

Universidade Federal de Juiz de Fora
Faculdade de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Antônio Sobrinho Campolina Martins

Alocação de Capacitores em Sistemas de Distribuição de Energia Elétrica: uma
Abordagem Baseada em Fluxo de Potência Trifásico Probabilístico Ótimo

Juiz de Fora
2022

Antônio Sobrinho Campolina Martins

**Alocação de Capacitores em Sistemas de Distribuição de Energia Elétrica: uma
Abordagem Baseada em Fluxo de Potência Trifásico Probabilístico Ótimo**

Dissertação apresentada ao corpo docente do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de Sistemas de Energia Elétrica, como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Leandro Ramos de Araujo, D. Sc.

Coorientadora: Prof^a. Débora Rosana Ribeiro Penido Araujo, D. Sc.

**Juiz de Fora
2022**

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

Martins, Antônio Sobrinho Campolina.

Alocação de Capacitores em Sistemas de Distribuição de Energia Elétrica : Uma Abordagem Baseada em Fluxo de Potência Trifásico Probabilístico Ótimo / Antônio Sobrinho Campolina Martins. -- 2022. 159 f.

Orientador: Leandro Ramos de Araujo

Coorientadora: Débora Rosana Ribeiro Penido Araujo

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2022.

1. Fluxo de Potência Ótimo. 2. Fluxo de Potência Probabilístico. 3. Alocação de Capacitores. 4. Sistemas Desequilibrados. I. Araujo, Leandro Ramos de, orient. II. Araujo, Débora Rosana Ribeiro Penido, coorient. III. Título.

Antônio Sobrinho Campolina Martins**Alocação de Capacitores em Sistemas de Distribuição de Energia Elétrica: uma Abordagem Baseada em Fluxo de Potência Trifásico Probabilístico Ótimo**

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

Aprovada em 07 de março de 2022.

BANCA EXAMINADORA

Prof. Dr. Leandro Ramos de Araujo - Orientador

Universidade Federal de Juiz de Fora

Profa. Dra. Débora Rosana Ribeiro Penido Araujo

Universidade Federal de Juiz de Fora

Prof. Dr. Eduardo Gontijo Carrano

Universidade Federal de Minas Gerais

Prof. Dr. Bruno Henriques Dias

Universidade Federal de Juiz de Fora

Juiz de Fora, 22/02/2022.



Documento assinado eletronicamente por **Leandro Ramos de Araujo, Professor(a)**, em 07/03/2022, às 16:42, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Debora Rosana Ribeiro Penido Araujo, Professor(a)**, em 07/03/2022, às 16:52, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Eduardo Gontijo Carrano, Usuário Externo**, em 08/03/2022, às 10:12, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Bruno Henriques Dias, Professor(a)**, em 09/03/2022, às 14:07, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **0688520** e o código CRC **44004E8F**.

Dedico este trabalho
aos meus pais, Antonio Henrique e Claudia;
aos meus irmãos, Joana, André e Ciro;
a meus avós, Hilton (*in memoriam*) e Selma.

AGRADECIMENTOS

Primeiramente agradeço a Deus, criador de todas as coisas, pelo dom da vida, pelas oportunidades a mim confiadas, por ter-me proporcionado a fortaleza e o discernimento necessários para superar mais uma importante etapa.

Aos meus pais, Antonio Henrique e Claudia, pelo incentivo, carinho e por tudo que fizeram por mim.

Aos meus irmãos, Joana, André e Ciro, por serem meus eternos companheiros, amigos, exemplos.

Aos meus orientadores, Leandro e Débora, por todo o conhecimento transmitido, pela persistência e paciência.

Agradeço a todos os membros do corpo docente do Programa de Pós-Graduação em Engenharia Elétrica da UFJF, por criarem as melhores condições possíveis de aprendizado para os alunos, em uma época tão difícil e desafiadora vivida nesses últimos dois anos.

Aos meus amigos da UFJF, que estiveram sempre comigo nessa jornada, tornando-a muito mais agradável.

RESUMO

O Fluxo de Potência é uma ferramenta vital para análise de sistemas de potência, seja por proporcionar a determinação dos mais diversos parâmetros elétricos em regime permanente, seja por subsidiar outros estudos, como o fluxo continuado ou análise de estabilidade. Sua formulação tradicional requer que sejam informadas variáveis de entrada determinísticas, como as que representam as configurações de geração e carga de determinada topologia. Entretanto, analisar o comportamento de um sistema sob uma perspectiva única apenas avalia uma condição específica de operação – o que não necessariamente traduz a realidade. Caso tal conjectura limitada seja empregada em estudos de planejamento de curto prazo, importantes erros podem ser provocados devido à discrepância entre as variáveis consideradas e aquelas manifestadas na prática. Buscando melhorar essas avaliações, o presente trabalho procura desenvolver e solucionar um problema de Fluxo de Potência Ótimo que apresenta uma formulação multi-cenário por meio do Fluxo de Potência Probabilístico, no qual a demanda do sistema passa a ser representada por uma variável aleatória. Para modelar os diversos cenários, é aplicada uma técnica de agrupamentos chamada *K-Means*. Buscam-se o posicionamento e dimensionamento ótimos de capacitores fixos e chaveados em sistemas de distribuição desequilibrados, considerando um horizonte de planejamento diário. Para isso, é proposta uma estrutura de otimização que trata de maneira individual cada uma das horas do dia, em uma abordagem que mistura técnicas clássicas e técnicas evolutivas. É alvo de otimização, também, a determinação da estratégia de chaveamento dos capacitores chaveados para cada hora do dia, com o intuito de minimizar o valor esperado das perdas totais diárias e evitar violações de tensão em cenários limítrofes, tendo como referência os valores ditos como aceitáveis de acordo com o Módulo 8 dos Procedimentos de Distribuição. Para aplicar o método proposto, foram feitos testes em topologias desequilibradas: IEEE 13, IEEE 37 e IEEE 123. Em todos os casos, foram constatadas melhoras em relação à energia total perdida e ao perfil de tensão. Além disso, foram levantadas comparações acerca da técnica de Fluxo de Potência Probabilístico desenvolvida, confrontando-a com o tradicional Método de Monte Carlo, possibilitando conclusões a respeito da precisão estatística do método e de seu desempenho computacional favorável.

Palavras-chave: Fluxo de Potência Ótimo, Fluxo de Potência Probabilístico, Alocação de Capacitores, Sistemas Desequilibrados.

ABSTRACT

The Power Flow is a vital tool for power systems analysis, either because it provides the determination of the most diverse electrical parameters in steady state, or because it supports other studies, such as continuous power flow or stability analysis. Its traditional formulation requires deterministic input variables, such as those that represent the generation and load configurations of a given topology. However, analyzing the behavior of a system from a single perspective only assesses a specific operating condition – which does not necessarily reflect the reality. If such limited conjecture is used in planning studies, important errors can be caused due to the discrepancy between the considered input variables and those verified in practice. Seeking to improve these evaluations, the present work proposes the development of an Optimal Power Flow problem that takes into account a multi-scenario formulation through the Probabilistic Power Flow, in which the demand is represented by a random variable. To model the different scenarios, a clustering technique called K-Means is applied. Optimal positioning and sizing of fixed and switched capacitors in unbalanced distribution systems is sought, considering a daily planning horizon. For this, an optimization framework is developed that deals with each hour of the day individually, in an approach that mixes classical and evolutionary techniques. The determination of the optimal switching strategy of the switched capacitors for each hour of the day is also targeted for optimization, to minimize the expected value of total daily losses and avoid voltage violations in critical scenarios, according to Brazilian standards. To apply the proposed method, tests were carried out in unbalanced topologies: IEEE 13, IEEE 37 and IEEE 123. In all simulations, improvements were found in relation to the total lost energy and the voltage profile. Furthermore, comparisons of the Probabilistic Power Flow technique developed with the traditional Monte Carlo Method were raised, through which conclusions were provided about the statistical precision of the method and its favorable computational performance.

Keywords: Optimal Power Flow, Probabilistic Power Flow, Capacitor Allocation, Unbalanced Systems.

LISTA DE ILUSTRAÇÕES

Figura 1 - Procedimento geral do FPP com N entradas e M saídas	38
Figura 2 - Fluxograma do MMC	39
Figura 3 - Fluxograma dos métodos por aproximação.....	40
Figura 4 - Fluxograma do FPTP desenvolvido	41
Figura 5 - Exemplo do banco de dados com n = 365 (dias).....	42
Figura 6 - Topologia IEEE 4 Node Test Feeder.....	46
Figura 7 - Curvas de Carga para K = 2	47
Figura 8 - Comparação K-Means x MMC: perdas por hora do dia	49
Figura 9 - Comparação K-Means x MMC: perfil de tensão (K = 2).....	51
Figura 10 - Comparação K-Means x MMC: perfil de tensão (Barra 4, Fase A).....	55
Figura 11 - Funções de probabilidade acumulada para tensão da barra 4.....	56
Figura 12 - Fluxograma do método desenvolvido para determinar número de clusters	58
Figura 13 - Evolução do tempo computacional de acordo com número de clusters para topologia IEEE 123	60
Figura 14 - Evolução da energia total perdida de acordo com número de clusters para topologia IEEE 123	61
Figura 15 - Apresentação simplificada do FPTPO.....	67
Figura 16 - Fluxograma do Módulo A	68
Figura 17 - Fluxograma do Módulo B	70
Figura 18 - Fluxograma do Módulo C	74
Figura 19 - Cromossomo introduzido na otimização genética FPO 2	76
Figura 20 - Fluxograma do Módulo D	80
Figura 21 - Cromossomo implementado em FPO 3.....	81
Figura 22 - (a) Curvas de carga obtidas pelo K-Means e (b) Curva de carga média ponderada pelos respectivos fatores de peso	86
Figura 23 - Topologia IEEE 13 Node Test-Feeder	88
Figura 24 - (IEEE 13) Estratégia de chaveamento do capacitor chaveado 1	88
Figura 25 - (IEEE 13) Estratégia de chaveamento do capacitor chaveado 2	89
Figura 26 - (IEEE 13) Estratégia de chaveamento do capacitor chaveado 3	89
Figura 27 - Comparativo do valor esperado de perdas por hora do dia	90

Figura 28 - Comparativo do perfil de tensão da barra 611, fase C: Caso Base x Caso Otimizado	91
Figura 29 - Comparativo do perfil de tensão para horizonte de carga leve: Caso Base x Caso Otimizado	92
Figura 30 - Comparativo do perfil de tensão para horizonte de carga pesada: Caso Base x Caso Otimizado	92
Figura 31 - Valores esperados das tensões nodais para o Caso Otimizado (IEEE 13)	93
Figura 32 - Topologia IEEE 37 Node Test-Feeder	94
Figura 33 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 1	95
Figura 34 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 2	95
Figura 35 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 3	96
Figura 36 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 4	96
Figura 37 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 5	97
Figura 38 - Comparativo do valor esperado de perdas por hora do dia	97
Figura 39 - Comparativo do perfil de tensão da barra 704, fase A: Caso Base x Caso Otimizado	98
Figura 40 - Comparativo do perfil de tensão para horizonte de carga leve: Caso Base x Caso Otimizado	99
Figura 41 - Comparativo do perfil de tensão para horizonte de carga pesada: Caso Base x Caso Otimizado	99
Figura 42 - Valores esperados das tensões nodais para o Caso Otimizado (IEEE 37)	100
Figura 43 - Paralelo entre o perfil mínimo de tensão e a estratégia ótima de chaveamento ..	100
Figura 44 - Topologia IEEE 123 Node Test-Feeder	101
Figura 45 - Comparativo do valor esperado de perdas por hora do dia	102
Figura 46 - Comparativo do perfil de tensão da barra 65, fase A: Caso Base x Caso Otimizado	103
Figura 47 - Comparativo do perfil de tensão para horizonte de carga leve: Caso Base x Caso Otimizado	104
Figura 48 - Comparativo do perfil de tensão para horizonte de carga pesada: Caso Base x Caso Otimizado	104
Figura 49 - Valores esperados das tensões nodais para o Caso Otimizado (IEEE 123)	105
Figura 50 - Comparação de valores esperados de perdas por hora do dia: K-Means x MMC	106

Figura 51 - Comparação para tensão na barra 611, fase C: K-Means x MMC	107
Figura 52 - Função de Probabilidade Acumulada: K-Means x MMC	108
Figura 53 - Comparação de valores esperados de perdas por hora do dia: K-Means x MMC	109
Figura 54 - Comparação para tensão na barra 704, fase A: K-Means x MMC	110
Figura 55 - Função de Probabilidade Acumulada: K-Means x MMC	110
Figura 56 - Comparação de valores esperados de perdas por hora do dia: K-Means x MMC	111
Figura 57 - Comparação para tensão na barra 65, fase A: K-Means x MMC	112
Figura 58 - Função de Probabilidade Acumulada: K-Means x MMC	112
Figura 59 - Probabilidade calculada através da integração da função densidade de probabilidade	128
Figura 60 - Exemplo de função densidade de probabilidade normal	130
Figura 61 - Exemplo de função de probabilidade acumulada normal	131
Figura 62 - Fluxograma do algoritmo K-Means	133
Figura 63 - Fluxograma do AG	139
Figura 64 - Dados estatísticos do banco de dados utilizado	140
Figura 65 - Cenários possíveis	141
Figura 66 - PDFs dos fatores proporcionais de carga	141
Figura 67 - Fluxograma do MMC para calcular FPP	142

LISTA DE TABELAS

Tabela 1 - Trabalhos destacados na revisão bibliográfica sobre FPP	25
Tabela 2 - Trabalhos destacados na revisão bibliográfica sobre FPPO	29
Tabela 3 - Parâmetros estatísticos para $K = 2$ (todos os valores em porcentagens).....	53
Tabela 4 - Parâmetros estatísticos para $K = 2, 5, 10$ e 100	54
Tabela 5 - Número K de clusters por topologia simulada e por dimensão do banco de dados	60
Tabela 6 - Valores esperados dos fatores proporcionais de carga por hora	85
Tabela 7 - Resultados das posições e potências dos capacitores para topologia IEEE 123 ...	102
Tabela 8 - Parâmetros estatísticos, em porcentagem, para mensurar erros: K-Means x MMC (IEEE 13 – Caso Otimizado).....	108
Tabela 9 - Parâmetros estatísticos, em porcentagem, para mensurar erros: K-Means x MMC (IEEE 37 – Caso Otimizado).....	111
Tabela 10 - Parâmetros estatísticos, em porcentagem, para mensurar erros: K-Means x MMC (IEEE 123 – Caso Otimizado).....	113
Tabela 11 - Análise de sensibilidade dos centroides para FPTP considerando IEEE 123	114
Tabela 12 - Dados dos condutores para topologia IEEE 4.....	144
Tabela 13 - Dados de alimentadores para topologia IEEE 4.....	144
Tabela 14 - Dados do transformador da topologia IEEE 4	145
Tabela 15 - Dados das cargas para topologia IEEE 4	145
Tabela 16 - Dados dos condutores para topologia IEEE 13.....	145
Tabela 17 - Dados de alimentadores para topologia IEEE 13.....	146
Tabela 18 - Dados do transformador para topologia IEEE 13	146
Tabela 19 - Dados das cargas para topologia IEEE 13	146
Tabela 20 - Dados de condutores para topologia IEEE 37	147
Tabela 21 - Dados dos alimentadores para topologia IEEE 37	147
Tabela 22 - Dados do transformador para topologia IEEE 37	149
Tabela 23 - Dados de cargas para topologia IEEE 37.....	149
Tabela 24 - Dados de condutores para topologia IEEE 123	150
Tabela 25 - Dados dos alimentadores para topologia IEEE 123.....	151
Tabela 26 - Dados do transformador para topologia IEEE 123	155
Tabela 27 - Dados de cargas para topologia IEEE 123.....	155
Tabela 28 - Repetibilidade do FPTPO	158

LISTA DE SIGLAS E ABREVIATURAS

AE	Algoritmos Evolutivos
AG	Algoritmos Genéticos
ANEEL	Agência Nacional de Energia Elétrica
BBO	<i>Biogeography Based Optimization</i>
CB	Caso Base
CDF	<i>Cumulative Distribution Function</i>
CER	Compensador Estático de Reativos
CO	Caso Otimizado
COM	<i>Component Object Model</i>
FM	Fator Multiplicativo de Potência dos Capacitores
FOB	Função Objetivo
FP	Fluxo de Potência
FPP	Fluxo de Potência Probabilístico
FPPO	Fluxo de Potência Probabilístico Ótimo
FPO	Fluxo de Potência Ótimo
FPTO	Fluxo de Potência Trifásico Ótimo
FPTP	Fluxo de Potência Trifásico Probabilístico
FPTPO	Fluxo de Potência Trifásico Probabilístico Ótimo
GD	Geração Distribuída
GSO	<i>Group Search Optimizer</i>
IEEE	Instituto de Engenheiros Elétricos e Eletrônicos
JP	<i>Jump Frog</i>
KM	<i>K-Means</i>
Matlab	<i>Matrix Laboratory</i>
MEP	Método da Estimativa dos Pontos
MICN	Método de Injeção de Correntes a N Condutores
MINLP	<i>Mixed Integer Non-Linear Programming</i>
MMC	Método de Monte Carlo
MPI	Método dos Pontos Interiores
OpenDSS	<i>Open Distribution System Simulator</i>
PDF	<i>Probability Density Function</i>

PESA-II	<i>Pareto Envelope-Based Selection Algorithm II</i>
PRODIST	Procedimentos de Distribuição
PSO	<i>Particle Swarm Optimization</i>
pu	Sistema por Unidade
SDEE	Sistemas de Distribuição de Energia Elétrica
SQP	<i>Sequential Quadratic Programming</i>
STATCOM	<i>Static Compensator</i>
WOA	<i>Whale Optimization Algorithm</i>

LISTA DE SÍMBOLOS

C	Conjunto que representa um <i>cluster</i>
c	Elemento de um conjunto <i>cluster</i>
E	Ocorrência de um evento
\bar{E}	Valor esperado de energia perdida, em kWh
$E[X]$	Valor esperado de uma variável aleatória X
$E[y^h]$	Valor esperado da variável de saída y , considerando hora h
$E[\mathbf{Y}]_{iter_k}$	Valores esperados de cada variável do conjunto \mathbf{Y} considerando iteração com parâmetro K atualizado
$E[\mathbf{Y}]_{iter_k}$	Valores esperados de cada variável do conjunto \mathbf{Y} considerando iteração anterior à atualização do parâmetro K
\overline{E}_{MC}	Valor esperado de perdas, em kWh, determinado via Método de Monte Carlo
\overline{E}_{KM}	Valor esperado de energia perdida, em kWh, determinado via <i>K-Means</i>
f_{max}	Maior fator de carga presente na matriz K_{mat} , em pu
f_{min}	Menor fator de carga presente na matriz K_{mat} , em pu
F	Função de probabilidade cumulativa
g	Conjunto genérico de equações ou restrições
h	Hora do dia
h_{max}	Hora do dia cujo valor esperado do fator de carga é máximo
h_{min}	Hora do dia cujo valor esperado do fator de carga é mínimo
I_k^i	Fasor de injeção de corrente correspondente ao elemento elétrico i no nó k , em A
k	Nó de origem de determinado elemento elétrico
K	Número de <i>clusters</i>
\mathbf{K}_{mat}	Matriz obtida após processo de <i>clustering</i>
m	Nó de destino de determinado elemento elétrico
n	Número de elementos de um conjunto Ω
N	Número total de nós em determinada topologia
N_{cap}^{fix}	Número máximo de capacitores fixos
N_{cap}^{sw}	Número máximo de capacitores chaveados

n_i	Número de elementos do <i>cluster</i> C_i
$n(E)$	Número de vezes que um evento ocorre
p	Função de probabilidade discreta
$\overline{p^h}$	Valor esperado de perdas, em kW, considerando hora h
P_i^h	Valor de perdas, em kW, considerando μ_i
$\overline{P_{MC}^h}$	Valor esperado de perdas, em kW, determinado via Método de Monte Carlo, para hora h
$\overline{P_{KM}^h}$	Valor esperado de perdas, em kW, determinado via <i>K-Means</i> , para hora h
$P(E)$	Probabilidade de um evento ocorrer
P_{MAX}	Valor máximo de potência ativa, em kW, que pode ser entregue pela subestação
P_{sub}	Potência ativa entregue pela subestação, em kW
Q_{adot}^{fix}	Potência reativa mínima, em kvar, adotada para capacitores fixos
Q_{adot}^{sw}	Potência reativa mínima, em kvar, adotada para capacitores chaveados
Q_{MIN}	Valor mínimo de potência ativa, em kvar, que pode ser entregue pela subestação
Q_{MAX}	Valor máximo de potência reativa, em kvar, que pode ser entregue pela subestação
Q_{sub}	Potência reativa entregue pela subestação, em kvar
R/X	Razão da resistência pela reatância
S	Espaço amostral
t	Tempo computacional, em segundos
V_{km}^{RE}	Componente real da diferença de potencial entre os nós k e m
V_{km}^{IM}	Componente imaginária da diferença de potencial entre os nós k e m
$\overline{V_{k,MC}^h}$	Valor esperado da magnitude de tensão no nó k , em pu, obtido via Método de Monte Carlo, considerando hora h
$\overline{V_{k,KM}^h}$	Valor esperado da magnitude de tensão no nó k , em pu, obtido via <i>K-Means</i> , considerando hora h
$V_{k,max,MC}^h$	Maior valor de magnitude de tensão obtido no nó k , observado em algum cenário do método de Monte Carlo, considerando hora h

$V_{k,max,KM}^h$	Maior valor de magnitude de tensão obtido no nó k , observado em algum cenário do método <i>K-Means</i> , considerando hora h
$V_{k,min,MC}^h$	Menor valor de magnitude tensão obtido no nó k , observado em algum cenário do método de Monte Carlo, considerando hora h
$V_{k,min,KM}^h$	Menor valor de magnitude de tensão obtido no nó k , observado em algum cenário do método <i>K-Means</i> , considerando hora h
V	Magnitude de tensão, em pu
$var(X)$	Variância de uma variável aleatória X
WF_{mat}	Matriz de fatores de peso
x^{RE}	Componente real de variável de controle
x^{IM}	Componente imaginária de variável de controle
X	Variável aleatória
\mathbf{X}	Conjunto de variáveis aleatórias de entrada
Y_i	Admitância do capacitor conectado ao nó i
Y_{MAX}	Admitância máxima do capacitor
\mathbf{Y}	Conjunto de variáveis aleatórias de saída
y_i^h	Variável de saída considerando entrada μ_i^h
\mathbf{z}	Conjunto de variáveis de decisão
δ	Tolerância para processos iterativos convergirem
ϵ	Erro ou resíduo de processos iterativos
ϵ_E	Erro de energia perdida
ϵ_P	Erro de potência perdida
ϵ_{Vmed}	Erro de valor esperado de tensão
$\overline{\epsilon_{Vmed}}$	Valor médio dos erros de valor esperado de tensões
$\epsilon_{V\sigma}$	Erro de desvio padrão de tensão
$\overline{\epsilon_{V\sigma}}$	Valor médio dos erros de desvio padrão de tensão
ϵ_{Vmax}	Erro do valor máximo de tensão
ϵ_{Vmin}	Erro do valor mínimo de tensão
μ_i	Centroide do i -ésimo <i>cluster</i>
μ_i^h	Centroide do i -ésimo <i>cluster</i> considerando hora h
ξ_i^h	Fator de peso do centroide μ_i^h

π_i	Probabilidade de ocorrência da amostra i , retirada de PDF previamente definida
σ	Desvio padrão
$\sigma_{V_{k,MC}}^h$	Desvio padrão da tensão no nó k , obtido via Método de Monte Carlo para hora h
$\sigma_{V_{k,KM}}^h$	Desvio padrão da tensão no nó k , obtido via <i>K-Means</i> para hora h
Ω	Conjunto de dados
Ω_b	Conjunto de nós onde há capacitores conectados
Ω_j	Conjunto de todos os alimentadores ou transformadores de uma topologia
Ω_k	Conjunto de todos os elementos elétricos conectados ao nó k
ω	Elemento do conjunto de dados Ω

SUMÁRIO

1 INTRODUÇÃO	20
1.1 CONSIDERAÇÕES GERAIS.....	20
1.2 REVISÃO BIBLIOGRÁFICA.....	22
1.2.1 FLUXO DE POTÊNCIA PROBABILÍSTICO	22
1.2.2 FLUXO DE POTÊNCIA PROBABILÍSTICO ÓTIMO	27
1.3 MOTIVAÇÕES	32
1.4 OBJETIVOS E CONTRIBUIÇÕES	33
1.5 PUBLICAÇÕES DECORRENTES DO TRABALHO.....	35
1.6 ESTRUTURA DO TRABALHO	35
2 FLUXO DE POTÊNCIA PROBABILÍSTICO	37
2.1 CONSIDERAÇÕES GERAIS.....	37
2.2 FLUXO DE POTÊNCIA TRIFÁSICO PROBABILÍSTICO VIA MÉTODO POR APROXIMAÇÕES BASEADO EM <i>K-MEANS</i>	41
2.3 APLICAÇÃO DO FPTP EM UM SISTEMA DIDÁTICO	45
2.3.1 APRESENTAÇÃO DA TOPOLOGIA E CONDIÇÕES DE SIMULAÇÃO	45
2.3.2 RESULTADOS DA SIMULAÇÃO DO EXEMPLO	46
2.4 MÉTODO PARA ESTIMAR NÚMERO DE <i>CLUSTERS</i>	58
3 MÉTODO PROPOSTO PARA AVALIAR O FLUXO DE POTÊNCIA TRIFÁSICO PROBABILÍSTICO ÓTIMO.....	62
3.1 CONSIDERAÇÕES INICIAIS	62
3.2 OBJETIVOS GERAIS DO ALGORITMO PARA AVALIAR O FPTPO	64
3.3 APRESENTAÇÃO DO ALGORITMO FPTPO.....	65
3.3.1 MÓDULO A	68
3.3.2 MÓDULO B	70
3.3.3 MÓDULO C	73
3.3.4 MÓDULO D	80
3.4 CONCLUSÕES PARCIAIS.....	82

4 RESULTADOS.....	84
4.1 CONSIDERAÇÕES DE SIMULAÇÃO.....	84
4.2 RESULTADOS DO FPTPO	87
4.2.1 IEEE 13 <i>NODE TEST-FEEDER</i>	87
4.2.2 IEEE 37 <i>NODE TEST-FEEDER</i>	93
4.2.3 IEEE 123 <i>NODE TEST-FEEDER</i>	101
4.3 COMPARAÇÕES DO FPTP: APROXIMAÇÕES VIA <i>K-MEANS</i> X MMC	105
4.3.1 IEEE 13 <i>NODE TEST-FEEDER</i>	106
4.3.2 IEEE 37 <i>NODE TEST-FEEDER</i>	109
4.3.3 IEEE 123 <i>NODE TEST-FEEDER</i>	111
4.4 ANÁLISE DE SENSIBILIDADE DO NÚMERO DE CENTROIDES	113
5 CONSIDERAÇÕES FINAIS	116
5.1 CONCLUSÕES.....	116
5.2 TRABALHOS FUTUROS.....	117
REFERÊNCIAS BIBLIOGRÁFICAS	119
ANEXO A: CONCEITOS FUNDAMENTAIS	124
ANEXO B: BANCO DE DADOS DOS FATORES DE CARGA	140
ANEXO C: ALGORITMO DO MÉTODO DE MONTE CARLO.....	142
ANEXO D: DADOS DAS TOPOLOGIAS	144
ANEXO E: REPETIBILIDADE DO FPTPO.....	158

1 INTRODUÇÃO

Neste capítulo, serão expostas as considerações gerais e revisões bibliográficas a respeito de métodos para cálculo de Fluxo de Potência (FP) considerando incertezas, que formaram as bases para o desenvolvimento deste trabalho. Posteriormente, serão explicitados as motivações e os objetivos do presente trabalho. Por fim, a sua estrutura será detalhada, destacando os conteúdos dos capítulos subsequentes.

