comportamento estatístico da demanda agregada no alimentador.



Fonte: Lautenschleger, Ferraz e Haffner (2018).

Os resultados da Simulação de Monte Carlo são frequentemente utilizados como referência na comparação com outras técnicas (HONG; FAN, 2016) e também no planejamento da operação e da expansão de sistemas elétricos de potência (CONTI; RAITI, 2007; CHEN *et al.*, 2018), devido às suas características de maior simplificação, precisão, flexibilidade e robustez.

Embora a PDF tenha a capacidade de refletir a natureza aleatória da GD e da carga, ela pode não representar de forma completa a sequência temporal dessas variações. Chayakulkheeree (2014) reforça que a PDF é obtida desagregando os dados em uma hora específica do dia. Ainda que alguns estudos adotem técnicas que permitam correlacionar diversas fontes aleatórias, o uso dessas abordagens baseadas em PDF pode levar à negligência da simultaneidade inerente entre diferentes consumidores e geração, bem como descartar sazonalidades, e, provavelmente, gerar combinações incorretas de pontos de operação (LI *et al.*, 2017; HAGH *et al.*, 2018). Por fim, a necessidade de um número elevado de amos-

tras, antes de produzir uma convergência estatística aceitável, torna impraticável o uso de PDF, para modelar a cronologia da operação, em problemas de planejamento da operação solucionados com PLIM (ZHANG *et al.*, 2019).

Diante do exposto, uma forma de representar a operação cronológica e simultânea de diferentes cargas e REDs, com um número reduzido de amostras se dá por meio de cenários representativos, a seguir descritos.

2.2.3 Cenários Representativos

A inclusão de recursos energéticos distribuídos na modelagem da cronologia de operação de SDEE impõe, ainda, novos desafios para manter continuamente o equilíbrio entre a energia gerada e a demanda do consumidor. Em tais circunstâncias, a avaliação de todos os estados possíveis de um sistema de potência pode se tornar uma tarefa extremamente complexa, devido ao elevado número de possibilidades (HAGH *et al.*, 2018).

Para reduzir a complexidade dos problemas citados, vários autores recomendam uma abordagem de representação com cenários que permite encontrar perfis de operação representativos (PAMSHETTI; SINGH; SINGH, 2019; TEICHGRAEBER; BRANDT, 2019; MORADIJOZ; MOGHADDAM; HAGHIFAM, 2018; SANNIGRAHI; ROY GHATAK; ACHARJEE, 2019). Deste modo, o número de avaliações necessárias para simular a operação da rede pode ser drasticamente reduzido, por meio cenários que representam os agrupamentos de curvas de carga e de geração dos REDs, que têm comportamento similar dentro do histórico da operação de SDEE.

As técnicas de agrupamento (também chamadas de clusterização) consistem em classificar os dados de acordo com suas semelhanças, sem rótulos pré-definidos, de modo que a semelhança é maximizada entre os pontos de dados que estão dentro de cada agrupamento comparados com os pontos em outros agrupamentos. O principal objetivo do agrupamento é descobrir estruturas subjacentes dentro dos dados a serem usados na redução de dimensão e otimização do modelo (LI; WANG; XIA, 2018).

Dentre os métodos encontrados na literatura, a forma mais simples é a clusterização “particional”, a qual visa particionar um conjunto de dados em subconjuntos disjuntos (*clusters*) a partir de métodos de otimização. O algoritmo *K-means clustering*, embora tenha sido proposto na década de 60 por Mac Queen (1967), recentemente foi considerado por Hoffmann *et al.* (2020), em um *review* de 204 artigos, como estado da arte na agregação de séries temporais. Isso se deve à capacidade do algoritmo em processar grandes conjuntos de dados com simples implementação, rápida convergência e aceitável precisão.

O objetivo do *K-means clustering* é particionar os dados em K *clusters*, de modo a minimizar a soma das distâncias entre todos os pontos de dados e os centros dos *clusters* (HAGH *et al.*, 2018), denominados centroides. Neste caso, a distância euclidiana é usada como medida para quantificar o distanciamento resultante entre os pontos de cada

agrupamento e seus respectivos centroides. Além disso, o número de centroides é determinado de acordo com as semelhanças e proximidade dos pontos de dados, de tal forma que a correlação entre diferentes quantidades (por exemplo, demanda de carga e REDs) seja garantida.

O *K-means clustering* é executado nos seguintes passos (LI, 2011):

1. **Inicialização** – Considerar $\mathbf{X} = \{x_i, i = 1, \dots, n\}$ como um conjunto de n pontos d -dimensionais, a serem agrupados em um conjunto $\mathbf{C} = \{c_k, k = 1, \dots, K\}$ de K *clusters*. Então, assumir u_k como o centroide do cluster c_k e particionar os dados de forma aleatória;
2. **Particionamento** – Gerar uma nova partição atribuindo cada ponto ao centroide mais próximo;
3. **Avaliação** – Calcular o erro quadrático $S(c_k)$ entre a média empírica de um *cluster* u_k e os pontos x_i do *cluster* c_k , definido por:

$$S(c_k) = \sum_{x_i \in c_k} \|x_i - u_k\|^2; \quad (2.1)$$

4. **Realocação** – Recalcular o centroide u_k de cada cluster;
5. **Convergência** – Repetir os Passos 2 a 4 até que o particionamento de n dados em K *clusters* estabilize (os centroides permaneçam inalterados entre iterações). O critério de convergência está na minimização do erro quadrático ou soma do quadrado das distâncias entre os pontos x_i e os centroides u_k , dado por:

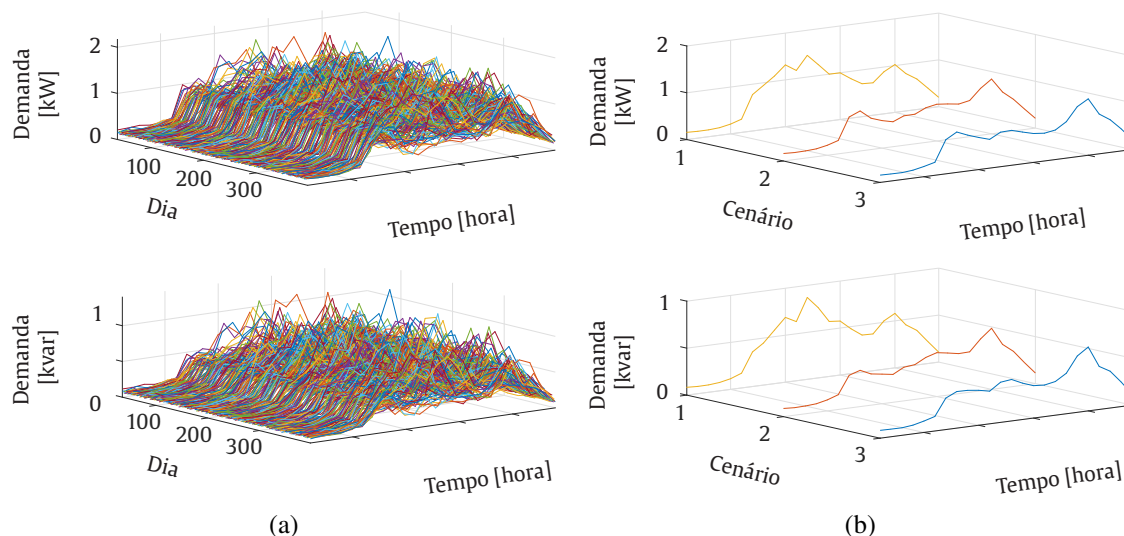
$$SS = \sum_{s=1}^K S(c_k). \quad (2.2)$$

Nesse contexto, a Figura 4 ilustra um exemplo de modelagem da cronologia da operação por meio de cenários representativos, selecionados a partir do algoritmo *K-means clustering*. Na Figura 4 (a) é ilustrada a base histórica de dados, com 365 curvas de demanda horária ativa e reativa de um consumidor residencial; e a Figura 4 (b) ilustra os 3 cenários representativos.

Embora vários métodos de clusterização tenham sido investigados nas últimas décadas, alguns aspectos tornam difícil a proposição de um algoritmo generalizado (JAIN, 2010). Fatores como a representação de dados, o propósito de agrupamento, o número de *clusters* e a validade do cluster, afetam diretamente o *design* e o desempenho de um método de clusterização (FERRAZ *et al.*, 2019).

O objetivo principal do agrupamento de dados é maximizar a similaridade (reduzir a distância) entre os pontos do mesmo *cluster* e maximizar a dessemelhança entre vários

Figura 4 – Curvas de carga de um consumidor residencial representadas por: (a) 365 dias (dados históricos), e (b) 3 cenários (selecionados com *K-means clustering*).



Fonte: Elaborado pela autora (2020).

clusters (HAGH *et al.*, 2018)¹. Logo, um número grande de *clusters* melhora a precisão da solução, mas aumenta a complexidade do problema, o que exige maior esforço computacional. Desta forma, o número adequado de *clusters* depende das características dos dados e do requisitos impostos pelo tomador de decisão, para solucionar o problema proposto (HOME-ORTIZ *et al.*, 2019).

Sannigrahi, Roy Ghatak e Acharjee (2019) desenvolveram um modelo de otimização multi-objetivo e multi-nível para estudos de planejamento de SDEE, no qual a variabilidade horária e a simultaneidade inerente à demanda das cargas e a injeção de potência de REDs, foi modelada a partir de 28 cenários representativos. Os autores escolheram o índice de Davies Bouldin para definir o número adequado de cenários representativos, selecionados por meio do *K-means clustering*. Este índice permite avaliar o número adequado de cenários que resulta em baixas medidas de dispersão intra-cluster e grandes distâncias entre clusters (DAVIES; BOULDIN, 1979).

Zatti *et al.* (2019) introduziram um novo método de clusterização que incorporou o algoritmo *K-medoides* em um modelo de PLIM, visando selecionar cenários típicos e extremos de operação e otimizar o uso de sistemas multi-energéticos. A diferença deste método consiste na seleção de um cenário presente na base de dados histórica, denominado medoide. Neste estudo, os autores otimizaram a operação de sistemas de climatização, cogeração, aquecimento, refrigeração, armazenamento de calor, bombas de calor, painéis solar-fotovoltaicos e solar-térmicos, a partir da seleção de 6 cenários típicos e 6 cenários extremos. Cada cenário incluiu demanda de energia elétrica, dados de aquecimento e re-

¹A existência de similaridade entre os centroides de diferentes agrupamentos indica que poderiam ser utilizados menos agrupamentos para representar este mesmo conjunto de dados.

frigeração, irradiância e temperatura ambiente, de modo a otimizar a operação de sistemas multi-energéticos presentes em prédios energeticamente eficientes.

Anzanello Júnior (2019), por sua vez, apresentou um algoritmo genético para alocação ótima de BCs no qual a variabilidade da carga e da geração distribuída foi representada por meio de 3 cenários selecionados com *K-means clustering*. O critério de escolha do número de cenários foi baseado em uma análise de sensibilidade proposta por Atwa e El-Saadany (2011), avaliando a precisão e esforço computacional de 1, 2, 3, 5, 10 e 100 *clusters* em um fluxo de carga convencional.

Assim, o algoritmo *K-means clustering* consiste na exploração aleatória de extensas bases dados, a fim de encontrar poucos cenários que representam comportamento variável da carga e dos REDs. A grande maioria dos estudos na literatura define esse processo como a modelagem da incerteza de operação de SDEE. No entanto, os mesmos estudos que buscam representar as incertezas existentes nos dados de entrada, apresentam resultados determinísticos, sem, de fato, lidar com as incertezas, tampouco formalizar o cálculo do intervalo de confiança dos resultados obtidos.

2.3 Incertezas na Operação de Sistemas de Distribuição

Incerteza é um parâmetro, associado ao resultado de uma medição (ou simulações numéricas), que caracteriza a dispersão dos valores que podem ser razoavelmente atribuídos ao mensurando (variável de resposta). Este parâmetro pode ser representado, por exemplo, por um desvio-padrão (ou um múltiplo dele), ou também a metade de um intervalo correspondente a um nível da confiança estabelecido. O resultado da medição, por sua vez, é a melhor estimativa do valor do mensurado. Todos os componentes da incerteza, incluindo aqueles resultantes dos efeitos sistemáticos, como os componentes associados com correções e padrões de referência, contribuem para a dispersão (GUM, 2008).

O cálculo das incertezas voltado à operação de sistemas elétricos de potência reflete a inerente característica estocástica da demanda de energia elétrica e de REDs (ROSTAMI; MOHAMMADI; RASTEGAR, 2020). Usualmente, o estado de operação em regime permanente de uma rede é obtido por meio de um fluxo de carga convencional, o qual calcula as magnitudes e ângulos de fase das tensões nodais, os fluxos de potências ativa e reativa e as perdas da rede. No entanto, o método de solução é determinístico e considera que os parâmetros de entrada do sistema sejam constantes para cada intervalo de tempo. Desta forma, novas abordagens probabilísticas têm sido propostas com o objetivo de incluir possibilidades operacionais ignoradas em métodos de solução determinísticos (GUPTA; KUMAR, 2017).

Para modelar a cronologia de operação probabilística de SDEE com inserção de fontes de energias renováveis, Kotzur *et al.* (2018) investigaram o efeito de agregação de séries temporais para reduzir a alta flutuação entre oferta e demanda de energia elétrica.

Dentre os objetivos propostos por Kotzur *et al.* (2018), destaca-se a avaliação do impacto de diferentes técnicas para obtenção de cenários representativos, incluindo a análise de sensibilidade em relação aos dados históricos (originais). A Figura 5 (a) ilustra a base de dados históricos, com perfil horário da irradiação global horizontal (de uma fonte de energia solar fotovoltaica) de 365 dias, bem como 4 cenários representativos, obtidos com a técnica de médias agregadas e com *K-means clustering*. Nesta figura é possível visualizar que com 4 cenários, o algoritmo *K-means clustering* se aproxima consideravelmente da representação original, especialmente quando comparado ao método das médias agregadas, que calcula curvas médias mensais, agregando-as por estações (conhecido como *averaging periods*) e reduz a resolução de tempo horária para patamares (conhecido como *downsampling*). O mesmo efeito foi observado para a velocidade do vento (de uma fonte de energia eólica), a demanda (individual) de uma residência e a demanda agregada (de um agrupamento de residências), nas Figuras 5 (b), (c) e (d), respectivamente.

A Tabela 2 evidencia numericamente a diferença dos resultados obtidos na Figura 5, a partir da comparação do erro quadrático médio entre os dados originais e os 4 cenários. Os resultados, ilustrados pela Figura 5 e detalhados na Tabela 2, demonstram menores valores de erro do *K-means clustering* quando comparado às médias agregadas, assim como permitem visualizar o efeito de diversas fontes de incertezas associadas ao problema de planejamento ótimo da operação de SDEE.

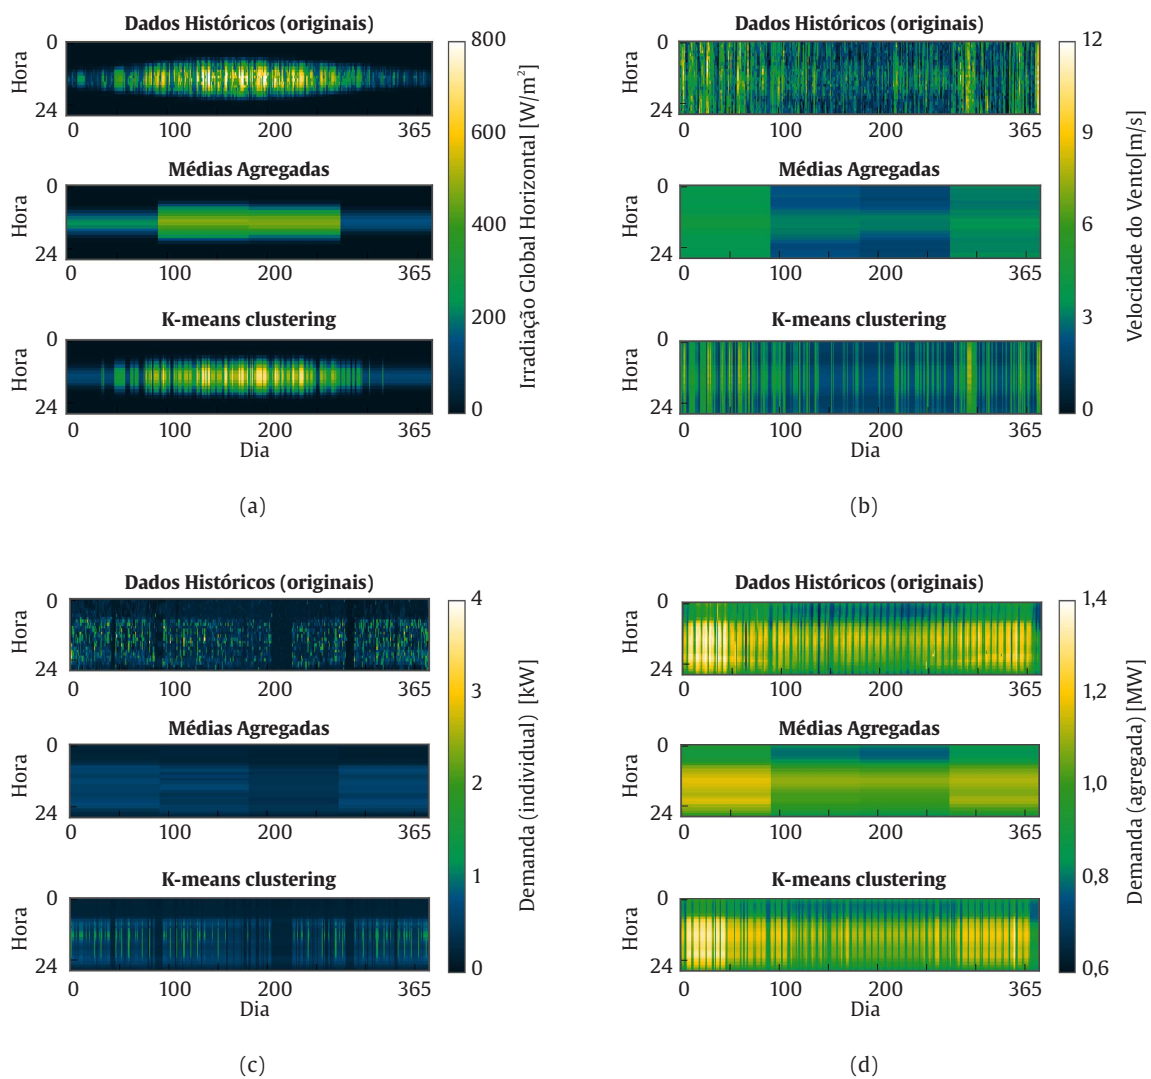
Tabela 2 – Erro quadrático médio [%] entre os dados históricos (originais) e 4 cenários representativos considerando diferentes técnicas de agregação de séries temporais.

Técnica de Agregação	Irradiação Global Horizontal	Velocidade do Vento	Demanda (individual)	Demanda (agregada)
Médias agregadas	10,45	14,44	9,39	12,90
<i>K-means clustering</i>	6,45	9,99	7,75	6,02

Fonte: Adaptado de Kotzur *et al.* (2018).

Em geral, o resultado de uma medição (o qual pode ser obtido por simulações numéricas) é somente uma aproximação ou estimativa do mensurando (correspondente ao valor da variável de saída de um modelo), assim, só é completo quando acompanhado pela declaração da incerteza dessa estimativa (GUM, 2008). Estudos recentes têm apresentado diversas formas de modelar as incertezas, considerando inclusive a correlação das variáveis de entrada em modelos de otimização e apresentando estimativas intervalares das variáveis de resposta (LIN; BITAR, 2017; QIAO *et al.*, 2019; ZHANG *et al.*, 2019; WANG *et al.*, 2020). No entanto, conforme Jordehi (2015) destacou, boa parte dos estudos ainda não considera a incerteza da operação de cargas, REDs, tarifas de eletricidade, entre outros, ignorando possibilidades operacionais e muitas vezes utilizando cenários pouco representativos.

Figura 5 – Agregação de séries temporais (eixo x: dias do ano; eixo y: hora do dia).



Fonte: Adaptado de Kotzur *et al.* (2018).

Para proposição de abordagens mais realistas, Rostron, Fearn e Ramsey (2020) mostraram que as incertezas de um método podem ser estimadas usando a análise de variância (ANOVA), a partir do *design* e análise de experimentos fatoriais (MONTGOMERY, 2017). Além disso, se faz necessário calcular intervalos de confiança para essas incertezas, os quais podem ser obtidos por intermédio de modelos de probabilidade que assumem dados normalmente distribuídos.

Nesse contexto, para proposição de uma modelagem mais realista da operação dos sistemas de distribuição, a seguir é descrito o método para expressão da incerteza e a definição/contextualização da análise de variâncias.

2.3.1 Método para Expressão da Incerteza

Em 1977, reconhecendo a falta de consenso internacional sobre a expressão da incerteza de medição, o Comitê Internacional de Pesos e Medidas (a maior autoridade mundial em metrologia), requereu ao Birô Internacional de Pesos e Medidas, o tratamento do problema em conjunto com os laboratórios nacionais de metrologia e a elaboração de uma proposta. Como resultado, foi elaborada a Recomendação n. 01/1981 do CIPM, sendo a única recomendação relacionada à expressão de incerteza em medição adotada por uma organização intergovernamental. A partir desse documento, em 2008, foi publicado o *Guia para Expressão de Incerteza de Medição* (GUM, 2008) com o suporte de diversas organizações internacionais². Os propósitos desse Guia foram: i) promover completa informação sobre como se chega a uma declaração de incerteza, e ii) fornecer uma base para a comparação internacional de resultados de medição.

Nesse contexto, conforme consta no GUM (2008, p. 27-28), o procedimento internacional para avaliação e expressão das incertezas pode ser resumido em três etapas essenciais:

1. determinação da *incerteza-padrão tipo A*, baseada na análise estatística das amostras obtidas para cada variável de entrada da função de medição;
2. determinação da *incerteza-padrão combinada*, resultante da combinação de todos os termos da expressão da função de medição;
3. determinação da *incerteza expandida*, associando um nível de confiança ao intervalo definido pela incerteza-padrão combinada.

²BIPM – *Bureau International des Poids et Mesures* (Birô Internacional de Pesos e Medidas); IE – *International Electrotechnical Commission* (Comissão Eletrotécnica Internacional), IFCC – *International Federation of Clinical Chemistry* (Federação Internacional de Química Clínica), ISO: *International Organization for Standardization* (Organização Internacional para a Normalização), IUPAC: *International Union of Pure and Applied Chemistry* (União Internacional de Química Pura e Aplicada) IUPAP: *International Union of Pure and Applied Physics* (União Internacional de Física Pura e Aplicada) OIML: *International Organization of Legal Metrology* (Organização Internacional de Metrologia Legal).

2.3.1.1 Incerteza-padrão Tipo A

A incerteza-padrão é definida como a incerteza do resultado expressa como um desvio-padrão, sendo Tipo A, quando o método de avaliação da incerteza baseia-se em uma análise estatística de uma de série de observações. Ao modelar a cronologia de operação de SDEE por meio de cenários representativos, por exemplo, as observações individuais, ou amostras, diferem em valor por causa dos efeitos aleatórios do algoritmo de agrupamento dos cenários de operação. Deste modo, para uma grandeza de entrada x_i determinada por n_s amostras (repetidas e independentes), a incerteza-padrão de sua estimativa será o desvio-padrão experimental da média, dado por:

$$u_A^{x_i} = \frac{s_p^{x_i}}{\sqrt{n_s}}, \quad (2.3)$$

onde:

$u_A^{x_i}$ incerteza-padrão tipo A calculada para estimativa da variável x_i considerando o conjunto de amostras;

$s_p^{x_i}$ desvio-padrão baseado em n_s amostras independentes da variável x_i , dado por:
 $s_p^{x_i} = \sqrt{\frac{1}{n_s-1} \sum_{s=1}^{n_s} (x_{i,s} - \bar{x}_i)^2}$;

n_s número de amostras.

2.3.1.2 Incerteza-padrão Combinada

O efeito de propagação das incertezas, denominado incerteza-padrão combinada, possibilita estimar as incertezas das grandezas de saída de interesse, por meio da combinação apropriada de incertezas-padrão das estimativas das variáveis de entrada. Em problemas de otimização, o resultado determinístico da função objetivo pode ser complementado pela a incerteza-padrão combinada de grandezas de saída, expressa por (GUM, 2008):

$$(u_c^y)^2 = \sum_{i=1}^C \sum_{ii=0}^C \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_{ii}} u^{x_i, x_{ii}}, \quad (2.4)$$

onde:

u_c^y incerteza-padrão combinada, calculada para estimativa da grandeza de saída y ;

f função de medição;

x_i, x_{ii} estimativas das grandezas de entrada;

$\frac{\partial f}{\partial x_i}, \frac{\partial f}{\partial x_{ii}}$ derivadas parciais, frequentemente denominadas coeficientes de sensibilidade, que descrevem a variação da estimativa de saída y em relação às alterações nos valores das estimativas de entrada x_1, x_2, \dots, x_C ;

C número de coeficientes de sensibilidade considerados;

- $u^{x_i, x_{ii}}$ covariância estimada associada com x_i e x_{ii} , dada por: $u^{x_i, x_{ii}} = u_A^{x_i} u_A^{x_{ii}} r^{x_i, x_{ii}}$;
- $u_A^{x_i}$ incerteza-padrão tipo A, calculada para estimativa da grandeza de entrada x_i ;
- $u_A^{x_{ii}}$ incerteza-padrão tipo A, calculada para estimativa da grandeza de entrada x_{ii} ;
- $r^{x_i, x_{ii}}$ grau de correlação estimado entre as grandezas de entrada x_i e x_{ii} .

A incerteza expressa por (2.4) é caracterizada pela raiz quadrada positiva da soma dos quadrados dos produtos do desvio padrão e suas correspondentes derivadas parciais, incluindo termos similares para as entradas dependentes e indicados por suas covariâncias ou correlações. Por meio de uma aproximação de primeira ordem da série de Taylor, obtém-se a Lei da Propagação da Incerteza Padrão, expressa por (MONTGOMERY, 2017):

$$u_c^y = \sqrt{\sum_{i=1}^C \left[\left(\frac{\partial f}{\partial x_i} \right)^2 (u_A^{x_i})^2 \right] + 2 \left(\sum_{i=1}^{C-1} \sum_{ii=i+1}^C \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_{ii}} u_A^{x_i} u_A^{x_{ii}} r^{x_i, x_{ii}} \right)}. \quad (2.5)$$

O grau de correlação r representa uma medida da dependência mútua relativa de duas variáveis de entrada, sendo igual à razão entre sua covariância e a raiz quadrada positiva do produto de suas variâncias, dado por:

$$r^{x_i, x_{ii}} = \frac{cov^{x_i, x_{ii}}}{\sqrt{(s_p^{x_i})^2 (s_p^{x_{ii}})^2}}, \quad (2.6)$$

onde:

$(s_p^{x_i})^2$ variância estimada, ou desvio quadrático em torno da estimativa, da variável aleatória x_i , expressa por: $(s_p^{x_i})^2 = \frac{1}{n_s - 1} \sum_{s=1}^{n_s} (x_{i,s} - \bar{x}_i)^2$, considerando n_s amostras;

$(s_p^{x_{ii}})^2$ variância estimada, ou desvio quadrático em torno da estimativa, da variável aleatória x_{ii} ;

$cov^{x_i, x_{ii}}$ covariância de duas variáveis aleatórias x_i e x_{ii} , dada por:

$$cov^{x_i, x_{ii}} = \frac{1}{n_s - 1} \sum_{s=1}^{n_s} (x_{i,s} - \bar{x}_i) (x_{ii,s} - \bar{x}_{ii}).$$

2.3.1.3 Incerteza Expandida

A incerteza expandida, também chamada de incerteza global, tem como propósito prover um intervalo com o qual se espera abranger uma extensa fração da distribuição de valores que podem razoavelmente ser atribuídos à grandeza de saída (mensurando). Esta fração pode ser vista como a probabilidade de abrangência, sendo necessário associar um nível da confiança específico ao intervalo definido pela incerteza expandida, dado por:

$$U^y = k_p u_c^y, \quad (2.7)$$

onde:

U^y incerteza expandida para a estimativa da grandeza de saída y ;

k_p fator de abrangência;

u_c^y incerteza padrão combinada para a estimativa da grandeza de saída y .

Por fim, observa-se que a escolha do fator de abrangência está atrelada ao nível de confiança estabelecido, o qual depende da distribuição de probabilidade caracterizada pela grandeza de saída y e sua incerteza-padrão combinada u_c^y .

2.3.2 Análise de Variância

A análise estatística de dados, por meio da proposição de projetos experimentais, é uma ferramenta amplamente utilizada em diferentes áreas, especialmente para quantificar a contribuição de diferentes fontes de incerteza (MOITRE; MAGNAGO, 2007). Um projeto experimental consiste em um conjunto de testes realizados em processos ou sistemas, nos quais as entradas são alteradas de forma a observar a resposta da saída e quantificar a sua relação com as entradas. O objetivo principal de um projeto experimental é determinar quais variáveis são mais influentes na resposta de saída (MONTGOMERY, 2017).

Em termos estatísticos, a análise de variância (ANOVA) testa a hipótese de que as médias de duas ou mais populações são iguais, permitindo avaliar a importância de um ou mais fatores, em relação à variável de resposta. O termo “análise de variância” baseia-se na abordagem em que o procedimento utiliza variâncias para determinar se as médias são diferentes. O procedimento funciona por meio da comparação da variância entre as médias de grupos *versus* a variância dentro dos grupos, de modo a determinar se os grupos são todos parte de uma população maior, ou populações distintas com características diferentes (MONTGOMERY, 2017). A Figura 6 ilustra o pseudocódigo de uma ANOVA.

Conforme consta na Figura 6, para efetuar uma ANOVA, *a priori* é necessário o projeto experimental, o qual determina os fatores controláveis e a variável de resposta, dados estes que compõem a matriz experimental. Ao executar a ANOVA, busca-se essencialmente aceitar ou rejeitar a hipótese nula, que afirma que todas as médias de população (médias de nível de fator) são iguais – enquanto a hipótese alternativa afirma que pelo menos uma é diferente.

Figura 6 – Pseudocódigo da análise de variâncias.

	Entrada: Matriz experimental
	Saída: Fator(es) controlável(eis) que afeta(m) a variável de saída
1	início
2	Montar matriz experimental;
3	Executar a ANOVA;
4	Verificar: Valor-p $\leq 0,05$?
5	se Sim então
6	Provável rejeição de H_0 ;
7	Verificar: potência estatística $> 80\%$?
8	se Sim então
9	Armazenar tamanho amostral (n_s);
10	Efetuar teste Levene's;
11	Verificar: Valor-p $< 0,05$?
12	se Sim então
13	Não há evidência de violação da premissa de variância constante.
14	Efetuar teste de Ryan-Joiner
15	Verificar: Valor-p $< 0,05$?
16	se Sim então
17	Não há evidência de violação da premissa da normalidade do erro.
18	O fator controlável afeta significativamente a variável de resposta.
19	se Não então
20	Evidência de violação da premissa de normalidade do erro;
21	Rever projeto experimental.
22	retorna Passo 2 - Montar matriz experimental
23	se Não então
24	Evidência de violação da premissa de variância constante;
25	Rever projeto experimental.
26	retorna Passo 2 - Montar matriz experimental
27	se Não então
28	Aumentar tamanho amostral
29	retorna Passo 2 - Montar matriz experimental
30	se Não então
31	Provável aceite de H_0 ;
32	Verificar: potência estatística $> 80\%$?
33	se Sim então
34	O fator controlável não afeta significativamente a variável de resposta.
35	Rever projeto experimental.
36	retorna Passo 2 - Montar matriz experimental se Não então
37	Aumentar tamanho amostral.
38	retorna Passo 2 - Montar matriz experimental
39	fim
40	fim

Dado a priori: projeto experimental, com fator(es) controlável(eis) e variável de resposta.

Objetivo: determinar a influência do(s) fator(es) controlável(eis) na variável de resposta.

Fonte: Elaborado pela autora (2020).

Tipicamente os resultados da ANOVA apresentam os seguintes atributos (MONTGOMERY, 2017):

- Fonte: representa a fonte de incerteza do modelo, como fator(es) controlável(eis), erro e total;
- GL – Graus de liberdade: determinado pelo número de observações da amostra;
- SQ (Aj.) – Soma dos quadrados ajustada: é uma medida da variação para os diferentes componentes do modelo;
- QM (Aj.) – Quadrados médios ajustados: medem o quanto a variação de um termo ou um modelo explica, assumindo que todos os outros termos estão no modelo, independentemente da ordem em que foram inseridos;
- Valor-F: é a estatística de teste usado para determinar se o termo está associado com a resposta;
- Valor-p: é uma probabilidade que mede a evidência contra a hipótese nula.

O primeiro teste, representado na linha 4 do pseudocódigo ilustrado na Figura 6, consiste na verificação do Valor-p a partir de um dado grau de significância ($\alpha = 0,05$ para 95% de confiança) do teste, segundo os requisitos:

- Valor-p $\leq \alpha$: as diferenças entre algumas das médias são estatisticamente significativas, e portanto, deve-se rejeitar a hipótese nula e concluir que nem todas as médias da população são iguais;
- Valor-p $> \alpha$: as diferenças entre algumas das médias não são estatisticamente significativas, e portanto, não há provas suficientes para rejeitar a hipótese nula de que as médias da população são todos iguais.

Haja vista que a estimativa de média da população é baseada na extração de amostras aleatórias, é possível que a média da sua amostra seja muito diferente da média da população. Assim, para evitar falsos aceites/rejeições, é necessário certificar-se de que o teste tenha poder suficiente para detectar uma diferença que seja significativa na prática. O poder de um teste de hipótese é a probabilidade de que o teste rejeite a hipótese nula de forma correta, sendo afetado pelo tamanho amostral, pela diferença, pela variabilidade dos dados e pelo nível de significância do teste. Além disso, a ANOVA exige dados de populações aproximadamente normalmente distribuídas com variâncias iguais entre fatores. Deste modo, são realizados os testes de Levene's e Ryan-Joiner (MONTGOMERY, 2017).

De acordo com a revisão bibliográfica realizada, Deladreue *et al.* (2001) apresentaram o primeiro estudo que propôs implementar um projeto experimental voltado a sistemas elétricos de potência. Neste trabalho, os autores desenvolveram uma metodologia

de análise de variância para gerenciamento das incertezas no planejamento de redes com inserção de produtores independentes de energia elétrica. Posteriormente, outros trabalhos abordaram ANOVA para detectar a influência que os dias e meses do ano exercem no preço de energia elétrica no mercado *spot* (MOITRE; MAGNAGO, 2006) e para verificar o impacto do consumo de petróleo e gás natural no preço da energia elétrica (MOITRE; MAGNAGO, 2007).