1.1 CONSIDERAÇÕES GERAIS

Os Sistemas de Distribuição de Energia Elétrica (SDEE) sofrem transformações significativas à medida que a tecnologia se desenvolve em diversos âmbitos, sobretudo nas áreas de automação e controle. Já se pode observar quebras de paradigmas em diversos aspectos de operação das redes: a proliferação de Geração Distribuída (GD) e o advento dos Veículos Elétricos (VEs) modificaram a forma como a energia elétrica é ofertada e consumida. Existe, atualmente, uma grande necessidade de simular SDEE conferindo-lhes o maior detalhamento possível para efetuar estudos de planejamento e operação. Nesse sentido, uma ferramenta considerada vital é o Fluxo de Potência (FP).

O FP é a ferramenta capaz de fornecer o estado da rede em regime permanente. Isto é, caracteriza o sistema através de informações de tensões e correntes elétricas, fluxos de potência ativos e reativos, perdas elétricas e outras variáveis de interesse. Tais informações são obtidas mediante a resolução de um conjunto de equações não lineares, sendo seus dados de entrada a topologia da própria rede e as condições de geração e carga. Muitos métodos foram sugeridos ao longo do desenvolvimento histórico dessa técnica. Uma das formulações mais empregadas na literatura é a que está contida em Monticelli (1983), dedicada a calcular o estado de redes de transmissão baseado no método de Newton-Raphson com coordenadas polares. Nela, são admitidas simplificações, dentre as quais destaca-se a representação da rede por meio de um equivalente de sequência positiva. Apesar dessa formulação ser utilizada para simular também os SDEE, o seu emprego pode levar a erros significativos, pois existem atributos específicos desses sistemas que contraindicam essa abordagem. Portanto, torna-se pertinente utilizar métodos multifásicos como forma de representar adequadamente as suas características próprias, como o desequilíbrio das cargas entre as fases, ramais monofásicos e bifásicos, conexões não usuais de transformadores, representação do condutor neutro, indução mútua

entre circuitos, entre tantas outras. Uma formulação que considera essas características está presente no trabalho de Penido *et al* (2010).

De maneira convencional, o FP consiste em um modelo matemático determinístico, ou seja, cujas variáveis de entrada são fixas e determinadas, não se alterando ao longo do processo de resolução. Tradicionalmente, essa abordagem tem sido amplamente utilizada, por simplicidade, considerando piores cenários de carregamento ou cenários médios (Ramadhani *et al*, 2020). Ainda que muitas concessionárias e empresas adotem FP sequenciais, isto é, simulações horárias de FP convencionais, os pontos que compõem as curvas de carga contêm, na maioria dos casos, as mesmas simplificações citadas. Entretanto, conjecturando um contexto mais fidedigno, as variáveis como tensões e correntes elétricas estão associadas a incertezas devido a erros de cálculo ou medição de demandas, desequilíbrio das cargas, volatilidade de preços de geradores e preços no mercado de energia. Além disso, tais imprevisibilidades tendem a aumentar cada vez mais com a crescente penetração de energias renováveis, que possuem sua geração atrelada às condições ambientais, e com a popularização de veículos elétricos, que representam cargas de comportamento altamente imprevisível. Nesse último caso, o comportamento da carga depende do tipo de veículo, do tipo de bateria e, principalmente, do perfil do consumidor. Dessa forma, torna-se cada vez mais difícil prever as curvas de carga às quais a rede será imposta.

Logo, analisar um sistema elétrico sob uma ótica determinística é limitar essa perspectiva a um cenário específico, não traduzindo a realidade e, se a visão for muito limitada, pode, inclusive, causar uma série de erros de planejamento, sobretudo quando seu horizonte é o curto prazo, no qual um maior detalhamento é requerido. A partir disso, foram desenvolvidas abordagens capazes de modelar as variáveis de entrada através de ferramentas que representam as incertezas inerentes a estas grandezas. Este método é chamado na literatura de Fluxo de Potência Probabilístico (FPP). O FPP se caracteriza à medida que as variáveis de entrada são modeladas por meio de funções de probabilidade. Muitas metodologias foram desenvolvidas na literatura para solucionar o FPP, podendo ser divididas em três grupos principais: métodos analíticos, que baseiam-se em operações aritméticas nas funções de probabilidade de entrada, métodos numéricos, que têm como referência a simulação do problema determinístico mediante sorteio de pontos das funções de probabilidade de entrada, e métodos por aproximações, que também baseiam-se na simulação do problema determinístico, porém instituem procedimentos específicos para determinar pontos que melhor representam as variáveis de entrada com o intuito de serem mais eficientes do ponto de vista do tempo computacional em relação aos

métodos numéricos. As variáveis de saída do FPP também são modeladas por funções de probabilidade, pois também contêm incertezas. Outras alternativas podem ser utilizadas para estimar o estado incerto da rede, como abordagens *fuzzy*, otimização robusta e aritmética intervalar (Ramadhani *et al*, 2020).

Considera-se, então, que estudos que levam em consideração a incerteza da demanda são fundamentais para o adequado planejamento de curto prazo de SDEE. Com o aumento crescente da demanda, existe uma grande preocupação no que concerne a operação ótima desses sistemas. Além disso, existe pressão de órgãos reguladores com o intuito de aprimorar cada vez mais a qualidade de energia elétrica. A necessidade por eficiência, confiabilidade e qualidade de energia aumentou ainda mais a responsabilidade das concessionárias.

Portanto, estudos que busquem determinar o estado ótimo de redes elétricas de distribuição, considerando sua modelagem multifásica e trabalhando com incertezas da demanda, são essenciais para que análises relevantes e de utilidade prática sejam alcançadas, dadas as necessidades atuais e os presentes desafios a serem ultrapassados.

1.2 REVISÃO BIBLIOGRÁFICA

Foram muitos os autores que se dedicaram ao estudo do FPP, contribuindo ao estado da arte com publicações relevantes. Na primeira subseção, é descrita uma revisão histórica acerca dessa metodologia, destacando trabalhos influentes e mostrando como essa técnica se desenvolveu ao longo das décadas. Posteriormente, na segunda subseção, serão selecionados os trabalhos notórios a respeito de métodos de Fluxo de Potência Ótimo (FPO) aliados a modelagens que considerem incertezas de seus parâmetros de entrada.

1.2.1 FLUXO DE POTÊNCIA PROBABILÍSTICO

Ao contrário do FP convencional, os dados de entrada do FPP apresentam incertezas. Essa consideração é fundamental para traduzir um contexto mais próximo da realidade, visto que tais imprecisões afetam as condições de regime permanente (Carpinelli *et al*, 2018). Sob essa perspectiva, estudos que visam tomadas de decisão possuem maior relevância quando submetidos a uma análise probabilística ou quando são levados em consideração muitos cenários possíveis (Ramadhani *et al*, 2020).

O FPP foi primeiramente sugerido no trabalho de Borkowska (1973), em uma metodologia direcionada aos sistemas de transmissão. Neste trabalho, as cargas foram caracterizadas por um conjunto de valores (cenários), juntamente com suas probabilidades de ocorrência. Para solucionar o problema, foram adotados métodos analíticos baseados em técnicas de convolução.

Klitin (1975) apresentou um método para estimar o efeito da propagação de erros no cálculo de FP devido às imprecisões dos dados de entrada, gerando variáveis de saída com suas respectivas probabilidades. O estudo se baseou em intervalos de confiança de distribuições de probabilidade e foi voltado para simulação de sistemas de transmissão.

No trabalho de Allan *et al* (1981), foi abordado um método para solucionar o FPP através de técnicas de convolução usando o domínio da frequência. O ganho computacional foi evidenciado quando comparado aos métodos numéricos, como Método de Monte Carlo (MMC).

O artigo de El-Hawary e Mbamalu (1991) foi um dos primeiros a tratar da formulação probabilística aliada a métodos de otimização, com o intuito de desenvolver uma estrutura de Fluxo de Potência Probabilístico Ótimo (FPPO) para determinar o despacho ótimo de geradores em sistemas de transmissão. Neste trabalho, as demandas foram modeladas por meio de distribuições de probabilidade normais. Foram testadas funções objetivo distintas, tais como custo de operação, perdas, geração ativa e os resultados foram confrontados com aqueles obtidos por uma formulação determinística, expondo as vantagens da perspectiva probabilística.

O trabalho de Karakatsanis e Hatzigryriou (1994) apresentou um método para ajustar variáveis de controle para evitar violações às restrições operacionais de FP destinado a redes de transmissão. As demandas foram modeladas por funções de probabilidade e os resultados apontaram a probabilidade de violação das restrições por ajuste fornecido.

Uma abordagem analítica destinada a solucionar o FPP harmônico foi proposta em Lehtonen (1998), onde as impedâncias equivalentes das cargas lineares foram modeladas como variáveis aleatórias, assim como as injeções de corrente das cargas não lineares. O método foi testado em um SDEE de pequeno porte.

O trabalho de Chun-Lien Su (2005) foi um dos primeiros a utilizar o Método da Estimativa dos Pontos (MEP) para resolver o FPP. Foi usada a técnica $2m$ para calcular os momentos estatísticos das soluções do FP. Nesse caso, o parâmetro m representa o número de

variáveis aleatórias consideradas, sendo $2m$ o número de FP determinísticos necessários para a sua convergência.

Em 2007, Morales *et al* aprimoraram esse desenvolvimento e expandiram a aplicabilidade do MEP usando outros esquemas de estimativa dos pontos, como as técnicas $2m+1$, $3m$ e $4m+1$. Foram evidenciados os prós e contras de cada um deles por meio de testes na topologia IEEE 118 barras.

O trabalho de Delgado e Navarro (2014) proporcionou uma expansão do MEP para sua aplicação em SDEE. Foram considerados sistemas com GD, incluindo incertezas de cargas e da geração eólica e solar. Testes foram realizados na topologia IEEE 123 barras, que é capaz de representar o desequilíbrio através de uma modelagem multifásica.

No artigo de Gupta e Doratha (2017), um FPP para sistemas de transmissão foi solucionado via MEP. Foram considerados geradores eólicos cuja modelagem é detalhada de acordo com as particularidades de um gerador de indução trifásico. Foi estudada também a variação do perfil de tensão mediante alteração do desvio padrão das distribuições de probabilidade das cargas.

Krishna e Gupta (2017) aplicaram novamente o MEP, porém considerando SDEE radiais. Foram testados os esquemas $2m$ e $3m$. As variáveis aleatórias consideradas nesse estudo foram as cargas e as gerações renováveis. O método é aplicado nos sistemas IEEE 33 barras e IEEE 69 barras.

O artigo de Ren *et al* (2017) considerou a incerteza da geração de energia maremotriz. A regularidade da maré foi modelada via agrupamentos *K-Means* e sua aleatoriedade foi obtida via estimativa de densidade *Kernel*. Dessa forma, foram obtidas amostras aleatórias para a potência desses geradores, que são introduzidos no MMC. O método foi testado no sistema IEEE 57 barras.

Carpinelli *et al* (2018) empregaram um método analítico para solucionar o FPP para sistemas de distribuição desequilibrados, chamado método de Taguchi. Nesse trabalho, foram vistas correlações de variáveis aleatórias atreladas às energias solar e eólica para construir um modelo robusto.

Li *et al* (2018) desenvolveram um método numérico baseado em *Latin Hypercube* para resolver o FPP com o intuito de melhorar computacionalmente o desempenho em comparação com MMC.

No artigo de Deng *et al* (2019), os dados de geração eólica e de carga foram agrupados em *clusters* por meio de algoritmos *K-Means*, sendo que cada um deles foi aplicado a métodos analíticos de solução de FPP.

Já em Ferraz *et al* (2019), foi apresentada uma análise dedicada a SDEE considerando incerteza das cargas. Foi considerada uma abordagem multi-cenário para preservar a simultaneidade e a combinação cronológica de diferentes cargas. A técnica de agrupamentos *K-Means* foi utilizada para reduzir um extensivo número de curvas de carga, onde o número de *clusters* é determinado por uma análise de sensibilidade baseada na execução de FP determinísticos.

Dado o estado da arte descrito, fica clara a importância de se desenvolver métodos de FP que considerem incerteza dos parâmetros de entrada. Ademais, foram vistas inúmeras aplicabilidades dessa ferramenta na literatura, dependendo dos objetivos almejados. Destaca-se novamente que são imprescindíveis estudos que modelem a incerteza das condições de entrada do FP, como forma de se aproximar cada vez mais das possibilidades práticas, traduzindo resultados mais relevantes para tomada de decisões.

A Tabela 1 contém um resumo das principais características dos trabalhos analisados, como forma de facilitação visual para compará-los. Ao final, é apresentada a caracterização do presente trabalho no que se refere às condições implementadas no FPP.

Tabela 1 - Trabalhos destacados na revisão bibliográfica sobre FPP

Trabalho	Método de Solução do FPP	Variáveis Aleatórias	Consideração de Modelagem Multifásica	Dimensão do Maior Sistema Simulado, em barras
Borkowska (1973)	Analítico	Injeções de potência	Não	15
Klitin (1975)	Intervalos de confiança	Injeções de potência	Não	40
Allan <i>et al</i> (1981)	Analítico	Injeções de potência	Não	32
El-Hawary e Mbamalu (1991)	Analítico	Injeções de potência	Não	23

Karakatsanis e Hatzargyriou (1994)	Analítico	Injeções de potência	Não	124
Lehtonen (1998)	Analítico	Cargas lineares e não lineares	Não	13
Chun-Lien Su (2005)	Aproximação via MEP	Injeções de potência e parâmetros de rede	Não	118
Morales <i>et al</i> (2007)	Aproximação via MEP	Geração e demanda	Não	118
Delgado e Navarro (2014)	Aproximação via MEP	Demanda, geração eólica e fotovoltaica	Sim	123
Gupta e Doratha (2017)	Aproximação via MEP	Demanda e geração eólica	Sim	118
Krishna e Gupta (2017)	Aproximação via MEP	Demanda e geração renovável	Não	69
Ren <i>et al</i> (2017)	Numérico	Aleatoriedade das marés	Não	57
Carpinelli <i>et al</i> (2018)	Analítico	Demanda, geração eólica e fotovoltaica	Sim	34
Li <i>et al</i> (2018)	Numérico	Velocidade do vento	Não	30
Deng <i>et al</i> (2019)	Analítico	Demanda e geração eólica	Não	118
Ferraz <i>et al</i> (2019)	Aproximação via K-Means	Demanda	Não	23
Presente Trabalho	Aproximação via K-Means	Demanda	Sim	123

Fonte: elaborado pelo autor (2022).

É possível perceber que a vasta maioria dos trabalhos citados não trata da modelagem multifásica das redes. Alguns trabalhos se dedicam aos sistemas de transmissão, o que tende a acarretar erros menores, devido ao seu maior equilíbrio e a uma relativa maior previsibilidade. Entretanto, ao simular SDEE, é imprescindível que a modelagem esteja apta a representá-lo de uma forma mais verossímil. Logo, faz-se necessária a consideração de cada fase do sistema, para que características como cargas desequilibradas, indução mútua entre circuitos, conexões não usuais de transformadores, entre outras, estejam todas presentes no equacionamento matemático.

1.2.2 FLUXO DE POTÊNCIA PROBABILÍSTICO ÓTIMO

Muitos autores realizaram estudos de otimização que envolvem a modelagem do FPP como restrições. Ou seja, busca-se avaliar o estado ótimo de uma determinada rede, dadas condições de entrada incertas. Esse tipo de problema é referido na literatura como Fluxo de Potência Probabilístico Ótimo (FPPO). Ao contrário da formulação tradicional do Fluxo de Potência Ótimo (FPO), a análise não é limitada a um único cenário determinístico. Isso faz-se necessário em situações em que o objetivo é tomar decisões de planejamento e operação de sistemas, considerando detalhamento que favorece a representação de situações mais diversas e próximas da realidade.

Nesta subseção, serão destacados estudos recentes que empregaram metodologias de FPPO para resolver problemas relacionados a sistemas elétricos, apresentando, portanto, resultados relevantes.

No trabalho de Malekpour *et al* (2013), foi apresentado um algoritmo multi-objetivo baseado em PSO (do inglês: *Particle Swarm Optimization*) para reconfigurar redes de distribuição sob uma perspectiva estocástica. O sistema analisado possui penetração de GD eólica e células de combustível. Foram investigadas as minimizações de quatro funções objetivo: perdas de energia, custo de geração, emissões poluentes e desvio de tensão. O FPP foi solucionado via MEP, sendo a demanda e a geração eólica as variáveis aleatórias consideradas.

Rodriguez *et al* (2014) sugeriram um método que combina duas meta-heurísticas, JP (do inglês: *Jump Frog*) e PSO, para determinar as posições e as potências de saída de geradores fotovoltaicos. O objetivo adotado foi minimizar o máximo índice de desequilíbrio de tensão. É utilizada uma abordagem probabilística, via MMC.

No artigo de Jain *et al* (2014), uma técnica baseada em PSO foi utilizada para posicionar otimamente unidades de GD eólica e capacitores, levando em consideração as incertezas da demanda e da geração renovável citada. Assim como no trabalho anterior, foi empregado o MMC para solucionar o FPP. Foram estudados os seguintes impactos: perfil de tensão, perdas, restrições ambientais e custo de geração.

No trabalho de Saunders (2014) foi proposta uma estrutura de FPPO destinada a sistemas de transmissão. O objetivo consistiu na minimização de custos de geração, considerando correlações de variáveis aleatórias associadas às gerações eólicas. Para isso, as incertezas foram modeladas via MEP.

Em Li *et al* (2014), os autores também usufruíram da abordagem via MEP para representar as incertezas em um problema cujo intuito foi a minimização dos custos de geração em sistemas de transmissão. A técnica de otimização empregada foi o Método dos Pontos Interiores (MPI). O FPP considerou correlação de variáveis aleatórias de geração eólica.

O artigo de Shargh *et al* (2016) apresentou a formulação de um problema de FPPO com o intuito de minimizar custos de geração e emissão de poluentes. As incertezas foram modeladas via MEP e a otimização foi efetivada por meio de uma meta-heurística denominada BBO (do inglês: *Biogeography Based Optimization*).

Já no desenvolvimento de Ke *et al* (2016), os autores apresentaram uma abordagem voltada para o mercado de energia elétrica. Nela, buscou-se desenvolver um método de FPPO que conseguisse mitigar a incerteza em relação à geração de energia no sistema, almejando equilíbrio dos preços de mercado. O FPP foi solucionado via algoritmos analíticos e a otimização foi feita por SQP (do inglês: *Sequential Quadratic Programming*).

O artigo de Ahmed *et al* (2018) apresentou uma otimização baseada na heurística PESA-II (do inglês: *Pareto Envelope-Based Selection Algorithm II*) com lógica *fuzzy*. O objetivo envolveu a alocação de compensadores estáticos de reativos (CER) para minimizar perdas e desvios de tensão em SDEE. Na otimização, levou-se em consideração o FPP em suas restrições, sendo este solucionado via técnicas analíticas.

O trabalho de Xie (2018) modificou a abordagem do MMC para resolver um FPPO considerando variáveis diferentes com o intuito de representar parques eólicos distintos. O objetivo da otimização foi minimizar os riscos em relação ao custo de combustível de geradores despacháveis. Para efetuar a otimização foi utilizada a meta-heurística GSO (do inglês: *Group Search Optimizer*).

Em Morshed *et al* (2018), os autores formularam e resolveram um problema de FPPO em um sistema que contém VEs, sistemas fotovoltaicos e eólicos. Assim como no trabalho anterior, o MMC foi modificado para ser mais eficiente do ponto de vista computacional. A Função Objetivo (FOB) adotada envolveu custos de geração e emissões de poluentes, sendo esta simulada via Algoritmos Genéticos.

A resolução de um problema de FPPO considerando redes desequilibradas e com penetração de energias renováveis foi proposta em Giraldo *et al* (2019). Nesse estudo, foi considerada a estrutura de uma otimização robusta onde as variáveis aleatórias compreendem a velocidade do vento, irradiação solar e a demanda. A proposta englobou uma otimização de dois níveis que busca minimizar o custo de geração, enquanto satisfaz as restrições robustas. As incertezas foram modeladas via MEP.

No trabalho de Uniyal e Sarangi (2021), foi sugerida a alocação ótima de unidades de GD e reconfiguração de redes para aprimorar a margem de estabilidade de tensão e visando redução de perdas. A otimização foi realizada via algoritmo WOA (do inglês: *Whale Optimization Algorithm*). Foi utilizado MEP para modelar as incertezas.

No trabalho de Srithapon *et al* (2021), foi proposta uma otimização baseada em técnicas de *machine learning* para calcular o FPPO, considerando irradiação solar, VEs e demandas incertas. O método adotado para modelar as incertezas consiste em um MEP chamado *Zhao Estimation Points*. Ele otimiza custos de operação, vida útil de equipamentos e objetivos ambientais. Neste trabalho, foi considerada a modelagem trifásica das redes, apesar dos autores terem simulado apenas um sistema de pequeno porte. A Tabela 2 contém um breve resumo das principais características dos trabalhos relacionados ao FPPO.

Tabela 2 - Trabalhos destacados na revisão bibliográfica sobre FPPO

Trabalho	Abordagem Adotada e Função Objetivo	Método de Otimização Utilizado	Método de Solução do FPP	Consideração de Modelagem Multifásica	Dimensão do Maior Sistema Simulado, em barras
Malekpour <i>et al</i> (2013)	Reconfiguração de redes multi-objetivo	PSO	MEP	Não	86

Rodriguez <i>et al</i> (2014)	Alocação de GD para reduzir desequilíbrio	JP e PSO	Monte Carlo	Sim	13
Jain <i>et al</i> (2014)	Posicionamento de GD eólica e capacitores para otimizar diversos propósitos	PSO	Monte Carlo	Não	41
Saunders (2014)	Otimizar despacho para minimizar custos de geração	Técnicas clássicas	MEP	Não	118
Li <i>et al</i> (2014)	Otimizar despacho para minimizar custos de geração	Técnicas clássicas	MEP	Não	292
Shargh <i>et al</i> (2016)	Otimizar despacho para minimizar custos de geração e emissões de poluentes	BBO	MEP	Não	30
Ke <i>et al</i> (2016)	Mitigar incertezas de geração para atender ao mercado	Técnicas clássicas	Técnicas analíticas	Não	24

Ahmed <i>et al</i> (2018)	Alocação de CER para reduzir perdas e desvios de tensão	PESA-II com lógica <i>fuzzy</i>	Técnicas analíticas	Não	69
Xie (2018)	Minimizar riscos em relação ao custo de combustível	GSO	MMC modificado	Não	118
Morshed <i>et al</i> (2018)	Custos de geração e emissões de poluentes	AG	MMC modificado	Não	118
Giraldo <i>et al</i> (2019)	Minimização de custos de geração	Técnicas clássicas	MEP	Sim	123
Uniyal e Sarangi (2021)	Alocação de GD e reconfiguração de redes para aprimorar margem de estabilidade e reduzir perdas	WOA	MEP	Não	69
Srithapon <i>et al</i> (2021)	Redução de custos de operação, otimização de vida útil de equipamentos e objetivos ambientais	Técnicas de <i>machine learning</i>	MEP	Sim	36

Presente Trabalho	Alocação de capacitores para redução de energia perdida, considerando horizonte de planejamento diário	Técnicas clássicas e AG	Aproximação via <i>K-Means</i>	Sim	123
-------------------	--	-------------------------	--------------------------------	-----	-----

Fonte: elaborado pelo autor (2022).

Através da revisão bibliográfica realizada, mostra-se que a maioria dos trabalhos presentes na literatura não sugere a formulação de problemas de FPPO para SDEE considerando a modelagem trifásica desses sistemas. Isso empobrece sua representação e os resultados podem ser distantes da realidade.

Além disso, é possível perceber que em muitos trabalhos são propostos métodos de aproximação para solucionar o FPP. Isso é devido ao enorme esforço computacional que os métodos numéricos requerem para alcançar resultados relevantes e à dificuldade de implementação de métodos analíticos. Nesse sentido, conclui-se que os métodos de aproximação são eficientes para serem implementados em problemas de otimização. Ao considerar a natureza trifásica dos sistemas, o tempo computacional para convergência dos FP se torna alvo de grande preocupação, sobretudo em sistemas de grande porte. Por conseguinte, o método de otimização a ser implementado e a técnica empregada de solução de FPP devem ser criteriosamente selecionados.

1.3 MOTIVAÇÕES

Analisando a necessidade e as possibilidades de estudos mais detalhados, pode-se considerar que a aplicação do FPP é imprescindível para a presente conjuntura do sistema elétrico, sobretudo para o planejamento de curto prazo, em que o aumento do detalhamento da modelagem se torna indispensável. Análises de redes sob a ótica probabilística são indicadas, o que pode ser verificado no atual estado da arte de pesquisas neste tema. Ademais, é necessário que tais análises sejam cada vez mais difundidas em detrimento de sua abordagem

determinística, principalmente em função do aumento de fontes renováveis distribuídas e VEs. Essas mudanças de paradigmas fazem com que exista enorme imprevisibilidade de geração e demanda de energia elétrica, de maneira que a modelagem das equações que regem esses fenômenos deve representar adequadamente tais incertezas.

Além disso, estudos de planejamento de SDEE são fundamentais para tomar decisões, visando a operação eficiente das redes e a manutenção da qualidade de energia dentro de padrões definidos por legislações vigentes. Logo, o desenvolvimento de estruturas de otimização que considerem as equações do FPP é relevante para a literatura. Para que os resultados desses estudos sejam fidedignos, a modelagem das redes deve representar o sistema corretamente, isto é, por meio de uma abordagem multifásica. Conforme visto na revisão bibliográfica apresentada na seção 1.2, são escassos os trabalhos que consideram simultaneamente as incertezas inerentes ao FPP e uma abordagem trifásica para representar adequadamente o desequilíbrio dos SDEE, representando uma carência na literatura.

Assim, todos os elementos citados são motivadores para um aprofundamento em FPPO e levaram ao desenvolvimento do presente trabalho. A aplicação escolhida para efetivar a proposta elaborada será descrita a seguir nos objetivos.

1.4 OBJETIVOS E CONTRIBUIÇÕES

O objetivo específico do presente trabalho é formular e solucionar um problema de otimização que visa identificar o posicionamento e dimensionamento de bancos monofásicos de capacitores fixos e chaveados, com o intuito de minimizar o valor esperado de energia perdida, considerando um horizonte de planejamento diário discretizado de forma horária. Nesse caso, as restrições do FPO incorporam incertezas da demanda, resultando em um problema de natureza probabilística.

Outro objetivo deste trabalho é o desenvolvimento de um método que esteja apto a estimar pontos relevantes de um parâmetro de entrada do FPP, de forma que apresente robustez suficiente para garantir bom desempenho computacional para ser implementado em algoritmos de otimização. Busca-se a acurácia de métodos numéricos, como o MMC, porém com esforço computacional semelhante ao visto nos MEPs.

As principais contribuições do trabalho estão listadas a seguir:

- É desenvolvido um método para cálculo de FPP trifásico baseado em aproximações via *K-Means*, onde é possível estimar as principais concentrações de um banco de dados ou de uma distribuição de probabilidades de maneira mais generalizada em relação aos MEPs presentes na literatura. Além disso, é formulada uma maneira de quantificar o quanto cada ponto estimado é influente na devida distribuição, formando-se, dessa maneira, os fatores de peso de cada concentração e gerando uma distribuição de probabilidade discreta para os parâmetros de entrada. A aplicação dessa técnica é fundamental para a modelagem de incertezas no problema de otimização formulado, pois consegue ser tão preciso quanto o MMC e requer menor esforço computacional.
- A formulação do FPP trifásico proposta é baseada no MEP convencional e, portanto, requer a solução de FP determinísticos para cada concentração observada. Para alcançar resultados mais relevantes, foi utilizada uma técnica de solução de FP trifásico denominada Método de Injeção de Correntes a N Condutores (MICN), que é ideal para representar SDEE vista sua aplicabilidade em modelar os nós do sistema de maneira individualizada, permitindo uma representação multifásica. Desta forma, os SDEE possuem todas as características que lhes são inerentes, como cargas desequilibradas, assimetria de rede, transformadores trifásicos, indução mútua entre circuitos, capacitores monofásicos e trifásicos, entre tantas outras.
- O problema de otimização formulado considera individualmente as 24 horas de um planejamento diário, isto é, está apto a determinar distribuições de probabilidade dos parâmetros de saída para cada uma das 24 horas do dia, em função de parâmetros de entrada também tratados individualmente para cada uma dessas horas. Isso confere ao problema uma veracidade muito maior, permitindo detalhamento horário das tomadas de decisão. Posteriormente, a técnica desenvolvida poderá ser generalizada para qualquer horizonte de planejamento desejado. Ressalta-se que a formulação de um FPO que considere, simultaneamente, as incertezas de parâmetros de entrada com o acoplamento temporal citado é uma contribuição para a literatura.
- A resolução do problema de otimização envolve técnicas clássicas e meta-heurísticas, que são solucionadas de forma iterativa. As técnicas clássicas são utilizadas para reduzir o espaço de busca do algoritmo empregado, baseado em AG. Essa consideração é importante para reduzir o tempo computacional empreendido e para a obtenção de resultados mais próximos dos pontos de otimalidade.

- A formulação do problema de otimização considera os limites de qualidade de energia estabelecidos nos Procedimentos de Distribuição ou PRODIST – Módulo 8, em relação à permissibilidade de limites de tensão em regime permanente. Logo, o presente trabalho possui aplicabilidade prática no que se refere à tradução de situações reais.

A partir das considerações feitas, a técnica desenvolvida foi simulada em sistemas-teste do IEEE que representam topologias de SDEE. A saber: IEEE 4 *Node Test-Feeder*, IEEE 13 *Node Test-Feeder*, IEEE 37 *Node Test-Feeder* e IEEE 123 *Node Test-Feeder*. Para conferir as respostas do FPP, simulações baseadas em MMC foram feitas através da execução de um FP sequencial probabilístico, revelando que os resultados foram muito próximos em termos de média e desvio padrão.

1.5 PUBLICAÇÕES DECORRENTES DO TRABALHO

O presente trabalho resultou nas seguintes publicações:

- “Um método de dois níveis para a alocação de compensações reativas monofásicas visando redução de perdas em sistemas de distribuição desequilibrados”. SBSE, VIII Simpósio Brasileiro de Sistemas Elétricos, 2020.
- “Avaliação dos impactos de modelos de máquina de indução trifásica no fluxo de potência multifásico”. CBA, XXIII Congresso Brasileiro de Automática, 2020.
- “Dimensionamento ótimo de filtros passivos em sistemas de distribuição desequilibrados”. CBQEE, XIV Conferência Brasileira sobre Qualidade de Energia Elétrica. 2021.
- “Capacitor allocation in unbalanced systems using a three-level optimization framework”. IEEE Latin America Transactions, 2021.

1.6 ESTRUTURA DO TRABALHO

Além desta introdução, o presente trabalho apresenta mais quatro capítulos. O capítulo 2 traz o arcabouço teórico acerca do Fluxo de Potência Probabilístico, a apresentação do método desenvolvido para avaliar o Fluxo de Potência Trifásico Probabilístico baseado em aproximações via *K-Means*, além de um exemplo aplicado a uma topologia didática. O capítulo

3 apresenta o problema de otimização desenvolvido para avaliar o Fluxo de Potência Trifásico Probabilístico Ótimo. No capítulo 4 são expostos os resultados obtidos através da aplicação prática de tal método. Por fim, o capítulo 5 expressa as considerações finais e são citados possíveis desenvolvimentos futuros.

O trabalho ainda contém cinco anexos. O anexo A trata de conceitos básicos cujo entendimento corrobora para a compreensão geral do trabalho. Serão apresentadas definições de estatística básica, os principais passos do algoritmo *K-Means*, além de conceitos gerais de sistemas de distribuição e métodos de otimização. O anexo B abrange as considerações a respeito do banco de dados que subsidia os estudos do Fluxo de Potência Probabilístico. O anexo C inclui o desenvolvimento teórico empregado para simular o Método de Monte Carlo. O anexo D compreende os dados das topologias simuladas. Por fim, o anexo E apresenta resultados acerca da repetibilidade do problema de otimização proposto.

2 FLUXO DE POTÊNCIA PROBABILÍSTICO

Nesta seção, o intuito é elucidar os principais conceitos teóricos acerca do Fluxo de Potência Probabilístico (FPP), assim como demonstrar o desenvolvimento matemático dos métodos empregados nesta dissertação. Ao fim da presente seção, será apresentado um exemplo de Fluxo de Potência Trifásico Probabilístico (FPTP) aplicado a um alimentador-teste de 4 barras do IEEE.

2.1 CONSIDERAÇÕES GERAIS

A análise do FP é vital para que se possa entender o comportamento de um determinado sistema em regime permanente, sendo muito utilizada em estudos de planejamento e operação. É uma ferramenta capaz de calcular tensões nodais e correntes que fluem nos circuitos, além dos fluxos de potência ativa e reativa nos mesmos, entre outras variáveis de interesse.

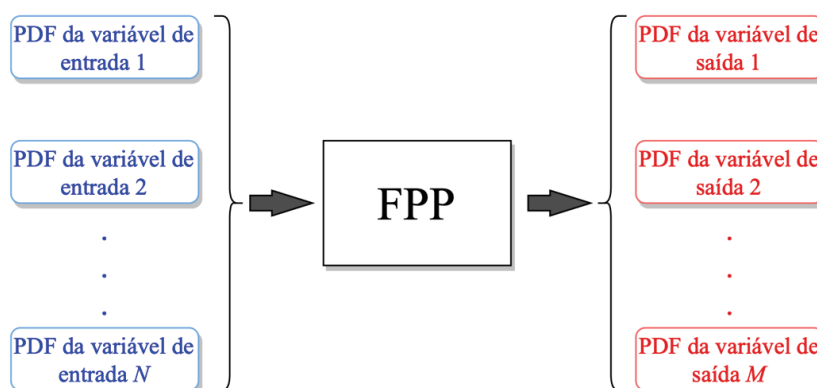
A formulação matemática do FP tem como base dados de entrada que caracterizam, além da própria rede, a geração e a carga do sistema trabalhado e, tradicionalmente, esses dados são determinísticos. Isto é, analisa-se um único patamar de geração e carga do sistema em uma abordagem baseada em *snapshot*, que consiste na determinação do estado da rede para aquela condição específica. Apesar da maioria dos trabalhos contidos na literatura ainda trabalharem com essas premissas, a consideração de um único cenário limita as análises que podem ser feitas, podendo até comprometer o estudo de planejamento. Cada vez mais há a necessidade de simular situações que considerem muitos cenários, sobretudo com o advento de fontes alternativas renováveis e veículos elétricos, que aumentam substancialmente a imprevisibilidade da geração e da carga do sistema. Nesse sentido, considerar um *snapshot* determinístico pode ocasionar erros significativos nos resultados alcançados, ainda que sejam simulados piores cenários. Uma vez que o uso de uma formulação determinística acarreta um único conjunto de soluções, diz-se que há ausência da variabilidade das variáveis de saída. Dessa forma, pode haver a negligência de certos problemas ocasionados em cenários específicos, os quais seriam apontados se uma formulação probabilística fosse adotada. Destacam-se distúrbios de tensão, como sobretensões e subtensões. Por exemplo, uma formulação determinística que considere um patamar de carga médio de acordo com um certo histórico, pode negligenciar um cenário em que tal parâmetro foi muito menor ou muito maior do que a referida média. Caso o operador seja guiado pelo seu estudo equivocado, problemas

oriundos dessa formulação podem surgir na prática, como subtensões ou sobretensões em patamares que não haviam sido verificados.

Por isso, torna-se necessário avaliar o FP que considere diversos pontos de operação, com condições de entrada distintas e introduzindo conceitos de estatística no seu equacionamento. Quanto maior for o detalhamento conferido, mais relevantes podem ser as tomadas de decisão.

A formulação do Fluxo de Potência Probabilístico (FPP) é uma das estratégias presentes na literatura para lidar com situações em que se deseja simular muitos cenários. Esse método é caracterizado pela modelagem das variáveis de entrada do FP através de funções densidade de probabilidade (ou PDFs, do inglês: *Probability Density Functions*), de forma que as variáveis de saída também podem ser representadas desta maneira (Ramadhani, 2020). A Figura 1 ilustra o processo geral do FPP.

Figura 1 - Procedimento geral do FPP com N entradas e M saídas



Fonte: elaborado pelo autor (baseado em Ramadhani, 2020).

Os métodos usados para solucionar o FPP podem ser divididos em três categorias: métodos numéricos, métodos de aproximações e métodos analíticos (Ramadhani, 2020).


Os métodos numéricos são aqueles que usam estimativas numéricas para solucionar problemas matemáticos. No âmbito do FPP, o mais empregado é o Método de Monte Carlo (MMC). O MMC é baseado na simulação repetitiva do problema determinístico a partir de amostras das funções de probabilidade das variáveis de entrada, permitindo a estimação das funções de probabilidade das variáveis de saída. Logo, uma consideração vital é o seu critério de parada, que pode ser introduzido via número máximo de simulações ou por meio de um

parâmetro de convergência (Ramadhani, 2020). Dessa forma, são simuladas amostras até que a convergência ocorra.

Uma vez que são necessárias muitas amostras para que se possa obter resultados relevantes via MMC, o esforço computacional para esse método tende a ser muito grande (Ramadhani, 2020). Por isso, ele é empregado majoritariamente para servir como referência a outros métodos. Existem, na literatura, versões aprimoradas para melhorar o seu desempenho computacional, tais como *latin hypercube* (Cai *et al*, 2014a) e *uniform design* (Cai *et al*, 2014b).

A Figura 2 ilustra os principais passos do algoritmo do MMC.

Figura 2 - Fluxograma do MMC



Fonte: Ramadhani, 2020.

Em **P1**, ocorre a leitura dos dados e a definição das PDFs de cada variável de entrada. Em **P2**, ocorre a seleção das amostras. Em **P3**, é executado o FP convencional, isto é, com os dados de entrada fixos e determinados de acordo com a amostra selecionada em **P2**. Em **P4**, é averiguado o critério de parada, que pode ser número máximo de simulações ou estagnação de uma ou mais variáveis. Diz-se que a estagnação ocorre quando, ao longo do processo iterativo, uma ou mais variáveis de saída de interesse têm sua variação inferior em relação à uma tolerância pré-estabelecida.

Caso haja convergência, o processo se encerra em **P5**, onde há a estimativa das PDFs das variáveis de saída de acordo com os resultados simulados das amostras. Caso contrário, retorna-se ao passo **P2**, onde uma nova amostra será selecionada ao acaso.


Os métodos de aproximação, também chamados de métodos de estimativas, são aqueles em que há a consideração de um número menor de amostras, a fim de reduzir o tempo computacional despendido pelo MMC. Nessa abordagem, são calculados os pontos que melhor representam as PDFs das variáveis de entrada, sendo a influência de cada um deles mensurada por um “fator de peso” (Ramadhani, 2020). O objetivo é gerar um número mínimo de amostras que esteja apto a representar de forma suficientemente precisa as PDFs das variáveis de entrada.

O método de aproximação mais comum é o Método da Estimativa dos Pontos (MEP), que utiliza propriedades estatísticas, como média aritmética e desvio padrão, para estimar os pontos mais influentes, não precisando recorrer necessariamente à distribuição de probabilidade propriamente dita.

Assim como nos métodos numéricos, os métodos de aproximação também envolvem a simulação do problema determinístico. O MEP apresenta muitas variações, estabelecidas inicialmente por Hong (1998). Os nomes de cada esquema de estimativa de pontos estão associados ao número de problemas determinísticos que serão simulados. Os mais comuns são: $2m$, $2m+1$, $3m$ e $4m$. Isto é, no método $2m$, por exemplo, será necessária a execução de $2m$ problemas determinísticos, onde m é o número de variáveis aleatórias compreendidas.

Na Figura 3, são apresentados os principais passos de um método por aproximação, de forma geral.

Figura 3 - Fluxograma dos métodos por aproximação



Fonte: elaborado pelo autor (baseado em Ramadhani, 2020).

Em **P1**, ocorre a leitura dos dados e a definição das variáveis de entrada e de suas probabilidades. Em **P2**, há o cálculo das principais concentrações e de seus respectivos fatores de peso. Em **P3**, ocorre a simulação do problema determinístico para cada concentração fornecida por **P2**. Calcula-se, enfim, as concentrações das variáveis de saída em **P4**, a partir dos resultados obtidos em **P3**. Finalmente, pode-se estimar, em **P5**, PDFs para as variáveis de saída a partir das concentrações obtidas. O processo se encerra em **P6**.

Os métodos ditos analíticos são aqueles que estão atrelados a operações aritméticas nas PDFs das variáveis de entrada. É comum que, nesse caso, haja simplificações nas equações do FP, como a adoção de sua abordagem linear (Ramadhani, 2020). Os principais métodos analíticos presentes na literatura são baseados em técnicas de convolução.

No presente trabalho, foi utilizado um método por aproximações baseado no algoritmo de agrupamento *K-Means*, cuja formulação será descrita na próxima subseção. Além disso, o MMC foi utilizado como referência comparativa.

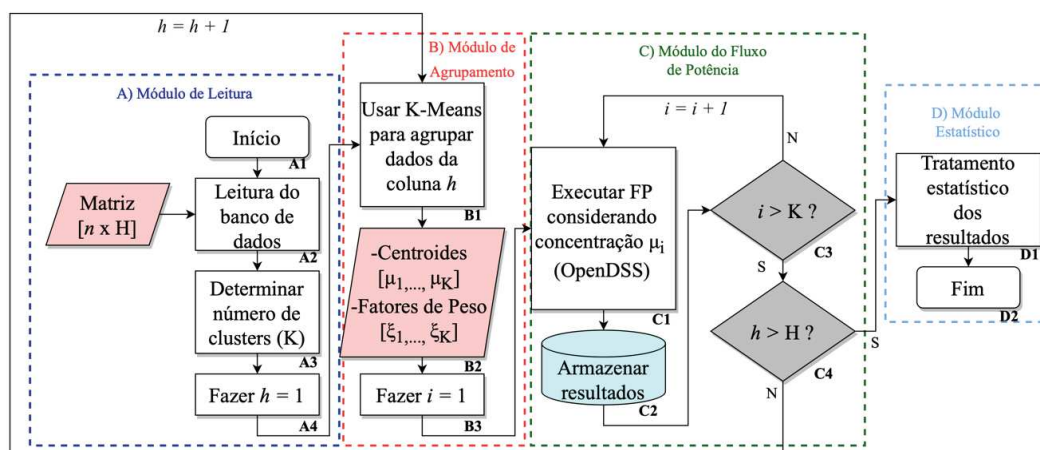
2.2 FLUXO DE POTÊNCIA TRIFÁSICO PROBABILÍSTICO VIA MÉTODO POR APROXIMAÇÕES BASEADO EM *K-MEANS*

Foi desenvolvido um algoritmo para solucionar o Fluxo de Potência Trifásico Probabilístico (FPTP) via método por aproximações. As concentrações e os fatores de peso são determinados por meio da técnica *K-Means*. Informações sobre tal algoritmo de agrupamento podem ser constatadas no anexo A.

A variável aleatória considerada para os cálculos é a demanda do sistema, todavia o método pode ser extrapolado para quaisquer conjuntos de variáveis aleatórias que se deseja representar.

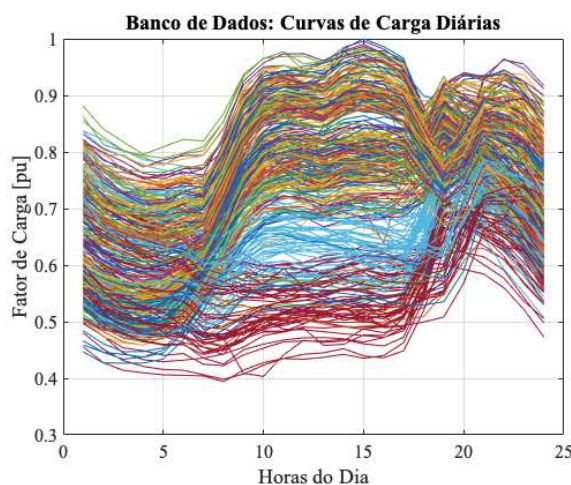
Dados um sistema conhecido e um banco de dados contendo informações horárias de demandas, o objetivo é obter o estado probabilístico da rede para cada hora do dia. Ou seja, são alvo do método o valor esperado, o desvio padrão e as funções de probabilidade das tensões nodais, das correntes que fluem nos circuitos, das potências ativas e reativas relacionadas a cada ramo, perdas, potências ativas e reativas geradas e quaisquer outras variáveis de interesse, considerando um horizonte de tempo diário. Por questão de economia de espaço e conveniência de representação de resultados, nesta seção serão enfatizadas as perdas ativas e as tensões nodais. O fluxograma do algoritmo desenvolvido pode ser observado na Figura 4. Posteriormente, cada um dos passos será abordado em detalhes.

Figura 4 - Fluxograma do FPTP desenvolvido



Fonte: elaborado pelo autor (2022).

Figura 5 - Exemplo do banco de dados com $n = 365$ (dias)



Fonte: elaborado pelo autor (2022).

O método é dividido em quatro grandes blocos, chamados “Módulos”. O primeiro deles, o Módulo A, se chama “Módulo de Leitura” e tem a responsabilidade de ler os dados de entrada e preparar as condições para a aplicação da técnica de agrupamento desses dados.

Em **A1**, o processo se inicia com a programação da topologia do sistema. Em **A2** há a leitura do banco de dados referentes à demanda do sistema. O banco de dados consiste em uma matriz de dimensão $n \times H$, com n leituras de demanda para cada intervalo de tempo, totalizando H discretizações. Para esse trabalho, foi adotado um horizonte diário com discretização horária, logo, $H = 24$. As entradas são valores que podem variar de 0 a 1, sendo, portanto, proporções que serão multiplicadas pela demanda original da topologia de maneira prévia à simulação do FP. Em outras palavras, os valores que compõem a matriz são fatores multiplicativos da carga original da topologia, que variam de hora para hora do planejamento diário. Essa matriz foi elaborada de acordo com os conhecimentos do autor do presente trabalho e mais detalhes podem ser observados no anexo B. A Figura 5 ilustra um exemplo de banco de dados com n igual a 365. Ou seja, o caso no qual são consideradas 365 curvas de carga.

Em **A3** é definido o número de *clusters* que será adotado. Isto é, para cada hora do dia, será decidido o número de concentrações K de forma a comprimir o banco de dados para uma matriz de dimensão $K \times 24$.

Em **A4** é iniciada uma operação em *loop* para varrer todas as horas do dia, por isso o contador de horas h é iniciado em $h=1$.

Inicia-se, portanto o Módulo B, chamado “Módulo de Agrupamento”. Nele, ocorrerá a compressão do banco de dados por meio de um algoritmo de *clustering*.

Em **B1**, é aplicada a técnica *K-Means* para os dados da hora h . Ou seja, é aplicada a técnica de *clustering* para a coluna h do banco de dados original. Dessa forma, reduz-se a quantidade n de observações para K . Para cada *cluster* definido, há o seu centro, também chamado centroide, que é o valor que melhor representa os dados nele contidos de acordo com as distâncias Euclidianas. Mais detalhes podem ser vistos no anexo A.

Os valores que vão compor a nova matriz, também chamada de matriz comprimida, serão justamente os K centroides que representam o grupo de dados original, sendo referidos pelo conjunto $\{\mu_1^h, \dots, \mu_K^h\}$. Além disso, os fatores de peso de cada centroide também são definidos nessa etapa. Esses fatores de peso são determinados em consonância com a lógica do *K-Means*. Conforme mencionado na seção 2.1 e apresentado em detalhes no anexo A.2, os fatores de peso são essenciais para qualquer método de aproximação, pois é por meio deles que as concentrações das variáveis de saída podem ser calculadas, assim como suas funções de probabilidade. Eles mensuram o quanto uma concentração é influente no conjunto de dados original e são determinados através da equação (2.1).

$$\xi_i^h = \frac{n_i}{n} \quad (2.1)$$

Onde:

ξ_i^h é o fator de peso do centroide μ_i e hora h ;

n_i é o número de elementos do *cluster* c_i , o qual é representado pelo centroide μ_i ;

n é o número total de elementos da coluna h do banco de dados original.

Como:

$$\sum_{i=1}^K n_i = n \quad (2.2)$$

Então:

$$\sum_{i=1}^K \xi_i^h = 1 \quad (2.3)$$

Pode-se inferir, portanto, que as concentrações ξ_i^h também podem ser interpretadas como a probabilidade de ocorrência de cada um desses cenários representados por μ_i^h .

Em **B2** são determinadas todas as concentrações μ_i^h , $i = \{1, \dots, K\}$, além de todos os fatores de peso ξ_i^h , referentes à hora h .

Em **B3**, uma lógica de *loop* é iniciada para varrer todos os elementos μ_i^h . Portanto, o contador i é inicializado em 1, referente ao centroide μ_1^h .

Inicia-se o Módulo C, chamado “Módulo do Fluxo de Potência”. Nele, haverá as simulações do problema de FP determinístico para cada concentração definida no Módulo anterior, assim como o armazenamento das variáveis de saída para cada centroide.

Em **C1**, é simulado o FP trifásico determinístico para a concentração μ_i^h . É importante frisar que as concentrações são proporções. Portanto, nessa etapa, multiplicam-se todas as demandas do sistema por μ_i^h e em seguida o problema de FP determinístico pode ser solucionado. Neste trabalho, são considerados SDEE, de forma que são buscados métodos de solução que considerem a natureza desequilibrada dos sistemas, tais como o Método de Injeção de Correntes a N Condutores (Penido *et al*, 2008) ou via *software OpenDSS*. Informações sobre ambos estão presentes no anexo A.

Em **C2**, são armazenadas todas as variáveis de saída desejadas. Podem ser tensões nodais, correntes nos ramos, perdas ativas, potência gerada por fase ou qualquer outra que for conveniente. Essas variáveis de saída serão genericamente denotadas por y_i^h , atreladas à entrada μ_i^h .

Em **C3**, é averiguado se o contador i varreu todos os K centroides. Caso seja verdade, o processo continua. Caso contrário, o contador é incrementado e o processo retorna ao passo **C1**.

Em **C4**, é averiguado se o contador h varreu todas as 24 horas do dia. Caso seja verdade, o processo continua. Caso contrário, o contador é incrementado e o processo retorna ao passo **B1**.

Após o término de todas as simulações determinísticas para todas as concentrações, há o Módulo D, chamado “Módulo Estatístico”. Nele são feitas análises de cunho estatístico dos resultados obtidos.

Em **D1**, são feitas as análises dos resultados, onde é obtido o estado probabilístico da rede. O valor esperado para a saída y^h considerando as K concentrações é dado pela equação (2.4).

$$\overline{y^h} = \sum_{i=1}^K \xi_i^h y_i^h \quad (2.4)$$

O desvio padrão para a saída y^h pode ser determinado de acordo com a equação (2.5).

$$\sigma = \sqrt{\sum_{i=1}^K (y_i^h - \overline{y^h})^2 \xi_i^h} \quad (2.5)$$

A variável y pode ser qualquer saída do problema convencional de FP. Nesse sentido, pode ser uma grandeza real, como o fluxo de potência ativa que transita nas redes, por exemplo, ou grandezas complexas, como tensões e correntes elétricas. Neste trabalho, os cálculos dos valores esperados e dos desvios padrões de variáveis complexas são feitos usando as magnitudes das grandezas fasoriais. Apesar de ser uma simplificação, é um artifício utilizado na literatura, principalmente quando métodos de aproximação são empregados. Dessa forma, evita-se utilizar a teoria de probabilidade em espaços complexos e matrizes de covariância. Isso pode ser visto em Morales *et al.* (2007) Delgado *et al.* (2014) e Krishna *et al.* (2017).

Com o conhecimento do valor esperado e do desvio padrão, pode-se determinar as PDFs de qualquer variável de saída utilizando a distribuição normal. Mais detalhes sobre essa representação podem ser verificados no anexo A.

2.3 APLICAÇÃO DO FPTP EM UM SISTEMA DIDÁTICO

A subseção a seguir aborda um exemplo prático para conferir melhor entendimento do processo de cálculo do FPTP em um sistema didático de 4 barras. Além disso, alguns conceitos de análise de sistemas sob a perspectiva probabilística serão introduzidos.

2.3.1 APRESENTAÇÃO DA TOPOLOGIA E CONDIÇÕES DE SIMULAÇÃO

A topologia escolhida para o exemplo aplicado é a do sistema *IEEE 4 Node Test-Feeder* (IEEE, 2021). Ela é caracterizada por ser trifásica, desequilibrada, contendo um transformador e uma carga desequilibrada conectada à barra 4. A potência de cada carga vale $1275 + j791$ kVA, $1800 + j873$ kVA e $2375 + j782$ kVA, respectivamente, nas fases A, B e C. Esses valores


são submetidos ao produto dos valores do banco de dados que, por sua vez, possui 365 leituras, representando uma matriz de dimensão 365 x 24. Inicialmente, foram considerados 2 *clusters* por hora, ou seja, foi adotado $K = 2$. A matriz comprimida no processo *K-Means* possui dimensão 2 x 24, portanto. Posteriormente, será proposta uma discussão acerca desse parâmetro.

O método sugerido foi comparado com MMC para promover um debate crítico sobre os resultados. As cargas foram modeladas através de distribuições normais, considerando uma distribuição por hora do planejamento diário. Além disso, para simular o MMC foi adotado um número de 10.000 simulações para cada distribuição de probabilidade horária (por cada hora do dia), totalizando 2.400.000 simulações no total. O procedimento adotado foi exatamente o mostrado na Figura 2, adotando número máximo de simulações como critério de parada. Mais detalhes a respeito da implementação do MMC podem ser vistos no anexo C.

Por motivos de limitação de espaço, as variáveis de saída analisadas foram as magnitudes das tensões nodais, perdas ativas por hora em kW e a energia total perdida no horizonte de tempo diário em kWh.

Na Figura 6, é apresentado o *layout* da topologia simulada.