Nos últimos anos, com o surgimento de métodos de aprendizagem de máquinas e aprendizado profundo (do inglês, *deep learning*), tornou-se possível modelar incertezas com o uso de extensos bancos de dados, entretanto, a complexidade dos modelos de otimização aumentou. Por esta razão, Xu, Mili e Zhao (2019) apresentaram uma análise de variâncias integrada ao método do Caos Polinomial para solucionar um fluxo de carga probabilístico. Os autores propuseram a ANOVA para lidar com problemas de alta dimensionalidade (chamado na literatura como *curse of dimensionality*), de maneira a encontrar os atributos significativos e reduzir a complexidade do método proposto. Recentemente, outros autores aplicaram a ANOVA para avaliar a precisão de novas meta-heurísticas, como *Enhanced Velocity Differential Evolutionary Particle Swarm Optimization* (DABHI; PANDYA, 2020a) e *Hybrid Levy Particle Swarm Variable Neighborhood Search Optimization* (DABHI; PANDYA, 2020b), voltadas ao problema de alta inserção de REDs em redes de distribuição.

2.4 Principais Abordagens Correlatas ao Modelo Proposto

Embora o planejamento da operação de sistemas de distribuição seja um tema discutido há algumas décadas, com o advento de redes elétricas inteligentes, inúmeras incertezas inerentes à inserção de REDs, estimulam novas propostas no tema. Nesse contexto, serão descritas a seguir as principais abordagens correlatas ao método proposto no presente estudo, as quais se encontram de forma sintetizada na Tabela 3.

2.4.1 Resener *et al.* (2019a)

Intitulado “*A comprehensive MILP model for the expansion planning of power distribution systems – Part I: Problem formulation*”, o estudo consiste na proposição um modelo linearizado para ser utilizado em problemas de planejamento da expansão de SDEE com inserção de geração distribuída. No escopo do planejamento, Resener *et al.* (2019a) avaliaram variáveis de investimento, como o recondutoramento das linhas e alocação ótima de bancos de capacitores e reguladores de tensão, objetivando minimizar o custo total (investimento e operação do sistema). Para viabilizar modelagem por intermédio de um problema de PLIM, os autores utilizaram uma formulação linearizada para calcular o ponto de operação em regime permanente de SDEE, evitando não-linearidades provenientes do fluxo de carga convencional, conforme detalhado em Resener *et al.* (2017). Esta

Tabela 3 – Caracterização das abordagens correlatas.

Características			Referências (1)			*
			A	B	C	
Escopo do Planejamento de SDEE	Tipo	Expansão	x	x	x	
		Operação	x	x	x	x
	Variáveis de	Alocação de BC	x			
		Alocação de RT	x			
		Controle BC	x			x
	Decisão	Controle RT	x			x
		Controle OLTC				
		Recondutoramento	x		x	
		Alocação de REDs		x	x	
	Estratégia de Controle volt-var	Operação de REDs	x	x	x	
Centralizada		x	x	x		
	Descentralizada				x	
Modelagem da Cronologia de operação	Abordagem	Determinística	x			
		Probabilística		x	x	x
	Representação	Curva de Duração	x			
		PDF			x	
		Cenários		x		x
Simultaneidade de Operação (cargas e RED) (2)		x	x	x		
Modelo de Otimização	Função Objetivo	Mono-objetivo	x			x
		Multi-objetivo		x	x	
	Formulação	Nível Único	x			x
		Multiníveis		x	x	
	Método Exato de Solução	x			x	
	Método Heurístico de Solução		x			
	Método Híbrido de Solução			x		
Incertezas na Operação de SDEE					x	x

Notas:

(1) Referência A: Resener *et al.* (2019a)

Referência B: Li, Wang e Xia (2018)

Referência C: Moradijoz, Moghaddam e Haghifam (2018)

* Abordagem proposta pela autora.

(2) Abordagem considerando operação cronológica e simultânea de diferentes cargas e REDs.

abordagem permitiu integrar o subproblema de operação, de forma a minimizar os custos com perdas e penalidade por violação dos limites de tensão.

A partir de uma estratégia centralizada de controle volt-var, Resener *et al.* (2019a) formularam restrições para parametrizar o horário de chaveamento dos BCs automáticos e os taps do RT. A cronologia de operação foi modelada de forma determinística, a partir de uma curva de duração baseada em patamares de carga leve, média e pesada (ver Figura 2), a qual fora aplicada de forma igual a todas as cargas do SDEE.

O modelo proposto por Resener *et al.* (2019a) pode ser resolvido separadamente ou compor uma solução conjunta que considere simultaneamente as três alternativas de investimento (recondutoramento, BC e RT). Os testes de validação e exemplos de aplicação, publicados na Parte II (RESENER *et al.*, 2019b), incluíram estudos de casos para os sistemas de 23 nós, 69 nós e um caso real de 276 nós. A formulação linear permitiu encontrar solução ótima por intermédio do *solver* comercial CPLEX (IBM, 2019). Adicionalmente, o detalhamento da extensa revisão bibliográfica que resultou nesta proposta, foi publicado anteriormente em uma pesquisa intitulada “*Optimization techniques applied to planning of electric power distribution systems: a bibliographic survey*” (RESENER *et al.*, 2018).

2.4.2 Li, Wang e Xia (2018)

Denominado “*Cooperative Planning of Active Distribution System with Renewable Energy Sources and Energy Storage Systems*”, o estudo propôs um modelo multiníveis e multi-objetivo para o planejamento da expansão de sistemas de distribuição ativos. O problema foi modelado a partir de uma estrutura hierárquica com três níveis de otimização, com objetivos distintos, os quais se complementam por meio das variáveis compartilhadas entre cada nível. Nesta estrutura, o modelo de nível superior serviu como mestre e desempenhou um papel decisivo para determinar os esquemas de planejamento da expansão. Os subproblemas-escravos (níveis inferiores) determinaram a alocação ótima de REDs e sistemas de armazenamento, bem como suas condições ótimas de operação. Além disso, os autores avaliaram a participação dos consumidores a partir de programas de resposta à demanda, por meio de tarifas de período de uso (do inglês, *time-of-use*). Os indicadores de avaliação obtidos nos níveis inferiores, como custos de operação, índices de confiabilidade e inserção de REDs, realimentaram o nível superior, afetando nos esquemas de planejamento de modo a maximizar o lucro da concessionária.

Para incluir as incertezas inerentes à carga e REDs, Li, Wang e Xia (2018) utilizaram a abordagem probabilística, por meio de cenários selecionados com o algoritmo *K-means clustering*. Baseado no índice de Davies Bouldin, foram selecionados 35 cenários que representaram a operação cronológica e simultânea de cargas e REDs (solar fotovoltaico e eólica). O problema de otimização não linear inteiro misto foi resolvido com a meta-heurística enxame de partículas. Os múltiplos objetivos foram avaliados *a posteriori*, considerando as soluções da fronteira de Pareto.

2.4.3 Moradijoz, Moghaddam e Haghifam (2018)

O artigo “*A Flexible Active Distribution System Expansion Planning Model: A Risk-Based Approach*” apresentou uma abordagem multiníveis para o planejamento da expansão de sistemas de distribuição ativos. O problema de otimização contemplou dois níveis, no qual o nível inferior avaliou a operação de SDEE a partir de um fluxo de potência ótimo com PLIM. O nível superior, por sua vez, avaliou os custos de investimento executando um algoritmo genético com sistemas imunológicos artificiais. As variáveis de investimento incluíram o recondutoramento das linhas, alocação de geração distribuída e alocação de sistema de armazenamento de energia elétrica, considerando estratégia centralizada de controle volt-var. Para modelar as incertezas, Moradijoz, Moghaddam e Haghifam (2018) representaram a cronologia de operação das cargas e REDs por meio de PDF, o que permitiu propor a consideração das incertezas na variável de resposta do modelo otimização. Desta maneira, os autores associaram um fator de risco ao plano de investimento, baseado na característica estocástica das demanda e injeção de potência na rede, de maneira a apresentar a PDF dos custos de planejamento, resultantes do modelo proposto.

2.5 Comentários sobre o Estado da Arte e Contribuições da Tese

Esta subseção objetiva exclusivamente identificar e ponderar as particularidades dos estudos apresentados na revisão bibliográfica, especialmente em relação às abordagens correlatas, as quais foram fundamentais para estruturar o método proposto.

Embora todas as abordagens correlatas tenham como escopo principal o planejamento da expansão de sistemas de distribuição, aspectos de operação foram incluídos indiretamente de variadas formas. Resener *et al.* (2019a) propuseram incluir no estudo de planejamento da expansão o controle ótimo de BCs e RTs. Para isso, o problema da operação foi incorporado na função objetivo, a partir dos custos operacionais referentes às perdas ativas e à penalidade por violação dos limites de tensão. As abordagens multi-níveis propostas por Li, Wang e Xia (2018) e Moradijoz, Moghaddam e Haghifam (2018) estabeleceram a operação como um problema escravo da expansão, executando sequencialmente as variáveis de investimento selecionadas pelo problema mestre, mantendo o acoplamento entre expansão e operação.

Dentre as variáveis de decisão do planejamento de SDEE, somente Resener *et al.* (2019a) propuseram a otimização do controle de BCs automáticos e RTs, simultaneamente. No entanto, a principal desvantagem consiste na estratégia centralizada de controle volt-var, definindo previamente o horário de funcionamento dos BCs, bem como a posição dos taps do RT, a partir de patamares de carga leve, média e pesada. Com isso, os dispositivos de controle volt-var são operados remotamente de forma centralizada, desacoplando a solução ótima da realidade de operação de SDEE. Li, Wang e Xia (2018) e Moradi-

joz, Moghaddam e Haghifam (2018) compartilham desta desvantagem, uma vez que as soluções de controle volt-var utilizando REDs também consistiram em estratégias centralizadas.

Em relação à cronologia de operação, Resener *et al.* (2019a) propuseram uma curva de duração que permite variar o carregamento da rede e operar BCs automáticos, manobrando-os apenas durante o horário de pico de maior demanda. Desta forma, os autores viabilizaram a proposição de um problema de PLIM, com garantia de otimalidade da solução encontrada. No entanto, abordagens determinísticas desconsideram as incertezas decorrentes da natureza estocástica tanto das cargas quanto dos REDs.

É oportuno salientar que todas as abordagens que representam a variação da carga por intermédio de curvas de duração tem como característica comum a ausência de sequenciamento temporal. Desta forma, por exemplo, não é possível limitar o número de chaveamentos que serão necessários para os BCs automáticos ao longo de sua operação diária. Dependendo das características do sistema isso pode implicar a ocorrência de inúmeros chaveamentos que irão provocar transitórios, elevar os custos de manutenção e reduzir a vida útil dos equipamentos.

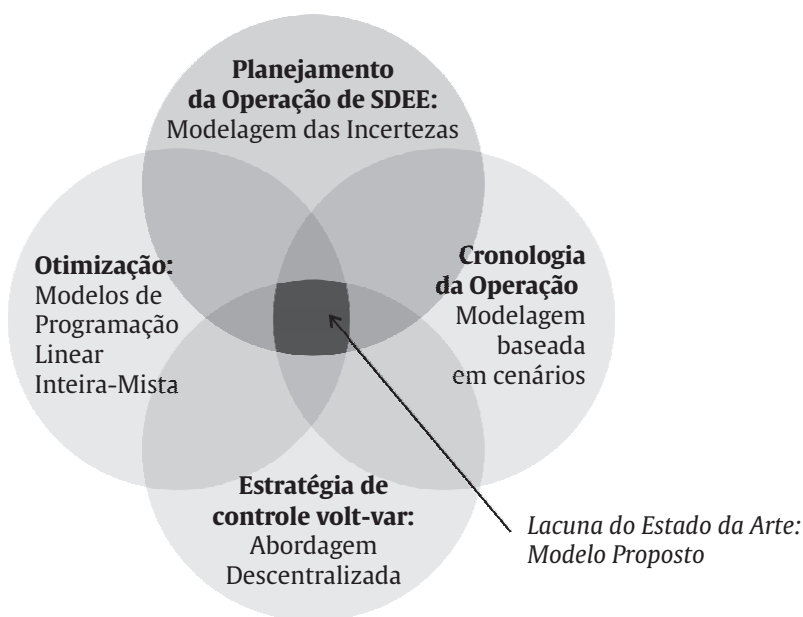
Nesse sentido, Li, Wang e Xia (2018) modelaram a operação cronológica a partir de cenários representativos, selecionados com algoritmo *K-means clustering*, de maneira a considerar a simultaneidade de cargas e REDs desiguais. Moradijoz, Moghaddam e Haghifam (2018), por sua vez, apresentaram a modelagem cronologia da operação modelada a partir de PDFs, o que permitiu avaliar as incertezas da operação de SDEE. Todavia, ambos estudos foram resolvidos com meta-heurísticas, sem garantia de otimalidade da solução encontrada.

Uma outra característica muito comum na representação do problema de operação por intermédio de modelos de otimização é que se assume a existência de um controle central que tem capacidade de atuar de modo coordenado sobre todos os equipamentos da rede de modo simultâneo para atender a um objetivo sistêmico. Embora isso possa ser realizado em nível de planejamento e para uma quantidade razoável de modos de operação previstos, é impossível contemplar todas as possibilidades. Assim, quando o sistema estiver experimentando uma situação que não possa ser classificada entre uma das situações que foram contempladas no modelo, seria necessário executar um fluxo de carga ótimo para determinar quais ajustes seriam adequados. O problema pode se agravar ainda mais, se considerarmos que durante esta situação não é possível ter certeza de quanto tempo o sistema vai operar nesta condição, ou seja, é possível que sejam realizados inúmeros ajustes para uma situação cuja duração é muito pequena e, em um curto espaço de tempo, ser necessário fazer novas alterações na rede. Além disto, para evitar atuação indevida, muitos dispositivos de controle dos SDEE são programados para retardar a sua atuação, por intermédio de limiares de operação e também histereses. Não considerar estas características pode fazer com que o modo de operação previsto pelo modelo de otimização

não seja efetivamente realizado na operação diária do SDEE.

Diante do exposto, dentre as bibliografias publicamente disponíveis nesta fase do estudo, a presente tese objetiva preencher uma lacuna no estado da arte (ilustrada pela Figura 7), a partir de um modelo de otimização clássica para planejamento da operação de SDEE considerando incertezas, o qual aborda a cronologia da operação de cargas e REDs a partir de cenários, e integra estratégias descentralizadas de controle volt-var. Além disto, o modelo permite a representação explícita dos parâmetros de controle que podem ser ajustados localmente tanto nos BCs quanto nos RTs.

Figura 7 – Proposição de contribuição científica da tese.



Fonte: Elaborado pela autora (2020).

3 MODELO PROPOSTO PARA PLANEJAMENTO DA OPERAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO

Neste capítulo, é apresentado o modelo proposto para o planejamento da operação de sistemas de distribuição. Partindo do modelo linear proposto por Resener (2016), para o planejamento da expansão, foram acrescentadas importantes funcionalidades de modo a descrever o problema de operação, tais como: (i) consideração da cronologia de operação; (ii) consideração das incertezas inerentes ao comportamento das cargas e dos REDs; (iii) representação dos dispositivos de controle volt-var descentralizados¹, tanto para os bancos de capacitores quanto para os reguladores de tensão; e (iv) representação da histerese e da saturação dos dispositivos de controle.

3.1 Definição do Escopo do Planejamento

Nesta tese, é apresentando um modelo de otimização para o planejamento da operação de SDEE considerando incertezas. Um grande diferencial do modelo apresentado está no fato de incluir a representação de elementos associados aos controles distribuídos (locais), cujos valores são determinados de modo que seja obtida a operação ótima do ponto de vista sistêmico. Desta forma, as variáveis que são obtidas como resultado da otimização são: (i) o ajuste do controle para que os bancos de capacitores automáticos operem de modo ótimo; e (ii) o ajuste ótimo do controle dos reguladores de tensão com compensação por queda de tensão na linha. Tais controles são definidos considerando a cronologia da operação, ou seja, levam em conta que a carga varia ao longo do dia e também varia de um dia para o outro. Embora esses ajustes possam ser aplicados de forma distribuída, individualmente em cada dispositivo controlado, o resultado operacional obtido é otimizado para o sistema como um todo.

A função objetivo do modelo proposto inclui os custos de operação, associados à manutenção, perdas ativas e penalidades pela violação dos limites de tensão. As seguintes

¹O modelo proposto nesta tese contempla a formulação de uma estratégia de controle volt-var descentralizada, a qual pode ser aplicada a sistemas supervisionados e não-supervisionados (conforme definições apresentadas na Seção 2.1.1).

premissas relacionadas ao modelo proposto de planejamento da operação de SDEE são consideradas: o local de instalação dos bancos de capacitores e reguladores de tensão é conhecido; e a cronologia de operação inclui dados de recursos energéticos distribuídos, provenientes de painéis solar fotovoltaicos e aerogeradores, bem como de demanda de energia elétrica de consumidores residenciais. De maneira a reduzir o espaço de busca e garantir soluções factíveis, são consideradas restrições de operação da rede e dos equipamentos, bem como restrições lógicas, as quais serão detalhadas ao longo deste capítulo.

3.2 Modelagem da Cronologia de Operação

Neste trabalho, a operação cronológica e simultânea de cargas e REDs é definida como cronologia da operação, sendo representada por meio de cenários. Cada cenário descreve um dia completo de operação de todo o SDEE, com valores horários de demanda ativa e reativa de cada carga, e de injeção de potência ativa dos REDs. Tal representação visa preservar a cronologia dos dados históricos de geração e demanda de energia elétrica, bem como considerar a simultaneidade entre diferentes cargas e unidades de geração, com um número reduzido de avaliações necessárias para simular a operação da rede.

A Tabela 4 apresenta as principais definições sobre a modelagem da cronologia de operação proposta no presente trabalho.

Tabela 4 – Definições sobre a modelagem da cronologia de operação proposta.

Parâmetro	Definição	Representação no MILP
Período de operação	Intervalo de tempo considerado para descrever o dia.	$j \in \mathcal{J}$
Cenário	Perfil de operação cronológica e simultânea de todas as cargas e REDs de um SDEE, representado com o centroide de um <i>cluster</i> K pertencente à amostra s , o qual é calculado por meio da técnica <i>K-means clustering</i> .	$sc \in \mathcal{P}_s^K$
Cluster	Agrupamento de diferentes dias de operação pertencentes ao cenário sc	k_{sc}
Duração do cenário	Quantidade de dias agrupados pelo cenário sc .	ΔT_{sc}
Quantidade de cenários	Número de cenários considerados, ou seja, total de <i>clusters</i> calculados com <i>K-means clustering</i> . Definida por meio de uma análise de sensibilidade.	K
Amostra	Repetição aleatória e independente do processo de seleção de K cenários.	$s \in \mathcal{S}$
Quantidade de amostras	Total de amostras geradas. Definido por meio de uma análise de variâncias (ANOVA) de um projeto fatorial.	n_s

A modelagem da cronologia da operação consiste em quatro etapas que são ilustradas

na Figura 8, considerando o histórico de 1 ano². As etapas são descritas a seguir:

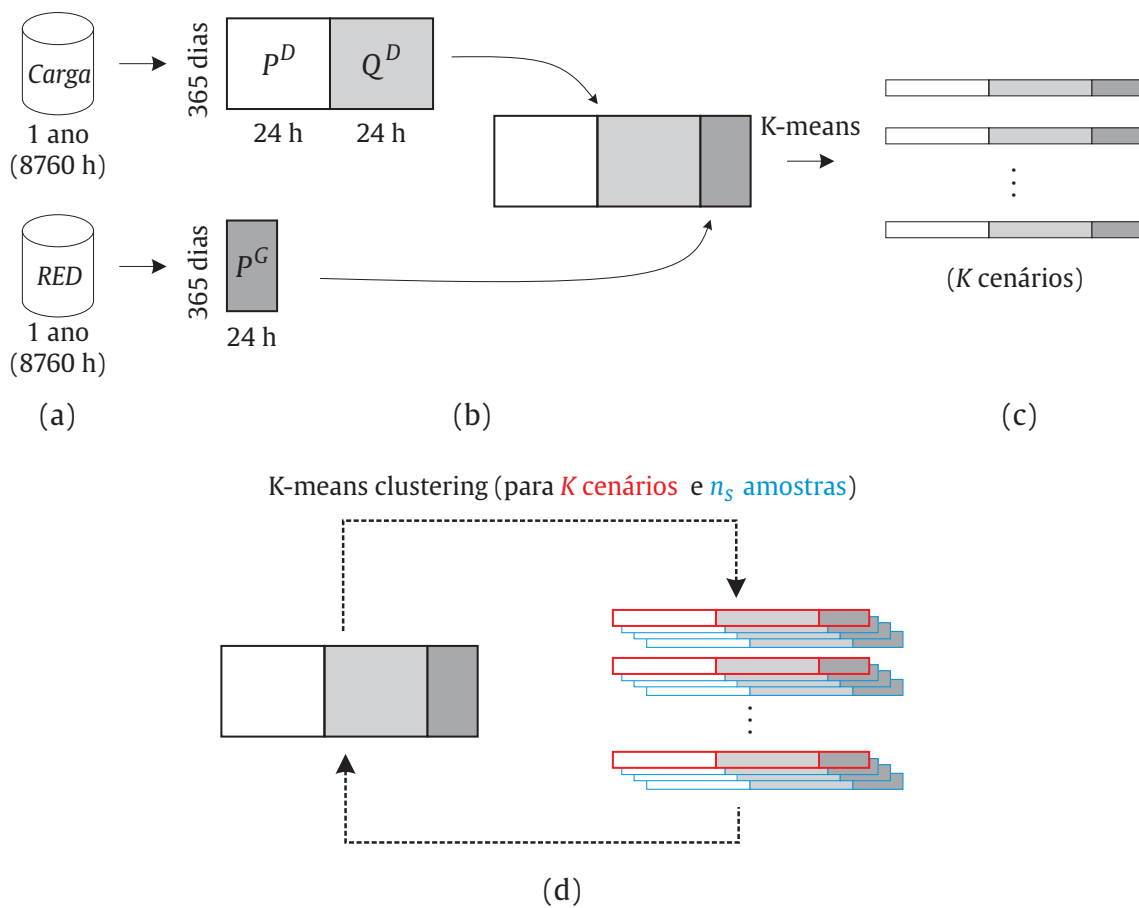
- (a) obtenção do histórico de 1 ano (8760 h) de operação das cargas e REDs do sistema de distribuição;
- (b) construção da matriz de dados históricos: as linhas representam os 365 dias do ano e as colunas representam os valores horários de demanda de potência ativa (P^D) e reativa (Q^D) das cargas, e de injeção de potência ativa (P^G) dos REDs;
- (c) agrupamento dos dias com características similares, por meio da técnica *K-means clustering*, nos quais a operação cronológica e simultânea de diferentes cargas e REDs é preservada por meio de K cenários, representados pelos centroides dos *clusters*;
- (d) obtenção de n_s amostras independentes e aleatórias, por meio da repetição da etapa (c) para um dado K (o qual é definido *a priori*).

A representação matricial do histórico de operação, indicada na etapa (b) da Figura 8, permite capturar variabilidade horária e simultânea de todas as cargas e REDs de um sistema de distribuição. Neste caso, conforme ilustrado na Figura 9, cada linha representa um dia de operação, definido como um ponto com d -dimensões, sendo d o número de colunas da matriz. Ao obter 1 ano de histórico, tem-se uma matriz com 365 linhas. Já o número de colunas irá depender da quantidade de cargas e REDs instalados no SDEE e do intervalo de tempo no qual o dia será segmentado – para os propósitos deste trabalho foi usado o intervalo de 1 hora. Dessa forma, cada célula da matriz corresponde a um período de operação de uma hora. Na Figura 9, não foram mostrados os cenários de operação, uma vez que esses são representados pelos centroides dos *clusters* (valor médio dos dias agrupados) e, portanto, não constam nos dados históricos de entrada.

Ao efetuar o agrupamento dos dias por meio da técnica *K-means clustering*, indicado na etapa (c) da Figura 8, o número de colunas da matriz é mantido, mas o número de linhas é drasticamente reduzido para o número de *clusters* determinado. Logo, os cenários representados pelos *clusters* possuem informações de um dia completo de operação (no caso, 24 horas), entretanto tais cenários não têm sequenciamento temporal, pois são oriundos da agregação de diversos dias de operação semelhante ao longo do horizonte de planejamento. Dessa maneira, um determinado cenário pode representar dias que não são contíguos (por exemplo, um determinado cenário pode descrever a operação aos domingos). Além disso, não existe razão para que o primeiro cenário de operação seja seguido pelo segundo; cada um representa uma quantidade de dias do horizonte de operação previsto para o sistema.

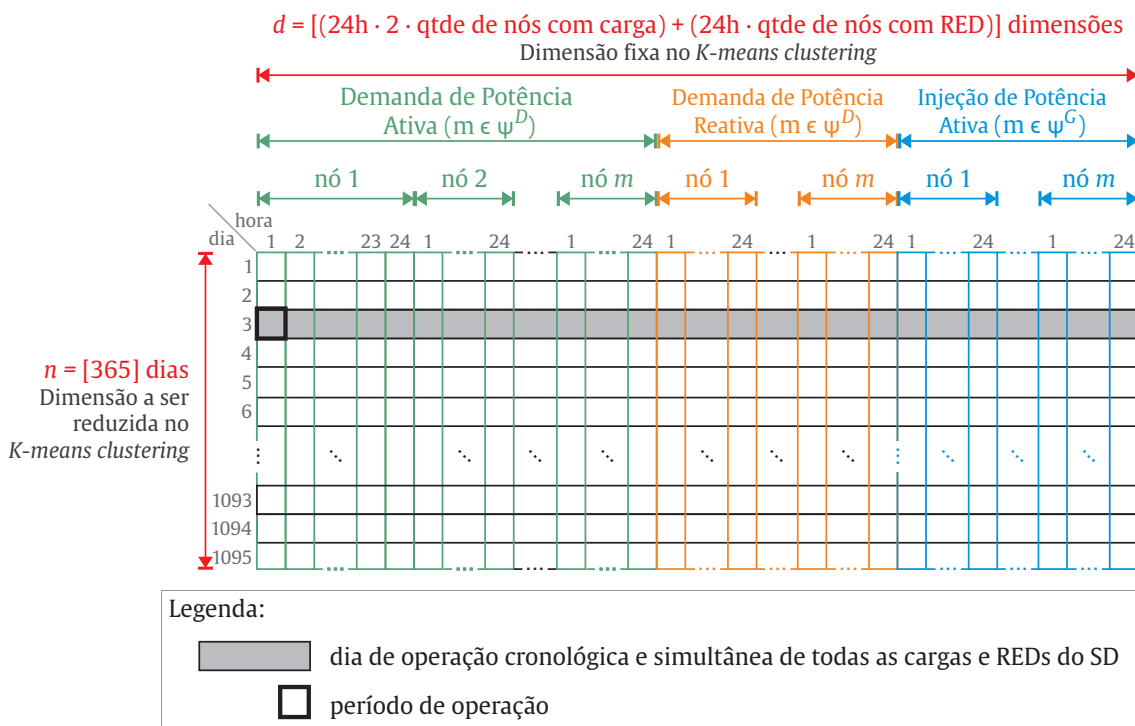
²Observar que, facilmente, é possível aplicar o mesmo processo para históricos de operação com duração diversa.

Figura 8 – Ilustração das principais etapas da modelagem da cronologia de operação: (a) leitura do histórico de dados (não-tratados); (b) processamento dos dados; (c) seleção de cenários; (d) geração de amostras independentes e aleatórias.



Fonte: Elaborado pela autora (2020).

Figura 9 – Representação matricial dos dados para modelagem da cronologia de operação do SDEE.



Fonte: Elaborado pela autora (2020).

Em relação à obtenção de amostras, indicada na etapa (d) da Figura 8, o algoritmo *K-means clustering* consiste na exploração aleatória de bases de dados e pode apresentar soluções diferentes (amostras) a cada execução, mesmo para uma quantidade definida de *clusters* (JAIN, 2010). Nesse caso, conforme amplamente discutido na Seção 2.2.3, a definição do número de cenários (K) e do número de amostras (n_s) é baseada em uma análise de sensibilidade, que pode incluir aspectos da análise de variâncias, de modo a obter o equilíbrio entre a precisão do *K-means clustering* e a complexidade do modelo, aliada ao esforço computacional para solução do problema.

3.3 Formulação do Modelo Linearizado

Este modelo de otimização determina uma estratégia de controle volt-var de maneira a minimizar os custos de operação de sistemas de distribuição. Visando a proposição de um problema de PLIM, esse modelo possui função objetivo e restrições lineares, variáveis binárias, e variáveis inteiras e contínuas, dependendo da estratégia adotada para o controle volt-var.

A formulação, apresentada a seguir, foi desenvolvida para determinar os parâmetros de ajuste dos controles dos bancos automáticos de capacitores e dos reguladores de tensão, visando a operação ótima do SDEE e considerando todos os cenários que são utilizados

para representar a operação diária. Detalhes da adaptação do modelo utilizado para representar a operação em regime permanente de SDEE (HAFFNER *et al.*, 2009; RESENER, 2016) encontram-se no Apêndice 6.

3.3.1 Função Objetivo

Sob a perspectiva da concessionária de energia elétrica, a função objetivo do modelo proposto consiste na minimização dos custos anuais de operação de SDEE, expressa por:

$$C_s^{\text{oper}} = \sum_{sc \in \psi_s^K} \Delta T_{sc,s} C_{sc,s}^{\text{oper}}, \quad \forall s \in \psi^S, \quad (3.1)$$

$$C_{sc,s}^{\text{oper}} = C_{sc,s}^{\text{loss}} + C_{sc,s}^{\text{vio}}, \quad (3.2)$$

onde:

C_s^{oper} custo anual de operação da amostra s [\$/ano];

$C_{sc,s}^{\text{oper}}$ custo diário de operação do cenário sc pertencente à amostra s [\$/dia];

$C_{sc,s}^{\text{loss}}$ custo diário das perdas de energia ativa do cenário sc pertencente à amostra s [\$/dia];

$C_{sc,s}^{\text{vio}}$ penalidade diária das violações dos limites de tensão do cenário sc pertencente à amostra s [\$/dia];

$\Delta T_{sc,s}$ duração anual do cenário sc pertencente à amostra s [dias/ano];

ψ_s^K conjunto de cenários diários de operação a ser considerado, pertencente à amostra s ;

ψ^S conjunto de amostras a ser considerado.

No cálculo do custo anual de operação da amostra s , dado por (3.1), os custos de cada cenário são multiplicados pela duração do mesmo ($\Delta T_{sc,s}$, em dias/ano), a qual é obtida por meio do método *K-means clustering*. Já os custos diários com as perdas de energia ativa e as penalidades diárias por violações de tensão de cada cenário sc pertencente à amostra s , dados na expressão (3.2), são calculados por:

$$C_{sc,s}^{\text{loss}} = C^{\text{MWh}} S_{\text{base}} \sum_{j \in \psi^J} \sum_{km \in \psi^B} P_{km,j,sc,s}^{\text{loss}}, \quad (3.3)$$

$$C_{sc,s}^{\text{vio}} = CV \sum_{j \in \psi^J} \sum_{m \in \psi^D} z_{m,j,sc,s}, \quad (3.4)$$

onde:

C^{MWh} custo da energia elétrica [\$/MWh];

S_{base} potência base do sistema [MVA];

- $p_{km,j,sc,s}^{\text{loss}}$ perdas ativas diárias ocorridas no ramo km durante a hora j do cenário sc pertencente à amostra s [pu/dia];
- CV fator de penalidade pela violação dos limites de tensão [\$/pu];
- $z_{m,j,sc,s}$ violação diárias ocorridas nos limites de tensão do nó m durante a hora j do cenário sc pertencente à amostra s [pu/dia];
- ψ^J conjunto das 24 horas que são consideradas em cada cenário para descrever um dia de operação;
- ψ^B conjunto de todos os ramos da rede;
- ψ^D conjunto de todos os nós da rede nos quais existe demanda de potência.

A expressão (3.3) calcula o custo diário das perdas de energia para cada cenário pertencente à amostra s , no entanto a estimativa das perdas ($p_{km,j,sc,s}^{\text{loss}}$) envolve o uso de equações não-lineares. Neste trabalho, as perdas ativas são determinadas por meio de uma aproximação linear que representa o valor dos quadrados dos termos real e imaginário das correntes dos ramos e utiliza esses valores para obter a perda ativa (RESENER *et al.*, 2016). Além disso, para calcular a penalidade pela violação dos limites de tensão, dada por (3.4), são determinados os desvios de tensão nodal considerando os limites mínimo e máximos estabelecidos pela ANEEL (2016) (HAFFNER; PEREIRA; GASPERIN, 2008). Detalhes sobre esta formulação estão disponíveis no Apêndice 6.

Para este modelo de otimização linear, são utilizadas restrições para descrever a operação da rede e propostas diversas restrições, necessárias para descrever o modo de operação dos dispositivos de controle volt-var utilizando BCs e RTs, conforme detalhamento a seguir.

3.3.2 Restrições de Operação da Rede

Entre as restrições que descrevem o ponto de operação em regime permanente de um SDEE estão as restrições de operação da rede, as quais incluem a aplicação das Leis de Kirchhoff. Dessa maneira, considerando a Lei de Kirchhoff das Correntes, onde a soma das correntes demandadas é igual à soma das injeções de corrente em um nó, $\forall j \in \psi^J$, $\forall sc \in \psi_s^K$ e $\forall s \in \psi^S$, tem-se que:

$$\mathbf{Sf}_{j,sc,s}^{\text{Re}} + \mathbf{g}_{j,sc,s}^{\text{Re}} = \mathbf{d}_{j,sc,s}^{\text{Re}} + \Delta \mathbf{f}_{j,sc,s}^{\text{Re}}, \quad (3.5)$$

$$-\mathbf{q}_{j,sc,s}^F - \mathbf{q}_{j,sc,s}^A + \mathbf{Sf}_{j,sc,s}^{\text{Im}} + \mathbf{g}_{j,sc,s}^{\text{Im}} = \mathbf{d}_{j,sc,s}^{\text{Im}} + \Delta \mathbf{f}_{j,sc,s}^{\text{Im}}. \quad (3.6)$$

onde:

- $\mathbf{q}_{j,sc,s}^F, \mathbf{q}_{j,sc,s}^A$ vetores com injeções de corrente relacionadas a operação de capacitores fixos e automáticos durante a hora j do cenário sc pertencente à amostra s [pu];

- $\mathbf{f}_{j,sc,s}^{\text{Re}}, \mathbf{f}_{j,sc,s}^{\text{Im}}$ vetores das partes real e imaginária das correntes nos ramos durante a hora j do cenário sc pertencente à amostra s [pu];
- \mathbf{S} matriz incidência nó-ramo da rede;
- $\mathbf{g}_{j,sc,s}^{\text{Re}}, \mathbf{g}_{j,sc,s}^{\text{Im}}$ vetores das partes real e imaginária da injeções nodais de corrente relacionadas à operação dos REDs, durante a hora j do cenário sc pertencente à amostra s [pu];
- $\mathbf{d}_{j,sc,s}^{\text{Re}}, \mathbf{d}_{j,sc,s}^{\text{Im}}$ vetores das partes real e imaginária das correntes de carga durante a hora j do cenário sc pertencente à amostra s [pu];
- $\Delta \mathbf{f}_{j,sc,s}^{\text{Re}}, \Delta \mathbf{f}_{j,sc,s}^{\text{Im}}$ vetores com as alterações nas partes real e imaginária no fluxo de corrente a montante dos RTs [pu].