Figura 6 - Topologia *IEEE 4 Node Test Feeder*



Fonte: elaborado pelo autor (2022).

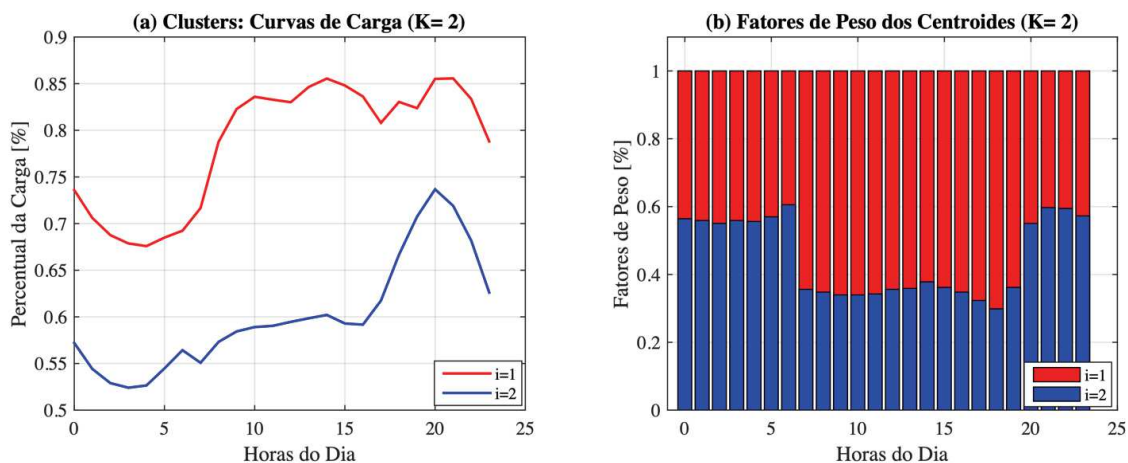
2.3.2 RESULTADOS DA SIMULAÇÃO DO EXEMPLO

Conforme mencionado na subseção 2.3.1, inicialmente foi adotado o número de *clusters* igual a 2. Nesse sentido, o banco de dados original, representado por 365 curvas de carga tal como visto na Figura 5, foi reduzido para duas curvas. Ambas são traçadas na Figura 7 (a).

Assim como os fatores multiplicativos proporcionais de carga por hora, também foram determinados seus respectivos fatores de peso, que quantificam o quanto cada um desses fatores representam o banco de dados original. Eles estão todos representados na Figura 7 (b). É

possível perceber que, dentro de uma mesma hora do dia, a soma dos fatores de peso sempre resulta na unidade, o que está em conformidade com a equação (2.3).

Figura 7 - Curvas de Carga para K = 2



Fonte: elaborado pelo autor (2022).

Dessa forma, podem ser estimadas algumas grandezas de interesse a partir dos resultados do FP determinístico para cada concentração ou centroide e de suas probabilidades ou fatores de peso.

O valor esperado das perdas por hora do dia, em kW, pode ser calculado por meio da expressão (2.6).

$$\overline{p^h} = \xi_1^h p_1^h + \xi_2^h p_2^h \quad (2.6)$$

Onde

ξ_1^h é o fator de peso do centroide μ_1 e hora h ;

ξ_2^h é o fator de peso do centroide μ_2 e hora h ;

P_1^h são as perdas, em kW, calculadas por meio do FP determinístico considerando fator proporcional de carga μ_1 e hora h ;

P_2^h são as perdas, em kW, calculadas por meio do FP determinístico considerando fator proporcional de carga μ_2 e hora h .

Já o valor esperado da energia perdida ao longo do dia pode ser calculado por meio da equação (2.7), aproveitando a linearidade do operador que determina o valor esperado da soma de variáveis aleatórias. Mais detalhes podem ser verificados no anexo A.

$$\bar{E} = \sum_{h=1}^{24} \bar{P}^h \quad (2.7)$$

A média ponderada das magnitudes das tensões nodais pode ser calculada, de maneira simplificada, através da equação (2.8).

$$\bar{V}_k^h = \xi_1^h V_{k,1}^h + \xi_2^h V_{k,2}^h \quad (2.8)$$

Onde

$V_{k,1}^h$ é a magnitude da tensão nodal do nó k , em pu, calculada por meio do FP determinístico considerando fator multiplicativo proporcional de carga μ_1 e hora h ;

$V_{k,2}^h$ é a magnitude da tensão nodal do nó k , em pu, calculada por meio do FP determinístico considerando fator multiplicativo proporcional de carga μ_2 e hora h .

O desvio padrão da tensão nodal do nó k pode ser calculada por intermédio de (2.9).

$$\sigma_{V_k} = \sqrt{\left(V_{k,1}^h - \bar{V}_k^h \right)^2 \xi_1^h + \left(V_{k,2}^h - \bar{V}_k^h \right)^2 \xi_2^h} \quad (2.9)$$

Conforme mencionado na subseção anterior, em (2.8) e em (2.9) são utilizadas as magnitudes dos fasores de tensão para calcular, respectivamente, o valor médio e o desvio padrão. Esse recurso, que se trata de uma simplificação, é empregado para que se possa evitar o uso de matrizes de covariância. O estudo de teorias de probabilidade em espaços complexos foi deixado para desenvolvimentos futuros.

Tendo as médias ponderadas e os desvios padrões de todas as magnitudes de todas as tensões, é possível traçar suas respectivas distribuições normais, tal como pode ser verificado no anexo A.

Em consonância com a teoria de funções normalmente distribuídas, diz-se que a probabilidade de uma variável aleatória estar contida no intervalo entre $\mu - 3,01\sigma$ e $\mu + 3,01\sigma$ é aproximadamente 99,9%, onde μ e σ são, respectivamente, a média e o desvio padrão usados

para constituir tal distribuição normal (Gallego *et al.*, 2012). Essa característica é expressa em (2.10).


$$P(\mu - 3,01\sigma < X < \mu + 3,01\sigma) \approx 0,999 \quad (2.10)$$

Em outras palavras, existe uma enorme confiança em relação aos valores de uma variável aleatória normalmente distribuída estarem contidos nesse intervalo. Sob essa perspectiva, torna-se razoável utilizar esses limites para que se possa estimar os valores máximos e mínimos de magnitude de tensão.

Tendo em vista os conceitos apresentados, foram traçados gráficos para demonstrar o comportamento probabilístico do sistema-teste sob análise.

Na Figura 8, foram traçados os valores esperados de perdas, em kW, por hora. As marcações circulares estão atreladas ao método *K-Means*, cujos pontos foram obtidos via equação (2.6). Já as marcações quadradas são referentes ao MMC, usado para comparação.

Figura 8 - Comparação *K-Means* x MMC: perdas por hora do dia



Fonte: elaborado pelo autor (2022).

Comparando ambas as curvas, pode-se inferir que o resultado obtido pelo método proposto foi semelhante ao MMC. É possível, ainda, quantificar o erro de potência perdida, ϵ_p , e o erro máximo de energia perdida, ϵ_E , através das equações (2.11) e (2.12).

$$\epsilon_P = \frac{|\overline{P_{KM}^h} - \overline{P_{MC}^h}|}{\overline{P_{MC}^h}} * 100\% \quad (2.11)$$

$$\epsilon_E = \frac{|\overline{E_{KM}} - \overline{E_{MC}}|}{\overline{E_{MC}}} * 100\% \quad (2.12)$$

Onde:

$\overline{P_{KM}^h}$ é o valor esperado de perdas, em kW, determinado via *K-Means* para hora h ;

$\overline{P_{MC}^h}$ é o valor esperado de perdas, em kW, determinado via MMC para hora h ;

$\overline{E_{KM}}$ é o valor esperado da energia total perdida, em kWh, determinado via *K-Means*;

$\overline{E_{MC}}$ é o valor esperado da energia total perdida, em kWh, determinado via MMC.


Tomando o FFTP baseado em *K-Means* com dois *clusters*, o erro máximo de potência perdida em relação ao MMC vale $\epsilon_P = 2,78\%$, enquanto o erro de energia perdida vale $\epsilon_E = 1,37\%$. Ambos os resultados evidenciam que o método é suficientemente preciso para estimar os valores esperados de perdas. Além disso, nota-se que o método proposto é mais eficiente do ponto de vista computacional – leva apenas 0,84 segundo para alcançar a convergência, contra 3.424 segundos (aproximadamente 57 minutos) quando o MMC é empregado.

Percebe-se que o erro, apesar de ser pouco significativo, ainda pode ser minimizado se forem adicionados mais *clusters*. Entretanto, isso proporcionará o aumento do tempo computacional. Futuramente, será avaliado como estimar corretamente o número de agrupamentos para que os resultados possuam tanto a acurácia desejada pelo usuário quanto esforço computacional aceitável.

De forma análoga, a Figura 9 tem como objetivo estabelecer uma comparação entre os valores esperados para o perfil de tensão, considerando o método via *K-Means* em relação ao MMC. Na figura, as marcações circulares na cor preta são associadas ao valor esperado de tensão por hora do dia, calculadas por meio da equação (2.8). Já as marcações quadradas na cor preta são atreladas aos valores esperados segundo o MMC, por hora do dia. Além disso, foram traçados mais dois grupos de gráficos: na cor vermelha, o valor máximo estimado de tensão e na cor azul o mínimo valor estimado – marcadores circulares relacionados ao *K-Means* e marcadores quadrados associados ao MMC. Ambos são estimados por meio de (2.10). Esses valores limítrofes serão importantes para a definição do problema de otimização que será

introduzida no capítulo 3. Por questão de conveniência de aproveitamento de espaço, optou-se por relatar graficamente os resultados da barra 4, fase A.

Figura 9 - Comparação *K-Means* x MMC: perfil de tensão ($K = 2$)



Fonte: elaborado pelo autor (2022).

Através da análise da Figura 9, pode-se verificar que o método obteve sucesso em estimar os valores esperados do perfil de tensão, uma vez que os marcadores pretos estão praticamente sobrepostos. Além disso, nota-se que, apesar de estarem próximos, há um erro visível em relação aos extremos máximos e mínimos esperados. É possível limitar ainda mais tal erro através do aumento do número de *clusters*.

São introduzidas outras variáveis importantes para quantificar as discrepâncias citadas no parágrafo anterior.

O erro de valor esperado de tensão, denotado por ϵ_{Vmed} , é calculado por meio da equação (2.13).

$$\epsilon_{Vmed} = \frac{|\overline{V_{k,KM}^h} - \overline{V_{k,MC}^h}|}{\overline{V_{k,MC}^h}} * 100\% \quad (2.13)$$

Onde:

$\overline{V_{k,KM}^h}$ é o valor esperado de tensão no nó k , em pu, obtido via *K-Means* para hora h ;

$\overline{V_{k,MC}^h}$ é o valor esperado de tensão no nó k , em pu, determinado via MMC para hora h .

O erro de desvio padrão de tensão, denotado por $\epsilon_{V\sigma}$, é calculado por meio da equação (2.14).

$$\epsilon_{V\sigma} = \frac{|\sigma_{V_{k,KM}}^h - \sigma_{V_{k,MC}}^h|}{\sigma_{V_{k,MC}}^h} * 100\% \quad (2.14)$$

Onde:

$\sigma_{V_{k,KM}}^h$ é o desvio padrão da tensão no nó k , obtido via *K-Means* para hora h ;

$\sigma_{V_{k,MC}}^h$ é o desvio padrão de tensão no nó k , determinado via MMC para hora h .

Define-se o valor médio de erros de valores esperados de tensão, denotado por $\overline{\epsilon_{Vmed}}$, por meio da equação (2.15).

$$\overline{\epsilon_{Vmed}} = \frac{1}{N} \sum_{i=1}^N \epsilon_{Vmed i} \quad (2.15)$$

Onde:

N é o número total de nós da topologia.

Esse parâmetro informa um valor médio de como os valores médios de tensões, obtidos via *K-Means*, diferem-se em relação aos obtidos via MMC.

O mesmo conceito pode ser extrapolado para os desvios padrões de cada tensão nodal. O valor médio dos erros de desvios padrões para tensões nodais, $\overline{\epsilon_{V\sigma}}$, pode ser definido pela equação (2.16).

$$\overline{\epsilon_{V\sigma}} = \frac{1}{N} \sum_{i=1}^N \epsilon_{V\sigma i} \quad (2.16)$$

Dessa forma, quantifica-se uma quantidade média para os erros de desvio padrão em todos os nós da topologia em relação ao MMC.

Por fim, são definidos mais dois parâmetros de interesse. Os erros de valores máximos e mínimos obtidos de tensão. Em ambas as metodologias, *K-Means* e MMC, são tomados os maiores e menores valores de tensão estimados por hora. Consistem justamente nas curvas

vermelhas e azuis apresentadas na Figura 9. Esses parâmetros são denotados por ϵ_{Vmax} e por ϵ_{Vmin} , respectivamente.

$$\epsilon_{Vmax} = \frac{|V_{k,max,KM}^h - V_{k,max,MC}^h|}{V_{k,max,MC}^h} * 100\% \quad (2.17)$$

$$\epsilon_{Vmin} = \frac{|V_{k,min,KM}^h - V_{k,min,MC}^h|}{V_{k,min,MC}^h} * 100\% \quad (2.18)$$

Onde:

$V_{k,max,KM}^h$ é o valor máximo estimado para magnitude de tensão do nó k , calculado por meio do método *K-Means*, considerando hora h ;

$V_{k,min,KM}^h$ é o valor mínimo estimado para magnitude de tensão do nó k , calculado por meio do método *K-Means*, considerando hora h ;

$V_{k,max,MC}^h$ é o valor máximo estimado para magnitude de tensão do nó k , calculado por meio do MMC, considerando hora h ;

$V_{k,min,MC}^h$ é o valor mínimo estimado para magnitude de tensão do nó k , calculado por meio do MMC, considerando hora h ;

Tendo em vista as definições acima, são apresentados, na Tabela 3, os parâmetros estatísticos introduzidos para o sistema simulado com dois *clusters*.

Tabela 3 - Parâmetros estatísticos para $K = 2$ (todos os valores em porcentagens)

$\max(\epsilon_{Vmed})$	$\max(\epsilon_{V\sigma})$	$\overline{\epsilon_{Vmed}}$	$\overline{\epsilon_{V\sigma}}$	$\max(\epsilon_{Vmax})$	$\max(\epsilon_{Vmin})$
0,18	23,05	0,01	16,37	2,09	2,98

Fonte: elaborado pelo autor (2022).

Os parâmetros evidenciam o que foi constatado anteriormente: o número mínimo de *clusters* é suficiente para obter uma boa aproximação dos valores esperados, com erro máximo de apenas 0,18% em relação ao MMC. Entretanto, a dispersão dos dados fica comprometida, com erro máximo de desvio padrão podendo alcançar 23,05%. Logo, devem ser adicionados mais *clusters* para que se possa alcançar boa precisão de média e desvio padrão e, por conseguinte, obter acurácia suficiente para as grandezas limítrofes.

Desta forma, é aumentado o número de *clusters* e são calculados os parâmetros estatísticos. A Tabela 4 contém os resultados para valores de K iguais a 5, 10 e 100. Todos os valores estão em porcentagem, com exceção do tempo computacional, denotado por t , cuja unidade é ‘segundo’ (s). Usando como referencial de comparação, o MMC levou 3.424 segundos para alcançar a convergência (aproximadamente 57 minutos). É importante frisar que, em cada simulação para os diferentes valores de K, as condições de simulação do MMC são exatamente as mesmas, o que torna legítima a comparação.

Tabela 4 - Parâmetros estatísticos para K = 2, 5, 10 e 100

K	ϵ_P	ϵ_E	$\max(\epsilon_{Vmed})$	$\max(\epsilon_{V\sigma})$	$\overline{\epsilon_{Vmed}}$	$\overline{\epsilon_{V\sigma}}$	ϵ_{Vmax}	ϵ_{Vmin}	t [s]
2	2,78	1,37	0,18	23,05	0,01	16,37	2,09	2,98	0,84
5	1,54	0,46	0,12	8,73	0,01	3,77	0,77	1,15	1,66
10	1,33	0,31	0,11	6,33	0,01	1,91	0,58	0,89	2,93
100	1,25	0,26	0,10	5,88	0,01	1,48	0,52	0,80	26,44

Fonte: elaborado pelo autor (2022).

A partir da análise dos dados contidos na Tabela 4, conclui-se que o aumento de *clusters* ocasiona diminuição em todos os parâmetros estatísticos, de sorte que os resultados se tornam progressivamente mais precisos. Ademais, frisa-se que o erro em relação aos desvios padrões decresce substancialmente, mostrando que o aumento de agrupamentos de fato se traduz em um aumento da variabilidade dos dados. Isso também pode ser verificado através da queda do erro em relação aos valores máximos e mínimos constatados. Porém, após a inserção de um certo número de *clusters*, a redução do erro passa a ser menos acentuada. Verifica-se essa questão pelo fato dos parâmetros estatísticos para K=10 e K=100 serem muito semelhantes.

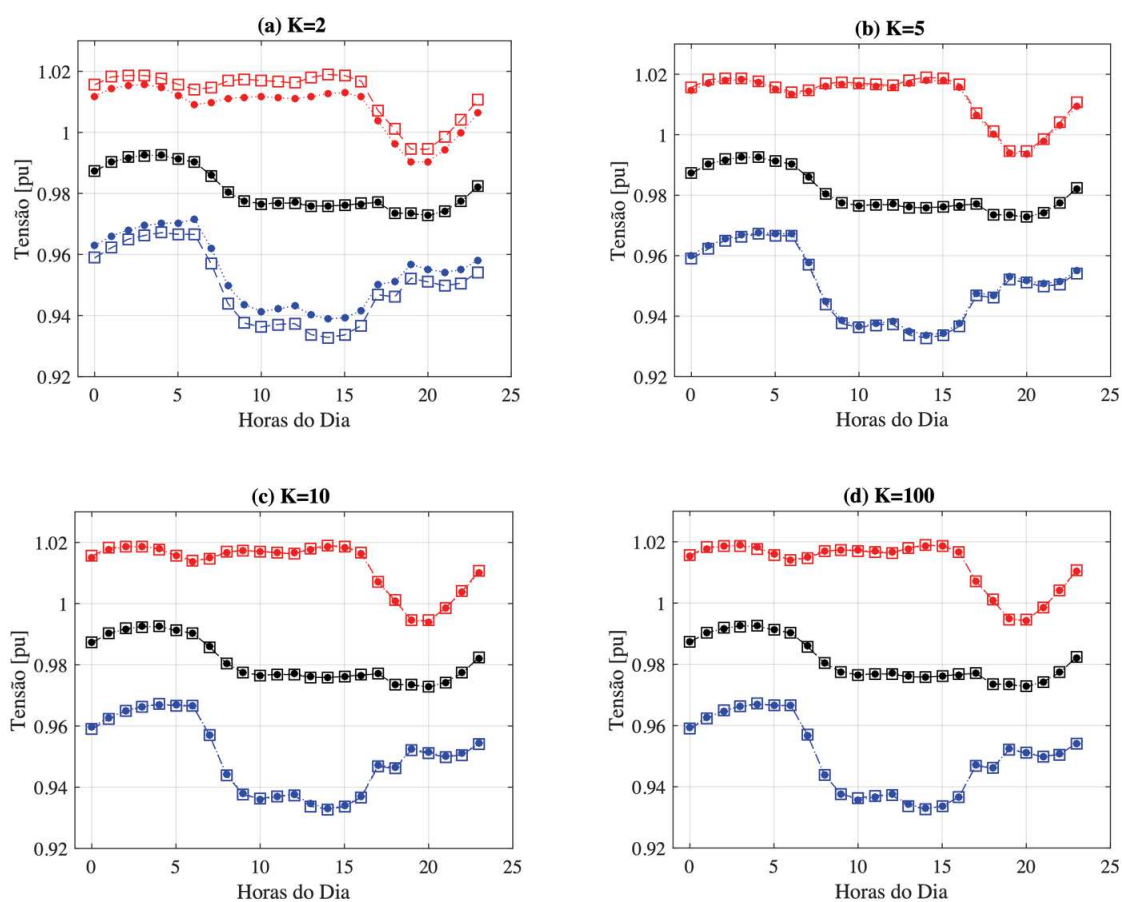
Portanto, é importante sublinhar que a definição do número de *clusters* é vital dependendo dos objetivos almejados pelo usuário. Há o interesse na obtenção de resultados precisos, tanto em média quanto em desvio padrão, porém considerando tempo computacional favorável. Isso significa que devemos adotar o mínimo número de *clusters* que cumpra tais propósitos. Uma maneira prática para definir esse valor de agrupamentos foi desenvolvida para esse trabalho e leva em consideração a execução do próprio FFTP. Tal algoritmo será elucidado passo a passo na próxima subseção.

Em relação ao tempo computacional, o algoritmo de FFTP via *K-Means* com 10 *clusters* é aproximadamente 1164 vezes mais rápido em relação ao MMC convencional. Mesmo

utilizando 100 *clusters*, o método proposto ainda é mais de 100 vezes mais rápido. Isto é uma das grandes vantagens do método desenvolvido.

Na Figura 10, são traçados os gráficos análogos aos mostrados na Figura 9, porém considerando 2, 5, 10 e 100 *clusters*. A legenda permanece a mesma.

Figura 10 - Comparação *K-Means* x MMC: perfil de tensão (Barra 4, Fase A)



Fonte: elaborado pelo autor (2022).

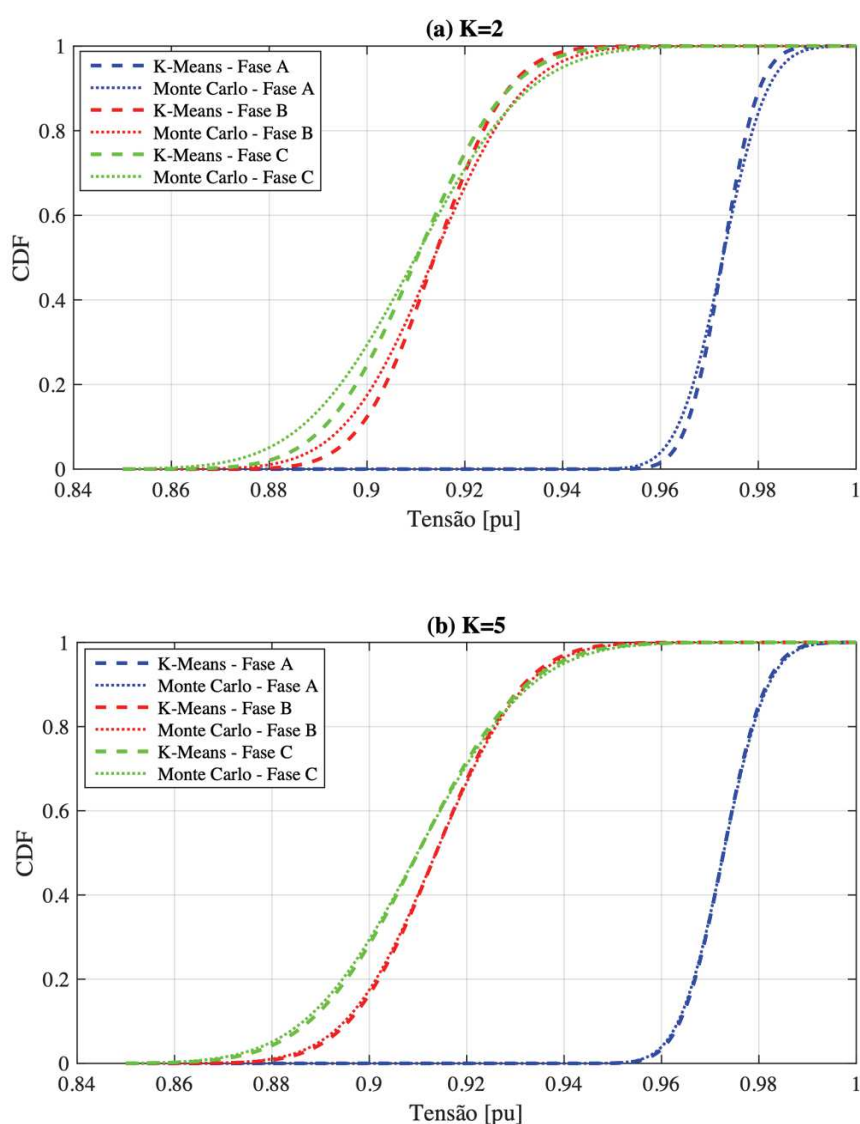
Pode-se constatar visualmente a progressiva diminuição do erro entre os valores máximos e mínimos estimados com o aumento de número de *clusters*. Isso está em consonância com os dados mostrados na Tabela 4.


Já a Figura 11 apresenta as funções de probabilidade acumulada, ou CDFs (do inglês: *Cumulant Distribution Function*), das tensões da barra 4. Tal função quantifica a probabilidade de ocorrência de um evento, dada por uma distribuição de probabilidade contínua, em um

determinado intervalo. Mais informações podem ser obtidas no anexo A. Por questões de conveniência de economia de espaço, optou-se por representar graficamente apenas os resultados para o horário de 20 horas.

As curvas em azul são referentes às CDFs da fase A. Em vermelho são plotadas as CDFs da fase B e em verde as da fase C. Novamente, enxerga-se a redução progressiva do erro presente pelo método baseado em *K-Means* à medida em que os *clusters* aumentam.

Figura 11 - Funções de probabilidade acumulada para tensão da barra 4






Fonte: elaborado pelo autor (2022).

É possível ver que as curvas obtidas via *K-Means* são muito próximas em relação àquelas verificadas pelo MMC, justificando também os baixos erros verificados de média e desvio padrão, sobretudo quando $K = 100$. A partir dos resultados expressados, conclui-se que o método de cálculo do FPTP desenvolvido, baseado em aproximações via *K-Means*, apresenta boa precisão e pode ser uma ferramenta útil devido à sua acurácia e ao seu tempo computacional favorável.

2.4 MÉTODO PARA ESTIMAR NÚMERO DE *CLUSTERS*

Foi desenvolvido um método prático para determinar um número adequado de *clusters*, de forma a obter boa precisão dos resultados. Ele se baseia na própria execução do FPTP e se caracteriza por ser um método iterativo. O fluxograma apresentado na Figura 12 revela os passos percorridos. Cada etapa será minuciosamente detalhada a seguir.

Figura 12 - Fluxograma do método desenvolvido para determinar número de *clusters*



Fonte: elaborado pelo autor (2022).

Em **P1**, ocorre o início do processo, em que há a leitura da topologia trabalhada e do banco de dados. Em **P2**, deve-se definir um conjunto **Y** de variáveis de saída, assim como uma

tolerância δ . Em **P3**, é preciso escolher um valor inicial de *clusters*, denotado por K_0 . Em **P4**, calcula-se o FPTP tal como apresentado na seção 3.2, tendo como base os K_0 *clusters*. São calculados, também, os valores esperados de cada variável de saída do conjunto \mathbf{Y} escolhido em **P2**.

Em **P5**, a quantidade de agrupamentos é incrementada e o passo **P4** é repetido com o valor de K atualizado. Em **P7**, é calculado o erro iterativo, denotado por ε , por meio da equação (2.19).

$$\varepsilon = \max \frac{|E[\mathbf{Y}]_{iter_{K'}} - E[\mathbf{Y}]_{iter_K}|}{E[\mathbf{Y}]_{iter_{K'}}} * 100\% \quad (2.19)$$

Onde:

$E[\mathbf{Y}]_{iter_{K'}}$ são os valores esperados de cada variável do conjunto \mathbf{Y} , considerando iteração do K atualizado;

$E[\mathbf{Y}]_{iter_K}$ são os valores esperados de cada variável do conjunto \mathbf{Y} , considerando a iteração anterior à atualização do parâmetro K .

Ou seja, o valor ε corresponde ao maior erro apresentado dentre todas os valores esperados das variáveis contidas no conjunto \mathbf{Y} pré-selecionado.

Em **P8**, é averiguado se tal erro ε é menor do que a tolerância δ pré-definida. Caso seja, o processo termina em **P9**. Caso contrário, retorna-se ao passo **P5**, onde a quantidade de *clusters* é incrementada.

Em outras palavras, ao fim do processo iterativo, será determinada uma quantidade K de *clusters* tal que é possível dizer que há estagnação dos valores esperados das variáveis de saída selecionadas, mediante uma tolerância.

Para exemplificar o método, foram tomadas quatro topologias desequilibradas do IEEE: IEEE 4, IEEE 13, IEEE 37 e IEEE 123 *Node Test-Systems*. Além disso, foram simulados bancos de dados de diferentes dimensões, que, assim como na seção anterior, caracterizam a demanda incerta do sistema por meio dos fatores proporcionais de carga. Os resultados estão mostrados na Tabela 5. As características de cada sistema-teste podem ser verificadas de forma detalhada no anexo D. Foi considerada uma tolerância $\delta = 0,01\%$ e o conjunto \mathbf{Y} contém a energia total perdida, ou seja, o parâmetro definido na equação (2.8). Esse valor foi escolhido pois terá vital importância no processo de otimização formulado no capítulo seguinte.

Conforme é possível constatar por meio da Tabela 5, o número de *clusters* varia muito pouco de acordo com a topologia. De forma geral, há uma variação mais significativa de acordo com a complexidade do banco de dados de entrada. Entretanto, nota-se que o intervalo obtido é limitado – sempre o algoritmo converge para algum valor entre 7 e 12 *clusters*, o que permite concluir que o algoritmo desenvolvido é suficientemente robusto.

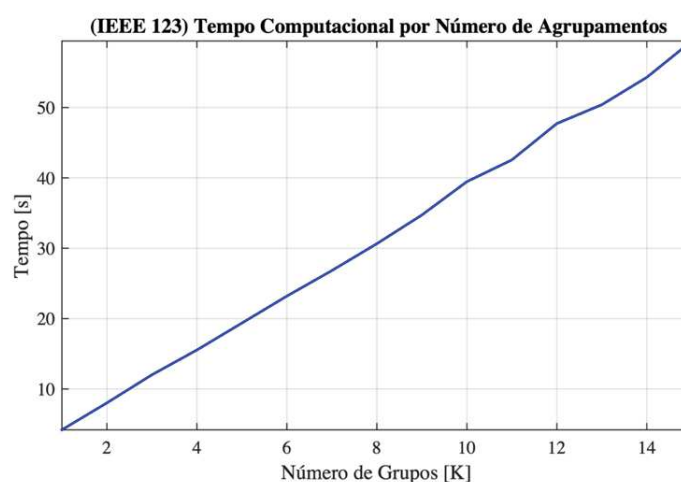
Tabela 5 - Número K de *clusters* por topologia simulada e por dimensão do banco de dados

Topologia Simulada	Dimensão do banco de dados					
	50 x 24	100 x 24	365 x 24	1000 x 24	2000 x 24	5000 x 24
IEEE 4	K = 7	K = 8	K = 11	K = 10	K = 12	K = 12
IEEE 13	K = 8	K = 8	K = 10	K = 10	K = 11	K = 11
IEEE 37	K = 7	K = 7	K = 10	K = 9	K = 10	K = 11
IEEE 123	K = 7	K = 7	K = 10	K = 9	K = 10	K = 11

Fonte: elaborado pelo autor (2022).

A Figura 13 apresenta a variação do tempo computacional para executar o FPTP considerando a topologia IEEE 123 e um banco de dados de dimensão 365 x 24, de acordo com o número de *clusters*.

Figura 13 - Evolução do tempo computacional de acordo com número de *clusters* para topologia IEEE 123

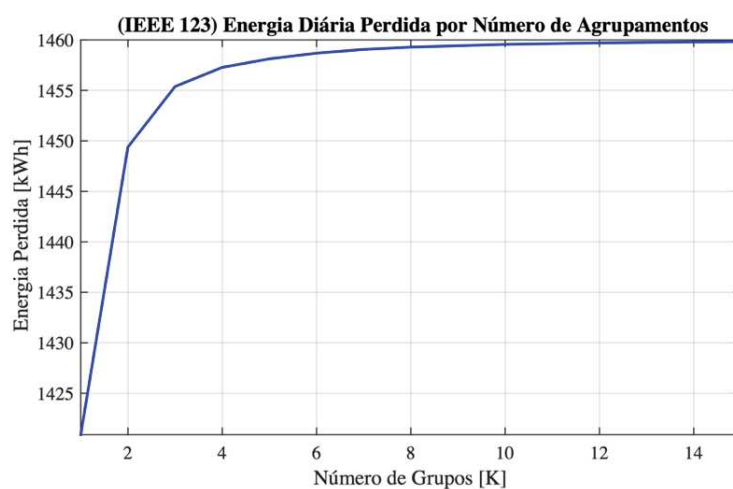


Fonte: elaborado pelo autor (2022).

Para o valor de $K = 10$, foram necessários aproximadamente 40 segundos para alcançar a convergência. É possível notar que o gráfico apresenta um comportamento aproximadamente linear, o que é computacionalmente favorável. Em outras palavras, a adição de um novo *cluster* irá implicar em um aumento linear do tempo computacional necessário.

Já a Figura 14 apresenta a variação do valor esperado para a energia total perdida em função do número de agrupamentos. Pode-se perceber visualmente a estagnação do resultado à medida que o número de *clusters* aumenta.

Figura 14 - Evolução da energia total perdida de acordo com número de *clusters* para topologia IEEE 123



Fonte: elaborado pelo autor (2022).

3 MÉTODO PROPOSTO PARA AVALIAR O FLUXO DE POTÊNCIA TRIFÁSICO PROBABILÍSTICO ÓTIMO

O presente capítulo objetiva apresentar o método desenvolvido para calcular o Fluxo de Potência Trifásico Probabilístico Ótimo (FPTPO).

3.1 CONSIDERAÇÕES INICIAIS

É muito comum a formulação de problemas de otimização para aplicações em estudos de planejamento de sistemas elétricos. Na literatura, convencionou-se chamar de “Fluxo de Potência Ótimo” (FPO) o resultado do problema de otimização cujas restrições envolvem as equações de um FP convencional. Consiste, portanto, em um ponto de operação ótimo, isto é, o estado da rede à luz de uma Função Objetivo (FOB). No entanto, por questões de simplicidade, a sigla FPO será usada, neste trabalho, para designar o problema de otimização que busca determinar tal estado operativo ótimo ou “quase ótimo” do sistema, englobando também os casos nos quais a otimalidade global não pode ser garantida.

Por intermédio dessa ferramenta são investigadas ações operativas para um determinado propósito. Uma formulação matemática genérica para um problema de otimização pode ser vista nas equações (3.1) a (3.3), onde \mathbf{z} é o vetor de variáveis de estado.

$$\min Z = f(\mathbf{z}) \quad (3.1)$$

Sujeito a:

$$g(\mathbf{z}) = 0 \quad (3.2)$$

$$h(\mathbf{z}) \leq 0 \quad (3.3)$$

A equação (3.1) diz respeito à FOB introduzida no problema. Trata-se do objetivo desejado pelo programador, para o qual o estado da rede terá seu comportamento ótimo. Muitas funções diferentes podem ser vistas na literatura, sendo algumas destacadas na revisão bibliográfica apresentada no capítulo 1.

As restrições designadas por (3.2) são as restrições de igualdade. Em problemas de FPO são geralmente formadas pelas equações do balanço de potência e também podem ser chamadas

de restrições de rede. Podem existir também outras restrições de igualdade definidas. Isso significa que a solução ótima deve necessariamente respeitar tal equacionamento. Já as restrições expressas por (3.3) são chamadas de restrições de desigualdade, restrições de canalização ou restrições operacionais. Buscam canalizar, no problema de otimização as condições a partir das quais o sistema pode operar. São extremamente importantes para impor limites operacionais de forma a respeitar normas vigentes, como os limites aceitáveis de perfil de tensão, por exemplo.

Na literatura, é usual a formulação do FPO usando restrições de rede determinísticas. Ou seja, usando as restrições de igualdade da expressão (3.2) como as equações de um FP determinístico. Tal perspectiva limita as variáveis de saída a um único cenário, o que pode não traduzir situações reais. Outra possibilidade é a análise de piores cenários ou cenários médios, o que pode levar a subdimensionamentos ou sobredimensionamentos de resultados. Por exemplo, calcula-se um FPO considerando o pior cenário de carregamento ou adotando uma média de acordo com uma série histórica.

Para aprimorar o modelo, foi desenvolvido o Fluxo de Potência Probabilístico Ótimo (FPPO). Nesse caso, é avaliado o estado ótimo da rede de acordo com uma FOB, porém considerando uma abordagem probabilística. Logo, tanto a FOB quanto as restrições recebem um tratamento probabilístico. Tal artifício confere à modelagem uma abordagem mais segura, pois, ao lidar com muitos cenários, o operador terá mais subsídio para tomada de decisões, minimizando a frequência de ocasiões nas quais uma operação pode incorrer em distúrbios de tensão ou outras irregularidades. Dessa forma, provoca resultados mais detalhados para análises. Nesse trabalho, será estudado o FPPO com modelagem baseada no método apresentado no capítulo anterior – isto é, método por aproximações via *K-Means*.

De forma geral, é possível modelar genericamente o problema de otimização a ser solucionado pelas equações (3.4) a (3.6).

$$\min Z = \sum_{i=1}^K \xi_i f_i(\mathbf{z}) \quad (3.4)$$

Sujeito a:

$$g_i(\mathbf{z}) = 0 \quad \forall i \in \{1, \dots, K\} \quad (3.5)$$

$$h_i(\mathbf{z}) \leq 0 \quad \forall i \in \{1, \dots, K\} \quad (3.6)$$

Sob essa abordagem, a FOB, expressa por (3.4) passa a ser a média ponderada das funções obtidas para cada um dos FP determinísticos, simulados para cada um dos K centroides do banco de dados de entrada. A ponderação é feita pelos fatores de peso. Já as restrições de rede, denotadas por (3.5), são as equações de todos os fluxos determinísticos simulados para cada um dos K centroides. Logo, a solução deve respeitar todos os FP solucionados ao longo do processo de otimização. Já as restrições de canalização, indicadas por (3.6) indicam que todos os K cenários simulados devem respeitar as condições operativas informadas pelo usuário. Logo, todos os cenários devem estar de acordo com as normativas vigentes e recomendações padronizadas.

É importante ressaltar que, apesar de ser uma formulação multi-cenário e probabilística, o vetor z de variáveis de estado ótimas obtido é único. Isso significa que, após a convergência do modelo, será obtido um conjunto singular de ações otimizadas que:

1. Minimiza em média os objetivos almejados pelo usuário, considerando todos os cenários possíveis.
2. Respeita as restrições, sejam de FP, sejam de condições operativas, para todos os cenários simulados.

Nesse sentido, a solução é obtida a partir de mais informações, tendendo a ser mais relevante e abrangente do que uma obtida via equacionamento determinístico.

3.2 OBJETIVOS GERAIS DO ALGORITMO PARA AVALIAR O FPTPO

Foi desenvolvido um algoritmo para calcular o Fluxo de Potência Trifásico Probabilístico Ótimo (FPTPO) em redes de distribuição desequilibradas. Ele é dito “trifásico”, uma vez que envolve a simulação do FP cujas redes são modeladas através de uma abordagem multifásica, conferindo-lhes verossimilhança em relação às características próprias do SDEE. Ele é “probabilístico” pois considera a formulação de FPTP apresentada no capítulo 2, ou seja, método de aproximações via *K-Means*. Finalmente, ele é dito “ótimo”, visto que usufrui desse equacionamento para criar uma estrutura de otimização capaz de determinar o estado ótimo da rede sob o ponto de vista de alguma FOB.

Em termos de aplicação, busca-se a alocação de capacitores monofásicos fixos e chaveados para obter a minimização do valor esperado da energia total perdida em um horizonte de tempo diário, sem que haja violações nos critérios de qualidade de energia referentes ao perfil de tensão nos cenários simulados no FPTP. Assim como mostrado no capítulo 2, a

variável aleatória de entrada consiste na demanda do sistema. Os critérios de qualidade são baseados no Módulo 8 do PRODIST, normativa vigente para regular as prerrogativas de limites mínimos e máximos de tensões de SDEE em regime permanente.

Em outras palavras, o intuito da otimização é obter:

1. As posições, ou seja, os lugares (barra e fase) nos quais os capacitores monofásicos fixos e chaveados serão instalados;
2. As capacidades, ou seja, as potências reativas nominais, em kvar, de todos os capacitores fixos e chaveados;
3. A estratégia de chaveamento horária de todos os capacitores chaveados, isto é, quais unidades estarão ligadas ou desligadas para cada hora do dia.

Assim como na formulação genérica apresentada pelas equações (3.4) a (3.6), a solução que é extraída do problema de otimização confere: (i) minimização da média da energia perdida diária, considerando todos os cenários possíveis; (ii) respeito às restrições de rede e operacionais em todos os cenários simulados.

Ou seja, a solução fornecerá as posições, capacidades e a estratégia de chaveamento dos capacitores que garantam o cumprimento dos itens (i) e (ii) listados no parágrafo anterior.

Ressalta-se que, em situações práticas, muitas vezes não é desejada uma configuração de alocação de capacitores que garanta o cumprimento de restrições operacionais para todos os cenários possíveis, como canalização de perfil de tensão por exemplo. Isso causaria o encarecimento substancial da solução candidata, uma vez que serão necessárias muitas unidades para efetivar tal controle em cenários críticos, porém pouco prováveis. No entanto, a formulação que será apresentada parte do pressuposto que todos os cenários devem estar de acordo com as normativas vigentes, sendo uma opção do operador aceitar ou não as soluções obtidas. O desenvolvimento de uma análise financeira associada a essas possibilidades será proposto em trabalhos futuros.

3.3 APRESENTAÇÃO DO ALGORITMO FPTPO

Conforme mencionado, busca-se a formulação de um problema de otimização cujo intuito é a obtenção da alocação ótima de capacitores monofásicos fixos e chaveados em sistemas de distribuição desequilibrados cuja demanda é modelada probabilisticamente via FPTP por aproximações, utilizando a técnica apresentada no capítulo 2 (método por

aproximações via *K-Means*) e considerando um horizonte de tempo diário com discretização horária.

Neste trabalho, o elemento “capacitor” é modelado como uma admitância constante. Logo, a potência reativa entregue ao sistema varia de acordo com a tensão nele aplicada. Porém, as variáveis de interesse no problema de otimização serão suas potências nominais, uma vez que é mais comum os fabricantes disponibilizarem seus produtos de acordo com tal parâmetro do que em relação à admitância ou à reatância dos bancos. Portanto, os resultados serão expressos em termos de potência reativa nominal, mas sabe-se que isso é apenas uma aproximação – trata-se da quantidade de potência reativa esperada quando a tensão nominal é aplicada. Ressalta-se ainda que existe uma relação única entre a potência reativa nominal de um capacitor e sua admitância, dada pela equação (3.7).

$$Q_{\text{nom}} = |V_{\text{nom}}|^2 Y_{\text{cap}} \quad (3.7)$$

Onde:

Q_{nom} é a potência reativa nominal do capacitor;

$|V_{\text{nom}}|$ é a magnitude da tensão aplicada sobre o capacitor;

Y_{cap} é a admitância do capacitor.


Tendo em vista tais definições, são chamados “capacitores fixos” aqueles que estão conectados fixamente durante todo o dia. Em outras palavras, não podem ter sua admitância alterada. Já os “capacitores chaveados” são aqueles que podem ter suas unidades conectadas ou desconectadas ao longo do dia. Logo, podem variar a admitância capacitiva resultante do banco, através de uma estratégia de chaveamento definida por hora. Isso também leva a uma alteração mais significativa da potência reativa entregue ao sistema pelo capacitor.

De maneira geral, o método desenvolvido é dividido em quatro grandes blocos, chamados “Módulos”. Cada um deles será minuciosamente explicado em subseções posteriores. Uma visão simplificada do algoritmo proposto pode ser verificada na Figura 15.

É importante frisar que a partição do problema em várias etapas de otimização é uma estratégia para que seja possível tratar um problema não-linear, inteiro, misto e que envolve séries temporais, tal como o que será definido a seguir. Logo, tal artifício renuncia à possibilidade de determinar o ponto ótimo global, para ganhar benefícios relacionados ao tempo computacional. Dessa forma, a sua intenção é encontrar uma configuração para a alocação dos

capacitores que cumpra os propósitos discutidos anteriormente, não necessariamente determinar a melhor configuração possível sob uma ótica global. Isso também irá justificar a escolha de técnicas de otimização baseadas em meta-heurísticas.

Figura 15 - Apresentação simplificada do FPTPO



Fonte: elaborado pelo autor (2022).

Cada módulo possui um desígnio específico. De forma resumida:

- Módulo A: responsável pela leitura do banco de dados relacionado à demanda do sistema. Nele, há a aplicação da técnica *K-Means*, em que o banco de dados original será comprimido para uma matriz menor, gerando todos os cenários a serem considerados no processo de otimização (K cenários por hora do dia, totalizando uma matriz de dimensão $K \times 24$).
- Módulo B: nele, é solucionado um problema de otimização determinístico, considerando os limites mínimo e máximo das demandas obtidas após o processo de *clustering*. O objetivo é obter os valores máximo e mínimo de potência reativa que podem ser injetados no sistema para evitar violações de tensão, de acordo com o PRODIST. Trata-se de uma redução do espaço de busca para as etapas seguintes. Utiliza-se o Método dos Pontos Interiores para realizar a otimização.
- Módulo C: nesta etapa, é utilizado o Algoritmo Genético (AG) para determinar as posições e capacidades nominais ótimas de capacitores fixos. A FOB empregada é a minimização das perdas esperadas, considerando todos os cenários no horário em que se espera que a carga seja mínima (ou seja, carga leve). De forma análoga, também são determinadas, na presente etapa, as posições e capacidades nominais dos capacitores chaveados, considerando todos os cenários no horário em que se espera que a carga seja máxima (ou seja, carga pesada).

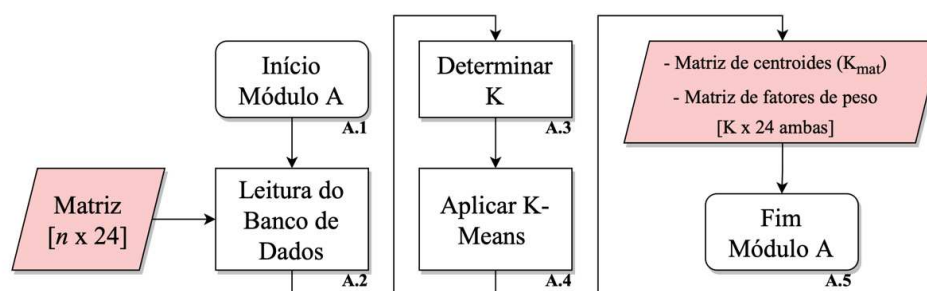
- Módulo D: após obter, no Módulo C, todas as potências nominais e posições dos capacitores fixos e chaveados para os horários de carga leve e pesada, basta otimizar a estratégia de chaveamento dos capacitores chaveados para as demais horas do dia. Conforme mencionado, os capacitores fixos se mantêm conectados ao sistema durante todo o horizonte de tempo trabalhado.

Logo, após a convergência do método, serão obtidas as posições e as potências nominais de todos os capacitores fixos, além das posições, das capacidades nominais e da estratégia de chaveamento de todos os capacitores chaveados. Nas próximas subseções, cada um dos módulos será detalhado passo a passo para que se possa obter uma compreensão mais ampla do FPTPO proposto.

3.3.1 MÓDULO A

O Módulo A tem como entrada o banco de dados original acerca das medições de demanda de um sistema de distribuição. Ele tem o intuito de ler e preparar os dados para as etapas posteriores. O fluxograma com os principais passos deste módulo pode ser visto na Figura 16.

Figura 16 - Fluxograma do Módulo A



Fonte: elaborado pelo autor (2022).

Os seus principais passos serão elucidados.

Em **A.1**, há o início do Módulo, que também demarca o início do algoritmo do FPTPO como um todo. Em **A.2**, ocorre a leitura do banco de dados original. Assim como no capítulo 2, corresponde a uma matriz cuja dimensão é $n \times 24$, isto é, n medições de demanda para as 24 horas do dia. Novamente, ressalta-se que tais medições são normalizadas, ou seja, retratam

porcentagens das cargas originais do sistema, compreendendo valores em um intervalo de 0 a 1. Em **A.3** é escolhido o valor de K , ou seja, o número de *clusters* por hora do dia é escolhido. O processo de escolha desse parâmetro já foi explicado na seção 2.4. Após tal definição, aplica-se a técnica *K-Means* para comprimir o banco de dados original em uma matriz de dimensões $K \times 24$, em **A.4**. Dessa forma, são obtidas duas matrizes de suma importância para o restante do processo de otimização:

1. Matriz de centroides, ou \mathbf{K}_{mat} : é uma matriz que apresenta os centroides por hora do dia após o processo de *clustering*. Em outras palavras, contém as proporções de carga que melhor representam os dados do banco original. Possui K linhas e 24 colunas, para representar os K cenários para cada hora do dia.
2. Matriz de fatores de peso, ou \mathbf{WF}_{mat} : mensura as probabilidades de ocorrência de cada cenário da matriz \mathbf{K}_{mat} . Tais fatores de peso (ou *Weight Factors*, do inglês) são calculados por meio das equações (2.2) e (2.3), mantendo a lógica demonstrada nos capítulos anteriores. Possui K linhas e 24 colunas, para representar a probabilidade de ocorrência de cada um dos K cenários para as 24 horas.

A representação das duas matrizes pode ser vista nas equações (3.8) e (3.9).

$$\mathbf{K}_{\text{mat}} = \begin{bmatrix} \mu_{1,1} & \mu_{1,2} & \dots & \mu_{1,24} \\ \mu_{2,1} & \mu_{2,2} & \dots & \mu_{2,24} \\ \vdots & \vdots & \ddots & \vdots \\ \mu_{k,1} & \mu_{k,2} & \dots & \mu_{k,24} \end{bmatrix} \quad (3.8)$$

$$\mathbf{WF}_{\text{mat}} = \begin{bmatrix} \xi_{1,1} & \xi_{1,2} & \dots & \xi_{1,24} \\ \xi_{2,1} & \xi_{2,2} & \dots & \xi_{2,24} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{k,1} & \xi_{k,2} & \dots & \xi_{k,24} \end{bmatrix} \quad (3.9)$$

É importante frisar que cada um dos centroides $\mu_{i,h}$ está submetido a um fator de peso denotado novamente por $\xi_{i,h}$, tal que:

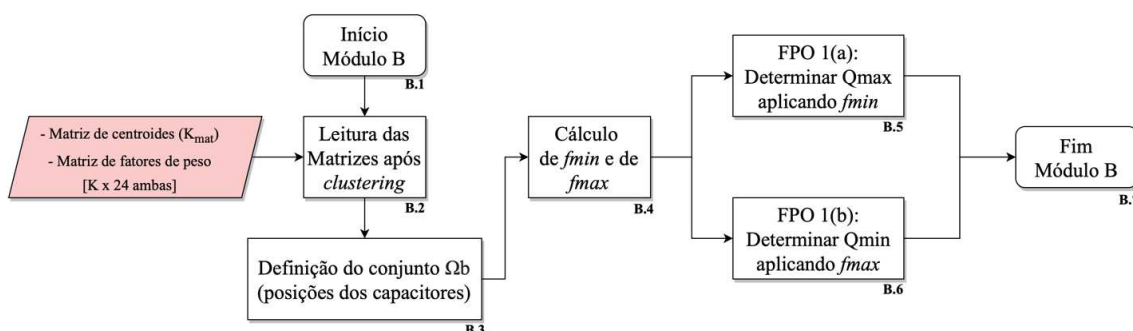
$$\sum_{i=1}^K \xi_{i,h} = 1 \quad (3.10)$$

Após a obtenção das duas matrizes, o Módulo A se encerra em **A.5**. Logo, os dados de saída desse módulo são as matrizes de centroides e de fatores de peso, que caracterizam por si só os cenários de carga que serão considerados nas etapas seguintes.

3.3.2 MÓDULO B

O Módulo B tem como entradas as duas matrizes, \mathbf{K}_{mat} e \mathbf{WF}_{mat} , obtidas no Módulo anterior. O seu objetivo é propor e solucionar um problema de otimização determinístico para averiguar os limites mínimo e máximo do somatório das potências reativas de todos os bancos monofásicos de capacitores a serem incluídos no sistema. Trata-se de uma redução do espaço de busca para as otimizações genéticas que ocorrerão nos módulos seguintes. O fluxograma dos principais passos do Módulo B pode ser visto na Figura 17.

Figura 17 - Fluxograma do Módulo B



Fonte: elaborado pelo autor (2022).

Os principais passos desse fluxograma serão detalhados a seguir.

Em **B.1**, o Módulo se inicia. Em **B.2**, há a leitura das duas matrizes, \mathbf{K}_{mat} e \mathbf{WF}_{mat} , obtidas no Módulo A. Em **B.3**, há a definição dos nós do sistema aos quais existirão capacitores instalados. Tal conjunto de nós é referido por Ω_b . Esse conjunto é primeiramente definido com posições aleatórias. Posteriormente, será visto que tais posições serão atualizadas iterativamente, como forma de refinar os resultados.

Em **B.4**, são calculados dois importantes parâmetros: f_{min} e f_{max} . Eles representam os horizontes de menor e maior carga, considerando todos os cenários possíveis. Logo, são extraídos da própria matriz \mathbf{K}_{mat} , tal como mostrado nas equações (3.11) e (3.12).

$$fmin = \min(\mathbf{K}_{mat}) \quad (3.11)$$

$$fmax = \max(\mathbf{K}_{mat}) \quad (3.12)$$

Em outras palavras, $fmin$ e $fmax$ são os limites mínimo e máximo de carregamento do sistema, considerando todos os possíveis cenários. Portanto, tais valores podem ser usados para que se possa estimar as quantidades máximas e mínimas de potência reativa que o sistema suporta, buscando evitar violações de tensão. Para isso, são formulados dois problemas de otimização determinísticos, denotados por FPO 1 (a) e FPO 1 (b).