De acordo com o detalhamento apresentado no Apêndice 6, os bancos de capacitores são modelados como impedância constante, então $\mathbf{q}_{j,sc,s}^F$ e $\mathbf{q}_{j,sc,s}^A$ representam os vetores de injeção de corrente de BCs fixos e automáticos, respectivamente, obtidas para todos os nós com BC ($\forall m \in \psi^{BC}$) por meio de uma formulação disjuntiva (RESENER *et al.*, 2016). Por outro lado, as cargas são representadas por injeções constantes de corrente (RESENER *et al.*, 2017), conforme explicado no Apêndice 6, e os termos $\mathbf{d}_{j,sc,s}^{\text{Re}}$ e $\mathbf{d}_{j,sc,s}^{\text{Im}}$ representam as partes real e imaginária da injeção de corrente em todos os nós com carga ($\forall m \in \psi^D$). Perante os modos de operação disponíveis para os REDs, com exceção do nó de referência, todos os nós com capacidade de geração operam como barras PQ. Assim, as injeções de corrente dos REDs ($\mathbf{g}_{j,sc,s}^{\text{Re}}$ and $\mathbf{g}_{j,sc,s}^{\text{Im}}$) são calculadas na etapa do *K-means clustering* e representam a operação cronológica de cada RED. Adicionalmente, a corrente de compensação é calculada exclusivamente para o nó terminal do RT ($\forall m \in \psi^{RT}$) e os vetores com as alterações nas partes real e imaginária no fluxo a montante dos RTs são representados por $\Delta \mathbf{f}_{j,sc,s}^{\text{Re}}$ e $\Delta \mathbf{f}_{j,sc,s}^{\text{Im}}$. Para lidar com as não linearidades que surgem com essa formulação, foi utilizada uma formulação disjuntiva (RESENER *et al.*, 2019a).

A aplicação da Lei de Kirchhoff das Tensões, por sua vez, permite calcular as quedas de tensão em todos os ramos do SDEE ($\forall km \in \psi^B$), conforme a seguinte expressão:

$$K_{km,j,sc,s} R_{km} f_{km,j,sc,s}^{\text{Re}} - X_{km} f_{km,j,sc,s}^{\text{Im}} + [\mathbf{S}]_{\text{linha } km} \mathbf{V}_{j,sc,s} - \Delta V_{m,j,sc,s} = 0, \quad (3.7)$$

onde:

- $K_{km,j,sc,s}$ fator de ajuste para o cálculo da queda de tensão no trecho km durante a hora j do cenário sc pertencente à amostra s [pu];
- R_{km} resistência do trecho de rede km [pu];
- X_{km} reatância do trecho de rede km [pu];
- $f_{km,j,sc,s}^{\text{Re}}$ parte real da corrente no ramo km durante a hora j do cenário sc pertencente à amostra s [pu];

- $f_{km,j,sc,s}^{\text{Im}}$ parte imaginária da corrente no ramo km durante a hora j do cenário sc pertencente à amostra s [pu];
- S** matriz incidência nó-ramo da rede, onde o sobrescrito ($'$) indica matriz transposta;
- $\mathbf{V}_{j,sc,s}$ vetor de magnitudes da tensão durante a hora j do cenário sc pertencente à amostra s [pu];
- $\Delta V_{m,j,sc,s}$ alteração da tensão no nó m durante a hora j do cenário sc pertencente à amostra s [pu].

A presença de RTs implica alteração da tensão no nó m ($\forall m \in \psi^{RT}$). Assim, similar aos termos $\Delta \mathbf{f}_{j,sc,s}^{\text{Re}}$ e $\Delta \mathbf{f}_{j,sc,s}^{\text{Im}}$ das expressões (3.5) e (3.6), a linearização disjuntiva formulada por Resener *et al.* (2019a) é adotada para evitar as não linearidades que envolvem o cálculo do $\Delta V_{m,j,sc,s}$. Além disso, para melhorar a aproximação da solução do modelo linearizado em relação à solução exata do modelo não linear (fluxo de carga), é adotado o fator de ajuste $K_{km,j,sc,s}$ ($\forall km \in \psi^B$), conforme proposto por Haffner, Pereira e Gasperin (2008).


3.3.3 Restrições para Controle volt-var com Bancos de Capacitores

Nos modelos de otimização, geralmente a definição do estado de operação das unidades automáticas está relacionada com o nível de carregamento que é observado na rede. Nas condições de carga mais elevada, as unidades permanecem ligadas e, nas condições de carga mais leve, são desligadas. Quando todas as cargas da rede têm o mesmo comportamento simultâneo, esta forma de ajustar o controle pode ser adequada. Entretanto, existem situações nas quais o comportamento das cargas é muito diferenciado, e isso se intensifica quando existem REDs. Na presença de REDs, um determinado nó do sistema pode estar injetando potência líquida máxima, enquanto os demais estão operando com consumo máximo. Desta forma, fica muito difícil definir quais são os momentos de carregamento elevado, principalmente se desejado que isso possa ser válido durante todo os dias de um ano (já que é notório que a carga apresenta variação ao longo do ano e ao longo dos dias da semana).

Quando se deseja considerar a incerteza das cargas e dos REDs não é mais possível definir *a priori* em que momento a demanda é mais elevada, pois essa varia entre os dias da semana e também ao longo dos meses do ano. Desta forma, neste trabalho foi desenvolvida uma nova representação para determinar o modo de operação dos BCs automáticos em modelos de otimização. É utilizada uma regra única que é válida para todos os instantes de tempo e todos os cenários operacionais. No modelo desenvolvido, o chaveamento das unidades automáticas é sensível à variação da carga a jusante dos BCs. Basicamente, por meio do monitoramento da corrente do ramo a jusante do BC ($f_{mn,j,sc,s}^{\text{Re}}$, $f_{mn,j,sc,s}^{\text{Im}}$), o controle liga ou desliga o banco baseado em uma histerese de corrente, conforme ilustra

a Figura 10. O BC automático AI , instalado na barra m será ligado quando a magnitude da corrente a jusante superar o valor de controle definido como $I_m^{on,AI}$, e permanecerá ligado até a magnitude da corrente a jusante ser inferior ao valor de controle definido como $I_m^{off,AI}$.

Figura 10 – Controle de corrente de BCs automáticos: (a) sistema com BC instalado no nó m ; (b) histerese de controle de corrente.



Fonte: Elaborado pela autora (2020).

Para reproduzir o comportamento ilustrado na Figura 10 (b), propõe-se uma formulação disjuntiva que emprega uma grandeza denominada corrente de transição para permitir o ajuste ótimo das correntes de liga e desliga do BC automático, $\forall m \in \psi^{BC}$, expressa por:

$$I_{m,j,sc,s}^{trs,AI} - I_m^{on,AI} \leq M \left(y_{m,j-1,sc,s}^{AI} \right), \forall j = 2, 3, \dots, 24, \quad (3.8)$$

$$I_m^{on,AI} - I_{m,j,sc,s}^{trs,AI} \leq M \left(y_{m,j-1,sc,s}^{AI} \right), \forall j = 2, 3, \dots, 24, \quad (3.9)$$

$$I_{m,j,sc,s}^{trs,AI} - I_m^{off,AI} \leq M \left(1 - y_{m,j-1,sc,s}^{AI} \right), \forall j = 2, 3, \dots, 24, \quad (3.10)$$

$$I_m^{off,AI} - I_{m,j,sc,s}^{trs,AI} \leq M \left(1 - y_{m,j-1,sc,s}^{AI} \right), \forall j = 2, 3, \dots, 24, \quad (3.11)$$

$$I_m^{off,AI} + \Delta I \leq I_m^{on,AI}. \quad (3.12)$$

onde:

$I_{m,j,sc,s}^{trs,AI}$ valor de corrente de transição durante a hora j do cenário sc pertencente à amostra s [pu];

$I_m^{on,AI}$ valor de corrente para ligar o BC automático do tipo I^3 instalado no nó m [pu];

$I_m^{off,AI}$ valor de corrente para desligar o BC automático do tipo I instalado no nó m [pu];

$y_{m,j,sc,s}^{AI}$ variável de utilização binária que indica que o BC automático do tipo I instalado no nó m está ligado durante a hora j do cenário sc pertencente à amostra s ;

ΔI largura de banda de corrente [pu];

³O tipo está relacionado à potência nominal do BC, e depende das características do estudo de caso.

M número grande o suficiente para satisfazer os possíveis valores da corrente de transição, $I_{m,j,sc,s}^{\text{trs},AI}$.

De acordo com a estratégia de controle adotada, o chaveamento do BC ocorre quando a corrente de transição $I_{m,j,sc,s}^{\text{trs},AI}$ é maior que $I_m^{\text{on},AI}$, nas expressões (3.8)-(3.9). É importante ressaltar que o BC só irá ligar se for constatado que estava desligado na hora anterior ($y_{m,j-1,sc,s}^{AI} = 0$). Por outro lado, se a corrente $I_{m,j,sc,s}^{\text{trs},AI}$ é menor que o limite estabelecido por $I_m^{\text{off},AI}$ nas expressões (3.10)-(3.11), o BC será desligado apenas se constatado que estava ligado na hora anterior ($y_{m,j-1,sc,s}^{AI} = 1$). A expressão (3.12) define a zona morta de controle (ΔI), representada pela largura de banda de corrente entre $I_m^{\text{on},AI}$ e $I_m^{\text{off},AI}$.

Baseando-se na magnitude da corrente monitorada à justante do BC automático a corrente de transição do BC automático $I_{m,j,sc,s}^{\text{trs},AI}$ deve restringir-se à:

$$|f_{mn,j,sc,s}| - I_{m,j,sc,s}^{\text{trs},AI} \leq M y_{m,j,sc,s}^{AI}, \quad (3.13)$$

$$I_{m,j,sc,s}^{\text{trs},AI} - |f_{mn,j,sc,s}| \leq M (1 - y_{m,j,sc,s}^{AI}), \quad (3.14)$$

onde $|f_{mn,j,sc,s}|$ corresponde à magnitude de corrente monitorada no ramo mn durante a hora j do cenário sc pertencente à amostra s , a qual é expressa por:

$$|f_{mn,j,sc,s}| = \sqrt{\left(f_{mn,j,sc,s}^{\text{Re}}\right)^2 + \left(f_{mn,j,sc,s}^{\text{Im}}\right)^2}. \quad (3.15)$$

Para eliminar a não linearidade introduzida pela expressão (3.15), foi adotada uma linearização por partes utilizando um modelo de combinação convexa desagregada para obtenção do termo $|f_{mn,j,sc,s}|$.

Tendo em vista que a expressão (3.15) representa uma função bidimensional, propõe-se a aproximação linear por planos. Baseando-se em Camponogara, Almeida e Hardt Júnior (2015) e Soares (2017), essa abordagem consiste no uso de variáveis binárias para selecionar o plano que aproxima a função não linear em cada hora j do cenário sc pertencente à amostra s , permitindo o cálculo da magnitude da corrente por meio da combinação convexa dos vértices. Dessa maneira, o uso de variáveis binárias e restrições adicionais, que relacionam as variáveis contínuas do modelo com as variáveis binárias auxiliares, transformam o problema de otimização em um problema linear inteiro-misto.

Nesse contexto, propõe-se aproximar o módulo da corrente, representado pela variável

$|f_{mn,j,sc,s}|$, por uma formulação de PLIM, formalmente expressa por:

$$c^{\text{Re}}(v) = f^{\text{max}} \cos \left[\frac{2\pi}{n_\rho} (i-1) \right], \quad (3.16)$$

$$c^{\text{Im}}(v) = f^{\text{max}} \text{sen} \left[\frac{2\pi}{n_\rho} (i-1) \right], \quad (3.17)$$

$$c^f(v) = f^{\text{max}}, \quad (3.18)$$

$$\sum_{\rho \in \mathcal{P}} \sum_{v \in \mathcal{V}(\rho)} \alpha_{mn,j,sc,s}^{\rho v} c^{\text{Re}}(v) = f_{mn,j,sc,s}^{\text{Re}}, \quad (3.19)$$

$$\sum_{\rho \in \mathcal{P}} \sum_{v \in \mathcal{V}(\rho)} \alpha_{mn,j,sc,s}^{\rho v} c^{\text{Im}}(v) = f_{mn,j,sc,s}^{\text{Im}}, \quad (3.20)$$

$$\sum_{\rho \in \mathcal{P}} \sum_{v \in \mathcal{V}(\rho)} \alpha_{mn,j,sc,s}^{\rho v} c^f(v) = |f_{mn,j,sc,s}|, \quad (3.21)$$

$$\alpha_{mn,j,sc,s}^{\rho v} \geq 0, \quad \forall \rho \in \mathcal{P} = \{\rho_1, \dots, \rho_{n_\rho}\}, \quad \forall v \in \mathcal{V}(\rho) = \{v_0, v_\rho, v_{\rho+1}\}, \quad (3.22)$$

$$\sum_{v \in \mathcal{V}(\rho)} \alpha_{mn,j,sc,s}^{\rho v} = h_{mn,j,sc,s}^\rho, \quad \forall \rho \in \mathcal{P}, \quad (3.23)$$

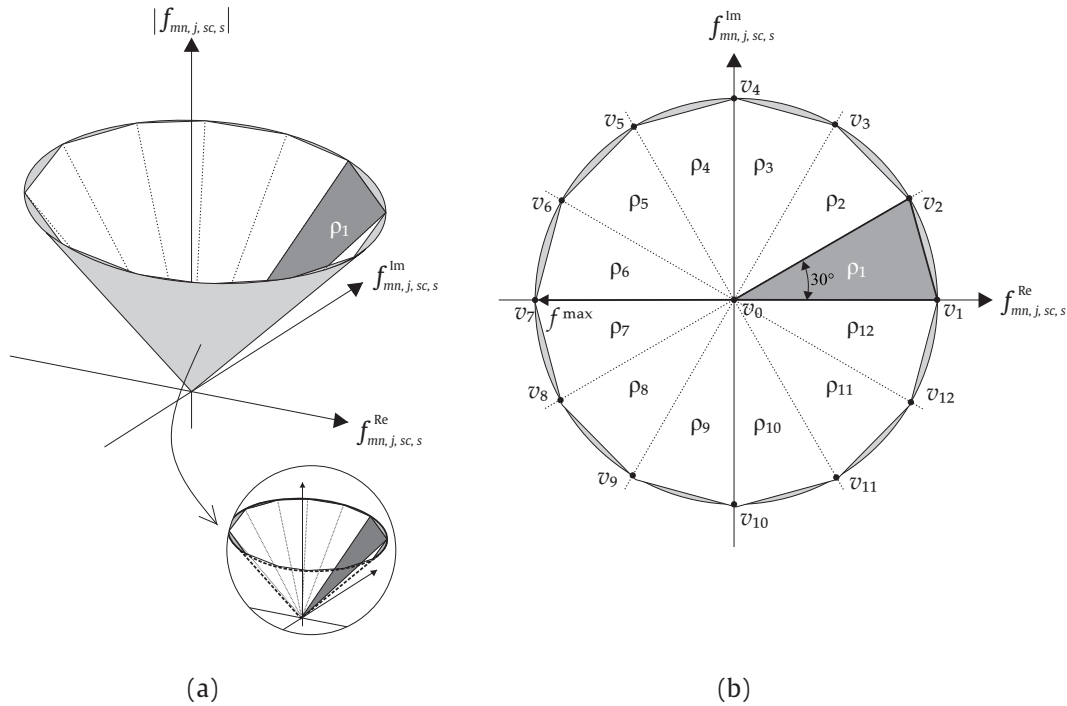
$$\sum_{\rho \in \mathcal{P}} h_{mn,j,sc,s}^\rho = 1, \quad (3.24)$$

onde:

$c^{\text{Re}}(v), c^{\text{Im}}(v), c^f(v)$	vértices do plano ρ [pu];
f^{max}	valor máximo que a variável pode assumir na linearização [pu];
n_ρ	número total de planos;
$\mathcal{V}(\rho)$	conjunto de vértices do plano ρ ;
\mathcal{P}	conjunto de n_ρ planos;
$f_{mn,j,sc,s}^{\text{Re}}, f_{mn,j,sc,s}^{\text{Im}}$	parcela real e imaginária da corrente do ramo mn durante a hora j do cenário sc pertencente à amostra s ;
$ f_{mn,j,sc,s} $	magnitude da corrente do ramo mn durante a hora j do cenário sc pertencente à amostra s (função a ser linearizada);
$\alpha_{mn,j,sc,s}^{\rho v}$	variáveis contínuas que parametrizam as combinações convexas dos vértices (há um conjunto delas, igual ao número de vértices, para cada plano);
$h_{mn,j,sc,s}^\rho$	variável de utilização binária que ativa ou não os planos (número dessas variáveis é igual ao número de planos).

O modelo definido nas expressões (3.16)–(3.24) pode ser detalhado por meio de um exemplo ilustrado pela Figura 11, no qual a magnitude da corrente é representada por um caso bidimensional de uma linearização por partes, subdivida em 12 planos ($n_\rho = 12$), com 3 vértices por plano.

Figura 11 – Exemplo da aproximação linear por partes proposta: (a) visualização em três dimensões do modelo de combinação convexa; (b) visualização em duas dimensões dos planos adotados.



Fonte: Elaborado pela autora (2020).

Os termos $c^{\text{Re}}(v)$, $c^{\text{Im}}(v)$ e $c^f(v)$ das expressões (3.16)–(3.18) são os vértices de cada plano usado na linearização e f^{max} representa o maior valor possível para a variável cujo valor absoluto se deseja aproximar.

De maneira a limitar a combinação convexa a apenas um plano, as expressões (3.23)–(3.24) representam restrições que ativam o plano ρ em cada hora j do cenário sc pertencente à amostra s , com o auxílio de variáveis binárias $h_{mn,j,sc,s}^\rho \in \{0, 1\}$, $\forall \rho \in \mathcal{P}$. Por exemplo, considerando que o plano ρ_1 é ativado ($h_{mn,j,sc,s}^{\rho_1} = 1$), então $\alpha_{mn,j,sc,s}^{\rho_1 v}$ assume valores dentro do intervalo de $[0, 1]$, visando parametrizar a combinação convexa dos vértices. Observa-se que $\alpha_{mn,j,sc,s}^{\rho v}$ dos demais planos (ρ_2 to ρ_{12}) são cancelados, uma vez que $h_{mn,j,sc,s}^\rho = 0$, $\forall \rho = \{2, \dots, 12\}$. Já as expressões (3.19)–(3.22) representam os pesos dos vértices do plano ativo, previamente calculados por meio das expressões (3.16)–(3.18).

O procedimento descrito pode ser usado para limitar a combinação convexa de apenas um plano para cada hora j do cenário sc pertencente à amostra s , onde o número total de planos a ser adotado depende do esforço computacional, associado ao espaço de busca das variáveis binárias, bem como o erro admitido no processo de linearização. Além disso, $f_{mn,j,sc,s}^{\text{Re}}$ e $f_{mn,j,sc,s}^{\text{Im}}$ são variáveis independentes da função a ser linearizada, e o termo $|f_{mn,j,sc,s}|$ representa a magnitude da corrente a jusante do CB automático, a qual é usada

no controle de corrente, previamente detalhado com as expressões (3.13)–(3.14).

Por fim, o modelo proposto inclui a limitação de manobras diárias dos BCs, formulado por:

$$w_{m,j,sc,s}^{AI} \geq y_{m,j,sc,s}^{AI} - y_{m,j-1,sc,s}^{AI}, \quad (3.25)$$

$$w_{m,j,sc,s}^{AI} \geq y_{m,j-1,sc,s}^{AI} - y_{m,j,sc,s}^{AI}, \quad (3.26)$$

$$W_{m,sc,s}^{\max,AI} \geq \sum_{j=2}^{24} w_{m,j,sc,s}^{AI}, \quad (3.27)$$

onde:

$w_{m,j,sc,s}^{AI}$ variável de utilização binária que indica manobra do BC automático do tipo *I* instalado no nó *m*; quando $w_{m,j,sc,s}^{AI} = 1$ o controle liga ou desliga o BC na hora *j* do cenário *sc* pertencente à amostra *s*;

$W_{m,sc,s}^{\max,AI}$ limite de manobras do BC automático do tipo *I* para o cenário *sc* pertencente à amostra *s*.

A partir das expressões (3.25)–(3.26) o modelo representa a manobra do BC automático, ou seja, sempre que o BC mudar de posição, $w_{m,j,sc,s}^{AI} = 1$. Para limitar a quantidade de manobras, quando o controle exigir que o BC esteja ligado na hora *j* do cenário *sc* pertencente à amostra *s*, por exemplo, o modelo vai verificar se o BC estava desligado na hora anterior, ou seja, se $y_{m,j-1,sc,s}^{AI} = 0$. Em caso afirmativo, o modelo interpretará a necessidade de um chaveamento, e vai verificar se ainda é possível manobrar o BC, de acordo com o limite imposto pela expressão (3.27). O mesmo procedimento ocorre quando o BC estava ligado e necessita desligar. Caso o BC permaneça na mesma posição da hora anterior, $w_{m,j,sc,s}^{AI} = 0$.

3.3.4 Restrições para Controle volt-var com Reguladores de Tensão

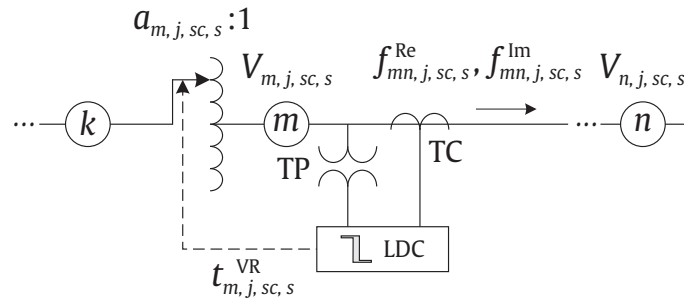
O modelo de otimização para operação ótima de RTs segue a mesma filosofia do controle volt-var com bancos de capacitores, uma vez que determina uma regra única, válida para todos os cenários, para definir o modo de operação dos RTs. No caso dos BCs automáticos, o modelo de otimização define o controle de corrente, já para os RTs, o modelo inclui a possibilidade de definir o controle com compensação por queda de tensão na linha (do inglês, *Line Drop Compensation* - LDC). Nesse sentido, as principais contribuições do controle de RTs em relação ao modelo proposto por Resener *et al.* (2019a) são:

- (i) proposição de controle do nível de tensão utilizando RTs com compensação por queda de tensão na linha;
- (ii) otimização da faixa de operação do RT, considerando a tensão de referência do RT como uma variável contínua e não mais como um parâmetro fixo;

- (iii) formulação para determinar a zona ótima de regulação dos RTs baseada nos limites operacionais do controlador;
- (iv) ampliação da zona de regulação do RT, permitindo a saturação do controle e a operação dos taps em condições operacionais específicas.

Conforme detalhado no Apêndice 6, os reguladores de tensão são autotransformadores com ajuste automático de tap sob carga. Logo, para garantir que o tap do regulador se altere dependendo da queda de tensão na linha, o modelo proposto considera que o RT seja controlado por um LDC. Por meio de um transformador de potencial e um transformador de corrente, o controlador LDC é conectado à rede, conforme ilustra a Figura 12. Desta forma, o LDC estima a tensão no nó n durante a hora j do cenário sc pertencente à amostra s , e opera o tap do RT ($t_{m,j,sc,s}^{RT}$), regulando a tensão quando a carga varia, conforme o fluxo de corrente a jusante do RT ($f_{mn,j,sc,s}^{Re}$, $f_{mn,j,sc,s}^{Im}$).

Figura 12 – Circuito simplificado que representa a operação do tap de um RT com compensação por queda de tensão na linha.



Fonte: Elaborado pela autora (2020).

Os RTs contêm uma chave inversora, o que permite regular a tensão usualmente $\pm 10\%$ em 32 passos mais a posição neutra. Para este intervalo de regulação o passo equivale a $0,625\%$ de variação de tensão, sendo a relação de transformação definida por:

$$a_{m,j,sc,s} = 1 - 0,00625 t_{m,j,sc,s}^{RT}, \quad (3.28)$$

onde:

$a_{m,j,sc,s}$ relação de transformação do RT, instalado no nó m , durante a hora j do cenário sc pertencente à amostra s ;

$t_{m,j,sc,s}^{RT}$ variável inteira que representa a posição do tap do RT, instalado no nó m , durante a hora j do cenário sc pertencente à amostra s .

A relação de transformação dada pela expressão (3.28) é calculada para RTs do tipo B (KERSTING, 2001), onde o circuito primário está conectado ao enrolamento série do regulador, sendo este conectado ao enrolamento paralelo, que por sua vez conecta-se ao

circuito regulado. Este tipo de RT caracteriza-se por uma excitação constante, dado que o enrolamento de excitação localiza-se no lado da carga, não sofrendo variações de tensão da fonte.

Já a posição do tap do RT instalado no nó m é representada por uma variável inteira, e é calculada conforme a seguinte expressão:

$$t_{m,j,sc,s}^{\text{RT}} = \sum_{i=1}^6 2^{(i-1)} r_{i,m,j,sc,s} - 16, \quad (3.29)$$

onde:

$r_{i,m,j,sc,s}$ variável binária relacionada com a restrição $\sum_{i=1}^6 2^{(i-1)} r_{i,m,j,sc,s} \leq 32$.

Observa-se que a variável $t_{m,j,sc,s}^{\text{RT}}$ é ajustada dentro do intervalo $[-16, 16]$, conforme ilustra a Figura 13 (a), e $a_{m,j,sc,s}$ varia dentro do intervalo $[(1 - 10\%), (1 + 10\%)]$ com passos discretos de 0,00625 pu (0,625%). Desta maneira, a tensão de referência do RT ($V_m^{\text{set,RT}}$), definida como a tensão que deve ser mantida pelo RT em um nó remoto, é ajustada dentro da faixa de regulação de $\pm 10\%$. A partir da tensão de referência é ajustada a insensibilidade ou largura de faixa, β , que determina a faixa de precisão da qual o RT entende que não há necessidade de comutação do tap.

Nesse sentido, a excursão da tensão de regulação ($V_{n,j,sc,s}$) em relação à tensão de referência $V_m^{\text{set,RT}}$ ($\forall m \in \psi^{\text{RT}}$) é dada por:

$$V_m^{\text{set,RT}} - \beta \leq V_{n,j,sc,s} \leq V_m^{\text{set,RT}} + \beta, \quad (3.30)$$

onde:

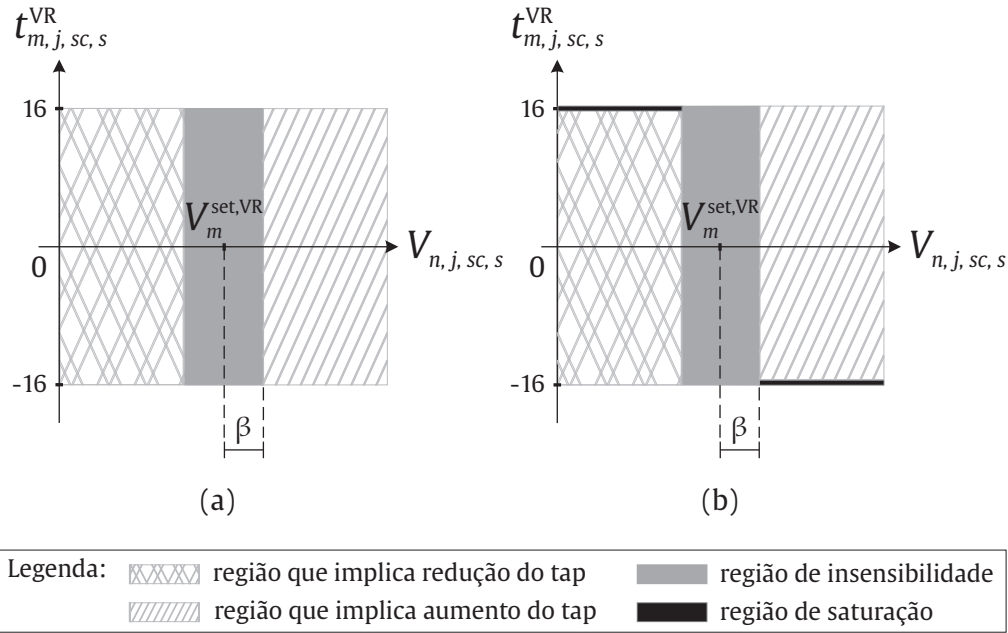
$V_m^{\text{set,RT}}$ variável contínua que representa o ajuste ótimo da tensão de referência do RT instalado no nó m [pu];

β insensibilidade do RT [pu];

$V_{n,j,sc,s}$ tensão no nó remoto n durante a hora j do cenário sc pertencente à amostra s [pu].

A expressão (3.30) resulta no ajuste ótimo da faixa de operação do RT. No entanto, se adotado o intervalo $\pm 10\%$, conforme proposto por Resener *et al.* (2019a), pode não ser possível regular a tensão para todas as horas j e cenários sc pertencentes à amostra s , limitando a operação do RT. Nessa situação, o controle do RT atinge a saturação (-10% ou $+10\%$), impossibilitando impor uma tensão de referência ($V_m^{\text{set,RT}}$), e o RT irá operar no limite atingido durante esse período (-10% ou $+10\%$), sem regular a tensão. Como resultado, duas situações podem ocorrer: (i) a primeira, e mais comum, ocorre quando o sistema está sobrecarregado e o RT necessita alterar a tensão secundária para manter o nó regulado na tensão desejada; (ii) a segunda situação ocorre quando é necessário que o

Figura 13 – Controle da operação do tap do RT: (a) abordagem sem saturação do controle; (b) abordagem proposta considerando região de saturação.



Fonte: Elaborado pela autora (2020).

RT reduza a tensão secundária, para manter o nó regulado na tensão desejada. As duas situações requerem alterações na abordagem tradicional de controle da operação do taps, a qual é ilustrada pela Figura 13 (a).

Nesse contexto, propõe-se o equacionamento para permitir que o RT otimize a faixa de operação mesmo quando existe limitação na atuação do seu controle, conforme ilustra a Figura 13 (b). A primeira situação é representada pela inclusão de um termo no lado direito da expressão (3.30):

$$V_{n,j,sc,s} - (V_m^{\text{set,RT}} - \beta) \geq -Mr_{6,m,j,sc,s}. \quad (3.31)$$

Desta forma, quando o RT estiver operando no tap máximo (+16), a restrição que força a tensão no nó regulado ser maior que a tensão de referência é relaxada. Vale salientar que o único modo de operação que possui a variável $r_{6,m,j,sc,s} = 1$ é o tap máximo, para todos os demais taps $r_{6,m,j,sc,s} = 0$. Adicionalmente, a segunda situação implica:

$$V_{n,j,sc,s} - (V_m^{\text{set,RT}} + \beta) \leq M(1 - rr_{m,j,sc,s}), \quad (3.32)$$

sendo $rr_{m,j,sc,s}$ uma variável de utilização binária que assume valor zero apenas quando o RT opera no tap mínimo (-16), ou seja, apenas quando todas as variáveis $r_{i,m,j,sc,s}$ são nulas para uma determinada hora j de um cenário sc pertencente à amostra s . A variável

$rr_{m,j,sc,s}$, por sua vez, é dada por:

$$0 \leq rr_{m,j,sc,s} \leq 1, \quad (3.33)$$

$$rr_{m,j,sc,s} \leq \sum_{i=1}^6 r_{i,m,j,sc,s}, \quad (3.34)$$

$$rr_{m,j,sc,s} \geq r_{i,m,j,sc,s}, \quad \forall i = \{1, 2, \dots, 6\}. \quad (3.35)$$

A formulação expressa por (3.31)–(3.35) permite solucionar o modelo de PLIM proposto para o controle volt-var com RTs, considerando a situação do controle; o que torna possível também a operação dos taps e solução do problema de otimização. Além disso, os resultados numéricos abordados posteriormente no Capítulo 4 tornarão mais claro não apenas o impacto, mas também o funcionamento do controle do RT com saturação (ver Figura 22).

3.4 Cálculo das Incertezas

A abordagem proposta neste trabalho visa avaliar a operação de sistemas de distribuição considerando as incertezas das cargas e dos REDs. Por meio do algoritmo *K-means clustering* é possível identificar as similaridades no comportamento de diferentes cargas e REDs, agrupar os dados e modelar cenários de operação cronológica do SDEE. No entanto, a fase de inicialização desse algoritmo é geralmente realizada de forma aleatória, implicando diferentes centroides para cada *cluster*, o que gera incertezas na estimativa do custo de operação de SDEE.

Define-se incerteza como um parâmetro, associado à melhor estimativa do mensurando (grandeza de saída), que caracteriza a dispersão dos valores que podem ser razoavelmente atribuídos a esse mensurando. A melhor estimativa disponível do valor esperado de uma grandeza que varia aleatoriamente é, na maioria dos casos, a média aritmética de n_s amostras independentes ($\forall s \in \psi^S$), dada por:

$$\overline{\Delta T}_{sc} = \frac{1}{n_s} \sum_{s=1}^{n_s} \Delta T_{sc,s}, \quad (3.36)$$

$$\overline{C}_{sc}^{\text{oper}} = \frac{1}{n_s} \sum_{s=1}^{n_s} C_{sc,s}^{\text{oper}}, \quad (3.37)$$

onde:

$\overline{\Delta T}_{sc}$ valor médio da duração do cenário sc [dias/ano];

$\overline{C}_{sc}^{\text{oper}}$ valor médio do custo de operação do cenário sc [\$/dia];

n_s número de amostras.

Deste modo, a média aritmética das grandezas de entrada, $\overline{\Delta T}_{sc}$ e $\overline{C}_{sc}^{\text{oper}}$, obtidas pelas expressões (3.36)-(3.37), são utilizadas para determinar a estimativa da grandeza de saída,

conforme a equação:

$$\bar{C}^{\text{oper}} = \sum_{sc \in \Psi_s^K} \bar{\Delta T}_{sc} \bar{C}_{sc}^{\text{oper}}, \quad (3.38)$$

onde:

\bar{C}^{oper} valor médio do custo de operação anual [\$/ano].

No presente trabalho, propõe-se avaliar a incerteza das seguintes grandezas de saída: 1) custo de operação anual (\$); 2) perdas de energia (MWh); e 3) violações dos limites de tensão (pu). Para isso, de forma análoga à expressão (3.38), as estimativas de perdas ativas e violações dos limites de tensão, considerando n_s amostras, são expressas por:

$$\bar{e}^{\text{loss}} = S_{base} \sum_{sc \in \Psi_s^K} \bar{\Delta T}_{sc} \bar{p}_{sc}^{\text{loss}}, \quad (3.39)$$

$$\bar{z} = \sum_{sc \in \Psi_s^K} \bar{\Delta T}_{sc} \bar{z}_{sc}, \quad (3.40)$$

onde:

\bar{e}^{loss} valor médio das perdas de energia anuais [MWh/ano];

\bar{z} valor médio das violações anuais dos limites de tensão [pu/ano];

$\bar{p}_{sc}^{\text{loss}}$ valor médio das perdas ativas diárias do cenário sc [MWh/dia];

\bar{z}_{sc} valor médio das violação diárias dos limites de tensão do cenário sc [pu/dia].

A relação de cada grandeza de saída com as variáveis de entrada é dada pelas funções de medições expressas por (3.38)–(3.40) e serve de base para a formulação do cálculo das incertezas de operação de um SDEE. No presente trabalho, o procedimento adotado para avaliação e expressão das incertezas baseia-se no Guia desenvolvido pelo Grupo de Trabalho 1 do Comitê Conjunto para Guias em Metrologia (GUM, 2008, p. 27-28), conforme detalhado na Seção 2.3.

A Tabela 5 apresenta um resumo da formulação, especificando as variáveis de entrada, a função de medição e as grandezas de saída do PLIM, bem como a incerteza associada a cada etapa do procedimento adotado.