Em **B.5**, é executado o primeiro problema de otimização, denotado por FPO 1 (a). Nele, busca-se calcular a soma máxima da potência dos capacitores conectados aos nós contidos no conjunto Ω_b , considerando o horizonte de carga leve. Esse cenário é gerado multiplicando-se as demandas originais de uma topologia pela porcentagem mínima presente em \mathbf{K}_{mat} , isto é, multiplicando-se todas as demandas por $fmin$. A ideia é que, sob essas condições, as tensões tendem a subir devido ao baixo carregamento do sistema, de forma que o intuito é obter o máximo de potência reativa que o sistema pode suportar sem que haja sobretensões. Logo, o problema de otimização determinística pode ser formulado por meio das equações (3.13) a (3.19).

$$FOB_{FPO1(a)} = Q_{max}^{fmin} = \max \sum_{i \in \Omega_b} |V_i|^2 * Y_i \quad (3.13)$$

Sujeito a:

$$\text{real}(I_{km}(\mathbf{z})) = 0 \quad (3.14)$$

$$\text{imag}(I_{km}(\mathbf{z})) = 0 \quad (3.15)$$

$$0 \leq P_{sub} \leq P_{MAX} \quad (3.16)$$

$$Q_{MIN} \leq Q_{sub} \leq Q_{MAX} \quad (3.17)$$

$$0,93 \leq |V_i| \leq 1,05 \quad (3.18)$$

$$0 \leq Y_i \leq Y_{MAX} \quad (3.19)$$

A equação (3.13) é referente à FOB do problema de otimização. Conforme mencionado, trata-se da maximização das potências reativas de todos os bancos monofásicos de capacitores conectados em todos os i nós previamente definidos, contidos no conjunto Ω_b .

As equações (3.14) e (3.15) são atreladas às restrições de igualdade ou restrições de rede. São as que objetivamente modelam a topologia simulada. São as equações do FP multifásico, ou seja, as equações do MICN. São elas que garantem que a resposta fornecida pelo algoritmo de otimização tem aplicabilidade prática no que se refere ao respeito às equações do FP.

Já as inequações expressas em (3.16) a (3.19) são chamadas de restrições de canalização ou restrições de desigualdade. Elas têm a responsabilidade de limitar, no problema de otimização, as condições a partir das quais o sistema pode operar. As expressões (3.16) e (3.17) definem os valores máximos e mínimos que a subestação pode entregar ao sistema em termos de potência ativa e reativa, de maneira a não desrespeitar as curvas de capacidade dos transformadores. A expressão (3.18) canaliza o perfil de tensão em valores considerados aceitáveis de acordo com o Módulo 8 do PRODIST. Por fim, a expressão (3.19) limita as admitâncias dos bancos de capacitores de acordo com os valores máximos que foram informados pelos usuários.

Após a execução do FPO 1 (a), obtém-se uma aproximação da quantidade máxima de potência reativa que pode ser entregue ao sistema via bancos de capacitores, nesta condição de carga mais leve. Conforme mencionado na seção 3.3, a potência reativa dos capacitores é uma consequência física dos valores de sua admitância e da tensão nela aplicada. Portanto, o valor obtido é uma estimativa da quantidade máxima de potência reativa que pode ser entregue ao sistema. No entanto, tal cálculo aproximado se justifica à medida que, ao se considerar o menor horizonte de carga, há uma tendência de que não haverá sobretensões sob qualquer outro fator proporcional de carga contido em \mathbf{K}_{mat} , uma vez que todos os outros serão iguais ou maiores do que o aplicado para a presente simulação, o que fará as tensões terem uma tendência a diminuir suas magnitudes em relação aos valores obtidos para FPO 1 (a).

Nesta simulação, são empregados métodos clássicos de otimização, via MPI. Isso se justifica uma vez que o problema não contém variáveis inteiras, nem sequer possui natureza combinatoria, visto que as posições dos capacitores estão fixadas nos nós presentes no conjunto Ω_b . O MPI é simulado através da *toolbox* de otimização não linear do *Matlab* chamada *fmincon*.

Em **B.6** é realizada uma otimização análoga à vista em **B.5**. Todavia, o intuito é a obtenção de uma quantidade mínima aproximada de potência reativa que os bancos

monofásicos podem entregar ao sistema, buscando evitar subtensões em carga pesada. Para isso, as cargas do sistema são ponderadas pela porcentagem de carga máxima, isto é, f_{max} . Tal etapa é denotada por FPO 1 (b). Dessa forma, busca-se estimar o valor mínimo da soma das potências reativas de todos os bancos tal que não haja subtensões no sistema.

De forma semelhante à vista em **B.5**, a consideração da carga pesada nesse caso gera uma tendência de que não existirão subtensões para quaisquer outros fatores de carga empregados, pois todos os demais presentes na matriz \mathbf{K}_{mat} serão iguais ou inferiores ao utilizado na presente otimização.

Em termos de modelagem matemática, o problema é idêntico ao visto em **B.5**, com alteração apenas na FOB, expressa por (3.20).

$$FOB_{FPO1(b)} = Q_{min}^{fmax} = \min \sum_{i \in \Omega_b} |V_i|^2 * Y_i \quad (3.20)$$

Essa otimização também é solucionada via MPI, assim como no caso anterior. Após a execução dessa etapa, são obtidos os valores limítrofes estimados para a soma de potência reativa dos bancos monofásicos, considerando as suas localizações nos nós do conjunto Ω_b .

Apesar do FPO 1 possuir uma abordagem determinística – são levados em consideração somente duas ponderações de carga – ele tem a função de limitar o espaço de busca do FPO 2, que, por sua vez, já possuirá formulação probabilística.

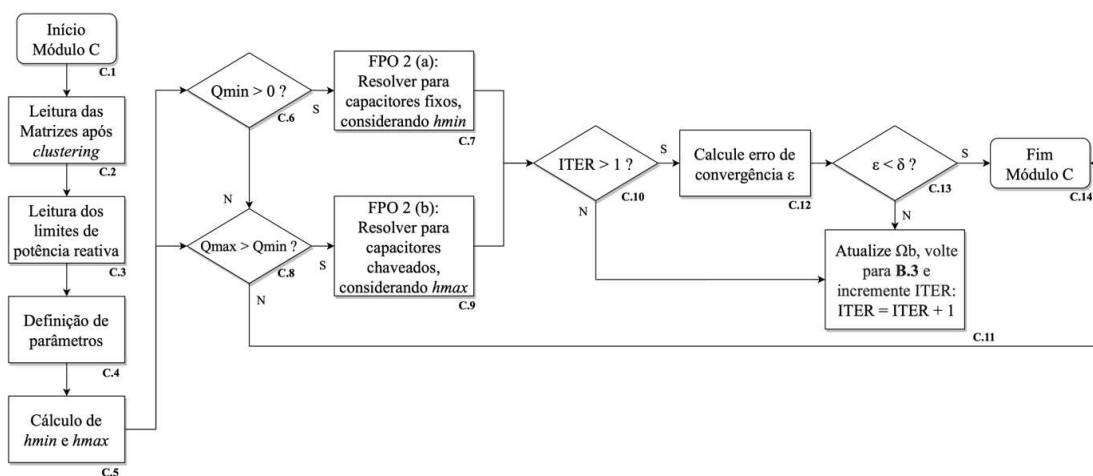
Por conseguinte, após as duas otimizações realizadas em **B.5** e em **B.6**, o Módulo B se encerra em **B.7**. As variáveis de saída são, portanto, Q_{max}^{fmin} e Q_{min}^{fmax} , que, por questões de simplicidade, serão denotadas por Q_{max} e Q_{min} a partir de agora.

3.3.3 MÓDULO C

As entradas para o Módulo C são os limites Q_{max} e Q_{min} , obtidos no passo anterior. O seu objetivo consiste em determinar, via AG, as posições e as capacidades dos capacitores fixos e chaveados, por meio de uma formulação probabilística aplicada a um problema de FPO.

O fluxograma do Módulo C pode ser visto na Figura 18. Posteriormente, seus principais passos serão descritos cuidadosamente.

Figura 18 - Fluxograma do Módulo C



Fonte: elaborado pelo autor (2022).

Em **C.1**, há o início do Módulo C. Em **C.2**, as matrizes \mathbf{K}_{mat} e \mathbf{WF}_{mat} , obtidas no Módulo A, são lidas. Em **C.3**, há a leitura dos limites para potência reativa dos capacitores Q_{max} e Q_{min} , obtidos no Módulo B.

Em **C.4** são definidos alguns parâmetros importantes:

- $N_{\text{cap}}^{\text{fix}}$ e $N_{\text{cap}}^{\text{sw}}$: informam o número máximo de capacitores fixos e chaveados que podem ser inseridos no sistema.
- Q_{adot} : informa o valor mínimo de potência nominal que um banco de capacitor monofásico pode assumir.
- δ : tolerância do processo iterativo.
- ITER: inicialmente igual a 1. Esse parâmetro irá contabilizar quantas vezes o Módulo C irá ser executado, visto que terá natureza iterativa, como será verificado posteriormente.

Esses parâmetros devem ser informados pelo usuário e podem variar de acordo com a topologia simulada.

Em **C.5**, são calculadas duas variáveis de interesse: h_{max} e h_{min} . Elas correspondem aos horários em que se espera que a carga do sistema seja máxima e mínima, respectivamente. Para descobrir isso, calcula-se a média ponderada de todas as colunas da matriz \mathbf{K}_{mat} , sendo a

ponderação efetuada a partir dos fatores de peso contidos na matriz \mathbf{WF}_{mat} . Esse procedimento é visto na equação (3.21).

$$\bar{f}_h = \sum_{i=1}^K \xi_{i,h} * \mu_{i,h} \quad (3.21)$$

Em outras palavras, considerando um horário h , a média ponderada de carga será igual à média dos centroides da coluna h de \mathbf{K}_{mat} , ponderados pelos seus respectivos fatores de peso, contidos na coluna h de \mathbf{WF}_{mat} .

Logo, são obtidos 24 valores, um para cada hora do dia, denotados pelo vetor $[\bar{f}_0, \bar{f}_1, \bar{f}_2, \dots, \bar{f}_{23}]$. Esse vetor pode ser interpretado como a proporção de carga esperada para cada hora do dia. Dessa forma, o índice do vetor que apresentar o menor valor esperado será *a hora do dia em que se espera carga leve*, denotada por $hmin$. De forma análoga, o índice do vetor que apresentar o maior valor esperado será *a hora do dia em que se espera carga pesada*, denotada por $hmax$. Esses dois horários irão subsidiar o segundo FPO proposto, chamado FPO 2.

Neste momento, é recordada a definição empregada no presente trabalho para “capacitor fixo”. Trata-se de um capacitor que necessariamente deve estar conectado ao sistema durante todo o horizonte diário. Logo, sua admitância permanece fixa, isto é, a mesma para todas as horas do dia.


Sob essa perspectiva, deve-se tomar cuidado para que tais capacitores não provoquem sobretensão em situações de carga leve, sendo a maior preocupação para o dimensionamento ótimo desses dispositivos. Se for possível uma operação livre de sobretensões sob carga leve, existe uma tendência de que esses distúrbios não estarão presentes nas demais situações operativas – uma vez que a carga do sistema será igual ou maior, o que fará com que as tensões tendam a diminuir suas magnitudes. Torna-se razoável o dimensionamento e o posicionamento ótimos de capacitores fixos tendo como horário de referência $hmin$, portanto. É exatamente nesse horário que se espera que a carga seja mínima.

Em C.6 é verificado o critério para a necessidade e existência de capacitores fixos. Como foi visto no Módulo B, a quantidade mínima requerida de potência reativa para efetuar o controle de tensão é resultado de um problema de minimização. Logo, é possível que esse resultado seja zero, o que indicaria que existe pelo menos um cenário possível tal que não são necessários capacitores para efetuar o controle de tensão. Ora, se existe um único cenário em

que isso ocorra, então não são necessários capacitores fixos, uma vez que os mesmos devem permanecer ligados e constantes durante todo o decorrer do dia. Conclui-se que, caso Q_{\min} seja igual a zero, a conexão de capacitores fixos provavelmente levará a sobretensões no sistema. Nesse caso, os capacitores fixos serão desconsiderados e o algoritmo irá se dirigir para o passo C.8, onde os capacitores chaveados são dimensionados. Caso contrário, será proposto um problema de otimização, em C.7, para obter as posições e capacidades ótimas dos capacitores fixos.

Uma vez que são buscadas as melhores posições no sistema para instalar os capacitores, percebe-se que o problema passa a ser não linear inteiro misto (MINLP). Para solucioná-lo, é empregado AG. O cromossomo introduzido possui $N_{\text{cap}}^{\text{fix}}$ genes relacionados à posição no sistema (barra e fase) e $N_{\text{cap}}^{\text{fix}}$ genes associados à potência de cada banco monofásico. Na verdade, esse último conjunto de genes será representado por múltiplos da quantidade nominal mínima adotada em C.4, denominada Q_{adot} . Logo, o cromossomo apresenta, no total, $2N_{\text{cap}}^{\text{fix}}$ genes. Na Figura 19 é apresentado o cromossomo introduzido na simulação genética.

Figura 19 - Cromossomo introduzido na otimização genética FPO 2



Fonte: elaborado pelo autor (2022).

As variáveis relativas às posições dos capacitores variam de 1 ao número máximo de nós da topologia. Cada nó está associado a uma barra e uma fase, justificando a alocação monofásica.

Na figura, a sigla “FM” significa “fator multiplicativo” da potência nominal dos capacitores. Consistem em variáveis inteiras. Por exemplo, caso seja adotado um valor nominal mínimo de $Q_{\text{adot}} = 100$ kvar e o resultado da otimização de determinado banco monofásico indique o seu respectivo $FM = 2$, o capacitor que efetivamente será utilizado no FP apresenta uma potência nominal de $2 * 100 = 200$ kvar. É importante ressaltar que se optou por utilizar como variáveis de otimização os parâmetros de potências reativas nominais para aproximar os resultados de valores comerciais.

Outra consideração importante envolve as restrições associadas ao FP trifásico, ou seja, as restrições de igualdade. Nessa situação, serão respeitadas através da integração do *software OpenDSS* ao *Matlab*, onde ocorre a otimização genética.

Tendo em vista todas as considerações feitas, é possível caracterizar matematicamente o FPO 2 (a), o que é feito em C.7 por meio das expressões (3.22) e (3.23).

$$FOB_{\text{FPO2(a)}} = \min \sum_{i=1}^K \sum_{j \in \Omega_j} \xi_{i,hmin} * Perdas_{i,hmin}^j \quad (3.22)$$

Sujeito a:

$$Q_{\min} \leq \sum_{i=1}^{N_{\text{cap}}^{\text{fix}}} Q_{\text{cap}_i}^{\text{fix}} \leq Q_{\max} \quad (3.23)$$

Onde:

$\xi_{i,hmin}$ é o fator de peso do i -ésimo centroide da matriz \mathbf{K}_{mat} , considerando a hora $hmin$, cujo valor esperado da carga é mínimo;

$Perdas_{i,hmin}^j$ é o valor total de perdas ativas, em kW, considerando todos os j ramos do alimentador de distribuição e transformadores da topologia, obtido após a execução do FP para o i -ésimo centroide na hora $hmin$;

Ω_j é o conjunto de todos os ramos do alimentador de distribuição e transformadores da topologia;

$Q_{\text{cap}_i}^{\text{fix}}$ é a potência do i -ésimo capacitor fixo alocado, dada por $Q_{\text{cap}_i}^{\text{fix}} = FM_i * Q_{\text{adot}}$.

A equação (3.22) é a FOB. Trata-se da minimização do valor esperado de perdas elétricas, considerando o horizonte de tempo de menor valor esperado de carga, denominado $hmin$. Já a inequação (3.23) expressa que o somatório das potências nominais de todos os capacitores fixos deve estar entre os valores mínimo e máximo estimados, calculados no FPO 1. É importante lembrar que as restrições do FP multifásico serão necessariamente respeitadas devido à operação conjunta do *OpenDSS* com o *Matlab*.

Após a execução desse passo, são obtidas as posições dos capacitores fixos e suas respectivas potências nominais, em kvar.

Antes de dar sequência aos passos do algoritmo do presente módulo, recorda-se a definição usada neste trabalho para “capacitores chaveados”. São capacitores cujas unidades podem se conectar ou desconectar ao longo das horas do dia. Portanto, suas admitâncias equivalentes podem se alterar de uma hora para outra. Isso gera, conseqüentemente, alterações maiores na potência reativa entregue ao sistema, visto que depende da própria admitância e da tensão nela aplicada. Assim, a conexão de unidades chaveadas pode entregar ao sistema uma quantidade adicional de potência reativa que promoverá o controle de tensão para os valores aceitáveis nos horários em que as unidades fixas não são suficientes para evitar subtensões. Logo, o momento mais crítico para o seu dimensionamento é o horário cuja carga esperada é máxima, ou seja, $hmax$. Dessa forma, utiliza-se esse horário para realizar o posicionamento e dimensionamento das unidades chaveadas.

Em **C.8** é verificado o critério de existência de capacitores chaveados, isto é, se Q_{max} é maior do que Q_{min} . Caso seja verdade, então existe um cenário tal que a quantidade Q_{min} não consegue controlar por si só as subtensões do sistema. Nessa situação, será necessária uma quantidade adicional de potência reativa para efetuar tal controle, proporcionada pelos capacitores chaveados, que serão otimizados em **C.9**. Caso contrário, o algoritmo se encerra em **C.14**.

Em **C.9** é proposto um problema de otimização análogo ao FPO 2 (a). Entretanto, será selecionada a hora do dia cujo valor esperado de fator de carga é máximo - $hmax$. Como os capacitores chaveados são acionados em determinados momentos do dia, ressalta-se que o efeito vigiado é a subtensão.

O cromossomo implementado é exatamente o mesmo visto na Figura 19, porém apresentando N_{cap}^{sw} genes. A descrição matemática do FPO 2 (b) pode ser constatada através das expressões (3.24) e (3.25).

$$FOB_{FPO2(b)} = \min \sum_{i=1}^K \sum_{j \in \Omega_j} \xi_{i,hmax} * Perdas_{i,hmax}^j \quad (3.24)$$

Sujeito a:

$$0 \leq \sum_{i=1}^{N_{cap}^{sw}} Q_{cap_i}^{sw} \leq Q_{max} - Q_{min} \quad (3.25)$$

Onde:

$Q_{cap_i}^{sw}$ é a potência do i -ésimo capacitor chaveado alocado, dada por $Q_{cap_i}^{sw} = FM_i * Q_{adot}$.

A equação (3.24) é referente à FOB, que é exatamente igual à anterior, com a única diferença do horário considerado, denotado por $hmax$.

Já a expressão (3.25) refere-se às restrições de canalização do somatório das potências dos bancos de capacitores. Neste caso, tal somatório pode variar de 0, situação na qual não há conexão de capacitores chaveados, até $Q_{max} - Q_{min}$, uma vez que considera-se que os capacitores fixos determinados em FPO 2 (a) já estão operando.

Ao fim desta etapa, serão conhecidas as posições e as potências de todos os capacitores fixos e chaveados. Dessa forma, é verificado o critério de convergência no passo **C.12**. Aqui recorda-se que os limites estimados de potência reativa, designados por Q_{max} e Q_{min} foram obtidos tendo como base um conjunto Ω_b arbitrário de posições. Logo, o processo deve ser feito pelo menos duas vezes (condição expressa em **C.10**), refinando tais valores com um conjunto de posições atualizadas. Tal conjunto atualizado é formado pelas posições obtidas em FPO 2 (a) e FPO 2 (b). Portanto, na segunda iteração, o processo inteiro é executado novamente, desde o Módulo B, dos passos **B.3** até **C.9**. A partir da segunda iteração, o algoritmo pode então convergir mediante o cálculo do parâmetro ε , em **C.12**. Tal variável é calculada através da equação (3.26).

$$\varepsilon = \max \{ \varepsilon_1, \varepsilon_2 \} \quad (3.26)$$

Onde:

$$\varepsilon_1 = \frac{|FOB_{FPO2(a)}^{ITER_i} - FOB_{FPO2(a)}^{ITER_{i-1}}|}{FOB_{FPO2(a)}^{ITER_i}} \quad (3.27)$$

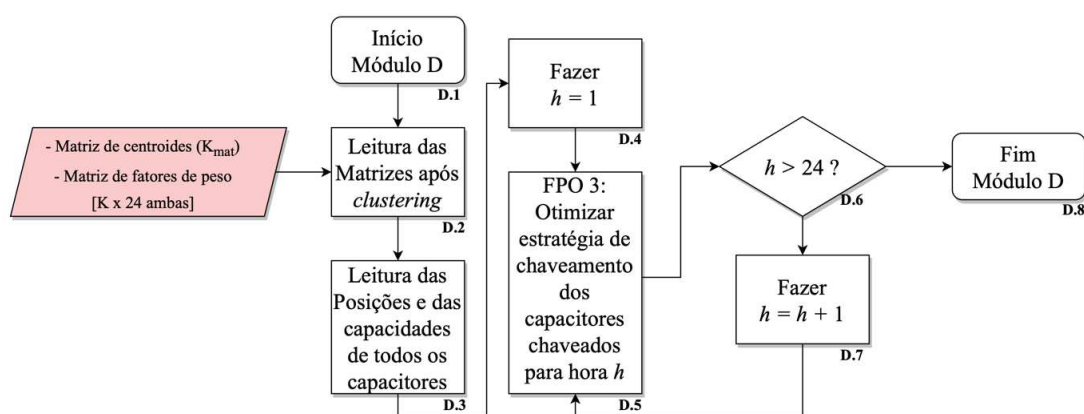
$$\varepsilon_2 = \frac{|FOB_{FPO2(b)}^{ITER_i} - FOB_{FPO2(b)}^{ITER_{i-1}}|}{FOB_{FPO2(b)}^{ITER_i}} \quad (3.28)$$

Ou seja, o erro ε é igual ao maior desvio dos valores de FOBs ao longo do processo iterativo. Caso esse erro seja menor do que uma tolerância δ pré-definida em C.4, considera-se que o processo iterativo estagnou, de forma que a potência reativa dimensionada em FPO 1 é dita adequada para as posições definidas em FPO 2. Caso contrário, o processo retorna em B.3, com o conjunto de posições Ω_b atualizado em C.11. Essa lógica iterativa também evita eliminar respostas obtidas por convergência prematura em alguma etapa que envolva AG, visto que, caso isso ocorra, a tendência é que os erros ε_1 e ε_2 sejam grandes.

Após a estagnação do processo iterativo, são obtidas as posições definitivas de todos os capacitores fixos e chaveados, além de suas potências reativas nominais, dadas por $FM * Q_{adot}$. Entretanto, foram analisados apenas dois horários do dia – os que apresentam valores esperados de carga máximo e mínimo. Resta, portanto, avaliar a estratégia de chaveamento dos capacitores chaveados para as demais horas do dia. Conforme mencionado, os fixos permanecerão ativos durante todo o horizonte diário.

3.3.4 MÓDULO D

Figura 20 - Fluxograma do Módulo D



Fonte: elaborado pelo autor (2022).

Após a execução do Módulo C, são obtidas as posições e as capacidades nominais de todos os capacitores fixos e chaveados. Portanto, resta determinar qual será a estratégia de chaveamento dos capacitores chaveados ao longo do dia, visando o controle de tensão em todos os cenários possíveis para os limites considerados adequados. O fluxograma apresentado na


Figura 20 contém os principais passos do último módulo proposto. Frisa-se que esse Módulo só existirá se a condição necessária para a alocação de capacitores chaveados for cumprida, ou seja, $Q_{\max} > Q_{\min}$, tal como visto em C.8.

Em D.1 o Módulo D se inicia. Em D.2, há a leitura das matrizes que contêm todos os cenários a serem simulados, ou seja, \mathbf{K}_{mat} e \mathbf{WF}_{mat} , obtidas no Módulo A. Em D.3 todas as posições de todos os capacitores fixos e chaveados são lidas, assim como suas capacidades nominais, obtidas no Módulo C.

A partir disso, é formulado, em D.5, um terceiro problema de otimização, denominado FPO 3. Ele busca determinar a potência reativa de cada um dos $N_{\text{cap}}^{\text{sw}}$ capacitores chaveados, considerando todos os horários do dia. É importante frisar que esse valor de potência reativa usado como variável de otimização é nominal, ou seja, o valor esperado de potência reativa entregue ao sistema, caso seja aplicada a tensão nominal. Na prática, o parâmetro que pode variar durante o chaveamento é a sua admitância capacitiva.

Logo, são executados 24 problemas de otimização, cada qual relacionado à determinada hora do dia. No FPO 3, as posições de todos os capacitores são mantidas fixas nos valores determinados em FPO 2, assim como as admitâncias dos capacitores fixos. Logo, as únicas variáveis de decisão são os fatores multiplicativos dos capacitores chaveados, que podem variar de 0 até FM_{\max} , que são os FM obtidos em FPO 2 (b). Essa otimização é novamente solucionada via AG, uma vez que todas as variáveis de decisão são inteiras. O cromossomo introduzido em FPO 3 é apresentado na Figura 21.

Figura 21 - Cromossomo implementado em FPO 3



Fonte: elaborado pelo autor (2022).

A partir das considerações mostradas, é formulado matematicamente o problema FPO 3, por meio das expressões (3.29) a (3.31).

$$\text{FOB}_{\text{FPO3}} = \min (s_0 + s_1) \quad (3.29)$$

Onde:

$$s_0 = \begin{cases} M * |\max(V_{fmin,h}) - 1.05|, & \text{se } \max(V_{fmin,h}) > 1,05 \\ 0, & \text{caso contrário} \end{cases} \quad (3.30)$$

$$s_1 = \begin{cases} M * |\min(V_{fmax,h}) - 0.93|, & \text{se } \min(V_{fmax,h}) < 0,93 \\ 0, & \text{caso contrário} \end{cases} \quad (3.31)$$

Onde:

M é um *big-number*;

$\max(V_{fmin,h})$ é o maior valor de magnitude de tensão obtido pela execução do FP considerando o menor centroide μ para hora h ;

$\min(V_{fmax,h})$ é o menor valor de magnitude de tensão obtido pela execução do FP considerando o maior centroide μ para hora h .

Dessa maneira, deseja-se obter uma estratégia de chaveamento tal que proporcione o menor desvio possível de tensão dos limites pré-estabelecidos pelo PRODIST, considerando casos limítrofes por hora. Em outras palavras, sempre que em algum caso crítico houver a violação de limites estabelecidos, ocorrerá o chaveamento para adicionar ou retirar unidades chaveadas de operação, visando a melhor adequação do perfil de tensão. Caso não haja violações, a FOB retornará valor nulo e não haverá necessidade de chaveamentos.

É importante ressaltar que esse problema é executado 24 vezes, uma para cada intervalo de tempo do horizonte diário. Portanto, a estratégia de chaveamento está atrelada ao controle de tensão, de forma a não permitir subtensões e sobretensões. Novamente, as restrições de rede são garantidas pelo *OpenDSS*. Em **D.6**, é verificado se o contador h percorreu todas as 24 horas do dia. Caso seja verdade, o processo se encerra em **D.8**. Caso contrário, o contador é incrementado em **D.7** e é simulado o FPO 3 para a hora seguinte.

Com o término da execução do algoritmo para avaliar o FPTPO, em **D.8**, podem ser feitas as análises estatísticas dos resultados.

3.4 CONCLUSÕES PARCIAIS

As contribuições do método apresentado se justificam pela consideração de uma formulação probabilística que analisa diversos cenários para obter uma estratégia de alocação e dimensionamento de capacitores fixos e chaveados em SDEE modelados adequadamente. Além disso, ressalta-se que a consideração individual das 24 horas do dia, representadas por

diferentes *clusters* de acordo com os horários, enriquece o desenvolvimento do algoritmo, detalhando as ações de planejamento. Destaca-se ainda a utilização de métodos clássicos e evolutivos executados de maneira iterativa para efetivamente estabelecer a otimização como contribuição relevante do presente trabalho.