Por fim, cabe ressaltar que os aspectos apresentados na Tabela 5 são utilizados na estimativa e avaliação das incertezas, conforme a formulação apresentada na Seção 2.3.1.

3.5 Considerações Finais

Neste capítulo, foram apresentados os modelos de otimização para os problemas de operação ótima de BCs e RTs em SDEE. Embora os modelos tenham sido apresentados separadamente, podem ser utilizados em conjunto de forma a obter uma solução que

Tabela 5 – Resumo dos aspectos que envolvem a avaliação e a expressão das incertezas.

Mensurando	Formulação		
	Variáveis de Entrada [x]	Função de medição [Y = f(x)]	Grandeza de Saída [Y]
Custos de operação	$\overline{\Delta T}_{sc}, \overline{C}_{sc}^{oper}$	(3.38)	\overline{C}^{oper}
Perdas ativas	$\overline{\Delta T}_{sc}, \overline{p}_{sc}^{loss}$	(3.39)	\overline{e}^{loss}
Violação dos limites de tensão	$\overline{\Delta T}_{sc}, \overline{z}_{sc}$	(3.40)	\overline{z}
Mensurando	Tipo de Incerteza		
	Padrão Tipo A [u _A ^x]	Padrão Combinada [u _c ^y]	Expandida [U ^y]
Custos de operação	$\overline{\Delta T}_{sc} \pm u_A^{\Delta T_{sc}}$ $\overline{C}_{sc}^{oper} \pm u_A^{\overline{C}_{sc}^{oper}}$	$\overline{C}^{oper} \pm u_c^{\overline{C}^{oper}}$	$\overline{C}^{oper} \pm U^{\overline{C}^{oper}}$
Perdas ativas	$\overline{\Delta T}_{sc} \pm u_A^{\Delta T_{sc}}$ $\overline{p}_{sc}^{loss} \pm u_A^{\overline{p}_{sc}^{loss}}$	$\overline{e}^{loss} \pm u_c^{\overline{e}^{loss}}$	$\overline{e}^{loss} \pm U^{\overline{e}^{loss}}$
Violação dos limites de tensão	$\overline{\Delta T}_{sc} \pm u_A^{\Delta T_{sc}}$ $\overline{z}_{sc} \pm u_A^{\overline{z}_{sc}}$	$\overline{z} \pm u_c^{\overline{z}}$	$\overline{z} \pm U^{\overline{z}}$

considere simultaneamente as duas estratégias de controle volt-var. Além disso, foi apresentada a modelagem da cronologia de operação da carga e REDs, a qual permite calcular as incertezas de operação de SDEE.

A estratégia adotada para solução do problema de planejamento da operação de SDEE, assim como os estudos de casos utilizados para validação do PLIM proposto e os exemplos de aplicação, são apresentados no próximo capítulo.

4 ESTUDOS DE CASO E RESULTADOS

As simulações e análises, descritas neste capítulo, visam validar e demonstrar a flexibilidade do modelo de otimização descrito no Capítulo 3. Antes de apresentar os resultados dos testes, será realizada uma descrição detalhada da estratégia de solução proposta para o modelo de otimização que foi desenvolvida neste trabalho.

4.1 Estratégia de Solução do Problema Proposto

O modelo linearizado proposto para problemas de planejamento da operação de sistemas de distribuição considerando incertezas envolve diversas etapas, uma vez que diferentes métodos são utilizados para obtenção da solução final. Nesse sentido, a Figura 14 ilustra um fluxograma com as principais etapas e métodos envolvidos na estratégia de solução que foi adotada no presente trabalho.

Na *etapa 1* da Figura 14 consta a definição do escopo do planejamento da operação de SDEE, que consiste na descrição dos dados do sistema teste escolhido, tais como: informações sobre condutores, características dos equipamentos existentes (BCs, RTs e/ou REDs) e características das cargas instaladas. Em relação à especificação dos equipamentos, foram considerados: (i) bancos de capacitores fixos e automáticos, com potência nominal de 600 e 1200 kvar; (ii) reguladores de tensão com compensação por queda de tensão na linha (LDC), capacidade de corrente igual a 400 A e insensibilidade de 1% ($\beta = 0,01$ pu); e (iii) recurso energético distribuído, proveniente de fontes intermitentes de energia (eólica e solar), com capacidade instalada de 1 MW e fator de potência unitário.

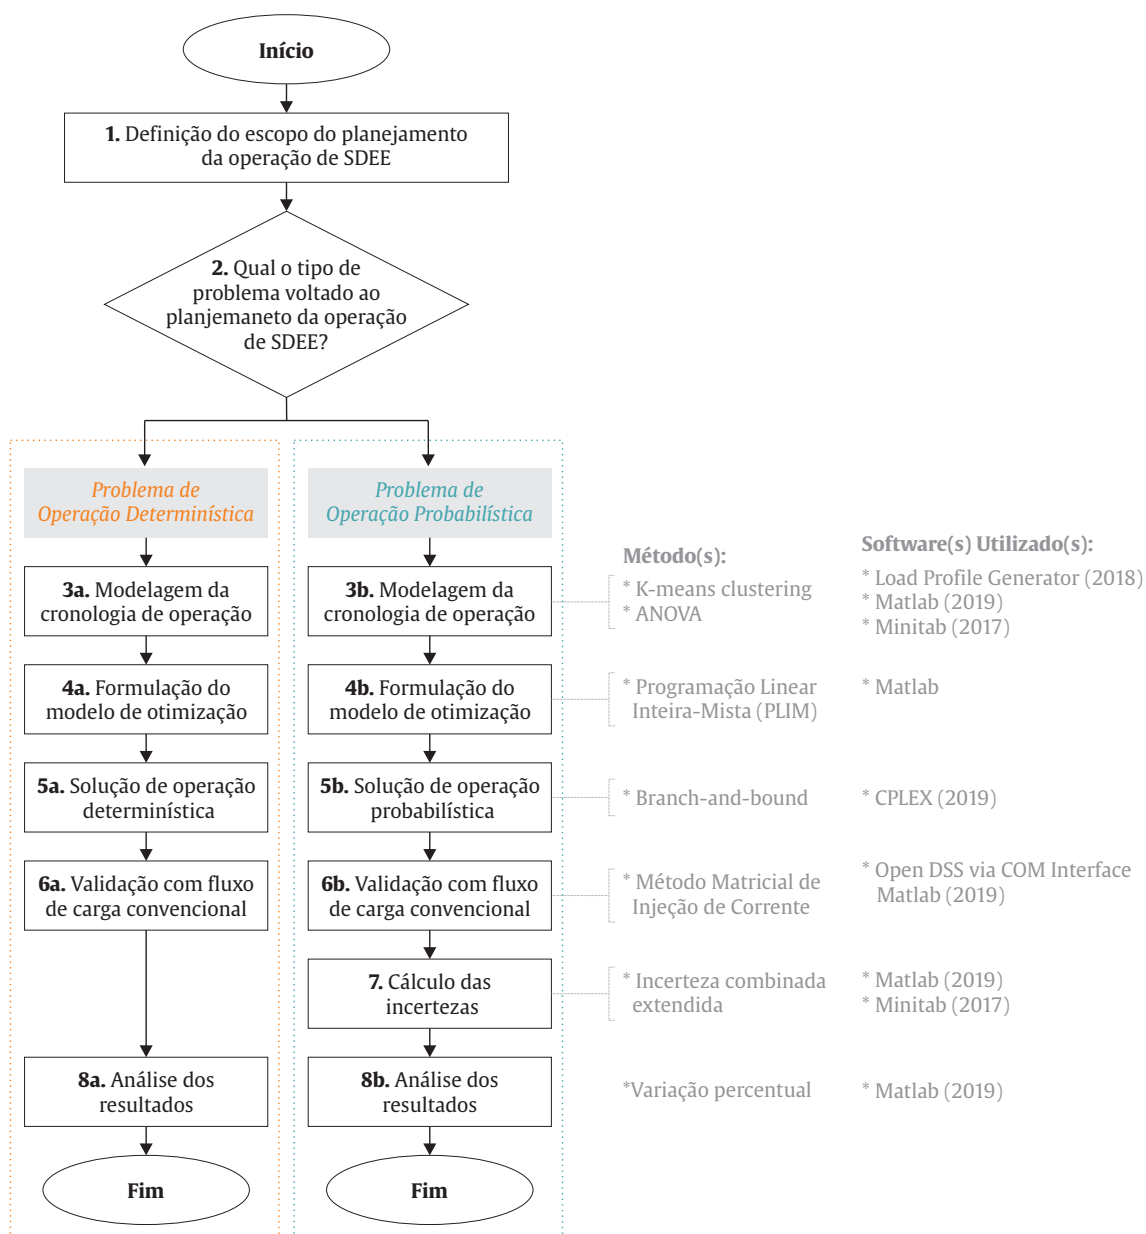
No fluxograma ilustrado pela Figura 14, duas possibilidades para o problema do planejamento da operação de SDEE são contempladas: uma abordagem com resultado determinístico e outra com resultado probabilístico. Deste modo, na *etapa 2* consta a definição da abordagem, de acordo com os dados disponíveis e o tipo de abordagem escolhida pelo planejador.

As *etapas 3a* e *3b* da Figura 14 consistem na modelagem da cronologia de operação a partir da seleção de cenários típicos por meio do método *K-means clustering*. Para obtenção sintética de dados históricos anuais de curvas de carga foi utilizado o *software Load*

Profile Generator (PFLUGRADT, 2018), o qual simula perfis residenciais de consumo de energia elétrica. Este procedimento foi descrito na Seção 3.2 e será exemplificado na Seção 4.2.3.

Em relação à operação considerando incertezas (probabilística), por meio da análise de variâncias (ANOVA) foi possível verificar o impacto do número de cenários (K) no custo de operação do SDEE e calcular o número adequado de amostras (n_s), o qual permite o cálculo das incertezas. Desempenhado na *etapa 3b*, o algoritmo proposto para análise de variâncias (ANOVA) consta detalhado na Seção 2.2.3 e será exemplificado no Seção 4.2.5.1.

Figura 14 – Abordagem proposta para solução do modelo de planejamento da operação de sistemas de distribuição.



Fonte: Elaborado pela autora (2020).

As etapas 4a e 4b consistem na formulação do modelo de otimização, definido pelas expressões (3.2)-(3.35). O PLIM foi descrito na linguagem de programação OPL (do inglês, *Optimization Programming Language*) (VAN HENTENRYCK, 1999), com o auxílio do software MATLAB (MATHWORKS, 2019).

Nas etapas 5a e 5b o PLIM foi resolvido por intermédio do método de *branch-and-bound* com o auxílio do *solver* CPLEX (IBM, 2019), empregando suas opções padrão (exceto quando especificado o contrário). Um computador com processador Intel Core i5-3337U CPU @ 1.80 GHz, 8 GB RAM, e sistema operacional Windows 10 Pro 64-bits foi utilizado nos estudos de casos. Nesta etapa, são obtidos o custo de operação anual do SDEE, as perdas ativas, a violação dos limites de tensão, as correntes liga/desliga dos BCs automáticos (quando aplicável) e a tensão de ajuste do RT (quando aplicável).

Nas etapas 6a e 6b, o ponto de operação em regime permanente obtido com o PLIM, considerando a estratégia de controle volt-var (definida na etapa 1) foi validado com os resultados de um fluxo de carga (FC) convencional. Para isso, as variáveis de controle volt-var que foram calculadas no PLIM – como corrente liga/desliga dos BCs automáticos e a tensão de ajuste do RT (quando aplicáveis) – foram definidas como parâmetros de entrada do FC. A partir do método matricial de injeção de corrente, o fluxo de carga foi modelado e executado com o auxílio do software OpenDSS (DUGAN, 2018). Para solução foi utilizado um servidor COM (do inglês, *Component Object Model*), implementado a partir da DLL (do inglês, *Dynamic-link library*) e controlado via MATLAB. No fluxo de carga convencional, foi adotada a representação usual de SDEE, na qual BCs são modelados como 100% impedância constante, as cargas como 50% potência constante e 50% impedância constante, e as REDs como injeção de 100% potência ativa constante (RESENER, 2016).

Na etapa 7 foram calculadas as incertezas de operação do SDEE, de maneira a obter o intervalo de confiança dos principais resultados do PLIM. Essa etapa foi formalmente apresentada na Seção 3.4 e será exemplificada na Seção 4.2.5.2.

Por fim, as etapas 8a e 8b consistem na análise do desempenho do PLIM proposto, considerando todos os resultados obtidos nas etapas anteriores.

4.2 Validação do Modelo Proposto


O modelo linearizado proposto para problemas de planejamento da operação de SDEE foi validado para um sistema de 23 nós (HAFFNER *et al.*, 2008), por meio de oito casos que contemplam diferentes estratégias de controle volt-var. É oportuno destacar que esse sistema, embora de pequeno porte, tem características que tornam sua operação bastante

complexa¹. A seguir, consta o descritivo do sistema e dos casos estudados, bem como o detalhamento da cronologia de operação, juntamente com os resultados da operação determinística e probabilística considerando incertezas.

4.2.1 Descrição do Sistema de 23 Nós

O sistema utilizado para validação do modelo consiste em um alimentador trifásico composto por 23 nós e 22 ramos, o qual opera com tensão nominal de 13,8 kV e 60 Hz. Todos os nós, exceto o nó 1, possuem uma carga trifásica, cujo valor nominal é de 189 kW e 124 kvar, totalizando 4158 kW e 2728 kvar. Os ramos são constituídos por segmentos de 2 km de condutores, com características de impedância e limite de corrente, descritas na Figura 15.

Figura 15 – Sistema de 23 nós.



Fonte: Adaptado de Resener (2016).

4.2.2 Descrição dos Estudos de Casos

O modelo proposto abrange diferentes estratégias de controle volt-var, considerando ou não a presença de REDs, na qual a operação ótima de BCs e RTs pode ser resolvida de forma independente ou integrada no mesmo estudo de caso, resultando nas seguintes combinações:

1. *Caso Base*: operação do sistema sem nenhum equipamento (BC, RT e RED) instalado;
2. *Caso BC*: operação ótima do sistema considerando somente a existência de BCs;
3. *Caso RT*: operação ótima do sistema considerando somente a existência de RT com compensação por queda de tensão na linha;

¹Apresenta um nível elevado de carregamento e a carga ativa e reativa está distribuída em todos os nós da rede. Isto faz com que sejam observados níveis de tensão muito abaixo do nominal e ocorram perdas elevadas. Além disto, a diferença nos valores horários das injeções de cada nó, tende a fazer com que a solução que resolve uma situação de carga leve (como nos horários da madrugada) seja impraticável quando a carga assume valores mais elevados.

4. *Caso BC + RT*: operação ótima do sistema considerando a existência de BCs e RT com compensação por queda de tensão na linha²;
5. *Caso Base + RED*: operação do sistema considerando somente a existência de RED;
6. *Caso BC + RED*: operação ótima do sistema considerando a existência de BCs e RED;
7. *Caso RT + RED*: operação ótima do sistema considerando a existência de RT com compensação por queda de tensão na linha e RED;
8. *Caso BC + RT + RED*: operação ótima do sistema considerando a existência de BCs, RT com compensação por queda de tensão na linha e RED.

Em relação à localização dos equipamentos existentes (BC, RT e RED), tendo em vista que o modelo resolve problemas de planejamento da operação de SDEE, a alocação foi baseada em um estudo prévio de planejamento da expansão do sistema de 23 nós, proposto por Resener *et al.* (2019b). A Tabela 6 apresenta um resumo dos equipamentos existentes no sistema de 23 nós em cada caso estudado.

Em todos os casos, a tensão do nó da subestação foi fixada em 1,02 pu, e os nós com carga variam a tensão entre 0,975 e 1,05 pu, sem penalidade por violação. Para mensurar o custo das perdas, expresso por (3.3), o custo da energia (C^{kWh}) adotado foi de 0,11 \$/kWh. No cálculo da penalidade das violações dos limites de tensão, expresso por (3.4), foi considerado um fator de penalidade linear (CV) igual a 10 \$/hora, suficiente para inibir violações sensíveis nos limites da tensão. Tais valores foram adotados conforme o estudo prévio de planejamento da expansão, proposto por Resener *et al.* (2019b), visando manter a coerência com as características adotadas dos equipamentos existentes no sistema de 23 nós. Por fim, o horizonte de planejamento da operação considerado foi de 1 ano.

²É oportuno destacar que um RT com LDC pode também operar como RT regulando a tensão terminal, desabilitando a função LDC. Para isso, o nó remoto n na expressão (3.30), será igual ao nó terminal m , ou seja, $V_{n=m,j,sc,s}$.

Tabela 6 – Equipamentos existentes no sistema de 23 nós em cada caso.

Caso	Especificações dos Equipamentos Existentes						
	BC			RT		black	
	Nó	Tipo	Potência Nominal	Nó	Capacidade de Corrente	Nó	Potência Nominal
Base	–	–	–	–	–	–	–
BC	8	A1200	0 ou 1200 kvar	–	–	–	–
	9	F600	600 kvar				
	16	F600	600 kvar				
	21	A600	0 ou 600 kvar				
RT	–	–	–	5	400 A	–	–
BC + RT	8	F600	600 kvar	5	400 A	–	–
	16	F600	600 kvar				
	21	A600	0 ou 600 kvar				
Caso Base + RED	–	–	–	–	–	14	1 MW
BC + RED	8	A1200	0 ou 1200 kvar	–	–	14	1MW
	9	F600	600 kvar				
	16	F600	600 kvar				
	21	A600	0 ou 600 kvar				
RT + RED	–	–	–	5	400 A	14	1 MW
BC + RT + RED	8	F600	600 kvar	5	400 A	14	1MW
	16	F600	600 kvar				
	21	A600	0 ou 600 kvar				

4.2.3 Resultados de Cronologia de Operação

As concessionárias de energia elétrica utilizam com frequência a curva de duração para estudos de planejamento de SDEE. Desta forma, a avaliação da operação do sistema de 23 nós baseia-se, originalmente, em uma curva de duração de carga, a qual inclui três níveis de carregamento representados por: 6 horas diárias com 100% do valor nominal (carga pesada); 10 horas diárias com 70% do valor nominal (carga média); 8 horas diárias com 30% do valor nominal (carga leve), mantendo o fator de potência constante. No entanto, esses níveis de carregamento são atribuídos igualmente a todas as cargas do sistema, desconsiderando as particularidades de operação de cada carga.

Visando preservar a simultaneidade e combinação cronológica de diferentes cargas e REDs, incluindo demandas ativa e reativa das cargas, foram adotados cenários típicos de operação agrupados por meio do algoritmo *K-means clustering* (conforme descrito na Seção 3.2). A seguir, consta o detalhamento da base de dados históricos e o procedimento de cálculo dos cenários para modelar a cronologia de operação do sistema de 23 nós.

4.2.3.1 *Dados Históricos*

Considerando que o sistema teste não possuía dados horários de demanda ativa e reativa das cargas e também não tinha informações sobre os valores gerados pelo RED, esses dados foram obtidos sinteticamente, para o período de um ano com resolução horária. Para obter as cargas, foi gerado o histórico de um ano de operação (8760 h) de 20 consumidores residenciais, com o auxílio do software *Load Profile Generator* (PFLUGRADT, 2018). Esses consumidores foram, então, combinados de forma aleatória em cada nó com carga, visando obter 365 curvas de carga agregadas para cada uma das 22 cargas instaladas no sistema em questão. A quantidade de consumidores incluída em cada nó foi definida de modo que a energia consumida pelo agregado das cargas fosse similar ao valor obtido pela curva de duração definida em Resener *et al.* (2019b).

Além disso, originalmente, o caso do sistema de 23 nós com geração distribuída apresenta uma unidade com capacidade de 1 MW, operando em potência nominal (1 pu). Levando isto em consideração, foram simuladas as curvas de geração (do RED instalado no nó 14), por meio da combinação de dois recursos energéticos, sendo eles: 500 kW provenientes de um sistema solar fotovoltaico, e 500 kW de um aerogerador. Os dados históricos foram sintetizados utilizando o repositório *Renewables Ninja* (PFENNINGER; STAFFELL, 2016; STAFFELL; PFENNINGER, 2016). No Apêndice 7 constam os dados de demanda e geração utilizados nas simulações.


Para o processamento dos dados anuais e obtenção dos cenários de operação, os dados históricos foram representados por meio de uma matriz com 365 linhas e 1080 colunas, considerando 24 horas de registro de demanda ativa (em kW) e reativa (em kvar) dos 22 nós com carga ($24 \times 2 \times 22 = 1056$ colunas) e 24h de injeção de potência ativa da RED, totalizando 1080 colunas. Com o objetivo de preservar a simultaneidade e cronologia da operação de diferentes cargas e REDs, o método de mineração de dados reduz o número de linhas da matriz (de 365 dias para K cenários que representam um dia de operação), mantendo o número de colunas (curvas de carga diária de todos os nós mais a curva de carga diária da geração). O número adotado de cenários e a validação dos *clusters* são detalhados a seguir.

4.2.3.2 *Cenários de Operação*

Tendo em vista que o número de cenários influencia no espaço de busca da solução ótima do problema de otimização proposto, é fundamental definir um critério de escolha que proporcione o menor esforço computacional com a maior precisão. Para isso, foi realizada a análise de sensibilidade em duas etapas, visando avaliar o erro do agrupamento em função do número de cenários, sendo elas:

Etapa 1. Análise de sensibilidade da entrada: a partir de inúmeras simulações do método *K-means clustering* foi possível avaliar precisão *versus* esforço computacional. Para isso, com o auxílio da função “kmeans” (MATHWORKS, 2019), a qual executa um algoritmo iterativo do *K-means clustering*, foi determinada a distância da soma dos quadrados (*SS*), para K variando de 1 a 365. A Figura 16 (a) apresenta a curva que relaciona a distância da soma dos quadrados, expressa por (2.2), e o número de cenários (variando de 1 à 365). Observa-se que à medida em que aumenta K , a precisão do agrupamento tende a melhorar, pois as diferenças entre *clusters* tendem a aumentar, e as diferenças das observações *intra-clusters* tendem a diminuir. O ponto de equilíbrio (dados *intra-clusters* mais homogêneos e *clusters* mais diferentes entre si), chamado critério de *elbow* (KODINARIYA; MAKWANA, 2013), define a quantidade mínima de cenários a ser adotada. Como o método calcula a distância das observações até o centro do agrupamento que ela pertence (distância média euclidiana), o ideal é que essa distância seja a menor viável, ou seja, uma quantidade de *clusters* em que a distância da soma dos quadrados, expressa por (2.2), seja a menor possível. Nesse contexto, os dados ilustrados na Figura 16 (b) demonstram que ao menos 2 cenários são necessários para representar a cronologia de operação do sistema de 23 nós. Todavia, a tomada de decisão acerca do número de cenários a ser adotado depende da análise de sensibilidade da saída, a seguir descrita.

Figura 16 – Avaliação da precisão dos cenários a partir da distância da soma dos quadrados (*SS*), considerando: (a) 1 a 365 cenários; (b) 1 a 5 cenários.



Fonte: Elaborado pela autora (2020).

Etapa 2. Análise de sensibilidade da saída: analisar a sensibilidade do erro de agrupamento em função do número de cenários não é suficiente, já que tal procedimento avalia apenas a precisão das curvas de carga adotadas (entrada), sem avaliar o impacto no custo de operação do SDEE (saída). Deste modo, foi avaliado o desempenho do sistema de 23 nós considerando $K = 1, 2, 3, 4, 5, 10, 100$, por meio de um estudo de fluxo de carga convencional (DUGAN, 2018). Os resultados listados na Tabela 7 demonstram que $K = 3$ e $K = 5$ são suficientes para representar o comportamento anual das cargas, já que a diferença percentual em relação ao comportamento da base histórica completa ($K = 365$) foi próxima à zero. Em relação ao desempenho do sistema, foi registrada uma variação em torno de 5% do custo de operação e das perdas ativas, sendo que a violação dos limites de tensão ficou próxima à zero (0,12%) quando adotado $K = 3$.

Tabela 7 – Resultados anuais de desempenho do sistema de 23 nós variando o número de cenários.

Número de Cenários (K)	Consumo de Energia		Custo de Operação	Perdas Ativas	Violação dos Limites de Tensão
	[MWh]	[Mvarh]	$[\times 10^3\$]$	[MWh]	[pu]
1	23266 (0,12%) ¹	16636 (-0,66%)	207,55 (-7,18%)	1334 (-9,21%)	0,6944 (-1,87%)
2	25269 (8,74%)	18215 (8,76%)	255,59 (14,31%)	1667 (13,46%)	0,7611 (7,54%)
3	23251 (0,06%)	16687 (-0,36%)	213,84 (-4,36%)	1388 (-5,50%)	0,7068 (-0,12%)
4	22977 (-1,13%)	16470 (-1,66%)	208,80 (-6,62%)	1356 (-7,69%)	0,6868 (-2,95%)
5	23250 (0,05%)	16695 (-0,31%)	214,98 (-3,85%)	1398 (-4,83%)	0,7310 (3,30%)
10	24143 (3,89%)	17424 (4,04%)	234,54 (4,90%)	1529 (4,10%)	0,7241 (2,32%)
100	23708 (2,02%)	17126 (2,26%)	230,59 (3,13%)	1513 (2,97%)	0,7372 (4,17%)
365	23238	16747	223,59	1469	0,7077

Nota:

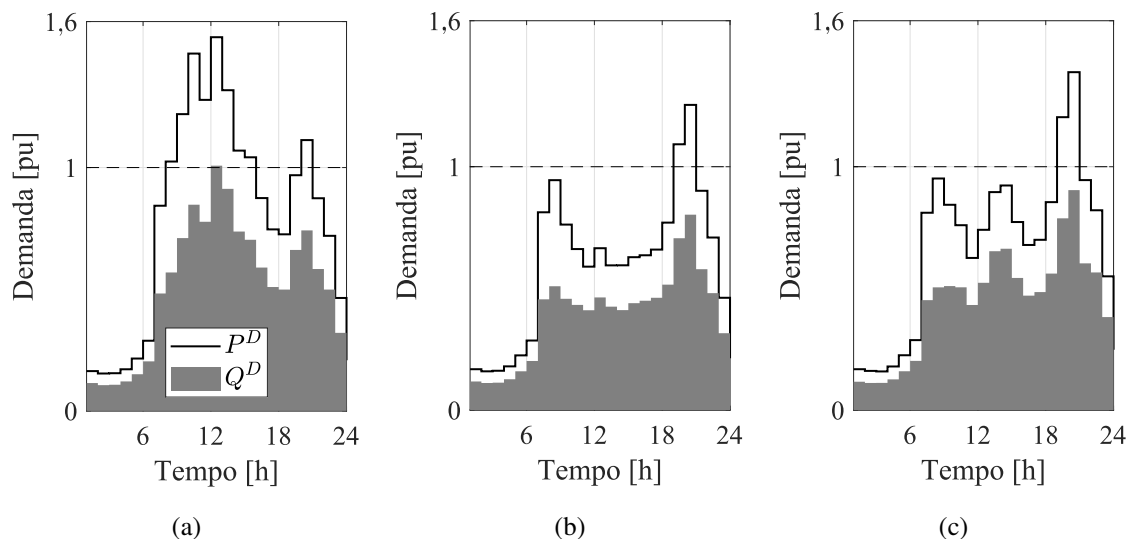
¹ Variação percentual resultante da comparação do resultado para $K = 365$.

Nesse contexto, foram adotados 3 cenários ($K = 3$) com duração conforme Tabela 8. A Figura 17 ilustra os perfis de demanda (ativa e reativa) agregada no nó 1 (subestação) do sistema de 23 nós, para cada um dos 3 cenários de operação adotados.

Tabela 8 – Duração de cada cenário adotado nos casos do sistema de 23 nós.

Cenário (sc)	Duração (ΔT_{sc}) [dias/ano]
1	147
2	110
3	108

Figura 17 – Curva de carga da demanda ativa (P^D) e reativa (Q^D), agregadas na subestação do sistema de 23 nós ($S_{base} = 4$ MVA) durante: (a) cenário 1; (b) cenário 2; e (c) cenário 3.




Fonte: Elaborado pela autora (2020).

Considerando que cada *cluster* agrupa uma parcela de dias do ano e que o centroide desse *cluster* representa um cenário de operação, é importante ressaltar que o método proposto gera combinações de pontos de operação mais realistas, uma vez que não negligencia a inerente simultaneidade de diferentes cargas. Logo, cada carga apresenta um comportamento diferente em cada hora e cenário.

Por exemplo, ao traçar o diagrama de caixa do vetor de demanda ativa ($\mathbf{P}_{j,sc}^D$) de todas as cargas ao longo das 24 horas do Cenário 1, obtém-se a Figura 18 (a). Observa-se que embora todas as 22 cargas apresentem o mesmo valor nominal (189 kW e 124 kvar), a demanda em cada cenário é diferente, caso contrário os diagramas das Figuras 18 (a)–(c)–(e) seriam idênticos. Analogamente, as Figuras 18 (b)–(d)–(f) ilustram os diagramas de caixa da demanda reativa das cargas ($\mathbf{Q}_{j,sc}^D$). De acordo com os diagramas ilustrados pela Figura 18, o Cenário 3 representou o *cluster* com maior variação horária de demanda ativa e reativa.


Figura 18 – Diagrama de caixa com variação horária das demandas ativas e reativas de todas as cargas instaladas no sistema de 23 nós, considerando: (a)–(b) dados do Cenário 1; (c)–(d) dados do Cenário 2; e (e)–(f) dados do Cenário 3.



Fonte: Elaborado pela autora (2020).

Por fim, a Figura 19 ilustra as curvas de geração do RED instalado no nó 14 do sistema. Conforme a cronologia de operação obtida para 3 cenários ($K = 3$), foi observado que o ponto máximo de injeção de potência igual à 865 kW, o qual ocorreu às 16 horas do Cenário 3. Observa-se que para o RED não ocorrem diferenças tão grandes de um cenário para o outro, como aquelas que foram observadas nas cargas. Além disso, a curva da Figura 19 contempla o somatório de injeções de potência provenientes de fontes eólica e solar-fotovoltaica.

Figura 19 – Cenários de operação do RED instalado no nó 14 do sistema de 23 nós.



Fonte: Elaborado pela autora (2020).

4.2.4 Resultados de Operação Determinística

A partir da modelagem da cronologia de operação por meio de 3 cenários, foram obtidos os resultados de operação do sistema de 23 nós para oito estudos de caso com o modelo linearizado proposto. Considerando um ano de horizonte de planejamento, a Tabela 9 apresenta o custo de operação, as perdas ativas, a violação dos limites de tensão e o tempo de processamento do PLIM no CPLEX (2019) relativos a cada caso. Além disso, a Tabela 10 lista os resultados do PLIM em relação à estratégia de controle volt-var em cada caso, incluindo a localização (nó) dos equipamentos, o ajuste ótimo das correntes de liga/desliga dos BCs automáticos ($I_m^{on,AI}$ e $I_m^{off,AI}$), e o ajuste ótimo da tensão de referência do RT ($V_m^{set,RT}$).

As diferenças percentuais listadas em parêntesis na Tabela 9 foram calculadas conforme a variação do modelo linearizado em relação ao fluxo de carga convencional, para cada caso, considerando as soluções ótimas de controle volt-var apresentadas na Tabela 10. Por exemplo, para avaliar a efetividade do controle do RT instalado no nó 5 no Caso RT, variável $V_m^{set,RT}$ foi ajustada para 1,0156 pu no fluxo de carga convencional do sistema de 23 nós. Assim, a comparação entre os custos de operação calculados com o modelo proposto e o fluxo de carga revelou uma diferença de 0,36%, ressaltando o bom desempenho do modelo linearizado. A efetividade da otimização da operação dos BCs automáticos pode ser feita de forma similar, ajustando $I_m^{on,AI}$ e $I_m^{off,AI}$ de todos os BCs existentes no sistema e avaliando os resultados do fluxo de carga.

Tabela 9 – Resultados do PLIM relativos à operação determinística do sistema de 23 nós.

Caso	C^{oper} [$\times 10^3$ US\$]	Perdas Ativas [MWh]	z^1 [pu]	Tempo de Processamento [s]
Caso Base	212,94 (-0,45%) ²	1380 (-0,61%) ³	0,6971 (-0,0002) ⁴	21
BC	124,45 (-1,04%)	1059 (-0,38%)	0,0904 (-0,0098)	115
RT	177,66 (0,36%)	1564 (2,37%)	0,0637 (-0,0382)	529
BC + RT	123,99 (-1,41%)	1112 (-0,13%)	0,0178 (-0,0183)	3360
Caso Base RED	184,38 (0,28%)	1185 (0,13%)	0,6162 (0,0040)	23
BC + RED	100,71 (-0,84%)	865 (-0,08%)	0,0631 (-0,0089)	103
RT + RED	145,54 (-3,24%)	1292 (-1,56%)	0,0387 (-0,0299)	572
BC + RT + RED	98,52 (-3,06%)	888 (-1,41%)	0,0090 (-0,0195)	1564 ⁵

Notas:

¹ Violação dos limites de tensão calculada da seguinte forma:

$$z = \sum_{sc \in \Psi^K} \Delta T_{sc} \sum_{j \in \Psi^J} \sum_{m \in \Psi^D} z_{m,j,sc}.$$

² Diferença percentual do custo de operação em relação ao resultado obtido com fluxo de carga convencional.

³ Diferença percentual das perdas ativas em relação ao resultado obtido com fluxo de carga convencional.

⁴ Diferença em pu da violação dos limites de tensão em relação ao resultado obtido com fluxo de carga convencional.

⁵ Para solução deste caso, o gap relativo de otimalidade foi alterado da opção padrão (0,01%) para 0,05%, visando deixar a solução do problema mais rápida (RESENER, 2016).

Tabela 10 – Resultados de ajuste ótimo do controle volt-var do sistema de 23 nós.