4 RESULTADOS

Este capítulo tem o intuito de apresentar os resultados obtidos por meio da aplicação do algoritmo de FPTPO abordado no capítulo 3. Primeiramente, serão listadas as considerações de simulação adotadas. Em seguida, haverá uma subseção para demonstrar os resultados obtidos por meio da otimização proposta, isto é, evidenciando os benefícios da alocação ótima de capacitores fixos e chaveados por meio de comparações entre o caso base e o caso otimizado. Posteriormente, será feita uma comparação do FPP proposto (via aproximações por *K-Means*) em relação ao MMC. Para isso, ambas as técnicas serão simuladas com os capacitores determinados *a priori* na otimização. O objetivo desta comparação é mostrar que os resultados obtidos por intermédio do algoritmo proposto são muito próximos àqueles alcançados pela tradicional técnica numérica, porém demanda um tempo computacional muito menor. Por fim, será feita uma análise de sensibilidade acerca do número de centroides em relação à precisão dos resultados, tomando como referência a topologia IEEE 123 *Node Test-Feeder*.

4.1 CONSIDERAÇÕES DE SIMULAÇÃO

Conforme visto no capítulo anterior, foi desenvolvido um algoritmo para avaliar o FPTPO em sistemas desequilibrados, com o intuito de alocar otimamente capacitores fixos e chaveados, em vista da redução do valor esperado de energia perdida em um horizonte diário de planejamento. Ele é dividido em três grandes blocos: FPO 1 é responsável por reduzir o espaço de busca, através da determinação dos valores mínimo e máximo de potência reativa que podem ser admitidos pelo sistema de maneira a evitar sobretensões e subtensões. Para isso, as cargas são ponderadas pelos fatores proporcionais máximo e mínimo, respectivamente, de forma a originar os cenários de carga máxima e carga mínima. O FPO 2 é responsável pelo posicionamento e dimensionamento dos capacitores fixos e chaveados, tomando os horários de carga leve e carga pesada, respectivamente, utilizando AG. Já o FPO 3 é dedicado a otimizar a estratégia de chaveamento dos capacitores chaveados para as demais horas do dia, também por meio de AG.

O algoritmo para avaliar o FPTPO foi aplicado em três alimentadores-teste do IEEE. A saber: IEEE 13, IEEE 37 e IEEE 123 *Node Test-Feeders*. São topologias trifásicas que representam SDEE adequadamente, possuindo cargas desequilibradas, ramais monofásicos e bifásicos, indução mútua entre circuitos, transformadores trifásicos entre outras características

inerentes aos SDEE. A única alteração em relação às topologias originais foi a desconsideração dos reguladores de tensão, como forma de evidenciar os efeitos da alocação dos capacitores. Informações adicionais podem ser verificadas no anexo D.

Em relação ao banco de dados relativo aos fatores proporcionais de carga, foram consideradas 365 leituras para cada uma das 24 horas. Ou seja, o banco de dados corresponde a uma matriz cuja dimensão é 365 x 24. Nesse sentido, a etapa em que há o agrupamento de dados via técnica *K-Means* irá considerar 10 grupos representados por 10 centroides para todos os sistemas-teste adotados, tal como visto na Tabela 5. Logo, a matriz \mathbf{K}_{mat} terá dimensão 10 x 24, representando os 10 cenários de demanda para cada hora do dia. De forma análoga, a matriz \mathbf{WF}_{mat} terá a mesma dimensão, contendo as probabilidades (ou fatores de peso) de cada cenário para cada hora.

Será usado o mesmo banco de dados para todas as topologias. Após a sua compressão, os valores mínimo (*fmin*) e máximo (*fmax*) de fatores proporcionais de carga observados em \mathbf{K}_{mat} são 0,4296 e 0,9694, respectivamente. Estes valores são calculados por (3.11) e (3.12) e serão introduzidos em FPO 1, representando os horizontes de carga mínima e máxima e utilizados para o dimensionamento das potências reativas mínima e máxima admitidas.

Na Figura 22 (a), são apresentadas as 10 curvas de carga obtidas após o processo de *clustering*, assim como os seus valores esperados por hora, traçados na cor preta na Figura 22 (b). Tais valores são calculados por meio de (3.21) e estão presentes também na Tabela 6.

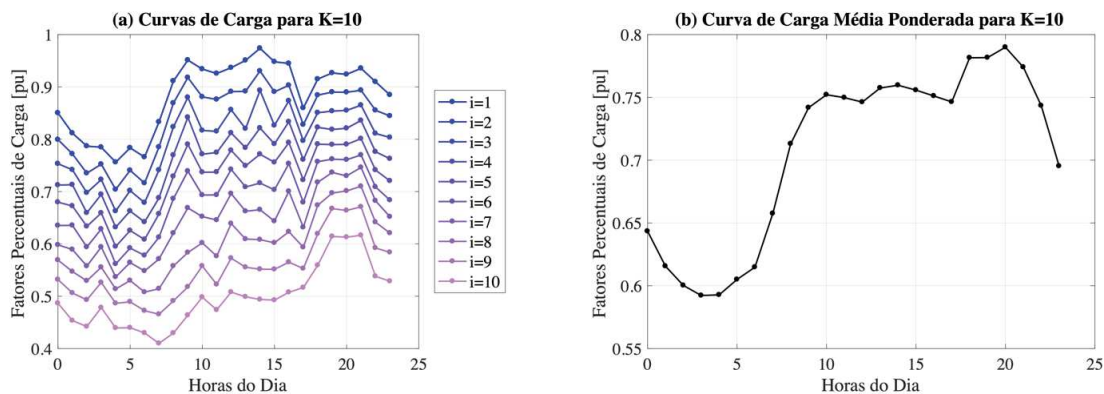
Considera-se, portanto, o horário de carga leve 3h e o horário de carga pesada 20h. Serão os horários considerados para o FPO 2 (a) e (b), para usar de referência no dimensionamento e posicionamento dos capacitores fixos e chaveados, respectivamente.

Tabela 6 - Valores esperados dos fatores proporcionais de carga por hora

<i>h</i>	0	1	2	3	4	5	6	7
\bar{f}_h	0,6434	0,6156	0,6003	0,5923	0,5927	0,6050	0,6148	0,6575
<i>h</i>	8	9	10	11	12	13	14	15
\bar{f}_h	0,7131	0,7418	0,7521	0,7498	0,7462	0,7575	0,7597	0,7558
<i>h</i>	16	17	18	19	20	21	22	23
\bar{f}_h	0,7511	0,7464	0,7815	0,7817	0,7899	0,7741	0,7434	0,6953

Fonte: elaborado pelo autor (2022).

Figura 22 - (a) Curvas de carga obtidas pelo *K-Means* e (b) Curva de carga média ponderada pelos respectivos fatores de peso



Fonte: elaborado pelo autor (2022).

No que se refere às condições de simulação do FPO 1, foram considerados como limites mínimo e máximo de tensão 0,93 e 1,05 pu, respectivamente, assim como mostrado na expressão (3.18). São os valores recomendados no PRODIST, Módulo 8. Conforme mencionado, este problema de otimização é solucionado pelo MPI por meio da *toolbox* de otimização não linear *fmincon*, presente no *Matlab*.

Em relação ao FPO 2, o valor de Q_{adot} e o número máximo de capacitores fixos e chaveados são escolhidos de acordo com a topologia. Esse problema é simulado via AG, operado pela *toolbox* do *Matlab*. Foi considerada uma população de 200 cromossomos, número máximo de gerações igual a 100 vezes o número de variáveis e critério de estagnação igual a 10 gerações. Assim como no FPO 2, o FPO 3 também é solucionado por tal técnica evolutiva. Todas as definições se mantêm as mesmas do caso anterior.

Por fim, a tolerância adotada para convergência do método iterativo foi $\delta = 0,05$, ou seja, o erro máximo das FOBs de FPO 2 (a) e (b) deve ser menor do que 5% para que o processo convirja.

O FPTPO proposto foi simulado 11 vezes. Informações estatísticas acerca da repetibilidade do método podem ser verificadas no anexo E.

Para conferir os resultados, o FPTP foi simulado com as respostas ótimas obtidas, tanto através do método proposto no capítulo 2, quanto por meio do MMC considerando 10.000 simulações para cada horizonte horário, totalizando 2.400.000 simulações no total.

Todos os casos foram simulados por meio de um computador de processador Intel®Core™ i5-7200U, CPU 2,50 GHz com dois núcleos, de memória RAM 8 GB.

4.2 RESULTADOS DO FPTPO

Este subcapítulo tem o intuito de mostrar os resultados obtidos através da execução do algoritmo mostrado no capítulo 3, isto é, o FPTPO desenvolvido. Logo, serão mostradas as configurações dos capacitores fixos e chaveados, ou seja, as suas respectivas posições, potências reativas nominais e a estratégia ótima de chaveamento definida. Posteriormente, serão apresentadas comparações acerca de perdas elétricas ativas e perfil de tensão entre o caso base, caso no qual não há capacitores inseridos na topologia, e o caso otimizado, no qual os capacitores obtidos no processo de otimização estão operando. O propósito é demonstrar os benefícios que uma alocação otimizada pode conferir ao sistema. Para estabelecer tal comparação, as situações confrontadas são obtidas a partir da simulação do FPTP por aproximações via *K-Means*, a técnica vista no capítulo 2, considerando o número de 10 centroides por hora simulada, conforme mencionado na seção 4.1.

4.2.1 IEEE 13 *NODE TEST-FEEDER*

O alimentador-teste IEEE 13 *Node Test-Feeder* é mostrado na Figura 23. Ele possui treze barras em dois níveis de tensão, 4,16 kV e 0,48 kV. Dentre as treze barras contidas na topologia, oito são trifásicas, três são bifásicas e duas são monofásicas. Contém um transformador, que abaixa o nível de tensão de média para baixa de tensão da barra 633 para a 634. As cargas são desequilibradas, com valores totais de $1175 + j616$ kVA, $1039 + j665$ kVA e $1252 + j821$ kVA, nas fases A, B e C, respectivamente. Tais cargas serão ponderadas pelos fatores proporcionais de carga presentes no banco de dados, dependendo do horário simulado, conforme mostrado nos capítulos 2 e 3. Ressalta-se que o número de centroides considerado no processo de *clustering* é igual a 10, e, portanto, a matriz \mathbf{K}_{mat} , que reúne todos os cenários possíveis, possui dimensão 10 x 24.


Além disso, o conjunto inicial de posições do conjunto Ω_b , adotado foi tal que contém todos os nós de todas as barras trifásicas da topologia, ou seja, as fases A, B e C das barras 632, 633, 634, 671, 692 e 675. A posição onde há a subestação foi desconsiderada.

Para esta topologia, foi estabelecido que $N_{\text{cap}}^{\text{fix}} = N_{\text{cap}}^{\text{sw}} = 3$. Isto é, o número máximo de capacitores monofásicos fixos e chaveados é igual a três unidades, sendo seis unidades no total.

Q_{adot} escolhido foi 100 kvar. Ou seja, os capacitores devem ter potência igual ou maior do que 100 kvar e variando de 100 em 100 kvar.

O método de FPTPO proposto convergiu para o resultado no qual três capacitores monofásicos fixos de 300 kvar são alocados nas posições 646-B, 671-A e 671-C.


Figura 23 - Topologia IEEE 13 Node Test-Feeder



Fonte: elaborado pelo autor (2022).


Além disso, são alocadas três unidades chaveadas, de 200 kvar, 300 kvar e 200 kvar, respectivamente, nas posições 671-C, 692-A e 645-C. A estratégia de chaveamento dos capacitores chaveados é apresentada da Figura 24 até a Figura 26.

Figura 24 - (IEEE 13) Estratégia de chaveamento do capacitor chaveado 1




Fonte: elaborado pelo autor (2022).

Figura 25 - (IEEE 13) Estratégia de chaveamento do capacitor chaveado 2



Fonte: elaborado pelo autor (2022).

Figura 26 - (IEEE 13) Estratégia de chaveamento do capacitor chaveado 3




Fonte: elaborado pelo autor (2022).

A partir das considerações obtidas sobre a posição dos capacitores fixos e chaveados, assim como suas potências reativas e suas estratégias de chaveamento, foi simulado o FPTP tal como descrito no capítulo 2, mais especificamente, seguindo os passos do fluxograma apresentado na Figura 4. Foram simulados dois casos: o denominado “Caso Base” (CB), em que não há a conexão de qualquer capacitor, e o “Caso Otimizado” (CO), em que há a consideração dos capacitores fixos e chaveados obtidos via FPTPO, levando em conta as suas respectivas estratégias de chaveamento.

A Figura 27 mostra um comparativo dos valores esperados de perdas por hora do dia, tanto do CB (gráfico na cor azul), quanto do CO (gráfico na cor laranja).

Figura 27 - Comparativo do valor esperado de perdas por hora do dia

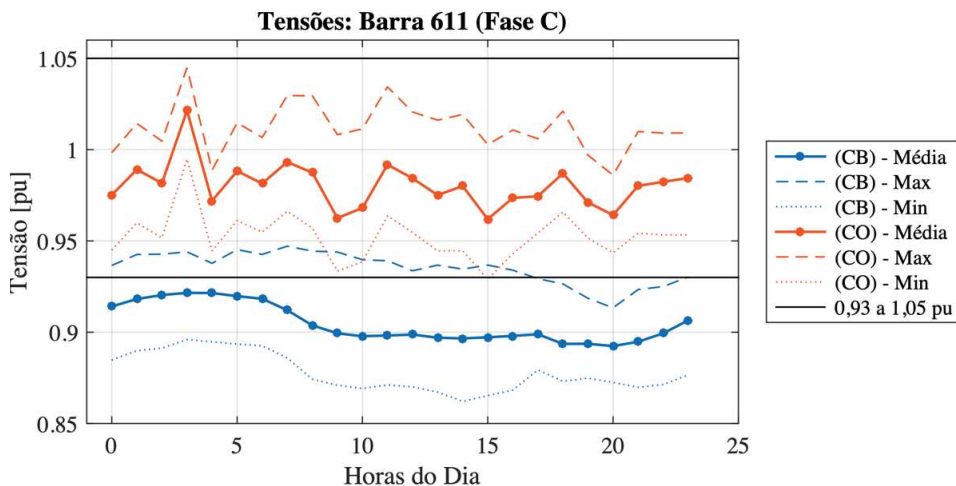


Fonte: elaborado pelo autor (2022).

O valor esperado da energia total perdida no horizonte de tempo diário, no CB, é igual a 1,83 MWh. Já no CO, é igual a 1,39 MWh. Isso equivale a uma redução de 24,05%, considerada significativa.

A Figura 28 apresenta um comparativo acerca do aprimoramento do perfil de tensão, uma consequência da alocação capacitiva, além de ser uma restrição importante para a operação dos SDEE. Nesse gráfico, as linhas contínuas com marcadores circulares são referentes aos valores esperados das tensões, sendo o gráfico azul associado ao CB e o laranja ao CO. Já as linhas pontilhadas são atreladas aos menores valores de tensão obtidos em alguns dos 10 cenários considerados por hora. De forma análoga, as linhas pontilhadas azuis estão associadas ao CB e as linhas pontilhadas laranjas estão associadas ao CO. Por fim, as linhas tracejadas se referem aos valores máximos de tensão obtidos em alguns dos 10 cenários considerados por hora. As cores das legendas se mantêm também para esse caso. Por conveniência de aproveitamento de espaço, optou-se por traçar o gráfico com o perfil de tensão do nó 611-C. Tal posição era a que apresentava maiores afundamentos de tensão no CB.

Figura 28 - Comparativo do perfil de tensão da barra 611, fase C: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).

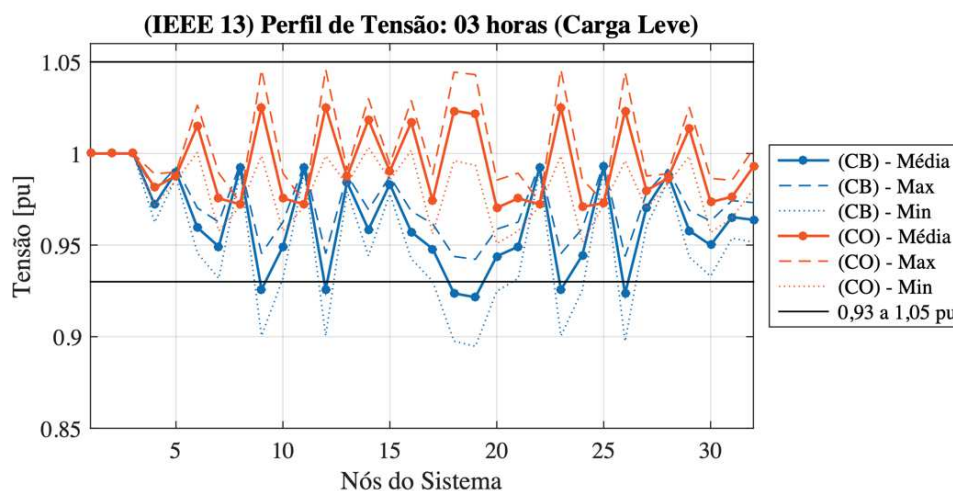
É possível perceber que há afundamentos de tensão que chegavam a aproximadamente 0,85 pu no CB, valores inadequados segundo o PRODIST. Após a alocação dos capacitores e adotando a estratégia de chaveamento obtida pelo FPTPO, todas as tensões passam a ter valores aceitáveis, sendo que seus comportamentos em situações limítrofes não causam nenhuma violação, seja sob carga leve, seja sob carga pesada. Isso pode ser constatado visualmente através das linhas laranjas que estão dentro do intervalo entre 0,93 e 1,05 pu, que, por sua vez, estão traçadas na cor preta para delimitar o intervalo aceitável. No CB, todos os valores esperados de tensão apresentavam violações, o que foi corrigido após a inserção dos capacitores.

Na Figura 29, é mostrado um comparativo a respeito do perfil de tensão considerando o horizonte de carga leve, isto é, às 3 horas da manhã. A legenda é exatamente a mesma vista para a Figura 28. Conclusões semelhantes às obtidas por meio da análise da Figura 28 podem ser alcançadas por intermédio dessa nova situação.

É possível verificar, novamente, que ocorre a adequação do perfil de tensão, corrigindo subtensões em todos os casos limítrofes, sem que haja sobretensões nos cenários de carga mais leve.


A Figura 30 é análoga, porém considerando a hora em que a carga tem seu valor esperado máximo, isto é, 20 horas.

Figura 29 - Comparativo do perfil de tensão para horizonte de carga leve: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).

Figura 30 - Comparativo do perfil de tensão para horizonte de carga pesada: Caso Base x Caso Otimizado




Fonte: elaborado pelo autor (2022).

Mais uma vez, é possível verificar a adequação do perfil de tensão e a correção de violações do CB.

A Figura 31 apresenta um gráfico tridimensional, onde há o comportamento dos valores esperados para o perfil de tensão de todos os nós da topologia e todas as horas do dia para o CO, ou seja, para o caso que considera os capacitores fixos e chaveados instalados. Neste gráfico, é importante notar que não há tensões cujo valor esperado seja inferior a 0,93 pu, nem

superior a 1,05 pu, valores limites adotados pelo PRODIST. Logo, conclui-se que a estratégia de alocação capacitiva proporcionou aprimoramento do perfil de tensão com sucesso, com tensões dentro de intervalos considerados como aceitáveis pelas normas brasileiras.

Figura 31 - Valores esperados das tensões nodais para o Caso Otimizado (IEEE 13)



4.2.2 IEEE 37 NODE TEST-FEEDER

O alimentador-teste IEEE 37 *Node Test-Feeder* é mostrado na Figura 32. Ele possui 37 barras trifásicas em dois níveis de tensão, 4,8 kV e 0,48 kV. Contém um transformador, que abaixa o nível de tensão de média para baixa tensão da barra 709 para a 775. As cargas são desequilibradas, cujos valores totais são iguais a $1017,8 + j499,8$ kVA, $894,6 + j439,6$ kVA e $1527,4 + j742$ kVA, nas fases A, B e C, respectivamente. Foi considerada uma carga 40% maior do que a topologia original, como forma de aumentar o desafio da otimização. Tais cargas serão ponderadas pelos fatores proporcionais de carga presentes no banco de dados.

Além disso, o conjunto inicial de posições do conjunto Ω_b adotado foi tal que contém todas as fases das barras 735, 711, 740 e 722, escolhidas ao acaso.


Para esta topologia, foi estabelecido que $N_{\text{cap}}^{\text{fix}} = N_{\text{cap}}^{\text{sw}} = 6$. Isto é, o limite de capacitores monofásicos fixos e chaveados é igual a seis unidades para cada modalidade, sendo no máximo doze unidades no total.

Por fim, Q_{adot} escolhido foi 50 kvar. Ou seja, os capacitores devem ter potência igual ou maior do que 50 kvar e variando de 50 em 50 kvar nas etapas de dimensionamento de cada banco.

A decisão ótima obtida pela execução do método de FPTPO apontou a alocação de cinco capacitores chaveados, cujas potências valem 100, 400, 100, 100 e 50 kvar, respectivamente, nas posições 737-B, 701-A, 707-C, 708-A e 710-A.


A estratégia ótima de chaveamento dessas unidades pode ser conferida nas Figuras 33 a 37.

Figura 32 - Topologia IEEE 37 Node Test-Feeder




Fonte: IEEE (online, 2021).

Figura 33 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 1




Fonte: elaborado pelo autor (2022).

Figura 34 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 2




Fonte: elaborado pelo autor (2022).

Figura 35 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 3




Fonte: elaborado pelo autor (2022).

Figura 36 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 4



Fonte: elaborado pelo autor (2022).

Figura 37 - (IEEE 37) Estratégia de chaveamento do capacitor chaveado 5




Fonte: elaborado pelo autor (2022).

De forma análoga à simulação da topologia anterior, foi executado o FPTP baseado em aproximações via *K-Means* para o sistema IEEE 37 com os capacitores obtidos na otimização alocados nas suas respectivas posições e respeitando sua lógica de chaveamento de acordo com o horário do dia. Novamente, foram empregados 10 centroides para modelar os cenários horários.

A Figura 38 apresenta um comparativo dos valores esperados de perdas, em kW, por hora do dia, considerando o CB e o CO.


Figura 38 - Comparativo do valor esperado de perdas por hora do dia



Fonte: elaborado pelo autor (2022).

No CB, o valor esperado das perdas totais de energia, englobado durante todo o período diário, é igual a 1,59 MWh. Já no CO, esse valor decaiu para 1,43 MWh, totalizando uma redução de 9,84%.

Figura 39 - Comparativo do perfil de tensão da barra 704, fase A: Caso Base x Caso Otimizado




Fonte: elaborado pelo autor (2022).

A Figura 39 apresenta uma comparação relativa ao perfil de tensão entre o CB e o CO. Novamente, por questão de simplicidade e conveniência de aproveitamento do espaço, será mostrado o valor associado ao nó a partir do qual obteve-se maior afundamento de tensão no caso base, isto é, barra 704-A. As legendas para esse gráfico permanecem as mesmas vistas na Figura 28.

Conforme é possível observar na Figura 39, no CB havia violações nos casos limítrofes de maior carregamento, com tensões abaixo de 0,93 pu. Após a alocação dos bancos chaveados, as referidas subtensões foram eliminadas.


Pode-se verificar o aprimoramento do perfil de tensão nos horários de carga leve e pesada, tal como mostrado na Figura 40 e na Figura 41. Na maior parte dos gráficos, a curva laranja está sobreposta ou acima da curva azul, demonstrando que o perfil de tensão teve de fato apresentou melhorias. O maior impacto, entretanto, está no horário de carga pesada (20 horas), em que nos casos limítrofes constavam tensões abaixo de 0,93 pu em alguns nós. Após a inserção dos capacitores, essas violações foram completamente eliminadas.

Figura 40 - Comparativo do perfil de tensão para horizonte de carga leve: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).


Figura 41 - Comparativo do perfil de tensão para horizonte de carga pesada: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).


A Figura 42 apresenta o gráfico no qual há o comportamento dos valores esperados para o perfil de tensão, considerando CO, para todos os nós da topologia, considerando as 24 horas por dia, em uma abordagem tridimensional. É possível constatar visualmente que não há subtensões presentes, com todos os valores acima de 0,93 pu.

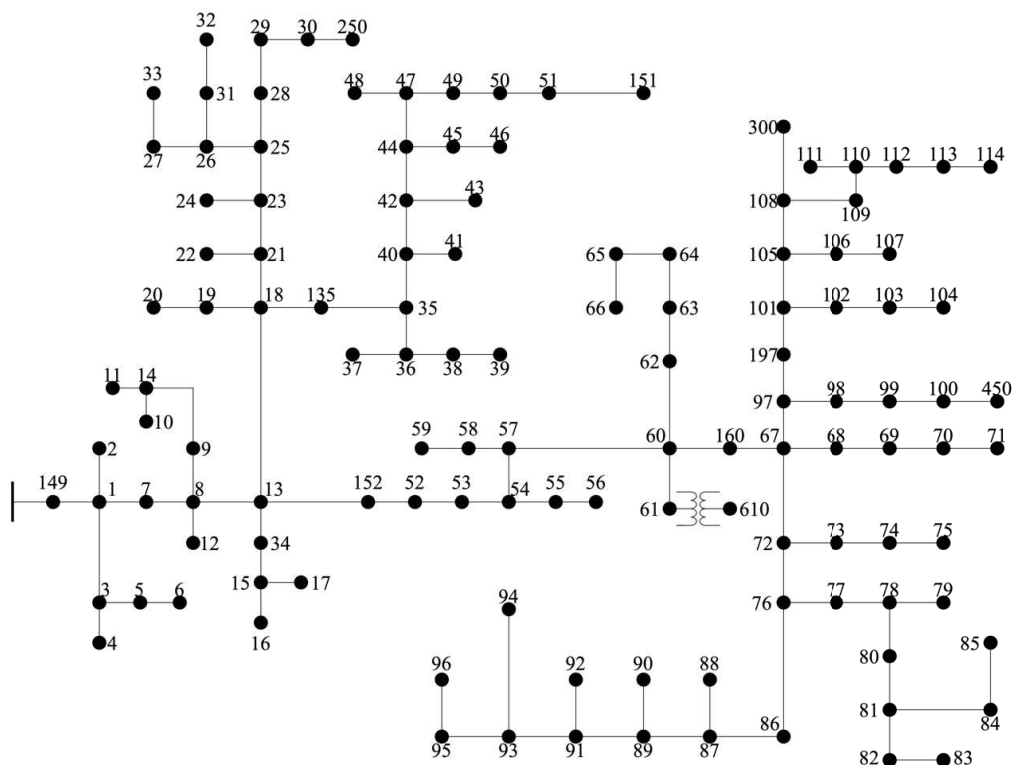
Figura 42 - Valores esperados das tensões nodais para o Caso Otimizado (IEEE 37)



A Figura 43 apresenta um paralelo entre o perfil mínimo de tensão e a estratégia de chaveamento ótima obtida por meio da estratégia proposta. No gráfico mostrado na Figura 43 (a), há o valor de tensão mínimo que pode se manifestar na posição 704-A, que é a posição na qual há os maiores afundamentos. Já na Figura 43 (b), há a estratégia de chaveamento para cada um dos cinco capacitores alocados. Nota-se que, mediante o correto uso desses dispositivos, não são notadas subtensões, isto é, tensões abaixo de 0,93 pu.