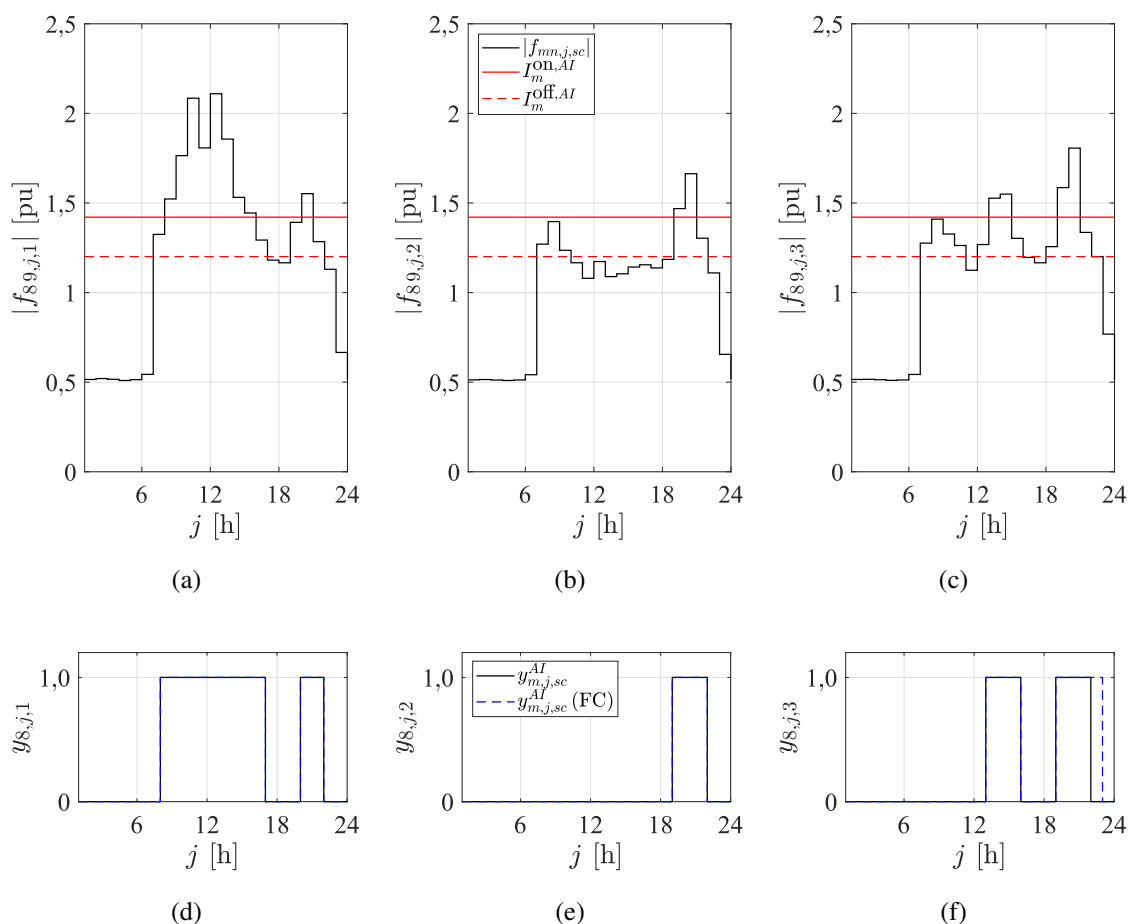
Caso	Banco de Capacitores				Regulador de Tensão	
	nó	tipo	$I_m^{on,AI}$ [pu]	$I_m^{off,AI}$ [pu]	nó	$V_m^{set,RT}$ [pu]
Caso Base	–	–	–	–	–	–
BC	8	A1200	1,4208	1,2007	–	–
	9	F600	–	–	–	–
	16	F600	–	–	–	–
	21	A600	0,3434	0,2213	–	–
RT	–	–	–	–	5	1,0156
BC + RT	8	F600	–	–	5	1,0069
	16	F600	–	–	–	–
	21	A600	0,3146	0,1950	–	–
Caso Base RED	–	–	–	–	–	–
BC + RED	8	A1200	1,4231	1,2028	–	–
	9	F600	–	–	–	–
	16	F600	–	–	–	–
	21	A600	0,3441	0,2219	–	–
RT + RED	–	–	–	–	5	1,0280
BC + RT + RED	8	F600	–	–	5	1,0100
	16	F600	–	–	–	–
	21	A600	0,3441	0,2219	–	–

Em relação aos casos com RED, verificou-se que o Caso BC + RED apresentou uma redução das perdas ativas e violação dos limites de tensão, em relação ao Caso BC. Além disso, observou-se $-0,84\%$ de diferença entre o custo de operação calculado com o PLIM e com o fluxo de carga convencional.

O problema de otimização para controle volt-var do Caso BC consiste no ajuste ótimo de corrente de liga/desliga que minimiza o custo de operação do sistema. Deste modo, mesmo com a expressiva variação da demanda ao longo dos cenários (ilustrado na Figura 18), o modelo calculou um único valor de corrente para operar o BC automático ao longo do ano. A Figura 20 ilustra as correntes de liga e desliga, $I_m^{on,AI}$ e $I_m^{off,AI}$, do BC de 1200 kvar instalado no nó 8. É possível observar que, baseado na corrente medida no ramo a jusante do BC automático $|f_{89,j,sc}|$, ilustrada na Figura 20 (a)–(c) para cada cenário, a solução ótima indicou operações intermitentes do BC ao longo dos cenários, conforme mostra a Figura 20 (d)–(f).

A partir dos resultados do Caso BC foi verificado que o limite diário de chaveamentos imposto ao BC automático, por meio das restrições (3.25)–(3.27), foi atendido (limitado a duas operações ao dia). Além disso, a Figura 20 (d)–(f) demonstra o nível de precisão do modelo linearizado em relação às horas de operação do BC calculadas com fluxo de carga convencional. Observa-se que o limiar de ajuste do controle do BC e corrente a jusante do banco, calculada para a hora 23 do cenário 3, $|f_{89,23,3}|$, implicou diferença entre a solução ótima do PLIM e a obtida com o fluxo de carga. Por fim, o Caso BC demonstrou uma expressiva redução da violação dos limites de tensão quando comparado ao Caso Base, assim como uma redução das perdas ativas.

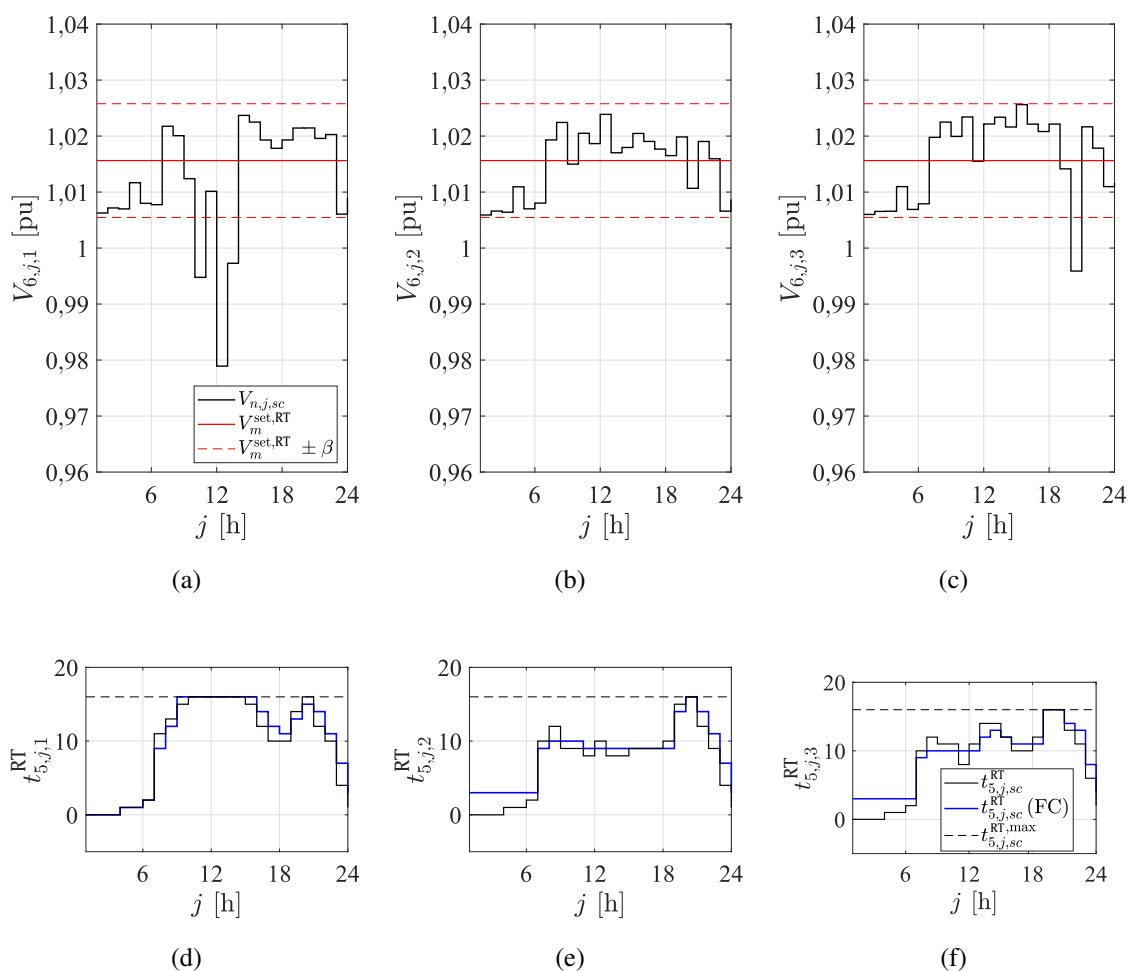
Figura 20 – Resultados de ajuste do BC automático instalado no nó 8 do sistema de 23 nós para o Caso BC: (a)–(c) perfil da corrente calculado para o ramo a jusante do BC durante os cenários 1, 2 e 3; (d)–(f) estado horário de operação do BC durante os cenários 1, 2 e 3.



Fonte: Elaborado pela autora (2020).

A estratégia de controle de volt-var do Caso RT consiste no ajuste ótimo da tensão de referência do RT instalado no nó 5, visando a minimização do custo de operação. Considerando a compensação por queda de tensão na linha, o controle do RT opera os taps de forma a regular a tensão no nó 6 ($V_{6,j,sc}$). Análogo ao controle do BC, o RT é ajustado considerando um valor de tensão único ao longo do ano. A Figura 21 (a)–(c) ilustra o perfil da tensão do nó 6, $V_{6,j,sc}$, durante os 3 cenários, e o ajuste ótimo do regulador, $V_m^{set,RT}$. Já as posições do tap, resultantes do modelo linearizado e do fluxo de carga convencional, são ilustradas pela Figura 21 (d)–(f). Tendo em vista que o RT pode operar em uma faixa de tensão, observaram-se diferenças nos valores de tap encontrados na solução ótima do PLIM e na solução obtida com o fluxo de carga convencional.


Figura 21 – Resultados de ajuste do RT instalado no nó 5 do sistema de 23 nós para o Caso RT: (a)–(c) perfil de tensão calculado para o nó remoto 6 durante os cenários 1, 2 e 3; (d)–(f) posição horária do tap durante os cenários 1, 2 e 3.



Fonte: Elaborado pela autora (2020).

O Caso RT exemplifica a importância da operação do tap do RT considerando uma região de saturação do controle, especialmente nos horários de pico de carregamento, expresso por (3.31)–(3.35). Para exemplificar esse aspecto, a Figura 22 (a) ilustra o efeito de saturação do controle de operação do tap do RT, quando esse atingiu o limite superior, ou seja, $t_{5,j,sc}^{RT} = 16$. Adicionalmente, a Figura 22 (b) ilustra a histerese de controle obtida com os resultados de taps ($t_{5,j,sc}^{RT}$) e tensão do nó remoto ($V_{6,j,sc}$) para o fluxo de carga convencional, considerando o ajuste ótimo da variável $V_m^{\text{set},RT}$, obtido com o PLIM. Observa-se que em algumas situações a tensão fica fora da região desejada pelo controle, pois este atingiu o seu valor máximo (no caso, o tap +16). A boa representação do modelo linearizado pode ser comprovada pela comparação entre os valores mostrados nas Figuras 22 (a) e 22 (c), pois neste caso os taps ótimos definidos no PLIM são empregados diretamente no FC, havendo uma diferença muito pequena nos valores observados na tensão do nó 6. Por outro lado, observa-se uma pequena diferença nos resultados das Figuras 22 (a) e 22 (b). Nesse caso, quem determina o tap de operação é o FC, segundo seu algoritmo de ajuste³.

Figura 22 – Histerese de controle do RT instalado no nó 5 do sistema de 23 nós, resultante do Caso RT considerando: (a) PLIM proposto; (b) fluxo de carga convencional com tensão $V_m^{\text{set},RT}$ definida; e (c) fluxo de carga convencional com taps definidos.




Fonte: Elaborado pela autora (2020).

A combinação de BCs e RT resultou na melhor solução de redução das perdas, em decorrência da presença de três BCs 600 kvar (dois fixos e um automático), e contribuiu na redução da violação dos limites de tensão, se comparado ao Caso Base. Além disso, a saturação da operação do tap pode ser observada, sendo que a presença de BCs fixos resultou em taps negativos, conforme ilustra Figura 23 (a). Além disso, o PLIM busca minimizar o custo de operação e, portanto, a posição dos taps foi otimizada. Novamente, o FC apresenta taps ligeiramente diferentes, mas dentro da zona de regulação e sem compromisso com otimização, conforme ilustra Figura 23 (b). Ao ajustar o fluxo de carga

³Como há uma tolerância para a tensão desejada, existem diversas posições de tap que são capazes de resolver o problema. Do ponto de vista do FC, qualquer uma destas posições é uma solução válida.

com os taps resultantes do PLIM, obteve-se a histerese ilustrada pela Figura 23 (c), que é muito próxima daquela que foi obtida pelo PLIM.

Figura 23 – Histerese de controle do RT instalado no nó 5 do sistema de 23 nós, resultante do Caso BC + RT considerando: (a) PLIM proposto; (b) fluxo de carga convencional com tensão $V_m^{\text{set,RT}}$ definida; e (c) fluxo de carga convencional com taps definidos.



Fonte: Elaborado pela autora (2020).

Finalmente, em relação aos testes com RED instalada no nó 14 do sistema, os ajustes de BC e RT obtidos (Tabela 10) foram marginalmente superiores quando comparados aos testes sem RED. Isto significa que os BCs vão ligar e desligar para carregamentos um pouco superiores aos que foram determinados para a condição sem RED, ou seja, os BCs irão permanecer ligados menos tempo quando houver RED. Os resultados demonstraram que no Caso BC + RT, a unidade automática permanece ligada durante 5.948 horas/ano, contra 5.840 horas/ano do Caso BC + RT + RED. Além disso, os resultados da Tabela 9 demonstram que todos os casos com RED apresentaram significativa redução no custo de operação em relação ao Caso Base, sendo que o caso BC + RT + RED apresentou o menor custo de operação para o sistema de 23 nós.

4.2.5 Resultados da Operação Considerando Incertezas


O processo de determinação dos cenários e durações empregando o algoritmo *K-means clustering* tem por característica a possibilidade de obtenção de inúmeras soluções diferentes, mas com qualidade semelhante. Neste caso, o algoritmo *K-means clustering* é inicializado de modo aleatório, logo os cenários obtidos a cada repetição do *K-means* podem ser diferentes entre si (tanto nos valores dos centroides quanto na quantidade de amostras presentes), implicando variabilidade na sua representação.

Nos resultados mostrados na Figura 16, a cronologia da operação foi considerada para uma amostra de diferentes quantidades de cenários (K). Entretanto, nessa análise, foi considerada uma única amostra de representação por cenários, tornando o resultado determinístico, embora leve em conta todas as possibilidades de operação anual (representadas pelos cenários e seus respectivos dias de ocorrência).

Para considerar as incertezas na representação por K cenários, foi necessário definir o número de amostras n_s , ou seja, o número de repetições do PLIM com K cenários, mas com representações diferentes, visando determinar o intervalo de confiança do custo de operação anual.

Ao atualizar a etapa de análise de sensibilidade da entrada (descrita na Seção 4.2.3.2) considerando 30 amostras para $K = \{1, 2, 3, 4, 5\}$, foram obtidos os resultados mostrados na Figura 24 (a). Ao reduzir a escala do eixo vertical (SS), verifica-se a variabilidade da SS de 30 amostras para cada K , conforme ilustra a Figura 24 (b). Ao que tudo indica, para o valor $K = 2$, o algoritmo obteve sempre os mesmos resultados com o mesmo valor de SS nas simulações realizadas, entretanto, para $K \geq 3$, as diferenças entre as diversas execuções são facilmente observáveis.

Figura 24 – Avaliação da precisão dos cenários a partir da distância da soma dos quadrados (SS), considerando 30 amostras e: (a) 1 a 5 cenários; (b) 2 a 5 cenários.



Fonte: Elaborado pela autora (2020).

Nesse contexto, visando definir o número adequado de amostras (n_s), foi realizada a análise de variâncias (ANOVA) de um projeto de experimentos fatorial (apresentada na Seção 2.3.2), conforme descrito a seguir.

4.2.5.1 Análise de Variâncias

No presente trabalho, a análise de variância tem como objetivo geral comprovar que o custo de operação do sistema de 23 nós varia significativamente conforme número de cenários (K) adotado. De forma específica, a ANOVA também permite calcular o tamanho

amostral adequado estatisticamente. De acordo com o algoritmo ilustrado na Figura 6, para montar a matriz experimental, foram consideradas as seguintes premissas:

- a variável de resposta correspondeu ao custo de operação de cada amostra s (C_s^{oper});
- o fator controlável correspondeu ao número de cenários (K);
- para garantir graus de liberdade na solução da ANOVA, foi necessário considerar no mínimo 2 níveis do fator controlável;
- para garantir a viabilidade do espaço de busca de soluções do PLIM, o fator controlável foi restrito em 5 cenários ($K = 5$).

Ao avaliar a Figura 24, foi observado que as 30 amostras de $K = 1$ e $K = 2$ cenários apresentaram o mesmo valor de SS . Isso significa que não ocorreu variabilidade dos cenários para diferentes amostras de $K = 1$ e $K = 2$, ou seja, o algoritmo sempre encontrou os mesmos cenários. No entanto, a partir de $K = 3$ foram registradas diferenças nos agrupamentos, implicando variabilidade da SS . Haja vista que geração de amostras tem como intuito encontrar diferentes possibilidades de agrupamentos e, assim, mensurar a incerteza do custo de operação, foi estabelecido que o fator controlável assume os valores: $K = \{3, 4, 5\}$. Definidos os valores de K , foram obtidas as variáveis de resposta, conforme descrito na Seção 2.3 e ilustrada na Figura 6. A Tabela 11 apresenta a matriz experimental adotada.

Com o auxílio do programa Minitab (2017) foram obtidos os resultados da ANOVA. Conforme listado na Tabela 12, o Valor-p igual a 0,000 sugere a rejeição da hipótese nula (onde todas as médias são iguais, e portanto, o custo de operação não varia significativamente conforme o número de cenários). Além disso, de acordo com a descrição da ANOVA na Seção 2.3, a Tabela apresenta 12 apresenta os graus de liberdade (GL), a soma dos quadrados ajustada (SQ Aj.), os quadrados médios ajustados (QM Aj.) e a estatística do teste (Valor-F). Conforme ilustra a Figura 25, para 30 amostras constatou-se potência estatística igual a 100%, concluindo que o tamanho amostral (30 amostras) não mascarou a resposta, evitando assim uma falsa rejeição da hipótese nula. Para obtenção da potência estatística foram considerados 3 níveis do fator controlável (ou seja, 3 possibilidades de quantidade de cenários, $K = \{3, 4, 5\}$), bem como o desvio padrão combinado (resultante da operação $\sqrt{M_{\text{erro}}} = \sqrt{30194} \approx 174$) obtido por meio da ANOVA e listado na Tabela 12.


Tabela 11 – Matriz experimental considerando dados históricos de 1 ano de operação.

Variável de Resposta [$\times 10^3$ \$/ano] $C_s^{oper} \forall s \in \psi^s$	Amostra	Fator Controlável [qtde de cenários]		
	s	$K = 3$	$K = 4$	$K = 5$
	1	210,95	211,36	211,87
2	210,78	211,52	211,56	
3	211,09	211,48	211,78	
4	210,77	211,54	211,72	
5	211,02	211,48	211,62	
6	211,00	211,46	211,51	
7	210,96	211,31	211,52	
8	211,10	211,48	211,67	
9	210,96	211,53	211,94	
10	211,05	211,49	211,93	
11	211,07	211,35	211,56	
12	211,05	211,47	211,87	
13	211,06	211,43	211,91	
14	211,06	211,52	211,91	
15	210,95	211,45	211,41	
16	211,08	211,50	211,74	
17	211,03	211,51	210,95	
18	211,10	211,11	211,91	
19	210,79	210,97	211,78	
20	210,76	211,47	211,61	
21	210,75	211,48	211,58	
22	211,10	211,54	211,47	
23	211,03	211,46	211,43	
24	211,08	211,52	211,84	
25	210,59	211,52	211,91	
26	211,05	211,57	211,38	
27	210,74	211,46	211,96	
28	211,07	211,51	211,93	
29	211,06	211,17	211,72	
30	211,08	211,51	211,58	
Média	210,97	211,44	211,69	
Desvio Padrão	0,14	0,13	0,22	

Tabela 12 – Análise de variância (ANOVA) considerando dados históricos de 1 ano de operação.

Fonte	GL	SQ (Aj.) [$\times 10^6$]	QM (Aj.) [$\times 10^6$]	Valor F	Valor-p
K	2	7,87	3,93	130,38	0,000
Erro	87	2,62	0,30	–	–
Total	89	10,50	–	–	–

Figura 25 – Avaliação da potência estatística baseada no tamanho amostral considerando dados históricos de 1 ano de operação (grau de confiança = 95%).



Fonte: Elaborado pela autora (2020).

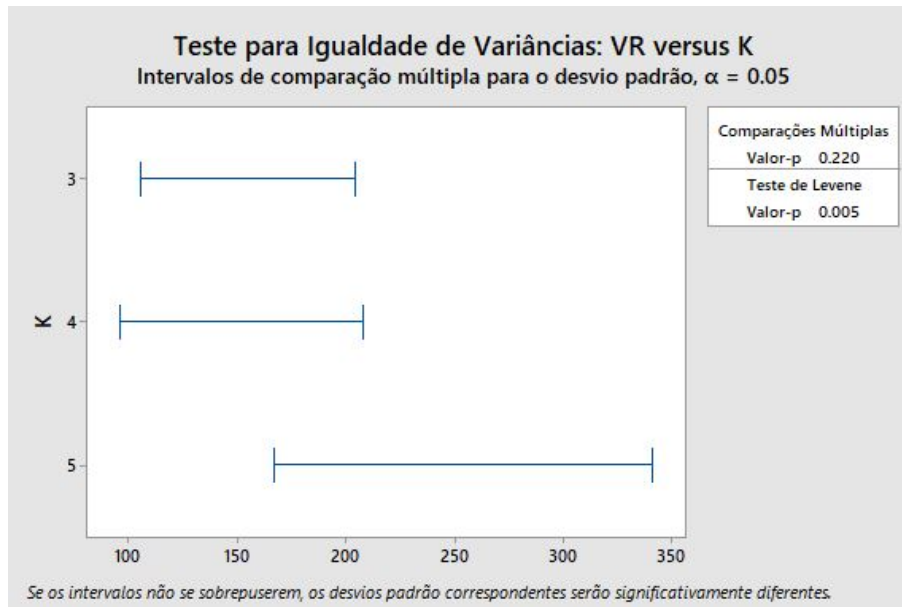
A avaliação das premissas estatísticas da ANOVA foi baseada no Valor-p de dois testes, o qual é definido como a probabilidade que mede a evidência contra a hipótese nula. Para isso, considerou-se 95% de grau de confiança ($\alpha = 0,05$). Ao avaliar os resultados obtidos no teste de Levene's (ilustrados na Figura 26) foi constatada a quebra da premissa de variância constante, uma vez que o Valor-p $< 0,01$ (ou seja, Valor-p $< \alpha$), impedindo o aceite da hipótese nula, a qual supõe igualdade de variâncias.

Ademais, o teste de hipóteses é formalmente baseado na suposição de normalidade dos dados. No entanto, os resultados obtidos no teste Ryan-Joiner (ilustrados na Figura 27) comprovam a quebra da premissa de normalidade do resíduo, uma vez que Valor-p = 0,005 (ou seja, Valor-p $< \alpha$).

Quando os dados são considerados não normais, duas alternativas podem guiar o passo 25 da Figura 6, que orienta “Rever projeto experimental”:


1. incrementar o número de amostras de maneira a executar uma análise para um tamanho amostral suficientemente grande;
2. rever dados históricos para modelagem da cronologia de operação.

Figura 26 – Teste de igualdade de variâncias considerando dados históricos de 1 ano de operação (grau de confiança = 95%).



Fonte: Elaborado pela autora (2020).

Figura 27 – Teste de normalidade dos resíduos considerando dados históricos de 1 ano de operação (grau de confiança = 95%).



Fonte: Elaborado pela autora (2020).

Considerando o significativo aumento do esforço computacional para solucionar o PLIM proposto com elevado número de amostras (por exemplo, 1000 amostras), optou-se por rever os dados históricos utilizados no *K-means clustering*. Buscando evitar que dias atípicos (feriados, por exemplo) fossem interpretados como *outliers* da base de dados, optou-se por aumentar a variabilidade dos dados utilizando uma base histórica de 3 anos de operação das cargas e RED. Com isso, foi obtida uma nova matriz experimental apresentada na Tabela 13.

Tabela 13 – Matriz experimental considerando dados históricos de 3 anos de operação.

	Amostra	Fator Controlável [qtde de cenários]		
	s	$K = 3$	$K = 4$	$K = 5$
Variável de Resposta [$\times 10^3$ \$/ano] $C_s^{\text{oper}} \forall s \in \psi^S$	1	612,76	614,34	615,40
	2	612,88	614,39	615,38
	3	612,56	614,74	615,75
	4	612,64	614,43	615,51
	5	613,48	614,44	615,74
	6	613,47	614,42	615,22
	7	612,71	614,16	615,75
	8	612,91	614,22	615,80
	9	612,92	614,40	615,77
	10	612,54	614,41	614,61
	11	612,91	614,73	615,81
	12	613,08	614,18	615,73
	13	613,49	614,47	615,81
	14	612,70	614,39	615,83
	15	612,61	614,80	615,59
	16	612,78	614,42	615,10
	17	612,26	614,09	615,73
	18	613,45	614,50	615,47
	19	613,45	614,44	615,75
	20	612,53	614,33	615,21
	21	612,69	613,94	615,80
	22	612,86	614,71	615,78
	23	612,54	614,46	615,79
	24	612,70	614,41	615,77
	25	613,49	614,53	615,80
	26	612,59	614,42	615,18
	27	612,70	614,59	614,67
	28	612,82	614,44	615,02
	29	613,47	614,16	615,12
	30	612,86	613,68	615,73
	Média	612,78	614,27	615,40
	Desvio Padrão	0,35	0,23	0,35


Os resultados da ANOVA, listados na Tabela 14, sugerem a possibilidade de rejeição

da hipótese nula, já que o Valor-p é igual à zero. Tal rejeição foi corroborada pela potência estatística igual à 100% para 30 amostras, conforme ilustra a Figura 28. Para obtenção da potência estatística foram considerados 3 níveis do fator controlável (ou seja, 3 possibilidades de quantidade de cenários, $K = 3, 4, 5$), bem como o desvio padrão combinado (resultante da operação $\sqrt{M_{\text{erro}}} = \sqrt{102103} \approx 320$) obtido por meio da ANOVA e listado na Tabela 14.

Tabela 14 – Análise de variância (ANOVA) considerando dados históricos de 3 anos de operação.

Fonte	GL	SQ (Aj.) [$\times 10^6$]	QM (Aj.) [$\times 10^6$]	Valor F	Valor-p
K	2	104,08	52,04	509,72	0,000
Erro	87	8,88	0,10	–	–
Total	89	112,97	–	–	–


Figura 28 – Avaliação da potência estatística baseada no tamanho amostral considerando dados históricos de 3 anos de operação (grau de confiança = 95%).



Fonte: Elaborado pela autora (2020).

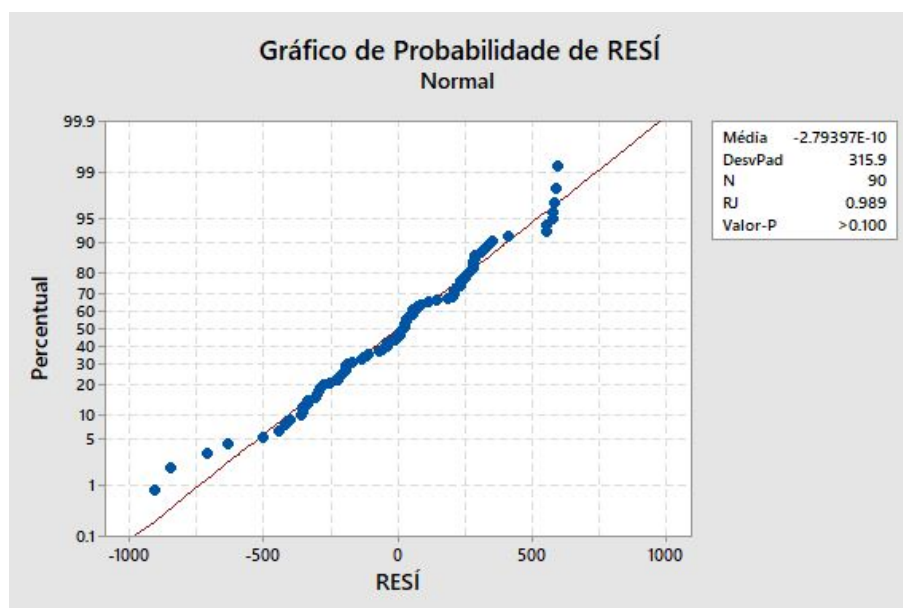
Constatou-se que o aumento do horizonte de tempo dos dados históricos de 1 ano para 3 anos foi efetivo, uma vez que os testes de Levene's e Ryan-Joiner apresentaram Valor-p superiores à 0,05, ou seja, não há evidências que as premissas de variância constante e normalidade dos resíduos tenham sido violadas. As Figuras 29 e 30 ilustram os resultados dos dois testes, considerando dados históricos de 3 anos de operação.

Figura 29 – Teste de igualdade de variâncias considerando dados históricos de 3 anos de operação (grau de confiança = 95%).



Fonte: Elaborado pela autora (2020).

Figura 30 – Teste de normalidade dos resíduos considerando dados históricos de 3 anos de operação (grau de confiança = 95%).



Fonte: Elaborado pela autora (2020).

Finalmente, a partir da ANOVA, pode-se concluir que:

1. o custo de operação varia significativamente conforme a quantidade adotada de cenários (K);
2. todos os níveis do fator controlável afetaram a variável de resposta, deste modo adotou-se o menor número de cenários, ou seja, $K = 3$;
3. para calcular a incerteza combinada expandida do modelo otimização proposto será adotado $n_s = 30$ amostras, garantindo potência estatística superior a 80%.

4.2.5.2 Incertezas

A partir da modelagem da cronologia de operação por meio de 3 cenários e 30 amostras, foram obtidos os resultados de operação considerando incertezas do sistema de 23 nós para os oito casos descritos anteriormente (na Seção 4.2.2). Para isto, quatro passos foram executados:

1. seleção da “melhor amostra” – dentre as 30 amostras disponíveis, foi selecionada aquela com maior precisão de agrupamento, ou seja, com menor distância da soma dos quadrados (SS);
2. solução de estratégia volt-var – o PLIM proposto foi solucionado para a melhor amostra selecionada no Passo 1, obtendo os parâmetros de controle de corrente dos BCs automáticos e controle de tensão com RT;
3. cálculo do ponto de operação em regime permanente para as demais amostras – a partir dos resultados de $I_m^{on,AI}$ e $I_m^{off,AI}$ dos BCs automáticos, e da $V_m^{set,RT}$ do RT, obtidos no Passo 2, foram obtidos os resultados de operação para as demais amostras;
4. cálculo das incertezas – a partir dos resultados de custo de operação, perdas ativas e violação dos limites de tensão das 30 amostras, foram calculadas as incertezas de acordo com a formulação detalhada na Seção 3.4.

De acordo com os Passos 1 e 2, a partir da melhor amostra foi obtido o ajuste ótimo do controle volt-var do sistema de 23 nós, considerando um ano de horizonte de planejamento. A Tabela 15 lista os resultados da estratégia volt-var adotada em cada caso. Além disso, a Tabela 16 apresenta o custo de operação, perdas ativas e violação dos limites de tensão obtidos com o PLIM para a melhor amostra. Cabe ressaltar que os resultados mostrados nas tabelas 15 e 16 foram diferentes dos encontrados na seção anterior, nas tabelas 10 e 9 (relativas à operação determinística), uma vez que os cenários utilizados também são diferentes.

Tabela 15 – Resultados de ajuste ótimo do controle volt-var do sistema de 23 nós, obtidos para a melhor amostra.

Caso	Banco de Capacitores				Regulador de Tensão	
	nó	tipo	$I_m^{on,AI}$ [pu]	$I_m^{off,AI}$ [pu]	nó	$V_m^{set,RT}$ [pu]
Caso Base	–	–	–	–	–	–
CB	8	A1200	1,5455	1,3141	–	–
	9	F600	–	–	–	–
	16	F600	–	–	–	–
	21	A600	0,3209	0,2002	–	–
RT	–	–	–	–	5	1,0164
BC + RT	8	F600	–	–	5	1,0033
	16	F600	–	–	–	–
	21	A600	0,3114	0,1922	–	–
Caso Base RED	–	–	–	–	–	–
BC + RED	8	A1200	1,5630	1,3300	–	–
	9	F600	–	–	–	–
	16	F600	–	–	–	–
	21	A600	0,3208	0,2007	–	–
RT + RED	–	–	–	–	5	1,0228
BC + RT + RED	8	F600	–	–	5	1,0117
	16	F600	–	–	–	–
	21	A600	0,3208	0,2007	–	–

De acordo com os Passos 3 e 4, com 30 amostras foi calculada a operação considerando incertezas do sistema de 23 nós, representada pelo intervalo de confiança dos principais resultados do modelo. A Tabela 17 lista o intervalo de confiança do custo de operação, perdas ativas e a violação dos limites de tensão, bem como o tempo de processamento total do PLIM no CPLEX (2019). O intervalo de confiança é composto pelo valor médio dos resultados obtidos para as 30 amostras e pela incerteza expandida, considerando um grau de confiança de 95%.

As diferenças percentuais listadas em parêntesis na Tabela 16 foram calculadas conforme a variação do modelo linearizado em relação ao fluxo de carga convencional, para cada caso, considerando as soluções ótimas de controle volt-var apresentadas na Tabela 15 – para a melhor amostra. De maneira geral, comparando as tabelas 10 e 15 foi verificada a melhoria da diferença percentual do PLIM em relação do fluxo de carga convencional em 5 casos da Tabela 15, sendo que nos casos RT + RED e BC + RT + RED, o erro reduziu consideravelmente. Tais resultados podem ser atribuídos à nova modelagem da cronologia de operação, representada pela melhor amostra de um total de 30 amostras selecionadas de uma base histórica de 3 anos.

Em relação aos resultados considerando incertezas, foi observado em média 10% de incerteza dos resultados dos casos sem RED e 12% de incerteza dos casos com RED.

Tabela 16 – Resultados do PLIM relativos à operação do sistema de 23 nós considerando a melhor amostra.

Caso	C^{oper} [$\times 10^3$ US\$]	Perdas Ativas [MWh]	z^1 [pu]	Tempo de Processamento [s]
Caso Base	206,65 (-0,32%) ²	1346 (-0,63%) ³	0,6683 (0,0030) ⁴	23
BC	121,91 (-0,85%)	1031 (-0,41%)	0,0960 (-0,0065)	118
RT	172,62 (0,43%)	1519 (2,20%)	0,0624 (-0,0326)	766
BC + RT	121,04 (-1,72%)	1082 (-0,03%)	0,0230 (-0,0239)	1967 ⁵
Caso Base RED	168,99 (0,56%)	1092 (0,23%)	0,5574 (0,0075)	28
BC + RED	91,00 (-0,44%)	777 (0,01%)	0,0629 (-0,0047)	142
RT + RED	135,86 (-0,98%)	1204 (0,61%)	0,0384 (-0,0245)	317
BC + RT + RED	89,88 (-2,03%)	808 (-0,39%)	0,0116 (-0,0173)	1764 ⁵

Notas:

¹ Violação dos limites de tensão calculada da seguinte forma:

$$z = \sum_{sc \in \psi^K} \Delta T_{sc} \cdot \sum_{j \in \psi^J} \sum_{m \in \psi^D} z_{m,j,sc} \cdot$$

² Diferença percentual do custo de operação em relação ao resultado obtido com fluxo de carga convencional.

³ Diferença percentual das perdas ativas em relação ao resultado obtido com fluxo de carga convencional.

⁴ Diferença em p.u. da violação dos limites de tensão em relação ao resultado obtido com fluxo de carga convencional.

⁵ Para solução deste caso, o gap relativo de otimalidade foi alterado da opção padrão (0,010%) para 0,015%, visando deixar a solução do problema mais rápida (RESENER, 2016).

Ao longo das simulações foi possível constatar que ao calcular a incerteza combinada desconsiderando a correlação das variáveis da função objetivo, essa incerteza reduz para em média 2,5% nos casos sem RED e 3% nos casos com RED.

Tabela 17 – Resultados do PLIM relativos à operação considerando incertezas do sistema de 23 nós (grau de confiança = 95%).

Caso	C^{oper} [$\times 10^3$ US\$]	Perdas Ativas [MWh]	z [pu]	Tempo de Processamento [s]
Caso Base	206,44 \pm 20,97	1344 \pm 137	0,6681 \pm 0,0670	694
BC	121,34 \pm 12,66	1032 \pm 104	0,0886 \pm 0,0137	2404
RT	172,27 \pm 18,25	1517 \pm 157	0,0608 \pm 0,0107	1570
BC + RT	120,78 \pm 12,98	1078 \pm 114	0,0245 \pm 0,0045	3193
Caso Base RED	168,91 \pm 20,00	1091 \pm 130	0,5584 \pm 0,0653	753
BC + RED	90,68 \pm 11,17	777 \pm 93	0,0592 \pm 0,0114	2045
RT + RED	135,69 \pm 16,76	1202 \pm 145	0,0391 \pm 0,0089	1102
BC + RT + RED	89,76 \pm 11,32	806 \pm 110	0,0126 \pm 0,0030	3138

Tendo em vista o caráter aleatório do *K-means clustering*, a cada simulação foram obtidas diferentes quantidades de dias em cada cenário. Isso significa que os dias trocam de cenários a cada amostra gerada, implicando correlação entre as variáveis de entrada da função de medição (ver Seção 3.4 – Tabela 5). Para comprovar isso, foi calculado o grau de correlação, dos custos e durações de cada cenário, expresso por (2.6). Logo, considerando a diagonal superior da matriz de correlação dada por:

$$\mathbf{R} = \begin{bmatrix} r_{C_{1,s}^{oper}, C_{1,s}^{oper}} & r_{C_{1,s}^{oper}, \Delta T_{1,s}} & r_{C_{1,s}^{oper}, C_{2,s}^{oper}} & r_{C_{1,s}^{oper}, \Delta T_{2,s}} & r_{C_{1,s}^{oper}, C_{3,s}^{oper}} & r_{C_{1,s}^{oper}, \Delta T_{3,s}} \\ 0 & r_{\Delta T_{1,s}, \Delta T_{1,s}} & r_{\Delta T_{1,s}, C_{2,s}^{oper}} & r_{\Delta T_{1,s}, \Delta T_{2,s}} & r_{\Delta T_{1,s}, C_{3,s}^{oper}} & r_{\Delta T_{1,s}, \Delta T_{3,s}} \\ 0 & 0 & r_{C_{2,s}^{oper}, C_{2,s}^{oper}} & r_{C_{2,s}^{oper}, \Delta T_{2,s}} & r_{C_{2,s}^{oper}, C_{3,s}^{oper}} & r_{C_{2,s}^{oper}, \Delta T_{3,s}} \\ 0 & 0 & 0 & r_{\Delta T_{2,s}, \Delta T_{2,s}} & r_{\Delta T_{2,s}, C_{3,s}^{oper}} & r_{\Delta T_{2,s}, \Delta T_{3,s}} \\ 0 & 0 & 0 & 0 & r_{C_{3,s}^{oper}, C_{3,s}^{oper}} & r_{C_{3,s}^{oper}, \Delta T_{3,s}} \\ 0 & 0 & 0 & 0 & 0 & r_{\Delta T_{3,s}, \Delta T_{3,s}} \end{bmatrix}, \quad (4.1)$$

onde cada termo da matriz \mathbf{R} representa a correlação a ser considerada no cálculo da incerteza combinada do custo de operação, definida como $u_c^{\overline{C}^{oper}}$ e expressa por (2.5). A partir dos dados listados na Tabela 18, os valores absolutos das correlações utilizadas foram:

$$|\mathbf{R}| = \begin{bmatrix} 1,00 & 0,68 & 0,79 & 0,80 & 0,37 & 0,75 \\ 0 & 1,00 & 0,21 & 0,82 & 0,78 & 0,97 \\ 0 & 0 & 1,00 & 0,47 & 0,08 & 0,31 \\ 0 & 0 & 0 & 1,00 & 0,74 & 0,91 \\ 0 & 0 & 0 & 0 & 1,00 & 0,80 \\ 0 & 0 & 0 & 0 & 0 & 1,00 \end{bmatrix}. \quad (4.2)$$

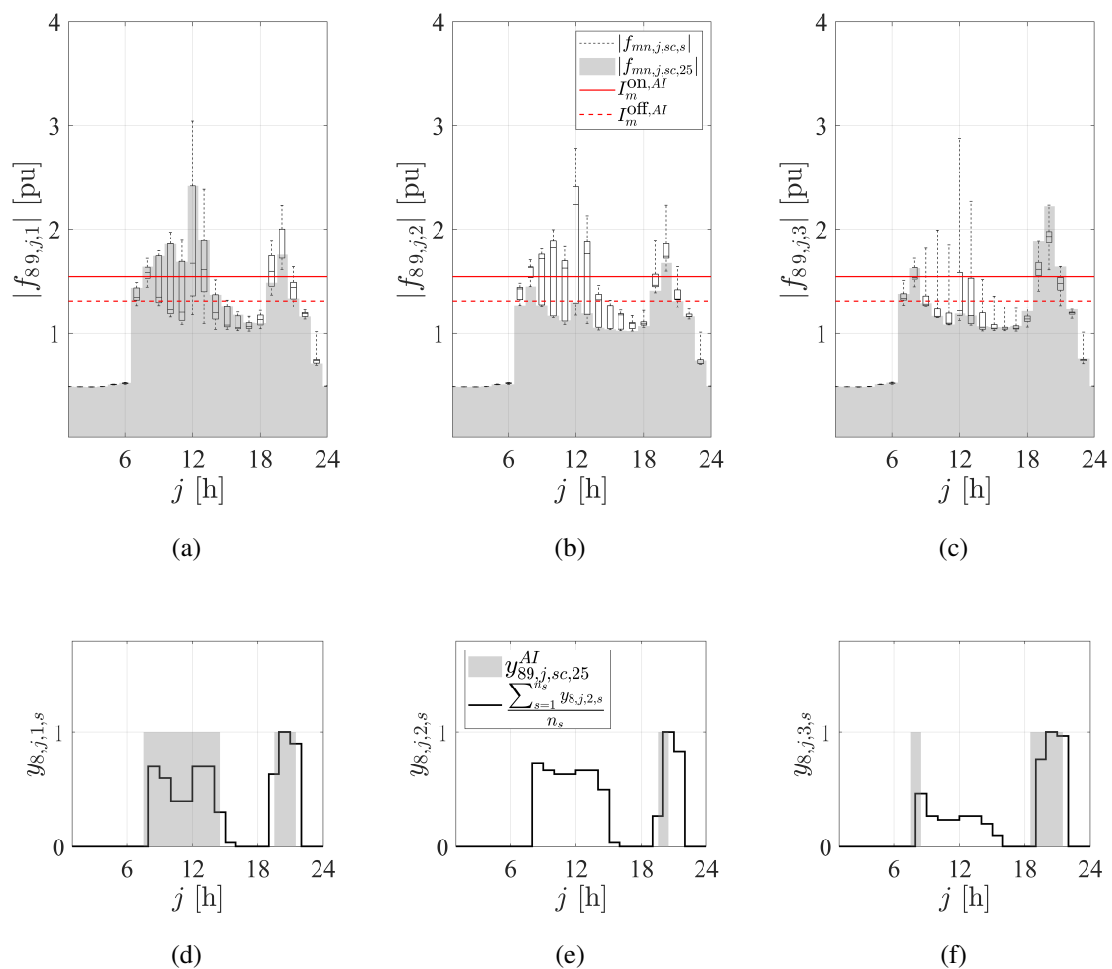
Além disso, para compor a Tabela 18, foi necessário classificar os cenários de cada amostra. No presente trabalho, foi adotado o critério da distância da soma dos quadrados SS , decisão esta, que impacta diretamente o intervalo de confiança obtido. Conforme o critério de classificação dos cenários das amostras, é possível que a incerteza seja superior à 10% nos casos sem RED e 12% nos casos com RED.

Tabela 18 – Custo de operação e quantidade de dias agrupados em cada cenário do Caso BC + RT + RED.

Amostra s	Cenário 1		Cenário 2		Cenário 3		C_s^{oper} [$\times 10^3$ \$/ano]	SS_s
	$C_{1,s}^{oper}$ [$\times 10^3$ \$/dia]	$\Delta T_{1,s}$ [dia]	$C_{2,s}^{oper}$ [$\times 10^3$ \$/dia]	$\Delta T_{2,s}$ [dia]	$C_{3,s}^{oper}$ [$\times 10^3$ \$/dia]	$\Delta T_{3,s}$ [dia]		
1	334,87	119	236,59	121	172,38	125	90,02	100,729
2	402,85	59	256,79	82	200,33	224	89,69	101,651
3	206,54	96	339,41	113	202,43	156	89,76	100,981
4	208,85	105	338,20	113	200,49	147	89,61	100,979
5	405,30	40	291,62	93	198,87	232	89,47	101,755
6	212,14	93	337,40	114	199,09	158	89,64	100,975
7	241,25	113	334,15	120	171,22	132	89,96	100,729
8	335,27	119	236,69	119	172,96	127	90,02	100,732
9	215,61	98	336,71	114	196,52	153	89,58	100,972
10	410,82	55	261,62	84	200,11	226	89,79	101,661
11	400,29	40	293,69	93	198,92	232	89,47	101,767
12	239,93	120	334,09	121	168,68	124	90,13	100,724
13	223,90	82	335,33	114	195,30	169	89,59	100,981
14	346,67	40	309,87	104	196,14	221	89,44	101,843
15	416,79	47	275,39	87	199,81	231	89,70	101,731
16	334,99	119	236,45	121	172,31	125	90,01	100,729
17	433,04	38	285,03	92	199,74	234	89,41	101,700
18	240,94	118	332,89	121	168,27	126	89,91	100,725
19	408,88	49	275,13	84	200,16	232	89,58	101,697
20	414,30	48	273,64	87	199,38	229	89,35	101,696
21	381,70	75	239,92	79	200,38	211	89,86	101,659
22	257,04	57	330,28	117	189,25	191	89,44	101,021
23	241,59	117	333,84	121	168,66	127	90,08	100,722
24	242,47	115	333,24	122	168,49	128	90,10	100,729
25	241,00	116	332,84	121	169,19	128	89,88	100,722
26	209,63	95	339,30	113	200,86	157	89,79	100,980
27	242,15	72	332,19	116	189,58	177	89,52	101,011
28	401,22	59	258,09	81	200,38	225	89,66	101,651
29	240,94	118	332,87	121	168,27	126	89,91	100,725
30	335,79	119	236,74	121	172,26	126	90,30	100,728

Em relação aos resultados do controle volt-var para operação considerando incertezas, a Figura 31 (a)–(c) ilustra as correntes de liga e desliga, $I_m^{\text{on},AI}$ e $I_m^{\text{off},AI}$, do BC automático de 1200 kvar instalado no nó 8 para o Caso BC. A partir de diagramas de caixa foi possível traçar a variabilidade da corrente medida no ramo à jusante do BC automático em questão ($|f_{89,j,sc,s}|$), para todas as amostras, sendo que a área em cinza ilustra esta corrente para a melhor amostra ($|f_{89,j,sc,25}|$), ou seja, aquela que foi utilizada para otimizar a corrente liga/desliga do BC. A Figura 31 (d)–(f) ilustra a média horária do estado de operação do BC em cada cenário, calculada por $\frac{1}{n_s} \sum_{s=1}^{n_s} y_{8,j,sc,s}$. O estado de operação da melhor amostra ($y_{8,j,sc,25}$) (ilustrado em cinza) comprova que a solução do PLIM atendeu à restrição de limite diário de manobras do BC em todos os cenários.

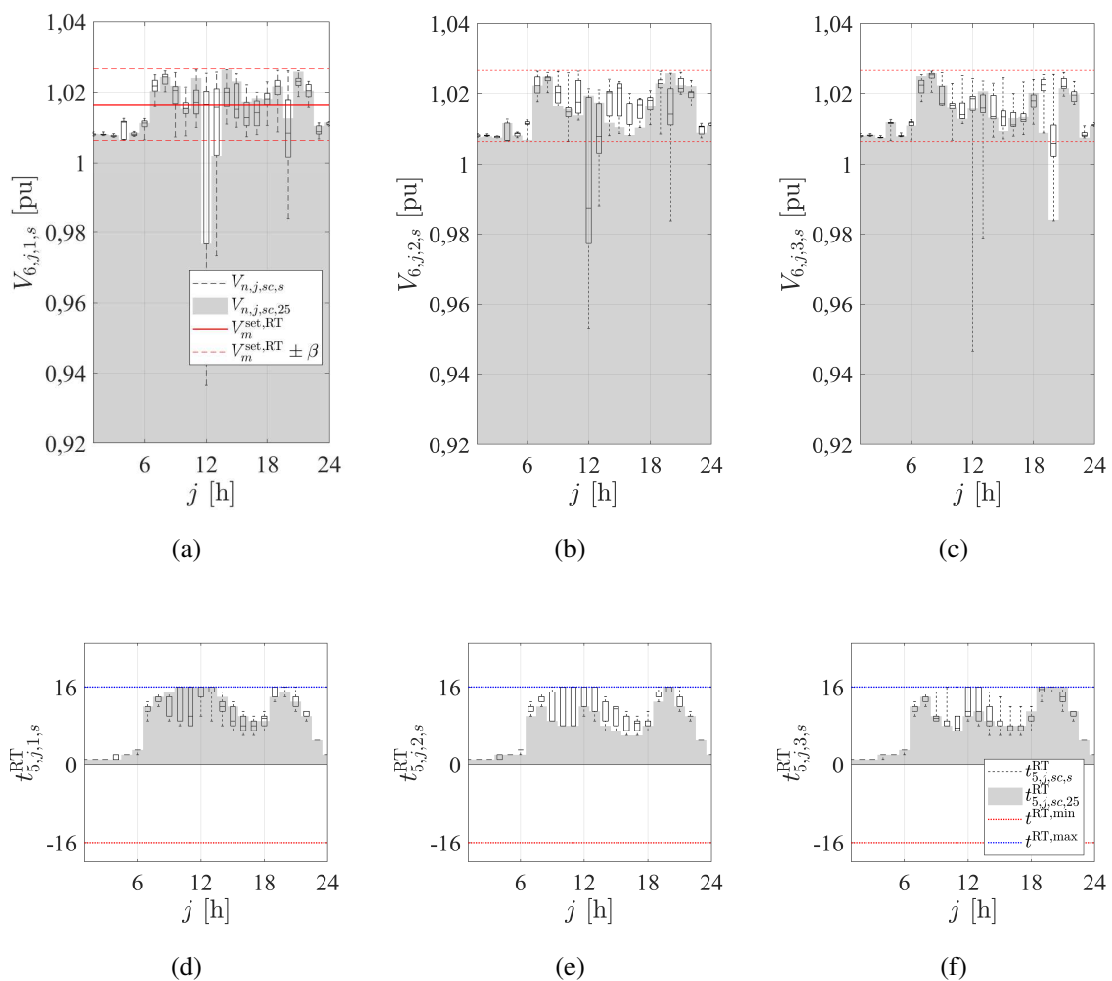
Figura 31 – Resultados de ajuste do BC automático instalado no nó 8 do sistema de 23 nós considerando 30 amostras para o Caso BC, onde: (a)–(c) diagrama de caixa com variação horária da corrente calculada para o ramo à jusante do BC durante os Cenários 1, 2 e 3; (d)–(f) somatório do estado de operação do BC durante os Cenários 1, 2 e 3, respectivamente.



Fonte: Elaborado pela autora (2020).

Em relação ao Caso RT, a Figura 32 (a)–(c) ilustra o intervalo de variação do perfil da tensão do nó 6, $V_{6,j,sc,s}$, durante todas as amostras dos 3 cenários, e o ajuste ótimo do regulador, $V_m^{set,RT}$. A variabilidade horária das posições do tap resultantes do modelo linearizado para todas as amostras é ilustrada pela Figura 32 (d)–(f). As soluções de tensão $V_{6,j,sc,25}$ e tap $t_{5,j,sc,25}^{RT}$ para a melhor amostra foram ilustradas em cinza na Figura 32.

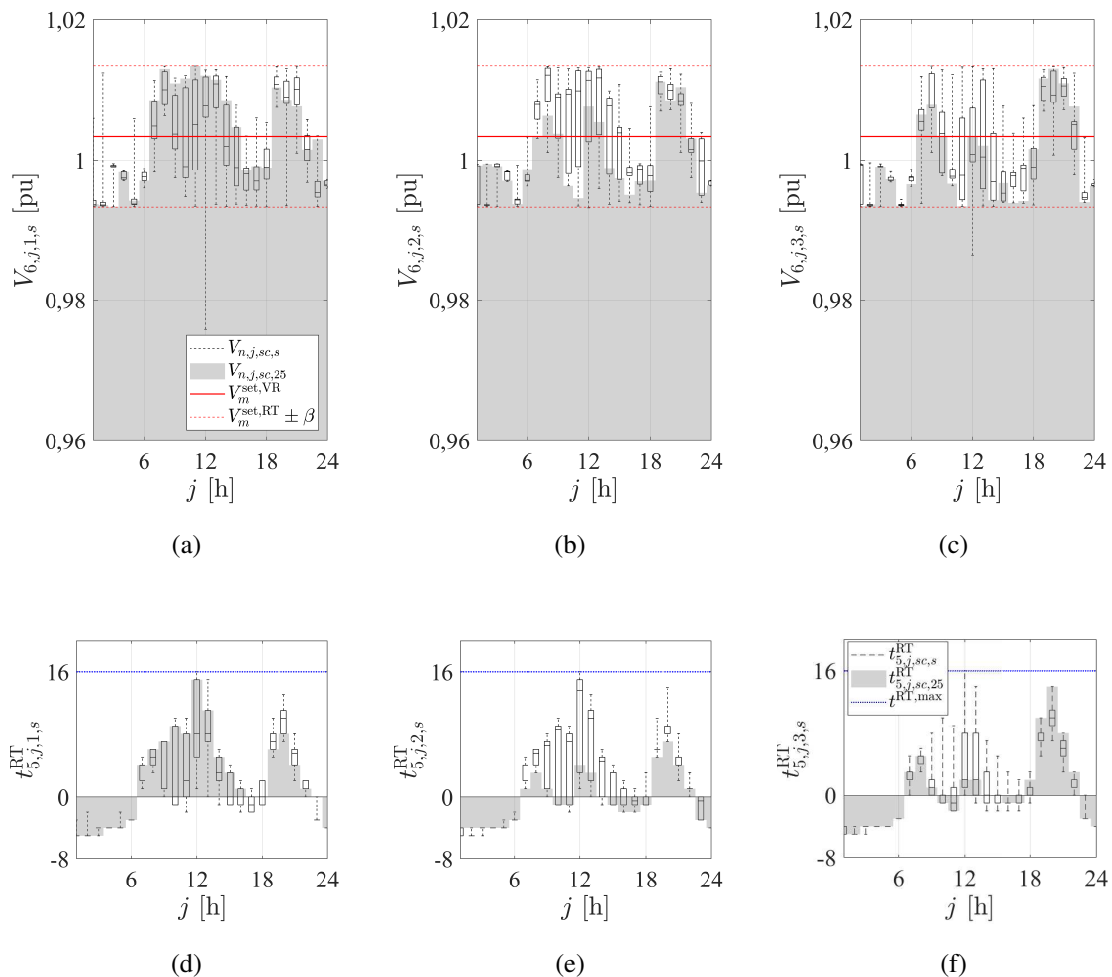
Figura 32 – Resultados de ajuste do RT instalado no nó 5 do sistema de 23 nós para o Caso RT: (a)–(c) perfis de tensão do nó 6, calculados para todas amostras, durante os Cenários 1, 2 e 3, respectivamente; (d)–(f) variabilidade da posição horária do tap RT, calculado para todas amostras, durante os Cenários 1, 2 e 3, respectivamente.



Fonte: Elaborado pela autora (2020).


De forma análoga, a Figura 33 ilustra os mesmos resultados obtidos para o Caso BC + RT. Adicionalmente, a Figura 34 ilustra a histerese de controle do RT obtida com os resultados de taps ($t_{5,j,sc,s}^{RT}$) e tensão do nó remoto ($V_{6,j,sc,s}$) para todas as amostras, nos dois casos. A partir da comparação dos resultados ilustrados na Figura 34, foi verificado que a estratégia com RT resulta na saturação do tap em alguns horários, sendo que ao adotar BC + RT, as violações de tensão reduziram, foram registrados taps negativos e não ocorreu saturação do tap.

Figura 33 – Resultados de ajuste do RT instalado no nó 5 do sistema de 23 nós para o Caso BC + RT: (a)–(c) perfis de tensão do nó 6, calculados para todas amostras, durante os Cenários 1, 2 e 3, respectivamente; (d)–(f) variabilidade da posição horária do tap RT, calculado para todas amostras, durante os Cenários 1, 2 e 3, respectivamente.



Fonte: Elaborado pela autora (2020).

Figura 34 – Histerese de controle do RT instalado no nó 5 do sistema de 23 nós, resultante da operação considerando incertezas dos casos: (a) RT; (b) BC + RT.




Fonte: Elaborado pela autora (2020).

4.3 Exemplo de Aplicação - Sistema de 69 nós

Com o objetivo de demonstrar a flexibilidade do modelo proposto, foram desempenhados testes em um sistema de 69 nós, proposto por Baran e Wu (1989), o qual é amplamente utilizado na literatura em estudos de otimização. O sistema de 69 nós opera em 12,66 kV, com carga nominal de 4027 kW e 2796 kvar, distribuída ao longo de 48 nós. A Figura 35 ilustra o sistema e os dados de linha e carga são apresentados no Apêndice 6.

Figura 35 – Topologia do sistema de 69 nós.



Fonte: Adaptado de Resener (2016).

De maneira similar ao sistema de 23 nós, neste exemplo de aplicação foram considerados 8 estudos de casos para diferentes estratégias de controle volt-var, considerando ou não a presença de RED. A Tabela 19 apresenta um resumo dos equipamentos existentes no sistema de 69 nós em cada caso estudado.

Tabela 19 – Equipamentos existentes no sistema de 69 nós em cada caso.

Caso	Especificações dos Equipamentos Existentes ¹						
	BC			RT		black	
	Nó	Tipo	Potência Nominal	Nó	Capacidade de Corrente	Nó	Potência Nominal
Base	–	–	–	–	–	–	–
BC	50	A1200	0 ou 1200 kvar	–	–	–	–
RT	–	–	–	42	400 A	–	–
BC + RT	50	A1200	0 ou 1200 kvar	42	400 A	–	–
Caso Base + RED	–	–	–	–	–	20	1 MW
BC + RED	50	A1200	0 ou 1200 kvar	–	–	20	1 MW
RT + RED	–	–	–	42	400 A	20	1 MW
BC + RT + RED	50	A1200	0 ou 1200 kvar	42	400 A	20	1 MW

Nota:

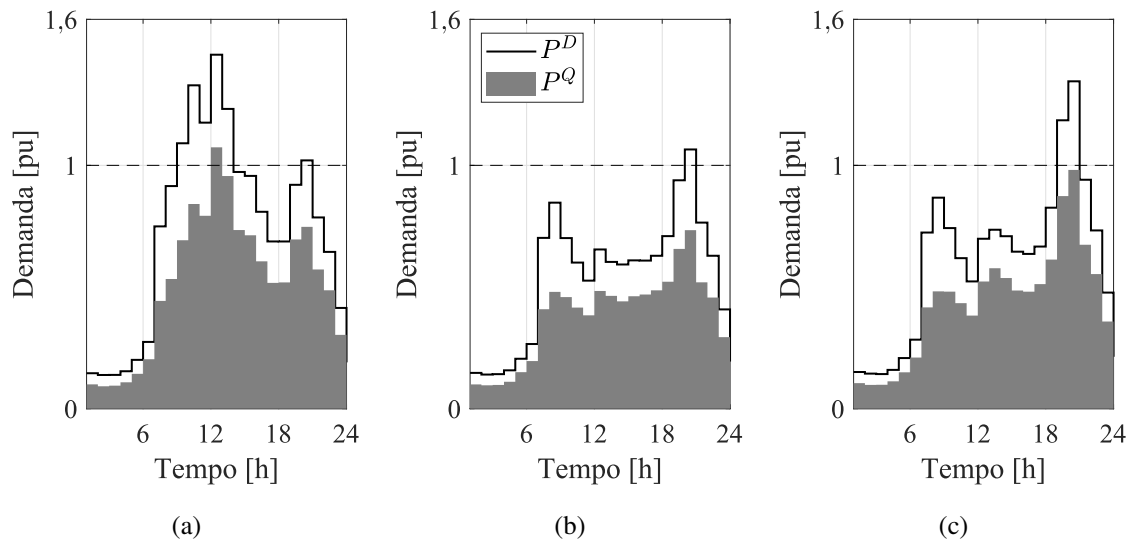
¹ As especificações dos equipamentos foram baseada em um estudo prévio de planejamento da expansão do sistema de 69 nós, proposto por Resener *et al.* (2019b).

A modelagem da cronologia de operação do sistema de 69 nós foi baseada em 3 cenários de operação, selecionada por meio do algoritmo *K-means clustering*. Tendo em vista que originalmente o sistema não apresenta curva de carga e de geração, foram sintetizados dados históricos de 1 ano de operação, de maneira análoga ao processo descrito para o sistema de 23 nós. A Figura 36 ilustra os perfis de demanda (ativa e reativa) agregada no nó 1 (subestação) do sistema de 69 nós, para os 3 cenários adotados, considerando as durações listadas na Tabela 20.

Tabela 20 – Duração de cada cenário adotado nos casos do sistema de 69 nós.

Cenário (<i>sc</i>)	Duração (ΔT_{sc}) [dias/ano]
1	112
2	135
3	118

Figura 36 – Curva de carga da demanda ativa (P^D) e reativa (Q^D), agregadas na subestação do sistema de 69 nós ($S_{base} = 4$ MVA) durante: (a) cenário 1; (b) cenário 2; e (c) cenário 3.



Fonte: Elaborado pela autora (2020).

Considerando um ano de horizonte de planejamento, a Tabela 21 apresenta o custo de operação, as perdas ativas, a violação dos limites de tensão e o tempo de processamento do PLIM proposto, que foi solucionado via CPLEX (2019). Além disso, a Tabela 22 lista os resultados do PLIM em relação à estratégia de controle volt-var adotada em cada caso.

De acordo com os resultados de operação determinística do sistema (Tabela 21), para todos os casos analisados, pequenas diferenças foram observadas entre a solução ótima do modelo linearizado proposto e o fluxo de carga convencional. Variações abaixo de 2,9% foram detectadas nos custos de operação e menores que 1% nas perdas ativas. Além disso, o modelo apresentou boa precisão na estimativa dos valores tensão, uma que a diferença máxima da violação dos limites de tensões foi de 0,04 pu, comprovando novamente a precisão do PLIM proposto.

De acordo com os resultados de operação determinística do sistema (Tabela 21), para todos os casos analisados, pequenas diferenças foram observadas entre a solução ótima do modelo linearizado proposto e o fluxo de carga convencional. Variações abaixo de 2,9% foram detectadas nos custos de operação e menores que 1% nas perdas ativas. Além disso, o modelo apresentou boa precisão na estimativa dos valores tensão, uma vez que a diferença máxima da violação dos limites de tensões foi de 0,04 pu, comprovando novamente a precisão do PLIM proposto.

Em relação aos casos com presença de RED, similarmente ao sistema de 23 nós, constatou-se a melhoria do custo de operação, sendo que o Caso BC + RT + RED indicou 38% de redução nos custos de operação em relação ao Caso Base.

Tabela 21 – Resultados do PLIM relativos à operação determinística do sistema de 69 nós.

Caso	C^{oper} [$\times 10^3$ US\$]	Perdas Ativas [MWh/year]	z^1 [pu]	Tempo de Processamento [s]
Caso Base	108,10 (-2,90%) ²	915 (0,56%) ³	0,0847 (-0,0433) ⁴	–
BC	77,32 (-1,50%)	672 (0,70%)	0,0384 (-0,0193)	81
RT	104,19 (-0,83%)	936 (0,39%)	0,0137 (-0,0146)	639
BC + RT	75,60 (-1,72%)	679 (0,05%)	0,0105 (-0,0156)	1223
Caso Base RED	97,99 (-2,28%)	837 (0,79%)	0,0676 (-0,0344)	73
BC + RED	74,83 (-1,60%)	645 (1,00%)	0,0444 (-0,0219)	81
RT + RED	94,33 (-0,70%)	853 (0,38%)	0,0051 (-0,0117)	168
BC + RT + RED	66,30 (-1,25%)	600 (0,11%)	0,0037 (-0,0104)	915

Notas:

¹ Violação dos limites de tensão calculada da seguinte forma:

$$z = \sum_{sc \in \Psi^K} \Delta T_{sc} \sum_{j \in \Psi^J} \sum_{m \in \Psi^D} z_{m,j,sc}.$$

² Diferença percentual do custo de operação em relação ao resultado obtido com fluxo de carga convencional.

³ Diferença percentual das perdas ativas em relação ao resultado obtido com fluxo de carga convencional.

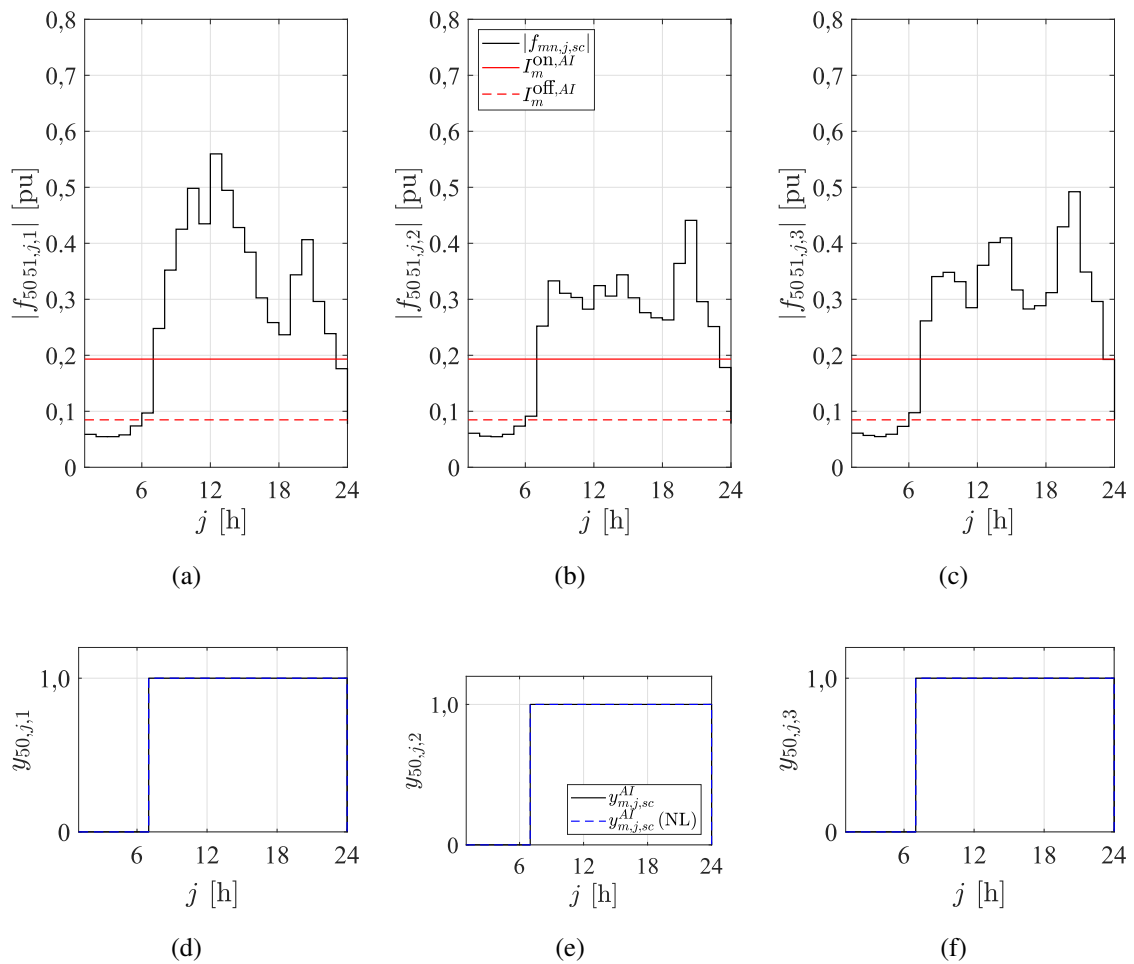
⁴ Diferença em p.u. da violação dos limites de tensão em relação ao resultado obtido com fluxo de carga convencional.

Tabela 22 – Resultados de ajuste ótimo do controle volt-var do sistema de 69 nós.

Caso	Banco de Capacitores				Regulador de Tensão	
	nó	tipo	$I_m^{on,AI}$ [pu]	$I_m^{off,AI}$ [pu]	nó	$V_m^{set,RT}$ [pu]
Caso Base	–	–	–	–	–	–
BC	50	A1200	0,1933	0,0849	–	–
RT	–	–	–	–	42	1,0275
BC + RT	50	A1200	0,1933	0,0849	42	1,0156
Caso Base RED	–	–	–	–	–	–
BC + RED	50	A600	0,1931	0,0847	–	–
RT + RED	–	–	–	–	42	1,0275
BC + RT + RED	50	A600	0,1931	0,0847	42	1,0188

Em relação ao ajuste ótimo do BC automático, constatou-se o mesmo período de operação do BC para os três cenários, conforme ilustra a Figura 37. Tendo em vista que o nó 50 apresenta a maior carga reativa instalada do alimentador (888 kvar), a solução ótima ajustou o BC para operar entre as 7 horas da manhã e a meia noite, ao longo de todo ano. Conseqüentemente, o Caso BC apresenta possibilidade de redução de 243 MWh/ano em perdas ativas.


Figura 37 – Resultados de ajuste do BC automático instalado no nó 50 do sistema de 23 nós para o Caso BC + RT + RED: (a)–(c) perfil da corrente calculado para o ramo à jusante do BC durante os cenários 1, 2 e 3; (d)–(f) estado horário de operação do BC durante os cenários 1, 2 e 3.



Fonte: Elaborado pela autora (2020).

Já a presença de RT reduz a violação dos limites de tensão, mas aumenta as perdas ativas, quando comparado ao Caso Base. Em contrapartida, o Caso BC + RT compõe uma estratégia completa de controle volt-var que reduz as perdas ativas e a violação dos limites de tensão. No entanto, originalmente o sistema não apresenta problemas de tensão, uma vez que no Caso Base observou-se violação (z) próxima à zero. Consequentemente, não foi registrada saturação do tap na histerese de controle do RT, conforme ilustra a Figura 38, para Caso BC + RT + RED.

Figura 38 – Histerese de controle do RT instalado no nó 43 do sistema de 69 nós, resultante do Caso BC + RT + RED considerando: (a) PLIM proposto; (b) fluxo de carga convencional com tensão $V_m^{\text{set,RT}}$ definida; e (c) fluxo de carga convencional com taps definidos.



Fonte: Elaborado pela autora (2020).

5 CONCLUSÃO

Uma formulação de PLIM voltada ao problema do planejamento da operação de SDEE foi proposta neste trabalho. Dentre as bibliografias publicamente disponíveis e referenciadas no Capítulo 2, o principal avanço desta tese consiste na modelagem de um problema de otimização exata, que contempla critérios probabilísticos de operação do SDEE, de modo a expressar as incertezas inerentes à demanda de energia elétrica e à injeção de potência proveniente de recursos energéticos distribuídos.

Outro fator importante é atribuído à formulação de um modelo abrangente com estratégias descentralizadas de controle volt-var. Em contraste com métodos encontrados na literatura, na formulação apresentada foram consideradas variáveis de controle explícitas para otimizar localmente a operação de bancos de capacitores e reguladores de tensão, e, simultaneamente, garantir a convergência para a solução ótima do sistema. Desta forma, o modelo proposto permite uma abordagem não-supervisionada de controle volt-var, quando não há disponível uma infraestrutura de comunicação no SDEE, mas não exclui a possibilidade de avaliar uma abordagem supervisionada na existência de sistemas de supervisão e controle. Para isso, foi considerado: (i) o controle de BCs automáticos por meio de uma histerese de corrente, tornando-os sensíveis às variações de carga a jusante; (ii) a saturação do controle do RT, permitindo operar os taps e reduzir a infactibilidade da otimização; (iii) a possibilidade de analisar a operação de RTs com compensação por queda de tensão na linha. É importante salientar que esses aspectos contribuíram para condições operativas mais próximas à realidade, uma vez que foi considerada a sensibilidade dos dispositivos volt-var às variações de demanda das cargas e injeção de potência produzida pelos REDs.

Em decorrência da crescente expansão de tecnologias inteligentes, em um futuro próximo o SDEE irá dispor de uma infraestrutura avançada de medição e uma quantidade expressiva de dados estará disponível ao planejador. Na atualidade especialistas de diversas áreas defendem a ideia de que os dados são tão valiosos quanto o petróleo, sendo necessário estabelecer métodos eficientes para a sua coleta e análise. Nessa perspectiva, a tomada de decisão com base em dados é essencial no contexto de planejamento do SDEE, e por isso, na metodologia proposta foi considerada uma análise estatística dos dados his-

tóricos de consumo e geração de energia elétrica. Desta forma, a inclusão de incertezas na operação permitiu reconhecer não somente a ocorrência da violação de tensão ou valor de perdas ativas, mas também a respectiva probabilidade de ocorrência.

O modelo formalmente apresentado no Capítulo 3 objetivou minimizar os custos de operação de SDEE, compostos pelo valor monetário das perdas ativas e a penalidade financeira das violações dos limites de tensão. Para viabilizar a solução de um PLIM, foi proposta uma função objetivo linear e restrições lineares (que descrevem os limites de operação da rede e dos equipamentos) e variáveis contínuas e binárias. Consequentemente, técnicas de linearização por partes permitiram a representação de expressões não-lineares com boa precisão. Especialmente, em relação ao cálculo das perdas ativas e da corrente de controle que é considerada na histerese do controle dos BCs automáticos.

Para representar a cronologia de operação de diferentes cargas e REDs foi utilizado o algoritmo *K-means clustering*. A partir de 3 *clusters*, o método proposto gerou combinações operacionais suficientes para representar 1095 dias registrados na base histórica de dados. Essa representação foi de suma importância para reduzir a redundância de informações sem desconsiderar as particularidades de cada carga/RED. Tendo em vista que o espaço de busca de soluções do problema de otimização é proporcional às possibilidades operacionais das cargas e REDs, é fundamental que o modelo seja capaz de determinar a solução ótima com alta precisão em um tempo razoável de processamento computacional, especialmente quando considerada operação em tempo real. Sempre vale a ressalva que o conceito de modelagem adequada pode variar com o tempo, já que modelos muito complexos hoje podem se tornar adequados no futuro com o aparecimento de novas técnicas de solução e/ou o desenvolvimento de computadores com maior capacidade de processamento que os disponíveis atualmente.

Para exemplificar o potencial do modelo proposto, a operação ótima de BCs e RTs foi resolvida de forma independente e também integrada no mesmo estudo de caso. Conforme os estudos numéricos apresentados no Capítulo 4, os resultados obtidos por meio do *solver* CPLEX, para o modelo linearizado, apresentaram boa precisão quando comparados aos resultados correspondentes obtidos com o fluxo de carga convencional. Pode-se concluir, portanto, que o modelo linearizado proposto é válido e que a solução ótima obtida evidencia a sua qualidade na aproximação de problemas originalmente não lineares. Além disso, a formulação proposta é abrangente e permite considerar a contribuição das incertezas de operação dos SDEE.

Em relação aos resultados probabilísticos, cabe salientar a importância da validação estatística da base de dados histórica a ser utilizada na modelagem das incertezas. A maioria dos estudos, no entanto, desconsidera essa etapa. Na presente tese foi utilizada a análise de variâncias, a qual permitiu avaliar o impacto de uma variável de entrada do problema (por exemplo, a demanda da carga) na variável de resposta (por exemplo, o custo de operação). Conforme demonstrado para o sistema de 23 nós, é possível que a

base de dados não atenda às premissas estatísticas necessárias, e portanto, novos dados devam ser coletados/utilizados. Essa análise também permitiu a escolha adequada do número de amostras utilizadas no cálculo das incertezas dos custos de operação, perdas ativas e violações de tensão, representadas a partir de estimativas intervalares com alto grau de confiança.

Por fim, cabe salientar que a abordagem proposta permite definir estratégias mais próximas à realidade operacional de SDEE, com flexibilidade da formulação em função das necessidades e critérios de planejamento adotados.

5.1 Trabalhos Futuros

Os resultados obtidos nesta tese permitiram vislumbrar novos desafios relacionados com o problema de planejamento da operação de SDEE:

- estender o modelo para aplicação em problemas de planejamento da expansão de SDEE;
- incluir a operação ótima de sistemas de armazenamento de energia elétrica;
- incluir a possibilidade de reconfiguração da rede por meio de chaves automáticas;
- avaliar o impacto das incertezas na qualidade da energia elétrica, a partir de indicadores probabilísticos de continuidade;
- aplicação em sistemas reais de grande porte.

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Procedimentos de distribuição**. Brasília, DF: ANEEL, 2016.

AHMADI, H.; MARTÍ, J. R.; DOMMEL, H. W. A framework for volt-VAR optimization in distribution systems. **IEEE Transactions on Smart Grid**, [S.l.], v. 6, n. 3, p. 1473–1483, 2014.

ANZANELLO JÚNIOR, J. D. **Alocação ótima de bancos de capacitores em sistemas de distribuição considerando a cronologia da operação e incertezas**. 2019. 118 p. Dissertação (Mestrado em Engenharia Elétrica) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019.

ATWA, Y. M.; EL-SAADANY, E. F. Probabilistic approach for optimal allocation of wind-based distributed generation in distribution systems. **IET Renewable Power Generation**, [S.l.], v. 5, n. 1, p. 79–88, 2011.

BAE, Y. Analytical method of capacitor allocation on distribution primary feeders. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 4, p. 1232–1238, 1978.

BARAN, M. E.; WU, F. F. Optimal capacitor placement on radial distribution systems. **IEEE Transactions on Power Delivery**, [S.l.], v. 4, n. 1, p. 725–734, 1989.

BOARDMAN, E. Advanced applications in an advanced distribution management system: essentials for implementation and integration. **IEEE Power and Energy Magazine**, [S.l.], v. 18, n. 1, p. 43–54, 2019.

BORGHETTI, A.; NAPOLITANO, F.; NUCCI, C. A. Volt/var optimization of unbalanced distribution feeders via mixed integer linear programming. **International Journal of Electrical Power & Energy Systems**, [S.l.], v. 72, p. 40–47, 2015.

BORKOWSKA, B. Probabilistic load flow. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 3, p. 752–759, 1974.

- BUNCH, J. B.; MILLER, R. D.; WHEELER, J. E. Distribution system integrated voltage and reactive power control. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 2, p. 284–289, 1982.
- CAI, D. *et al.* Probabilistic load flow algorithms considering correlation between input random variables: a review. *In: CONFERENCE ON INDUSTRIAL ELECTRONICS AND APPLICATIONS*, 10., 2015. **Proceedings [...]** [S.l.: s.n.], 2015. p. 1139–1144.
- CAMPONOGARA, E.; DE ALMEIDA, K. C.; JUNIOR, R. H. Piecewise-linear approximations for a non-linear transmission expansion planning problem. **IET Generation, Transmission & Distribution**, [S.l.], v. 9, n. 12, p. 1235–1244, 2015.
- CAVRARO, G.; CARLI, R. Local and distributed voltage control algorithms in distribution networks. **IEEE Transactions on Power Systems**, [S.l.], v. 33, n. 2, p. 1420–1430, 2018.
- CEYLAN, O.; LIU, G.; TOMSOVIC, K. Coordinated distribution network control of tap changer transformers, capacitors and PV inverters. **Electrical Engineering**, [S.l.], v. 100, n. 2, p. 1133–1146, 2018.
- CHAYAKULKHEEREE, K. Probabilistic optimal power flow: an alternative solution for emerging high uncertain power systems. *In: INTERNATIONAL ELECTRICAL ENGINEERING CONGRESS*, 2014. **Proceedings [...]** [S.l.: s.n.], 2014. p. 1–4.
- CHEN, Y. *et al.* Bringing probabilistic analysis capability from planning to operation. **Control Engineering Practice**, [S.l.], v. 71, p. 18–25, 2018.
- CIVANLAR, S.; GRAINGER, J. Volt/Var control on distribution systems with lateral branches using shunt capacitors and voltage regulators Part II: the solution method. **IEEE transactions on power apparatus and systems**, [S.l.], n. 11, p. 3284–3290, 1985.
- CIVANLAR, S.; GRAINGER, J. Volt/Var control on distribution systems with lateral branches using shunt capacitors and voltage regulators Part II: the solution method. **IEEE transactions on power apparatus and systems**, [S.l.], n. 11, p. 3284–3290, 1985.
- CONTI, S.; RAITI, S. Probabilistic load flow using Monte Carlo techniques for distribution networks with photovoltaic generators. **Solar Energy**, [S.l.], v. 81, n. 12, p. 1473–1481, 2007.
- COOK, R. Analysis of capacitor application as affected by load cycle. **Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems**, [S.l.], v. 78, n. 3, p. 950–956, 1959.

COOK, R. Optimizing the application of shunt capacitors for reactive-volt-ampere control and loss reduction. **Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems**, [S.l.], v. 80, n. 3, p. 430–441, 1961.

DABHI, D.; PANDYA, K. Enhanced velocity differential evolutionary particle swarm optimization for optimal scheduling of a distributed energy resources with uncertain scenarios. **IEEE Access**, [S.l.], v. 8, p. 27001–27017, 2020.

DABHI, D.; PANDYA, K. Uncertain scenario based microgrid optimization via hybrid levy particle swarm variable neighborhood search optimization (HL_PS_VNSO). **IEEE Access**, [S.l.], v. 8, p. 108782–108797, 2020.

DALL'ANESE, E.; DHOPLÉ, S. V.; GIANNAKIS, G. B. Optimal dispatch of photovoltaic inverters in residential distribution systems. **IEEE Transactions on Sustainable Energy**, [S.l.], v. 5, n. 2, p. 487–497, 2014.

DAVIES, D. L.; BOULDIN, D. W. A cluster separation measure. **IEEE transactions on pattern analysis and machine intelligence**, [S.l.], n. 2, p. 224–227, 1979.

DELADREUE, S. *et al.* Application of ANOVA methodology to the uncertainties management in Power System planning in an open market environment. *In: IEEE PORTO POWER TECH PROCEEDINGS (CAT. NO. 01EX502)*, 2001. **Proceedings** [...] [S.l.: s.n.], 2001. v. 1, p. 4–pp.

DOBBE, R. *et al.* Learning to control in power systems: design and analysis guidelines for concrete safety problems. **Electric Power Systems Research**, [S.l.], v. 189, p. 106615, 2020.

DUGAN, R. C. **Software OpenDSS (version 7.6.5.52)**. [S.l.]: Electric Power Research Institute (EPRI), 2018.

DURA, H. Optimum number, location, and size of shunt capacitors in radial distribution feeders a dynamic programming approach. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 9, p. 1769–1774, 1968.

EHSAN, A.; YANG, Q. State-of-the-art techniques for modelling of uncertainties in active distribution network planning: a review. **Applied energy**, [S.l.], v. 239, p. 1509–1523, 2019.

EVANGELOPOULOS, V. A.; GEORGILAKIS, P. S.; HATZIARGYRIOU, N. D. Optimal operation of smart distribution networks: a review of models, methods and future research. **Electric Power Systems Research**, [S.l.], v. 140, p. 95–106, 2016.

FERRAZ, B. P. *et al.* Analysis of distribution system considering load uncertainties: a K-means clustering approach. *In: IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE-LATIN AMERICA (ISGT LATIN AMERICA)*, 2019. **Proceedings [...]** [S.l.: s.n.], 2019. p. 1–6.

FRANCO, J. F. *et al.* A mixed-integer LP model for the optimal allocation of voltage regulators and capacitors in radial distribution systems. **International Journal of Electrical Power & Energy Systems**, [S.l.], v. 48, p. 123–130, 2013.

GONÇALVES, R. R.; FRANCO, J. F.; RIDER, M. J. Short-term expansion planning of radial electrical distribution systems using mixed-integer linear programming. **IET Generation, Transmission & Distribution**, [S.l.], v. 9, n. 3, p. 256–266, 2014.

GRAINGER, J.; CIVANLAR, S. Volt/var control on distribution systems with lateral branches using shunt capacitors and voltage regulators part I: the overall problem. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 11, p. 3278–3283, 1985.

GRAINGER, J.; CIVANLAR, S.; LEE, S. Optimal design and control scheme for continuous capacitive compensation of distribution feeders. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 10, p. 3271–3278, 1983.

GRAINGER, J. J.; LEE, S. Optimum size and location of shunt capacitors for reduction of losses on distribution feeders. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 3, p. 1105–1118, 1981.

GRAINGER, J.; LEE, S. Capacity release by shunt capacitor placement on distribution feeders: a new voltage-dependent model. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], n. 5, p. 1236–1244, 1982.

GUM. **Avaliação de dados de medição-guia para a expressão de incerteza de medição**. [S.l.]: Grupo de Trabalho 1 do Comitê Conjunto para Guias em Metrologia, 2008.

GUPTA, A. R.; KUMAR, A. Comparison of deterministic and probabilistic radial distribution systems load flow. **Journal of The Institution of Engineers**, India, v. 98, n. 6, p. 547–556, 2017.

HAFFNER, S.; PEREIRA, L. A.; GASPERIN, L. Modelo aproximado para representação de redes de distribuição de energia elétrica. *In: CONGRESSO BRASILEIRO DE AUTOMÁTICA*, 16., 2008. **Anais [...]** [S.l.: s.n.], 2008. p. 1–8.

HAFFNER, S. *et al.* Multistage model for distribution expansion planning with distributed generation—Part II: numerical results. **IEEE Transactions on Power Delivery**, [S.l.], v. 23, n. 2, p. 924–929, 2008.

- HAFFNER, S. *et al.* Allocation of capacitor banks in power distribution networks aiming to eliminate voltage violations. **SBA Controle & Automação**, [S.l.], v. 20, n. 4, p. 546–563, 2009.
- HAGH, M. T. *et al.* Probabilistic load flow using particle swarm optimization clustering method. **IET Generation, Transmission & Distribution**, [S.l.], v. 12, n. 3, p. 780–789, 2018.
- HOFFMANN, M. *et al.* A review on time series aggregation methods for energy system models. **Energies**, [S.l.], v. 13, n. 3, p. 641, 2020.
- HOME-ORTIZ, J. M. *et al.* Optimal location-allocation of storage devices and renewable-based DG in distribution systems. **Electric Power Systems Research**, [S.l.], v. 172, p. 11–21, 2019.
- HONG, T.; FAN, S. Probabilistic electric load forecasting: a tutorial review. **International Journal of Forecasting**, [S.l.], v. 32, n. 3, p. 914–938, 2016.
- IBM. **Software CPLEX Optimization Studio v 12.9.0.0**. [S.l.: s.n.], 2019.
- JABR, R. A. Robust Volt/VAR control with photovoltaics. **IEEE Transactions on Power Systems**, [S.l.], v. 34, n. 3, p. 2401–2408, 2019.
- JABR, R. A.; DŽAFIĆ, I. Sensitivity-based discrete coordinate-descent for volt/var control in distribution networks. **IEEE Transactions on Power Systems**, [S.l.], v. 31, n. 6, p. 4670–4678, 2016.
- JAIN, A. K. Data clustering: 50 years beyond K-means. **Pattern Recognition Letters**, [S.l.], v. 31, n. 8, p. 651–666, 2010.
- JHA, R. R. *et al.* Bi-level volt-VAR optimization to coordinate smart inverters with voltage control devices. **IEEE Transactions on Power Systems**, [S.l.], v. 34, n. 3, p. 1801–1813, 2019.
- JORDEHI, A. R. Optimisation of electric distribution systems: a review. **Renewable and Sustainable Energy Reviews**, [S.l.], v. 51, p. 1088–1100, 2015.
- KABIR, M.; MISHRA, Y.; BANSAL, R. Probabilistic load flow for distribution systems with uncertain PV generation. **Applied Energy**, [S.l.], v. 163, p. 343–351, 2016.
- KERSTING, W. H. **Distribution system modeling and analysis**. [S.l.]: CRC, 2001.
- KODINARIYA, T. M.; MAKWANA, P. R. Review on determining number of cluster in K-means clustering. **International Journal of Advance Research in Computer Science and Management Studies**, [S.l.], v. 1, n. 6, p. 90–95, 2013.

- KOTZUR, L. *et al.* Impact of different time series aggregation methods on optimal energy system design. **Renewable Energy**, [S.l.], v. 117, p. 474–487, 2018.
- KUMAR, K.; SATSANGI, S.; KUMBHAR, G. B. Extension of life of distribution transformer using Volt-VAr optimisation in a distribution system. **IET Generation, Transmission & Distribution**, [S.l.], v. 13, n. 10, p. 1777–1785, 2019.
- LAUTENSCHLEGER, A. H.; FERRAZ, B. M. P.; HAFFNER, S. Análise do desempenho de sistemas de distribuição considerando incertezas na carga. *In: XXII CONGRESSO BRASILEIRO DE AUTOMÁTICA*, 2018. **Anais [...]** [S.l.: s.n.], 2018. p. 1–6.
- LI, R. *et al.* A review of optimal planning active distribution system: models, methods, and future researches. **Energies**, [S.l.], v. 10, n. 11, p. 1715, 2017.
- LI, R.; WANG, W.; XIA, M. Cooperative planning of active distribution system with renewable energy sources and energy storage systems. **IEEE Access**, [S.l.], v. 6, p. 5916–5926, 2018.
- LI, W. **Probabilistic transmission system planning**. [S.l.]: John Wiley & Sons, 2011. v. 65.
- LIN, W.; BITAR, E. Decentralized stochastic control of distributed energy resources. **IEEE Transactions on Power Systems**, [S.l.], v. 33, n. 1, p. 888–900, 2017.
- LIU, Y. *et al.* Probabilistic load flow considering correlations of input variables following arbitrary distributions. **Electric Power Systems Research**, [S.l.], v. 140, p. 354–362, 2016.
- MACEDO, L. H. *et al.* Optimal operation of distribution networks considering energy storage devices. **IEEE Transactions on smart grid**, [S.l.], v. 6, n. 6, p. 2825–2836, 2015.
- MACQUEEN, J. *et al.* Some methods for classification and analysis of multivariate observations. *In: BERKELEY SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY*, 1967. **Proceedings [...]** [S.l.: s.n.], 1967. p. 281–297.
- MALEKPOUR, A. R.; ANNASWAMY, A. M.; SHAH, J. Hierarchical hybrid architecture for volt/var control of power distribution grids. **IEEE Transactions on Power Systems**, [S.l.], v. 35, n. 2, p. 854–863, 2020.
- MANBACHI, M. *et al.* Impact of EV penetration on volt–var optimization of distribution networks using real-time co-simulation monitoring platform. **Applied Energy**, [S.l.], v. 169, p. 28–39, 2016.

MANBACHI, M. *et al.* Smart grid adaptive volt-VAR optimization: challenges for sustainable future grids. **Sustainable Cities and Society**, [S.l.], v. 28, p. 242–255, 2017.

MATHWORKS. **Software Matlab (version R2019a)**. 2019.

MEHIGAN, L. *et al.* A review of the role of distributed generation (DG) in future electricity systems. **Energy**, [S.l.], v. 163, p. 822–836, 2018.

MOITRE, D.; MAGNAGO, F. Using manova methodology in a competitive electric market under uncertainties. *In: IEEE/PES TRANSMISSION & DISTRIBUTION CONFERENCE AND EXPOSITION: LATIN AMERICA, 2006. Proceedings [...]* [S.l.: s.n.], 2006. p. 1–6.

MOITRE, D.; MAGNAGO, F. Multivariate analysis of variance applied to competitive electricity markets: the fixed effects model. *In: IEEE POWER ENGINEERING SOCIETY GENERAL MEETING, 2007. Proceedings [...]* [S.l.: s.n.], 2007. p. 1–7.

MONTGOMERY, D. C. **Design and analysis of experiments**. [S.l.]: John Wiley, 2017.

MORADIJOZ, M.; MOGHADDAM, M. P.; HAGHIFAM, M. A flexible active distribution system expansion planning model: a risk-based approach. **Energy**, [S.l.], v. 145, p. 442–457, 2018.

NEAGLE, N.; SAMSON, D. Loss reduction from capacitors installed on primary feeders [includes discussion]. **Transactions of the American Institute of Electrical Engineers. Part III: Power Apparatus and Systems**, [S.l.], v. 75, n. 3, p. 950–959, 1956.

PAMSHETTI, V. B.; SINGH, S.; SINGH, S. P. Combined impact of network reconfiguration and volt-var control devices on energy savings in the presence of distributed generation. **IEEE Systems Journal**, [S.l.], p. 1–12, 2019.

PAREJA, L. A. G. **Fluxo de potência em redes de distribuição de energia elétrica considerando incertezas**. 2009. 156 p. Tese (Doutorado em Engenharia Elétrica) — PPGEE UNESP, Ilha Solteira, SP, 2009.

PFENNINGER, S.; STAFFELL, I. Long-term patterns of European PV output using 30 years of validated hourly reanalysis and satellite data. **Energy**, [S.l.], v. 114, p. 1251–1265, 2016.

PFLUGRADT, N. **Load Profile Generator (version 1.3.5)**. 2018.

PRUSTY, B. R.; JENA, D. A critical review on probabilistic load flow studies in uncertainty constrained power systems with photovoltaic generation and a new approach. **Renewable and Sustainable Energy Reviews**, [S.l.], v. 69, p. 1286–1302, 2017.

QIAO, X. *et al.* Impact of uncertainty and correlation on operation of micro-integrated energy system. **International Journal of Electrical Power & Energy Systems**, [S.l.], v. 112, p. 262–271, 2019.

RESENER, M. **Modelo linearizado para problemas de planejamento da expansão de sistemas de distribuição**. 2016. 199 p. Tese (Doutorado em Engenharia Elétrica) — UFRGS, Porto Alegre, RS, 2016.

RESENER, M. *et al.* Mixed-integer LP model for volt/var control and energy losses minimization in distribution systems. **Electric Power Systems Research**, [S.l.], v. 140, p. 895–905, 2016.

RESENER, M. *et al.* A convex model for the optimization of distribution systems with distributed generation. In: BERTSCHWOLF, V. *et al.* (Ed.). **Advances in energy system optimization**. [S.l.]: Springer, 2017. p. 231–245.

RESENER, M. *et al.* Optimization techniques applied to planning of electric power distribution systems: a bibliographic survey. **Energy Systems**, [S.l.], v. 9, n. 3, p. 473–509, 2018.

RESENER, M. *et al.* A comprehensive MILP model for the expansion planning of power distribution systems—Part I: problem formulation. **Electric Power Systems Research**, [S.l.], v. 170, p. 378–384, 2019.

RESENER, M. *et al.* A comprehensive MILP model for the expansion planning of power distribution systems—Part II: numerical results. **Electric Power Systems Research**, [S.l.], v. 170, p. 317–325, 2019.

RIBEIRO, É. T. A. **Modelos de programação inteira mista para a alocação ótima de bancos de capacitores em sistemas de distribuição de energia elétrica radiais**. 2013. Dissertação (Mestrado em Engenharia Elétrica) — Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, 2013.

ROSTAMI, A.; MOHAMMADI, M.; RASTEGAR, M. An improved transformation based probabilistic load flow analysis using appropriate reference variable. **International Journal of Electrical Power & Energy Systems**, [S.l.], v. 120, p. 106052, 2020.

ROSTRON, P. D.; FEARN, T.; RAMSEY, M. H. Confidence intervals for robust estimates of measurement uncertainty. **Accreditation and Quality Assurance**, [S.l.], p. 1–13, 2020.

ROYTELMAN, I.; SHAHIDEHPOUR, S. Practical aspects of distribution automation in normal and emergency conditions. **IEEE Transactions on Power Delivery**, [S.l.], v. 8, n. 4, p. 2002–2008, 1993.

SABILLON-ANTUNEZ, C. *et al.* Volt-Var control and energy storage device operation to improve the electric vehicle charging coordination in unbalanced distribution networks. **IEEE Transactions on Sustainable Energy**, [S.l.], v. 8, n. 4, p. 1560–1570, 2017.

SAMBALIAH, K. S.; JAYABARATHI, T. Loss minimization techniques for optimal operation and planning of distribution systems: a review of different methodologies. **International Transactions on Electrical Energy Systems**, [S.l.], v. 30, n. 2, p. e12230, 2020.

SAMET, H.; KHORSHIDSAVAR, M. Analytic time series load flow. **Renewable and Sustainable Energy Reviews**, [S.l.], v. 82, p. 3886–3899, 2018.

SAMIMI, A.; KAZEMI, A. Coordinated Volt/Var control in distribution systems with distributed generations based on joint active and reactive powers dispatch. **Applied Sciences**, [S.l.], v. 6, n. 1, p. 4, 2016.

SANNIGRAHI, S.; ROY GHATAK, S.; ACHARJEE, P. Multi-Scenario based bi-level coordinated planning of active distribution system under uncertain environment. **IEEE Transactions on Industry Applications**, [S.l.], p. 1–12, 2019.

SCHMILL, J. Optimum size and location of shunt capacitors on distribution feeders. **IEEE Transactions on Power Apparatus and Systems**, [S.l.], v. 84, n. 9, p. 825–832, 1965.

SOARES, B. R. d. C. **Aplicação de técnica de linearização por partes a problemas de planejamento da operação de sistemas hidrotérmicos**. 2017. 166 p. Tese (Doutorado em Engenharia Elétrica) — PPGEE UFSC, Florianópolis, SC, 2017.

SOFTWARE, M. . S. **Minitab reference manual**. [S.l.]: Minitab Inc. State College, PA, 2017.

STAFFELL, I.; PFENNINGER, S. Using bias-corrected reanalysis to simulate current and future wind power output. **Energy**, [S.l.], v. 114, p. 1224–1239, 2016.

TAHIR, M. *et al.* A review of Volt/Var control techniques in passive and active power distribution networks. *In: IEEE SMART ENERGY GRID ENGINEERING (SEGE)*, 2016. **Proceedings [...]** [S.l.: s.n.], 2016. p. 57–63.

- TEICHGRAEBER, H.; BRANDT, A. R. Clustering methods to find representative periods for the optimization of energy systems: an initial framework and comparison. **Applied Energy**, [S.l.], v. 239, p. 1283–1293, 2019.
- TURITSYN, K. *et al.* Options for control of reactive power by distributed photovoltaic generators. **Proceedings of the IEEE**, [S.l.], v. 99, n. 6, p. 1063–1073, 2011.
- VAN HENTENRYCK, P. **The OPL optimization programming language**. [S.l.]: MIT, 1999.
- VÍTOR, T. S.; ASADA, E. N.; VIEIRA, J. C. d. M. Optimal volt/var control applied to modern distribution systems. In: RESENER, M. *et al.* (Ed.). **Handbook of optimization in electric power distribution systems**. [S.l.]: Springer, 2020. p. 1–56.
- WANG, C. *et al.* A scenario-based analytical method for probabilistic load flow analysis. **Electric Power Systems Research**, [S.l.], v. 181, p. 106193, 2020.
- XU, Y.; MILI, L.; ZHAO, J. Probabilistic power flow calculation and variance analysis based on hierarchical adaptive polynomial chaos-ANOVA method. **IEEE Transactions on Power Systems**, [S.l.], v. 34, n. 5, p. 3316–3325, 2019.
- YEH, H.-G.; GAYME, D. F.; LOW, S. H. Adaptive VAR control for distribution circuits with photovoltaic generators. **IEEE Transactions on Power Systems**, [S.l.], v. 27, n. 3, p. 1656–1663, 2012.
- YILMAZ, M.; EL-SHATSHAT, R. State-based Volt/VAR control strategies for active distribution networks. **International Journal of Electrical Power & Energy Systems**, [S.l.], v. 100, p. 411–421, 2018.
- ZATTI, M. *et al.* k-MILP: a novel clustering approach to select typical and extreme days for multi-energy systems design optimization. **Energy**, [S.l.], v. 181, p. 1051–1063, 2019.
- ZHANG, C.; XU, Y. Hierarchically-coordinated voltage/var control of distribution networks using PV inverters. **IEEE Transactions on Smart Grid**, [S.l.], 2020.
- ZHANG, J. *et al.* An improved probabilistic load flow simulation method considering correlated stochastic variables. **International Journal of Electrical Power & Energy Systems**, [S.l.], v. 111, p. 260–268, 2019.

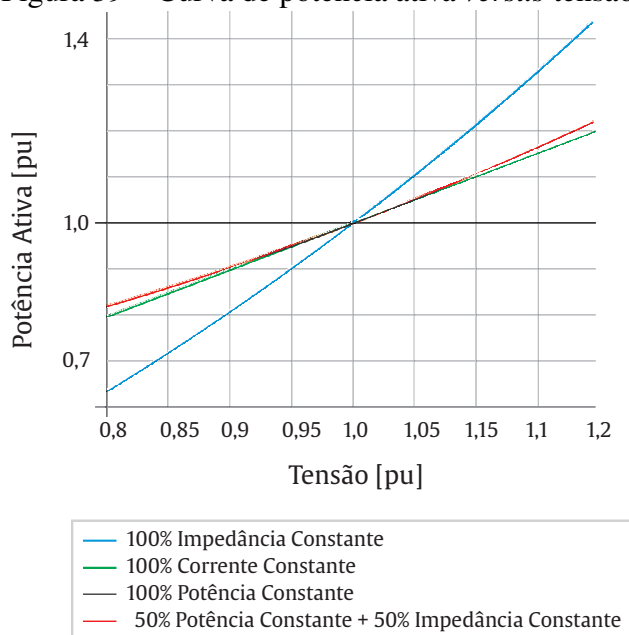
6 REPRESENTAÇÃO DOS SISTEMA DE DISTRIBUIÇÃO

Neste apêndice é descrita a formulação dos componentes de SDEE já utilizados em trabalhos anteriores Haffner *et al.* (2009) e Resener (2016). A referida formulação foi adaptada para lidar com cenários e períodos de tempo com cronologia sequencial – antes os modelos consideravam uma curva de duração que era dividida em níveis de carregamento, mas não havia sequenciamento temporal entre estes níveis.

6.1 Representação dos Componentes de SDEE

Para representação das cargas é adotado o modelo de injeção constante de corrente (intermediário entre potência constante e impedância constante), proposto por Resener (2016) e ilustrado na Figura 39, o que permite que as correntes dos ramos e tensões nodais sejam representadas com expressões lineares, sem a necessidade de processo iterativo.

Figura 39 – Curva de potência ativa *versus* tensão.



Fonte: Adaptado de Resener (2016).

Desta forma, as correntes demandadas em cada nó são obtidas a partir das demandas

de potência ativa e reativa para cada cenário típico sc do período de operação j , pertencente à amostra s , considerando que as cargas são trifásicas e equilibradas, os ângulos de fase das tensões são idênticos e iguais a zero, as magnitudes das tensões são iguais aos seus valores nominais (HAFFNER; PEREIRA; GASPERIN, 2008). Neste caso, considerando o circuito equivalente por fase e utilizando grandezas por unidade, as correntes demandadas pelas cargas $\forall m \in \Psi^D$, $j \in \Psi^J$, $sc \in \Psi_s^K$, $s \in \Psi^S$ são obtidas pela seguinte expressão:

$$d_{m,j,sc,s}^{\text{Re}} + jd_{m,j,sc,s}^{\text{Im}} = \left(\frac{\bar{S}_{m,j,sc,s}^D}{\bar{V}_{m,j,sc,s}} \right)^* = \left(\frac{P_{m,j,sc,s}^D - jQ_{m,j,sc,s}^D}{\bar{V}_{m,j,sc,s}} \right)^* \quad (6.1)$$

onde $d_{m,j,sc,s}^{\text{Re}}$ e $d_{m,j,sc,s}^{\text{Im}}$ correspondem às parcelas real e imaginária da corrente demandada, $\bar{S}_{m,j,sc,s}^D$ representa a demanda complexa, $\bar{V}_{m,j,sc,s}$ é o fasor tensão, $P_{m,j,sc,s}^D$ representa a potência ativa e $Q_{m,j,sc,s}^D$, a potência reativa, relativos ao nó m durante o período de operação j e cenário sc , pertencente à amostra s . Considerando a tensão nominal ($\bar{V}_{m,j,sc,s} = 1/\underline{0}$ pu), tem-se que:

$$d_{m,j,sc,s}^{\text{Re}} + jd_{m,j,sc,s}^{\text{Im}} = P_{m,j,sc,s}^D - jQ_{m,j,sc,s}^D \quad (6.2)$$

O efeito da existência de um BC em um nó corresponde à inclusão de uma demanda de corrente adiantada com relação à tensão, ou seja, uma demanda com parte imaginária positiva (HAFFNER; PEREIRA; GASPERIN, 2008). Deste modo, as correntes demandadas pelos BCs para todo o nó candidato à instalação de BC ($\forall m \in \Psi^{BC}$) são expressas por:

$$(jd_{m,j,sc,s}^{\text{Im}})^{BC} = \left(\frac{-jQ_m^{BC}}{\bar{V}_{m,j,sc,s}} \right)^* \quad (6.3)$$

onde Q_m^{BC} refere-se à potência nominal (em pu) do BC instalado no nó m , durante o período de operação j e cenário sc , pertencente à amostra s . O valor da demanda de corrente associada a cada banco BC também pode ser determinado a partir da sua potência nominal, considerando que o mesmo opera com tensão nominal ($\bar{V}_{m,j,sc,s} = 1/\underline{0}$ pu) conforme:

$$(jd_{m,j,sc,s}^{\text{Im}})^{BC} = jQ_m^{BC} \quad (6.4)$$

sendo $Q_m^{BC} < 0$ a potência reativa do BC candidato à instalação no nó m para qualquer período de operação j e cenário sc , pertencente à amostra s .

Para avaliar o impacto da inclusão de um banco de capacitores em um determinado nó da rede, o termo obtido pela expressão (6.4) deve ser acrescido à demanda deste nó conforme:

$$d_{m,j,sc,s}^{\text{Re}} + jd_{m,j,sc,s}^{\text{Im}} = P_{m,j,sc,s}^D - \left(jQ_{m,j,sc,s}^D + jQ_m^{BC} \right) \quad (6.5)$$

A modelagem dos bancos de capacitores como corrente constante permite uso de expressões lineares, no entanto, o modelo de impedância constante possibilita representar

com maior fidelidade o comportamento destes equipamentos, quando a localização, capacidade e estado de operação não são previamente definidos, mesmo em condições extremas de operação (quando a tensão é muito distante do valor nominal). Desta forma, determina-se a demanda de corrente associada ao BC considerando a magnitude de tensão de operação para cada período de operação j e cenário sc , pertencente à amostra s . Sendo a admitância de um BC (em pu) no nó m definida por:

$$Y_m^{BC} = \frac{(-jQ_m^{BC})^*}{|\bar{V}_{m,j,sc,s}|^2} \quad (6.6)$$

Deste modo, para tensão nominal ($\bar{V}_{m,j,sc,s} = 1/\underline{0}$ pu) tem-se:

$$Y_m^{BC} = jQ_m^{BC} \quad (6.7)$$

Logo, a demanda de corrente (em pu) é obtida conforme:

$$(jd_{m,j,sc,s}^{Im})^{BC} = V_{m,j,sc,s} Y_m^{BC} = jV_{m,j,sc,s} Q_m^{BC} \quad (6.8)$$

Observa-se que quando a expressão (6.8) é utilizada, a demanda de corrente de cada banco depende do nó de instalação, do período de operação e do cenário considerado. Alternativamente, quando a injeção do BC é dada pela expressão (6.8), a expressão (6.5) torna-se:

$$d_{m,j,sc,s}^{Re} + jd_{m,j,sc,s}^{Im} = P_{m,j,sc,s}^D - \left(jQ_{m,j,sc,s}^D + jV_{m,j,sc,s} Q_m^{BC} \right) \quad (6.9)$$

Os reguladores de tensão são representados neste trabalho pela inclusão de uma barra adicional, a montante da barra de instalação e pela inclusão de uma fonte ideal de tensão com amplitude dependendo do tap de operação do equipamento. A descrição completa da representação dos reguladores de tensão utilizada nesta tese, consta detalhada em Resener (2016, p.74–80).

Os geradores são representados por injeções de corrente com componentes real ($g_{m,j,sc,s}^{Re}$) e imaginária ($g_{m,j,sc,s}^{Im}$) definidas para todo o nó com capacidade de geração ($\forall m \in \psi^G$). Usualmente uma das barras ou nó com capacidade de geração é escolhido para fechar o balanço de corrente, da mesma forma como ocorre no fluxo convencional, para fechar o balanço de potência (RESENER, 2016). De maneira a determinar o modo ótimo de operação da geração distribuída (GD), ao invés de serem especificados valores para a tensão e para as injeções ativa e reativa dos geradores, é recomendável trabalhar com limites para estas variáveis, conforme lista a Tabela 23.

Para representar a rede de distribuição é utilizado um modelo por fase linearizado, definido a partir de um ponto de operação no qual os equipamentos de compensação de fator de potência e de regulação de tensão não estão presentes. No modelo linearizado utilizado, os fasores tensão são representados por grandezas reais que representam apenas a sua magnitude (o ângulo de fase é considerado igual a zero para todas as tensões),

Tabela 23 – Limites segundo o modelo de operação dos geradores.


Limites	Modos de Operação	
	Barra PQ	Barra PV
V_m^{\min}	V_m^{\min}	$V_{m,j,sc,s}^{\text{esp}}$
V_m^{\max}	V_m^{\max}	$V_{m,j,sc,s}^{\text{esp}}$
$g_{m,j,sc,s}^{\min, \text{Re}}$	$g_{m,j,sc,s}^{\text{esp, Re}}$	$g_{m,j,sc,s}^{\text{esp, Re}}$
$g_{m,j,sc,s}^{\max, \text{Re}}$	$g_{m,j,sc,s}^{\text{esp, Re}}$	$g_{m,j,sc,s}^{\text{esp, Re}}$
$g_{m,j,sc,s}^{\min, \text{Im}}$	$g_{m,j,sc,s}^{\text{esp, Im}}$	$g_{m,j,sc,s}^{\min, \text{Im}}$
$g_{m,j,sc,s}^{\max, \text{Im}}$	$g_{m,j,sc,s}^{\text{esp, Im}}$	$g_{m,j,sc,s}^{\max, \text{Im}}$
$g_{m,j,sc,s}$	$g_{m,j,sc,s}$	$g_{m,j,sc,s}$

Fonte: Adaptado de Resener (2016).

as impedâncias e as correntes são representadas por duas parcelas cada. As quedas de tensão nos ramos da rede são calculadas a partir de uma aproximação do produto do fasor corrente pelo seu respectivo fasor impedância (HAFFNER; PEREIRA; GASPERIN, 2008). Além disso, as correntes que representam as demandas, geração, SAE e BC, possuem duas componentes: uma parcela real, relacionada com a potência ativa; outra parcela imaginária, relacionada com a potência reativa. Deste modo, conforme o sistema ilustrado pela Figura 40, o fluxo no ramo $km \forall km \in \psi^B$ é expresso por:

$$\bar{f}_{km,j,sc,s} = f_{km,j,sc,s}^{\text{Re}} + j f_{km,j,sc,s}^{\text{Im}} \quad (6.10)$$

é expresso por: onde $f_{km,j,sc,s}^{\text{Re}}$ e $f_{km,j,sc,s}^{\text{Im}}$ correspondem, respectivamente, às partes real e imaginária da corrente no ramo km no período de operação j e cenário sc , pertencente à amostra s (em pu).



Fonte: Adaptado de Resener (2016).

Analogamente, a impedância série Z do ramo km é dada por:

$$\bar{Z}_{km} = R_{km} + jX_{km} \quad (6.11)$$

onde R_{km} , X_{km} representam a resistência e reatância do trecho de rede km (em pu).

Segundo Resener (2016), a partir das expressões (6.10) e (6.11), pode-se calcular o fasor queda de tensão no ramo km , desprezando a parte imaginária, conforme o seguinte

equacionamento:

$$\begin{aligned}\Delta \bar{V}_{km,j,sc,s} &= \bar{V}_{k,j,sc,s} - \bar{V}_{m,j,sc,s} \\ \Delta \bar{V}_{km,j,sc,s} &= (R_{km} + jX_{km}) \left(f_{km,j,sc,s}^{\text{Re}} + j f_{km,j,sc,s}^{\text{Im}} \right) \\ \Delta V_{km,j,sc,s} &\approx R_{km} f_{km,j,sc,s}^{\text{Re}} - X_{km} f_{km,j,sc,s}^{\text{Im}}\end{aligned}\quad (6.12)$$

De forma à igualar a solução obtida pelo modelo linearizado com a solução exata do fluxo de carga ($\Delta V_{km,j,sc,s}^{\text{FC}}$), HAFFNER; PEREIRA; GASPERIN (2008) propõem uma alteração no cálculo de queda de tensão no ramo km durante o período de operação j e cenário sc , pertencente à amostra s , conforme:

$$\Delta V_{km,j,sc,s}^{\text{ML}} = K_{km,j,sc,s} R_{km} f_{km,j,sc,s}^{\text{Re}} - X_{km} f_{km,j,sc,s}^{\text{Im}} \quad (6.13)$$

incluindo de um fator de ajuste $K_{km,j,sc,s}$, dado por:

$$K_{km,j,sc,s} = \frac{\Delta V_{km,j,sc,s}^{\text{FC}} + X_{km} f_{km,j,sc,s}^{\text{Im}}}{R_{km} f_{km,j,sc,s}^{\text{Re}}} \quad (6.14)$$

Resener (2016) explica que valor de $\Delta V_{km,j,sc,s}^{\text{FC}}$ é obtido por intermédio de um fluxo de carga não linear para obter as quedas de tensão nos ramos e a partir das Leis de Kirchhoff são calculados os fluxos de corrente. Observa-se ainda, que o fator $K_{km,j,sc,s}$ geralmente encontra-se próximo à unidade (HAFFNER *et al.*, 2009).

6.2 Representação das Grandezas de Interesse

De maneira à quantificar o impacto financeiro no custo de operação dos desvios de tensão e das perdas ativas, a seguir constam a modelagem dessas grandezas de interesse.


6.2.1 Desvio da Tensão Nodal

A minimização do desvio da tensão nodal foi proposta por Haffner, Pereira e Gasperin (2008) visando atender aos limites mínimo e máximo estabelecidos pela ANEEL (2016). Propõe-se então, complementar tal abordagem com a inclusão das incertezas, de maneira à obter o menor desvio de tensão nodal $z_{m,j,sc,s}$ com relação aos seus limites mínimo e máximo, $\forall m \in \Psi^D$, $j \in \Psi^J$, $sc \in \Psi^K$, $s \in \Psi^S$, por intermédio do seguinte equacionamento:

$$\begin{aligned}\min \quad & z_{m,j,sc,s} \\ \text{s.a.} \quad & z_{m,j,sc,s} \geq V_{m,j,sc,s} - 1,1290 V_m^{\text{ref}} \\ & z_{m,j,sc,s} \geq V_m^{\text{ref}} - V_{m,j,sc,s} \\ & z_{m,j,sc,s} \geq 0 \\ & V_m^{\text{ref}} \geq V_m^{\text{min}} = 0,8370 \\ & V_m^{\text{ref}} \leq 0,8857 V_m^{\text{max}} = 0,93\end{aligned}\quad (6.15)$$

onde $V_{m,j,sc,s}$ é a tensão no nó m durante o período de operação j e cenário sc , pertencente à amostra s , V_m^{\min} e V_m^{\max} representam os limites de tensão (mínimo e máximo) e V_m^{ref} é a tensão de referência, que permite flexibilizar os limites de tensão. A solução do problema de otimização, definido pela expressão (6.15), pertence a um ponto dos segmentos de reta em destaque da Figura 41, sendo que a área hachurada representa a região viável.

Figura 41 – Função de representação da violação dos limite de tensão - limites móveis.



Fonte: Adaptado de Haffner *et al.* (2009).

6.2.2 Perdas Ativas

No modelo proposto por Resener *et al.* (2017), as perdas são estimadas por intermédio de uma aproximação linear quadrática que quantifica o valor dos quadrados dos termos real e imaginário das correntes nos ramos. De maneira análoga ao desvio nodal de tensão, a presente tese propõe a inclusão de incertezas, provenientes da operação da GD e da carga. Portanto, seja $f_{km,j,sc,s}$ a corrente no ramo km durante o período de operação j e cenário sc , pertencente à amostra s , $\forall km \in \Psi^B$, $j \in \Psi^J$, $sc \in \Psi^K$, $s \in \Psi^S$, pode-se afirmar que:

$$|f_{km,j,sc,s}|^2 = \left(f_{km,j,sc,s}^{\text{Re}}\right)^2 + \left(f_{km,j,sc,s}^{\text{Im}}\right)^2 \quad (6.16)$$

Assim sendo, as perdas ativas no ramo km são expressas por:

$$P_{km,j,sc,s}^{\text{perdas}} = R_{km} \left(f_{km,j,sc,s}^{\text{Re}}\right)^2 + R_{km} \left(f_{km,j,sc,s}^{\text{Im}}\right)^2 \quad (6.17)$$

Conforme ilustra a Figura 42, as parcelas $\left(f_{km,j,sc,s}^{\text{Re}}\right)^2$ e $\left(f_{km,j,sc,s}^{\text{Im}}\right)^2$ podem ser aproximadas por N^{RL} expressões lineares, dadas por:


$$\left(f_{km,j,sc,s}^{\text{Re}}\right)^2 \approx f_{km,j,sc,s}^{2\text{Re}} \geq a_p f_{km,j,sc,s}^{\text{Re}} + b_p \quad (6.18)$$

$$\left(f_{km,j,sc,s}^{\text{Im}}\right)^2 \approx f_{km,j,sc,s}^{2\text{Im}} \geq a_p f_{km,j,sc,s}^{\text{Im}} + b_p \quad (6.19)$$

onde $p = 1, 2, \dots, N^{RL}$, a_p e b_p são constantes e N^{RL} é o número de restrições lineares. Observa-se que a precisão da aproximação está atrelada à N^{RL} . Reescrevendo a expressão 6.17, as perdas ativas podem ser expressas por:

$$P_{km,j,sc,s}^{\text{perdas}} \approx R_{km} \left(f_{km,j,sc,s}^{2\text{Re}}\right) + R_{km} \left(f_{km,j,sc,s}^{2\text{Im}}\right) \quad (6.20)$$

Figura 42 – Restrições lineares utilizadas para aproximar as perdas ativas nas linhas.



Fonte: Adaptado de Resener (2016).

7 DADOS UTILIZADOS NAS SIMULAÇÕES

Neste apêndice são apresentados os dados obtidos com o algoritmo *K-means clustering* para o sistema de 23 nós no problema de operação determinística apresentado no Capítulo 4. O detalhamento dos sistemas de 23 nós e 69 nós, em relação às impedâncias dos ramos e cargas instaladas nos nós, são apresentados em Resener *et al.* (2016).

Tabela 24: Valores de demanda ativa [kW] dos nós 2 à 12.

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		2	3	4	5	6	7	8	9	10	11	12
1	1	19	35	30	37	28	25	29	36	27	40	21
1	2	17	32	27	35	26	24	28	34	26	39	19
1	3	17	32	27	35	26	24	28	34	26	41	19
1	4	18	35	30	39	29	25	30	38	29	47	21
1	5	25	42	39	43	41	34	40	40	42	57	27
1	6	38	51	53	50	56	50	55	46	63	76	39
1	7	130	160	154	152	164	156	155	145	147	199	124
1	8	193	195	185	168	194	188	190	186	152	228	171
1	9	239	226	229	217	228	215	212	241	198	234	200
1	10	277	269	283	244	283	272	271	275	258	254	250
1	11	239	234	253	208	239	249	232	230	235	218	218
1	12	283	315	340	231	263	344	258	258	292	265	222
1	13	268	241	260	200	234	278	238	224	267	210	217
1	14	227	180	196	162	202	204	211	187	201	170	199
1	15	216	217	206	160	192	196	191	172	188	171	176
1	16	154	189	171	144	160	160	155	144	158	170	145
1	17	125	149	144	114	144	129	144	132	128	153	131
1	18	115	141	143	108	134	137	142	123	134	150	124
1	19	179	170	188	146	184	211	178	169	175	175	163
1	20	215	212	217	172	220	226	198	196	187	193	190
1	21	158	168	166	156	160	168	165	163	141	159	143
1	22	130	151	128	141	122	129	132	141	123	132	110
1	23	86	104	83	85	85	79	85	90	73	85	74
1	24	29	44	39	42	38	36	38	42	34	47	27
2	1	21	36	30	37	30	25	31	37	27	41	22
2	2	18	34	28	36	27	24	28	36	26	40	20

(Continua na próxima página.)

Tabela 24 – Valores de demanda ativa [kW] dos nós 2 à 12 (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		2	3	4	5	6	7	8	9	10	11	12
2	3	18	34	28	38	27	24	28	37	27	43	19
2	4	19	36	30	43	30	25	31	41	31	51	21
2	5	26	44	40	47	42	34	40	44	44	62	27
2	6	38	51	54	52	54	50	52	47	63	73	36
2	7	131	190	141	126	158	157	152	130	127	181	133
2	8	186	194	163	147	181	182	182	176	126	187	166
2	9	164	124	123	134	141	140	142	154	127	127	147
2	10	133	90	102	141	118	100	121	144	122	104	147
2	11	107	87	96	136	103	86	102	115	116	100	132
2	12	115	73	134	141	109	119	100	137	160	97	145
2	13	105	76	107	118	101	101	104	104	138	100	135
2	14	100	77	101	114	110	87	120	103	126	104	148
2	15	101	75	105	140	106	98	116	102	145	120	150
2	16	94	74	103	152	105	98	116	105	145	120	160
2	17	112	83	112	142	113	118	121	112	142	116	147
2	18	143	137	153	140	137	158	129	128	152	137	127
2	19	224	209	227	173	203	251	180	184	200	168	165
2	20	266	257	247	187	242	264	220	208	214	193	210
2	21	170	176	174	144	172	180	176	156	153	146	155
2	22	131	153	129	132	123	135	131	130	124	116	114
2	23	84	110	82	88	82	76	84	90	74	83	69
2	24	29	50	38	44	37	35	40	43	35	46	28
3	1	21	36	31	37	30	26	31	37	26	40	21
3	2	18	34	29	37	27	24	29	37	26	41	20
3	3	18	34	28	37	27	24	28	35	26	41	19
3	4	19	35	31	43	30	25	30	41	32	51	21
3	5	25	43	40	47	40	35	41	43	45	64	28
3	6	37	51	54	50	56	51	55	45	63	74	39
3	7	129	200	135	130	157	150	150	124	127	182	138
3	8	189	198	166	146	180	184	178	175	128	192	167
3	9	184	135	126	153	157	144	162	178	134	140	175
3	10	156	109	103	164	139	104	145	168	127	124	180
3	11	118	88	96	150	107	84	108	131	118	101	150
3	12	130	84	135	176	121	115	107	155	173	104	181
3	13	165	103	127	213	153	111	161	172	193	128	266
3	14	186	114	114	212	171	95	183	179	173	126	292
3	15	146	97	117	164	139	104	148	136	159	133	201
3	16	107	80	113	149	114	108	128	121	148	134	157
3	17	125	96	122	139	121	125	134	122	142	125	148
3	18	163	151	167	152	151	173	155	142	160	150	145
3	19	236	247	247	201	221	274	199	203	211	185	185
3	20	292	286	278	209	267	298	247	228	233	211	229
3	21	170	196	184	157	173	196	179	156	167	155	157

(Continua na próxima página.)

Tabela 24 – Valores de demanda ativa [kW] dos nós 2 à 12 (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		2	3	4	5	6	7	8	9	10	11	12
3	22	157	204	134	155	135	142	153	154	135	131	142
3	23	101	136	92	110	90	88	103	108	92	95	85
3	24	33	58	45	52	42	38	47	50	42	54	34

Tabela 25: Valores de demanda ativa [kW] dos nós 13 à 23.

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		13	14	15	16	17	18	19	20	21	22	23
1	1	19	35	30	37	28	25	29	36	27	40	21
1	2	17	32	27	35	26	24	28	34	26	39	19
1	3	17	32	27	35	26	24	28	34	26	41	19
1	4	18	35	30	39	29	25	30	38	29	47	21
1	5	25	42	39	43	41	34	40	40	42	57	27
1	6	38	51	53	50	56	50	55	46	63	76	39
1	7	130	160	154	152	164	156	155	145	147	199	124
1	8	193	195	185	168	194	188	190	186	152	228	171
1	9	239	226	229	217	228	215	212	241	198	234	200
1	10	277	269	283	244	283	272	271	275	258	254	250
1	11	239	234	253	208	239	249	232	230	235	218	218
1	12	283	315	340	231	263	344	258	258	292	265	222
1	13	268	241	260	200	234	278	238	224	267	210	217
1	14	227	180	196	162	202	204	211	187	201	170	199
1	15	216	217	206	160	192	196	191	172	188	171	176
1	16	154	189	171	144	160	160	155	144	158	170	145
1	17	125	149	144	114	144	129	144	132	128	153	131
1	18	115	141	143	108	134	137	142	123	134	150	124
1	19	179	170	188	146	184	211	178	169	175	175	163
1	20	215	212	217	172	220	226	198	196	187	193	190
1	21	158	168	166	156	160	168	165	163	141	159	143
1	22	130	151	128	141	122	129	132	141	123	132	110
1	23	86	104	83	85	85	79	85	90	73	85	74
1	24	29	44	39	42	38	36	38	42	34	47	27
2	1	21	36	30	37	30	25	31	37	27	41	22
2	2	18	34	28	36	27	24	28	36	26	40	20
2	3	18	34	28	38	27	24	28	37	27	43	19
2	4	19	36	30	43	30	25	31	41	31	51	21
2	5	26	44	40	47	42	34	40	44	44	62	27
2	6	38	51	54	52	54	50	52	47	63	73	36
2	7	131	190	141	126	158	157	152	130	127	181	133
2	8	186	194	163	147	181	182	182	176	126	187	166
2	9	164	124	123	134	141	140	142	154	127	127	147
2	10	133	90	102	141	118	100	121	144	122	104	147
2	11	107	87	96	136	103	86	102	115	116	100	132

(Continua na próxima página.)

Tabela 25 – Valores de demanda ativa [kW] dos nós 13 à 23 (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		13	14	15	16	17	18	19	20	21	22	23
2	12	115	73	134	141	109	119	100	137	160	97	145
2	13	105	76	107	118	101	101	104	104	138	100	135
2	14	100	77	101	114	110	87	120	103	126	104	148
2	15	101	75	105	140	106	98	116	102	145	120	150
2	16	94	74	103	152	105	98	116	105	145	120	160
2	17	112	83	112	142	113	118	121	112	142	116	147
2	18	143	137	153	140	137	158	129	128	152	137	127
2	19	224	209	227	173	203	251	180	184	200	168	165
2	20	266	257	247	187	242	264	220	208	214	193	210
2	21	170	176	174	144	172	180	176	156	153	146	155
2	22	131	153	129	132	123	135	131	130	124	116	114
2	23	84	110	82	88	82	76	84	90	74	83	69
2	24	29	50	38	44	37	35	40	43	35	46	28
3	1	21	36	31	37	30	26	31	37	26	40	21
3	2	18	34	29	37	27	24	29	37	26	41	20
3	3	18	34	28	37	27	24	28	35	26	41	19
3	4	19	35	31	43	30	25	30	41	32	51	21
3	5	25	43	40	47	40	35	41	43	45	64	28
3	6	37	51	54	50	56	51	55	45	63	74	39
3	7	129	200	135	130	157	150	150	124	127	182	138
3	8	189	198	166	146	180	184	178	175	128	192	167
3	9	184	135	126	153	157	144	162	178	134	140	175
3	10	156	109	103	164	139	104	145	168	127	124	180
3	11	118	88	96	150	107	84	108	131	118	101	150
3	12	130	84	135	176	121	115	107	155	173	104	181
3	13	165	103	127	213	153	111	161	172	193	128	266
3	14	186	114	114	212	171	95	183	179	173	126	292
3	15	146	97	117	164	139	104	148	136	159	133	201
3	16	107	80	113	149	114	108	128	121	148	134	157
3	17	125	96	122	139	121	125	134	122	142	125	148
3	18	163	151	167	152	151	173	155	142	160	150	145
3	19	236	247	247	201	221	274	199	203	211	185	185
3	20	292	286	278	209	267	298	247	228	233	211	229
3	21	170	196	184	157	173	196	179	156	167	155	157
3	22	157	204	134	155	135	142	153	154	135	131	142
3	23	101	136	92	110	90	88	103	108	92	95	85
3	24	33	58	45	52	42	38	47	50	42	54	34

Tabela 26: Valores de demanda reativa [kvar] dos nós 2 à 12.

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		2	3	4	5	6	7	8	9	10	11	12
1	1	11	30	19	27	23	14	20	24	15	30	16

(Continua na próxima página.)

Tabela 26 – Valores de demanda reativa [kvar] dos nós 2 à 12 (continuação).

cenário (sc)	hora (j)	nó ($m \in \psi^D$)										
		2	3	4	5	6	7	8	9	10	11	12
1	2	10	27	17	25	21	13	18	23	14	30	14
1	3	10	27	17	26	21	12	18	24	14	31	15
1	4	11	30	20	29	24	14	20	26	17	35	16
1	5	15	35	27	31	32	20	26	28	25	43	20
1	6	25	42	38	36	43	33	37	32	40	56	27
1	7	71	98	88	89	92	94	79	89	85	125	55
1	8	110	101	104	97	104	111	95	112	88	134	80
1	9	146	121	135	135	127	130	113	151	122	139	101
1	10	176	149	164	150	156	160	145	169	157	145	122
1	11	152	136	155	129	139	157	139	142	151	133	121
1	12	189	208	223	147	160	230	174	164	201	177	143
1	13	186	167	183	132	156	195	170	152	188	144	152
1	14	156	123	136	108	138	143	151	126	138	114	141
1	15	145	147	141	106	128	136	132	113	129	113	117
1	16	102	129	117	96	106	109	105	95	108	116	96
1	17	84	105	98	77	97	87	101	90	85	105	90
1	18	78	99	100	73	92	95	99	83	89	104	85
1	19	124	110	131	98	125	147	124	117	119	116	111
1	20	148	126	148	116	143	159	138	134	126	123	123
1	21	108	107	111	106	104	116	114	111	94	103	93
1	22	91	109	87	96	83	89	94	97	83	91	77
1	23	59	77	56	59	60	53	58	61	48	58	52
1	24	18	35	25	30	29	22	26	28	20	34	20
2	1	12	30	20	27	24	14	21	25	15	31	17
2	2	10	29	18	27	22	13	19	24	15	31	15
2	3	10	29	18	28	21	12	19	25	15	33	15
2	4	11	31	20	31	24	13	21	29	18	39	16
2	5	16	37	28	34	33	21	26	31	27	46	20
2	6	25	42	39	37	42	33	34	33	40	54	25
2	7	73	97	78	73	91	93	84	77	75	107	61
2	8	103	93	86	82	97	106	95	97	74	103	80
2	9	101	74	73	83	83	89	80	92	79	76	84
2	10	87	66	64	90	77	66	80	85	79	71	99
2	11	72	65	66	91	73	58	73	76	78	69	100
2	12	80	55	92	93	76	84	72	86	111	67	109
2	13	73	58	78	78	75	71	76	70	96	70	103
2	14	68	58	73	73	79	59	84	68	83	71	106
2	15	68	55	77	90	77	67	83	70	98	85	109
2	16	64	53	74	101	76	69	86	71	100	86	120
2	17	74	59	80	96	80	81	88	76	98	83	109
2	18	94	91	104	92	92	105	87	85	103	93	86
2	19	153	123	151	114	129	167	114	125	134	101	101
2	20	183	143	161	124	151	174	143	143	143	112	127

(Continua na próxima página.)

Tabela 26 – Valores de demanda reativa [kvar] dos nós 2 à 12 (continuação).

cenário (sc)	hora (j)	nó ($m \in \psi^D$)										
		2	3	4	5	6	7	8	9	10	11	12
2	21	114	109	112	96	107	121	111	104	100	88	94
2	22	89	108	85	89	82	93	89	89	83	76	78
2	23	57	81	53	60	58	49	59	61	49	57	49
2	24	18	39	25	32	28	20	27	29	21	33	20
3	1	12	30	20	26	24	14	20	25	15	30	16
3	2	10	29	19	27	22	13	19	25	14	30	15
3	3	10	29	18	27	22	13	19	24	15	31	15
3	4	11	30	20	31	24	14	20	29	19	39	16
3	5	15	36	28	34	32	21	27	31	28	48	20
3	6	24	43	38	35	43	33	36	31	40	55	26
3	7	74	99	76	75	91	88	84	75	74	106	61
3	8	104	88	87	82	95	106	90	98	75	104	79
3	9	112	80	75	97	92	93	92	108	84	83	103
3	10	103	80	65	104	92	68	99	105	82	84	124
3	11	80	66	64	101	75	56	77	85	79	68	112
3	12	92	65	94	117	86	81	78	101	121	73	139
3	13	118	80	92	143	113	78	123	122	136	91	211
3	14	132	87	82	139	126	66	137	126	117	88	225
3	15	101	71	85	107	102	73	107	94	106	93	148
3	16	71	56	79	99	81	74	91	80	101	94	114
3	17	83	65	85	94	84	85	97	82	98	87	108
3	18	108	94	111	99	98	113	104	95	107	99	94
3	19	160	146	166	133	143	184	132	140	143	112	117
3	20	201	169	187	138	169	203	163	156	156	126	140
3	21	113	122	118	104	105	131	113	101	110	94	94
3	22	109	148	90	105	91	97	107	107	91	86	99
3	23	70	101	62	75	63	58	74	75	61	65	61
3	24	21	45	31	37	32	23	33	34	27	39	25

Tabela 27: Valores de demanda reativa [kvar] dos nós 13 à 23.

cenário (sc)	hora (j)	nó ($m \in \psi^D$)										
		13	14	15	16	17	18	19	20	21	22	23
1	1	11	30	19	27	23	14	20	24	15	30	16
1	2	10	27	17	25	21	13	18	23	14	30	14
1	3	10	27	17	26	21	12	18	24	14	31	15
1	4	11	30	20	29	24	14	20	26	17	35	16
1	5	15	35	27	31	32	20	26	28	25	43	20
1	6	25	42	38	36	43	33	37	32	40	56	27
1	7	71	98	88	89	92	94	79	89	85	125	55
1	8	110	101	104	97	104	111	95	112	88	134	80
1	9	146	121	135	135	127	130	113	151	122	139	101
1	10	176	149	164	150	156	160	145	169	157	145	122

(Continua na próxima página.)

Tabela 27 – Valores de demanda reativa [kvar] dos nós 13 à 23 (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		13	14	15	16	17	18	19	20	21	22	23
1	11	152	136	155	129	139	157	139	142	151	133	121
1	12	189	208	223	147	160	230	174	164	201	177	143
1	13	186	167	183	132	156	195	170	152	188	144	152
1	14	156	123	136	108	138	143	151	126	138	114	141
1	15	145	147	141	106	128	136	132	113	129	113	117
1	16	102	129	117	96	106	109	105	95	108	116	96
1	17	84	105	98	77	97	87	101	90	85	105	90
1	18	78	99	100	73	92	95	99	83	89	104	85
1	19	124	110	131	98	125	147	124	117	119	116	111
1	20	148	126	148	116	143	159	138	134	126	123	123
1	21	108	107	111	106	104	116	114	111	94	103	93
1	22	91	109	87	96	83	89	94	97	83	91	77
1	23	59	77	56	59	60	53	58	61	48	58	52
1	24	18	35	25	30	29	22	26	28	20	34	20
2	1	12	30	20	27	24	14	21	25	15	31	17
2	2	10	29	18	27	22	13	19	24	15	31	15
2	3	10	29	18	28	21	12	19	25	15	33	15
2	4	11	31	20	31	24	13	21	29	18	39	16
2	5	16	37	28	34	33	21	26	31	27	46	20
2	6	25	42	39	37	42	33	34	33	40	54	25
2	7	73	97	78	73	91	93	84	77	75	107	61
2	8	103	93	86	82	97	106	95	97	74	103	80
2	9	101	74	73	83	83	89	80	92	79	76	84
2	10	87	66	64	90	77	66	80	85	79	71	99
2	11	72	65	66	91	73	58	73	76	78	69	100
2	12	80	55	92	93	76	84	72	86	111	67	109
2	13	73	58	78	78	75	71	76	70	96	70	103
2	14	68	58	73	73	79	59	84	68	83	71	106
2	15	68	55	77	90	77	67	83	70	98	85	109
2	16	64	53	74	101	76	69	86	71	100	86	120
2	17	74	59	80	96	80	81	88	76	98	83	109
2	18	94	91	104	92	92	105	87	85	103	93	86
2	19	153	123	151	114	129	167	114	125	134	101	101
2	20	183	143	161	124	151	174	143	143	143	112	127
2	21	114	109	112	96	107	121	111	104	100	88	94
2	22	89	108	85	89	82	93	89	89	83	76	78
2	23	57	81	53	60	58	49	59	61	49	57	49
2	24	18	39	25	32	28	20	27	29	21	33	20
3	1	12	30	20	26	24	14	20	25	15	30	16
3	2	10	29	19	27	22	13	19	25	14	30	15
3	3	10	29	18	27	22	13	19	24	15	31	15
3	4	11	30	20	31	24	14	20	29	19	39	16
3	5	15	36	28	34	32	21	27	31	28	48	20

(Continua na próxima página.)

Tabela 27 – Valores de demanda reativa [kvar] dos nós 13 à 23 (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^D$)										
		13	14	15	16	17	18	19	20	21	22	23
3	6	24	43	38	35	43	33	36	31	40	55	26
3	7	74	99	76	75	91	88	84	75	74	106	61
3	8	104	88	87	82	95	106	90	98	75	104	79
3	9	112	80	75	97	92	93	92	108	84	83	103
3	10	103	80	65	104	92	68	99	105	82	84	124
3	11	80	66	64	101	75	56	77	85	79	68	112
3	12	92	65	94	117	86	81	78	101	121	73	139
3	13	118	80	92	143	113	78	123	122	136	91	211
3	14	132	87	82	139	126	66	137	126	117	88	225
3	15	101	71	85	107	102	73	107	94	106	93	148
3	16	71	56	79	99	81	74	91	80	101	94	114
3	17	83	65	85	94	84	85	97	82	98	87	108
3	18	108	94	111	99	98	113	104	95	107	99	94
3	19	160	146	166	133	143	184	132	140	143	112	117
3	20	201	169	187	138	169	203	163	156	156	126	140
3	21	113	122	118	104	105	131	113	101	110	94	94
3	22	109	148	90	105	91	97	107	107	91	86	99
3	23	70	101	62	75	63	58	74	75	61	65	61
3	24	21	45	31	37	32	23	33	34	27	39	25

Tabela 28: Valores de injeção de potência ativa do RED [kW].

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^G$)
		14
1	1	332
1	2	322
1	3	310
1	4	301
1	5	285
1	6	272
1	7	260
1	8	254
1	9	250
1	10	256
1	11	342
1	12	506
1	13	655
1	14	755
1	15	807
1	16	823
1	17	799
1	18	740
1	19	632

(Continua na próxima página.)

Tabela 28 – Valores de injeção de potência ativa do RED [kW] (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^G$)
		14
1	20	482
1	21	342
1	22	301
1	23	313
1	24	317
2	1	320
2	2	313
2	3	305
2	4	299
2	5	290
2	6	278
2	7	270
2	8	265
2	9	252
2	10	245
2	11	329
2	12	485
2	13	638
2	14	757
2	15	825
2	16	844
2	17	813
2	18	751
2	19	640
2	20	495
2	21	358
2	22	307
2	23	311
2	24	319
3	1	334
3	2	330
3	3	325
3	4	319
3	5	310
3	6	295
3	7	280
3	8	267
3	9	254
3	10	253
3	11	339
3	12	502
3	13	663
3	14	783

(Continua na próxima página.)

Tabela 28 – Valores de injeção de potência ativa do RED [kW] (continuação).

cenário (<i>sc</i>)	hora (<i>j</i>)	nó ($m \in \psi^G$) 14
3	15	848
3	16	864
3	17	837
3	18	772
3	19	666
3	20	530
3	21	392
3	22	340
3	23	344
3	24	352