Figura 43 - Paralelo entre o perfil mínimo de tensão e a estratégia ótima de chaveamento



4.2.3 IEEE 123 *NODE TEST-FEEDER*Figura 44 - Topologia IEEE 123 *Node Test-Feeder*

Fonte: IEEE (online, 2021).

O alimentador-teste IEEE 123 *Node Test-Feeder* pode ser visto na Figura 44. Ele possui 123 barras em dois níveis de tensão, 4,16 kV e 0,48 kV. Apresenta 121 ramos, incluindo monofásicos e trifásicos. Contém um transformador, que abaixa o nível de tensão de média para baixa tensão da barra 61 para a 610. As cargas são desequilibradas, sendo iguais a $1420 + j775$ kVA, $915 + j515$ kVA e $1155 + j635$ kVA, nas fases A, B e C, respectivamente. Tais cargas serão ponderadas pelos fatores de carga presentes no banco de dados. Na otimização, foram considerados novamente 10 centroides para cada hora do horizonte de planejamento.

Além disso, o conjunto inicial de posições do conjunto Ω_b adotado foi tal que contém todas as fases das barras 60, 61, 62, 63, 64, 65, 66, 67, 80, 81, 82, 83, 86, 87, 89, 91, 93, 95, 97, 98, 99, 100, 101, 105 e 108, escolhidas ao acaso.

Para esta topologia, foi estabelecido que $N_{cap}^{fix} = N_{cap}^{sw} = 10$. Isto é, o limite de capacitores monofásicos fixos e chaveados é igual a dez unidades para cada modalidade, sendo no máximo vinte unidades no total.

Por fim, Q_{adot} escolhido foi 10 kvar. Ou seja, os capacitores devem ter potência igual ou maior do que 10 kvar e variando de 10 em 10 kvar nas etapas de dimensionamento de cada banco.

A decisão ótima foi a alocação de dez capacitores fixos. Os capacitores chaveados não são necessários para o controle de tensão dessa topologia. Os resultados podem ser vistos na Tabela 7. Na Tabela, “POS” indica a posição do capacitor (barra-fase) enquanto “Q” revela sua potência nominal em kvar.

Tabela 7 - Resultados das posições e potências dos capacitores para topologia IEEE 123


POS	Q	POS	Q	POS	Q	POS	Q	POS	Q
91-C	40	107-B	50	90-B	60	48-A	60	49-C	60
POS	Q	POS	Q	POS	Q	POS	Q	POS	Q
62-A	80	77-C	20	97-C	80	88-A	160	38-B	30

Fonte: elaborado pelo autor (2022).

A Figura 45 mostra uma comparação dos valores esperados das perdas de acordo com o horário do dia. Em azul, o CB e em laranja o CO.

No CB, a energia total perdida esperada vale 1,46 MWh. Já após a inserção dos capacitores fixos, esse valor decaiu para 1,21 MWh, representando uma redução percentual de 16,85%.


Figura 45 - Comparativo do valor esperado de perdas por hora do dia



Fonte: elaborado pelo autor (2022).

A Figura 46 apresenta uma comparação relativa ao perfil de tensão entre o CB e o CO. Novamente, por questão de simplicidade e conveniência de aproveitamento do espaço, será mostrado o valor associado à barra 65-A. A legenda permanece a mesma da Figura 39.

Figura 46 - Comparativo do perfil de tensão da barra 65, fase A: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).


As Figuras 47 e 48 mostram o aprimoramento do perfil de tensão para os horários de carga leve e carga pesada, considerando todos os nós da topologia.

É possível constatar a melhora do perfil de tensão em todos os nós, inclusive corrigindo subtensões em alguns nós durante o horário de carga pesada.

Assim como na Figura 28 e na Figura 39, os gráficos em azul estão associados ao CB e os em laranja ao CO. As linhas contínuas com marcadores circulares estão referidas aos valores esperados da tensão para cada hora do dia. As linhas tracejadas estão atreladas ao caso de tensão máxima dentre os cenários analisados no FPTP e as linhas pontilhadas associam-se com os casos de tensão mínima. É possível perceber que houve melhora do perfil de tensão em todos os aspectos e em todas as horas do dia.


A Figura 49 apresenta o gráfico com o comportamento dos valores esperados para o perfil de tensão, considerando o CO, para todos os nós da topologia, considerando as 24 horas por dia. Conforme mostrado, não há valores esperados para tensões abaixo de 0,93 pu, portanto não há subtensões esperadas na topologia.

Figura 47 - Comparativo do perfil de tensão para horizonte de carga leve: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).


Figura 48 - Comparativo do perfil de tensão para horizonte de carga pesada: Caso Base x Caso Otimizado



Fonte: elaborado pelo autor (2022).

Logo, o método de otimização desenvolvido se mostrou apto a melhorar o desempenho operacional de todos os sistemas, incluindo um de grande porte. Em todos os testes efetuados, puderam ser constatadas melhoras em relação às perdas esperadas de energia total no horizonte diário, além de adequações do perfil de tensão em todos os cenários possíveis. Sob esses aspectos, diz-se que os objetivos propostos no capítulo 1 foram alcançados com sucesso.

Figura 49 - Valores esperados das tensões nodais para o Caso Otimizado (IEEE 123)



Fonte: elaborado pelo autor (2022).

4.3 COMPARAÇÕES DO FFTP: APROXIMAÇÕES VIA *K-MEANS* X MMC

Este subcapítulo tem como objetivo estabelecer uma comparação entre o método de FFTP desenvolvido no capítulo 2, ou seja, o Método de Aproximações via *K-Means*, e o MMC. Nesse sentido, ambas as técnicas serão simuladas, tendo como referência os sistemas-testes abordados no subcapítulo anterior, isto é, IEEE 13, IEEE 37 e IEEE 123. Além disso, os capacitores determinados por meio do método de otimização avaliado no Capítulo 3 serão considerados em ambas as técnicas. Ou seja, a comparação será estabelecida a partir do Caso Otimizado. Portanto, frisa-se que não haverá qualquer tipo de otimização nesta subseção, apenas as comparações do FFTP considerando: (i) sua execução pelo método por aproximações via *K-Means*, mais especificamente seguindo os passos apresentados na Figura 4, e (ii) sua execução via MMC, compreendendo os passos vistos no Anexo C.


Através disso, busca-se demonstrar a aplicabilidade prática do FFP desenvolvido, evidenciando que os resultados obtidos se aproximam muito do MMC, porém requerem um tempo computacional muito menor para alcançarem a convergência.

Para o método baseado em *K-Means*, foram considerados 10 centroides para cada hora simulada do dia, tal como visto nos capítulos 2 e 4.1. Já em relação ao MMC, foram considerados 10.000 cenários por hora, totalizando 2.400.000 simulações.

4.3.1 IEEE 13 NODE TEST-FEEDER

Para estabelecer comparações críticas, a primeira topologia simulada foi IEEE 13. É importante frisar que foi simulado o problema de FFTP considerando os capacitores fixos e chaveados obtidos na otimização proposta, não sendo realizado qualquer tipo de otimização envolvendo MMC. Aqui, busca-se avaliar apenas o FFTP. Como já informado na seção 4.1, foram consideradas 10.000 amostras para simular cada hora do planejamento diário.

Figura 50 - Comparação de valores esperados de perdas por hora do dia: *K-Means* x MMC



Fonte: elaborado pelo autor (2022).

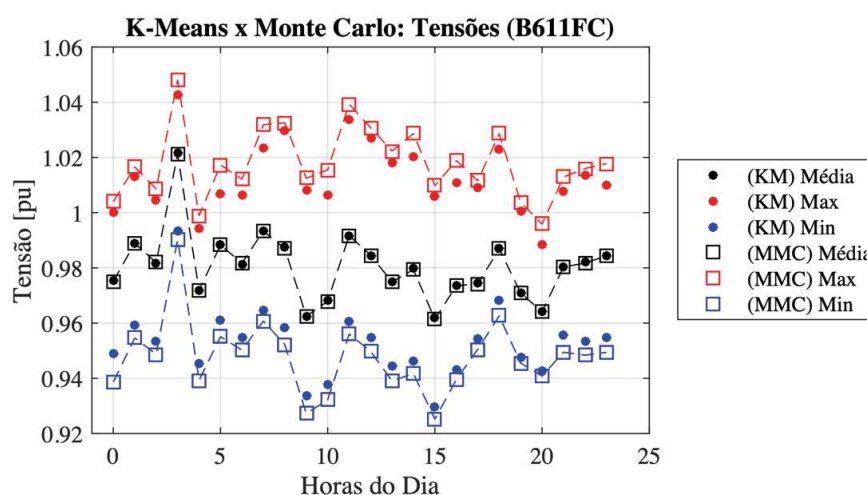
A Figura 50 contém uma comparação acerca do valor esperado de perdas por hora do dia, onde o gráfico plotado com marcadores circulares está associado ao método baseado em aproximações via *K-Means*. Já os marcadores quadrados demarcam os valores obtidos via MMC.

Já a Figura 51 apresenta um comparativo do perfil de tensão na posição 611-C. Os marcadores circulares estão associados aos valores determinados pela abordagem *K-Means*, onde a cor preta indica os valores esperados, a cor vermelha indica os valores máximos obtidos a partir dos 10 cenários por hora e a cor azul indica os valores mínimos contidos em tais cenários analisados. Já os marcadores quadrados estão atrelados aos resultados obtidos pelo MMC, onde as cores preta, vermelha e azul também representam, respectivamente, os valores esperados, máximos e mínimos obtidos pela execução desta técnica.

Ao contrário do que foi mostrado no capítulo 2, mais especificamente na Figura 10, em que os valores máximos e mínimos foram estimados por meio da equação (2.10), aqui o objetivo

é analisar os valores mínimos e máximos de tensão considerando os cenários simulados, isto é, levando em consideração os resultados de cada FP determinístico simulado para cada centroide contido na matriz \mathbf{K}_{mat} . Isso se justifica à medida em que se deseja mostrar que todos os cenários introduzidos na otimização apresentam suas tensões dentro dos limites estabelecidos por norma. Logo, determinar esses limites por intermédio de aproximações acaba por ocultar os resultados práticos oriundos das próprias execuções do FP. Nesse sentido, destaca-se que os marcadores circulares azuis e vermelhos estão atrelados aos valores de tensão mínimos e máximos obtidos por meio da execução do FPTP pelo método proposto, considerando todos os 10 cenários possíveis por hora do dia, enquanto os marcadores quadrados azuis e vermelhos indicam os valores mínimos e máximos de tensão obtidos através da execução do FPTP via MMC, considerando os 10.000 cenários por hora do dia.

Figura 51 - Comparação para tensão na barra 611, fase C: *K-Means* x MMC



Fonte: elaborado pelo autor (2022).


Nota-se que, apesar da enorme discrepância entre o número de cenários entre os dois métodos, os resultados finais foram muito próximos.

Por fim, é apresentado, na Figura 52, um gráfico que compara a função de probabilidade acumulada para a tensão na barra 611, fase C, às 10 horas, tanto na ótica *K-Means*, representado pelo gráfico em pontos, quanto pelo MMC, representado pelo gráfico com marcadores quadrados.

A partir das Figuras 50, 51 e 52, é possível constatar visualmente que os resultados obtidos através da técnica baseada em aproximações via *K-Means* são muito próximos àqueles

alcançados pelo MMC, o que valida as análises realizadas. Além disso, é possível quantificar os erros cometidos através dos parâmetros estatísticos introduzidos no capítulo 2. Tais considerações estão contidas na Tabela 8.

Figura 52 - Função de Probabilidade Acumulada: *K-Means* x MMC



Fonte: elaborado pelo autor (2022).

Tabela 8 - Parâmetros estatísticos, em porcentagem, para mensurar erros: *K-Means* x MMC (IEEE 13 – Caso Otimizado)

ϵ_P	ϵ_E	$\overline{\epsilon_{Vmed}}$	$\overline{\epsilon_{V\sigma}}$	ϵ_{Vmax}	ϵ_{Vmin}
1,23	0,27	0,01	1,17	0,97	0,92

Fonte: elaborado pelo autor (2022).

Visto que todos os erros são inferiores a 2%, conclui-se que o método apresentou acurácia suficiente. Além disso, houve erros abaixo de 1% na energia total perdida, que era o maior alvo de otimização. É importante frisar que esses erros diminuem ou aumentam à medida que o número de *clusters* é alterado. Para reduzir ainda mais esses erros em relação ao MMC, basta, portanto, aumentar o número de *clusters*. Entretanto, para os desígnios do presente trabalho, tais valores foram considerados aceitáveis. Uma análise de sensibilidade a esse respeito será efetuada posteriormente, na seção 4.4.

Finalmente, compara-se o tempo computacional de cada método para avaliar o FPTP para esta topologia. A abordagem sugerida, baseada em *K-Means*, necessitou de 9 segundos


para alcançar a convergência. Já a baseada no MMC precisou de 11798 segundos. Logo, o método proposto é aproximadamente 1300 vezes mais rápido para esta topologia.

4.3.2 IEEE 37 NODE TEST-FEEDER

A segunda topologia usada para comparar a aplicabilidade prática do FPTP baseado em aproximações via *K-Means* em relação ao MMC foi o sistema-teste IEEE 37. Novamente, é ressaltado que, no que se refere ao método proposto, foram utilizados 10 centroides para simular cada hora do dia, contra 10.000 cenários por hora no que diz respeito ao MMC.

A Figura 53 mostra os valores esperados de perdas, em kW, por hora, obtidos através da execução de ambas as técnicas.

Figura 53 - Comparação de valores esperados de perdas por hora do dia: *K-Means* x MMC



Fonte: elaborado pelo autor (2022).

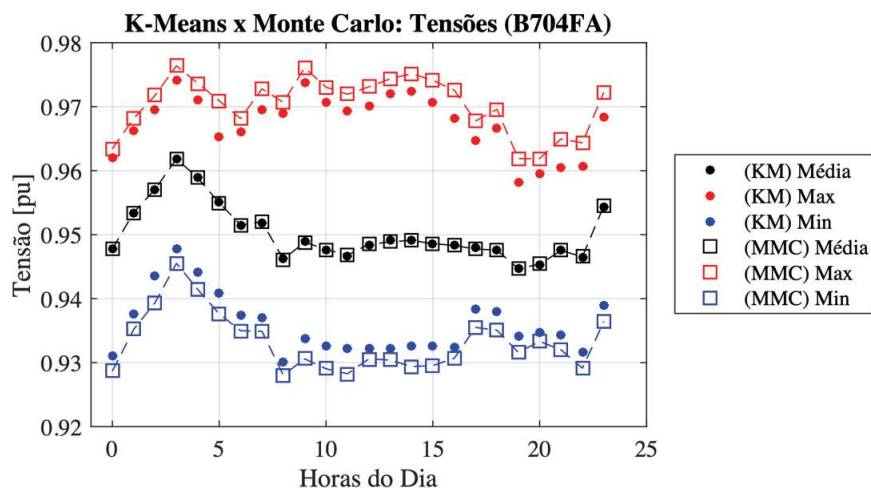
A Figura 54 estabelece uma comparação do perfil de tensão entre o método proposto e o MMC. A legenda permanece a mesma vista na Figura 51. Por questões de conveniência, foi escolhida a tensão da posição 704-A para exercer a comparação.

Por fim, na Figura 55 pode-se verificar a comparação das funções de probabilidade da tensão da barra 704-A, entre a obtida pelo método proposto e aquela obtida pelo MMC. Optou-se por mostrar os resultados para o horário de 20 horas.

Mais uma vez, percebe-se que todas as comparações foram bem-sucedidas, com os valores obtidos por meio do FPTP proposto muito próximos daqueles obtidos via MMC.

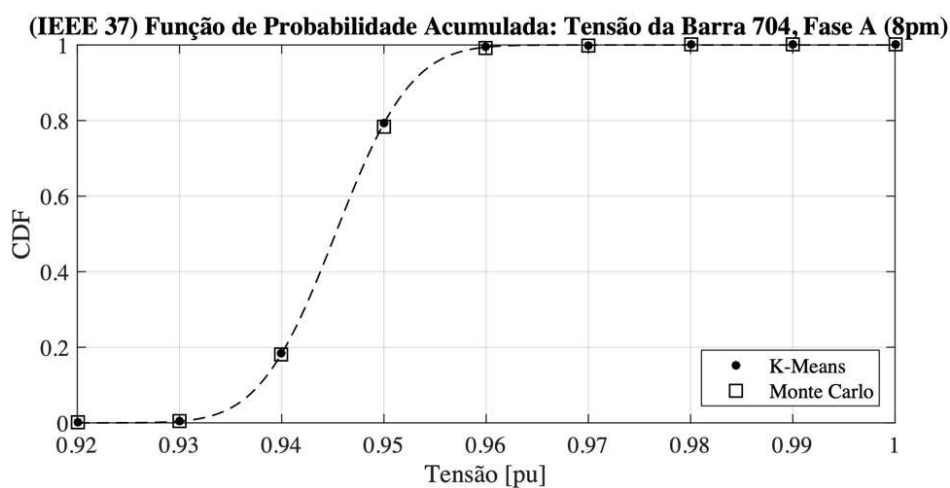
É possível mensurar os erros cometidos, de maneira análoga à realizada para a topologia IEEE 13. Os parâmetros estatísticos para o sistema IEEE 37 estão contidos na Tabela 9.

Figura 54 - Comparação para tensão na barra 704, fase A: *K-Means* x MMC



Fonte: elaborado pelo autor (2022).

Figura 55 - Função de Probabilidade Acumulada: *K-Means* x MMC



Fonte: elaborado pelo autor (2022).

Todos os erros são próximos ou inferiores a 1%, conclui-se, portanto, que o método apresentou acurácia suficiente. Além disso, houve erros abaixo de 0,1% na energia total perdida, que era o maior alvo de otimização.

Tabela 9 - Parâmetros estatísticos, em porcentagem, para mensurar erros: *K-Means* x MMC (IEEE 37 – Caso Otimizado)


ϵ_P	ϵ_E	$\overline{\epsilon_{Vmed}}$	$\overline{\epsilon_{V\sigma}}$	ϵ_{Vmax}	ϵ_{Vmin}
0,82	0,05	0,01	1,17	0,52	0,59

Fonte: elaborado pelo autor (2022).

Considerando o método por aproximações baseado em *K-Means*, o FPTP necessitou de 20 segundos para alcançar sua convergência. Já o MMC apresentou um esforço computacional aproximadamente 985 vezes maior, precisando de 19706 segundos para convergir.

4.3.3 IEEE 123 NODE TEST-FEEDER

Figura 56 - Comparação de valores esperados de perdas por hora do dia: *K-Means* x MMC




Fonte: elaborado pelo autor (2022).

De maneira similar às simulações das topologias anteriores, o método proposto foi comparado com o MMC também para o IEEE 123. A Figura 56 mostra os valores esperados de perdas, em kW, por hora, estabelecendo uma comparação entre o método de aproximações baseado em *K-Means* e o MMC, considerando 10 centroides e 10.000 cenários, respectivamente.


A Figura 57 estabelece uma comparação do perfil de tensão entre o método proposto e o MMC. A legenda permanece a mesma vista na Figura 51 e na Figura 54. Por questões de conveniência, foi escolhida a tensão do nó 65-A para exercer a comparação.

Figura 57 - Comparação para tensão na barra 65, fase A: K-Means x MMC



Fonte: elaborado pelo autor (2022).

Figura 58 - Função de Probabilidade Acumulada: K-Means x MMC



Fonte: elaborado pelo autor (2022).

Por fim, na Figura 58 pode-se verificar a comparação das funções de probabilidade da tensão na posição 65-A, às 20 horas, entre a obtida pelo método proposto e aquela obtida pelo MMC.

É possível verificar que todas as comparações foram bem-sucedidas, com os valores obtidos por meio do FPTP proposto muito próximos daqueles obtidos via MMC.

Além disso, pode-se mensurar os erros cometidos, de maneira análoga à realizada para as topologias IEEE 13 e IEEE 37. Os parâmetros estatísticos para o sistema IEEE 123 estão contidos na Tabela 10.

Tabela 10 - Parâmetros estatísticos, em porcentagem, para mensurar erros: *K-Means* x MMC (IEEE 123 – Caso Otimizado)

ϵ_P	ϵ_E	$\overline{\epsilon_{Vmed}}$	$\overline{\epsilon_{V\sigma}}$	ϵ_{Vmax}	ϵ_{Vmin}
1,29	0,03	0,01	1,13	0,67	0,53

Fonte: elaborado pelo autor (2022).

Conforme é possível constatar por intermédio da Tabela 10, os resultados do método via aproximações proposto apresentam erros inferiores a 2% em relação ao MMC para todas as topologias, incluindo a IEEE 123. Além disso, para esta última topologia, o erro no valor esperado da energia total perdida vale 0,03%, que era o objetivo principal da otimização. Novamente, é frisado que esses parâmetros que mensuram tais discrepâncias podem aumentar ou diminuir à medida que o número de *clusters* é alterado para calcular o FPTP. Os erros mostrados na Tabela 10 foram considerados aceitáveis, visto que não alteram a análise crítica dos resultados. Em outras palavras, os valores esperados apresentaram erros bastante limitados e, nos casos limítrofes, as diferenças para o MMC não levam a erros de interpretação dos resultados, não havendo sobretensões ou subtensões também para esse método. É importante notar que os erros sobre essas condições limítrofes foram menores do que 1%.

Acerca do tempo computacional para que o FPTP pudesse alcançar a convergência, ressalta-se que o método proposto foi significativamente superior, demandando apenas 52 segundos, contra 51960 segundos no MMC. Isso revela que o método por aproximações via *K-Means* se mostrou aproximadamente 1012 vezes mais rápido.

Sob essa perspectiva, conclui-se que o método de FPTP avaliado apresentou desempenho favorável, pois se mostrou robusto também para um sistema de grande porte, tal como é o IEEE 123. Logo, os objetivos levantados na seção 1.4 foram cumpridos.

4.4 ANÁLISE DE SENSIBILIDADE DO NÚMERO DE CENTROIDES

Ao longo da demonstração dos resultados obtidos na subseção 4.3 – em que foi feita uma comparação acerca das variáveis de saída do FPTP simulado pelo método baseado em

aproximações via *K-Means* e o MMC – foi visto que o número de 10 centroides introduzido na modelagem foi suficiente para uma boa precisão de acordo com os objetivos almejados. Entretanto, essa precisão pode aumentar ou diminuir à medida que centroides são acrescentados ou diminuídos da matriz \mathbf{K}_{mat} . Nesse sentido, na presente seção busca-se mostrar como tais índices de erro se comportam quando o número de centroides é alterado, de maneira a evidenciar, portanto, as conclusões parciais alcançadas na subseção anterior.

Para isso, a mesma análise presente na seção 4.2.3 será realizada, porém considerando a variação do número de centroides. Em outras palavras, o FPTP será simulado para diferentes números de centroides, comparando os erros em relação ao MMC, assim como o tempo computacional necessário para a convergência.

A topologia IEEE 123 barras foi escolhida por ser a maior e mais complexa, de modo a permitir um desenvolvimento robusto da comparação desejada.

Os números de centroides que serão analisados são: 10, 20, 50 e 100. Os resultados obtidos estão dispostos na Tabela 11, similar à Tabela 7. Foram adicionadas colunas. A saber: V_{min} indica o valor mínimo de tensão, em pu, obtido em algum dos K cenários, em duas casas decimais de precisão (para ser coerente com a precisão do PRODIST); o índice V_{max} é análogo ao anterior, porém considerando valor máximo de tensão obtido em algum dos K cenários; t reporta o tempo computacional em segundos; $t_{\%MMC}$ revela quantas vezes o método proposto é mais rápido do que o MMC, que levou 51960 segundos (aproximadamente 14 horas) para convergir.

Tabela 11 - Análise de sensibilidade dos centroides para FPTP considerando IEEE 123

K	ϵ_P [%]	$\overline{\epsilon_{Vmed}}$ [%]	$\overline{\epsilon_{V\sigma}}$ [%]	ϵ_{Vmax} [%]	ϵ_{Vmin} [%]	V_{min} [pu]	V_{max} [pu]	t [s]	$t_{\%MMC}$
10	1,29	0,01	1,13	0,67	0,53	0,93	1,00	52	999
20	1,25	0,01	0,88	0,32	0,29	0,93	1,00	83	626
50	1,24	0,01	0,85	0,08	0,13	0,93	1,00	236	220
100	1,24	0,01	0,85	0,01	0,02	0,93	1,00	400	130

Fonte: elaborado pelo autor (2022).

Algumas conclusões podem ser feitas a partir dos resultados expostos na Tabela 11:

1. À medida em que os centroides são adicionados, os parâmetros estatísticos tendem a reduzir, indicando que as variáveis de saída do FPTP baseado em

aproximações via *K-Means* se tornam cada vez mais próximas daquelas obtidas via MMC;

2. Quanto maior o número de centroides, maior também é o tempo computacional para o FPTP convergir. Isso já havia sido destacado no capítulo 2, onde foi visto que esse aumento é aproximadamente linear, o que é uma característica favorável.
3. Mesmo com 100 centroides, o que representaria aproximadamente um quarto do banco de dados original, o método ainda é 130 vezes mais rápido do que o MMC.
4. A partir de 10 centroides, o valor de tensão mínimo e máximo permanecem inalterados. Isso possui duas consequências:
 - a. Mesmo quando é considerado um número muito grande de centroides, não há subtensões ou sobretensões presentes no sistema. Além disso, esses valores se mantêm inalterados, considerando a precisão do PRODIST – o que revela a robustez do método de estimativa de *clusters* exposto no capítulo 2.
 - b. Isso demonstra que o número de centroides foi corretamente selecionado também do ponto de vista computacional. Um número maior de cenários iria acarretar um maior esforço computacional, sem alterar qualitativamente o *status* operacional das tensões – a resposta encontrada pela otimização revela resultados adequados do ponto de vista de perfil de tensão, mesmo quando uma quantidade muito maior de centroides é empregada.

Tendo em vista tais observações, ressalta-se que o método para avaliar o FPTP, aliado ao procedimento adotado para estimar o número de centroides, são robustos o suficiente para alcançar resultados precisos mediante um tempo computacional favorável.

5 CONSIDERAÇÕES FINAIS

Este último capítulo tem como objetivo expor as considerações finais acerca do estudo efetuado que culminou na presente dissertação. Serão apresentadas as principais conclusões obtidas por meio da aplicação do método para avaliar o FPTPO. Serão avaliados, também, os principais trabalhos futuros a serem desenvolvidos como forma de dar prosseguimento ao estudo realizado.

5.1 CONCLUSÕES

Foi desenvolvida uma ferramenta capaz de avaliar o estado da rede sob perspectivas probabilísticas e ótimas. Em outras palavras, foi alvo da presente dissertação avaliar o FPO, considerando uma formulação que levasse em consideração a natureza probabilística da demanda. Nesse sentido, foi formulado um problema de otimização com o intuito de minimizar o valor esperado da energia total perdida em um horizonte de planejamento diário através da alocação de capacitores fixos e chaveados. As restrições de tal problema envolvem as equações do FPTP, expressas via método por aproximações, baseado na técnica de *clustering K-Means*. As principais conclusões do presente estudo serão listadas a seguir.

- Foi desenvolvido um algoritmo para avaliar o FPP considerando redes trifásicas desequilibradas, englobando incerteza das demandas. Conforme visto, a técnica foi baseada no algoritmo *K-Means* e apresentou precisão comparável ao MMC, porém muito mais eficiente sob uma perspectiva de tempo computacional.
- A técnica desenvolvida confere um detalhamento horário do planejamento, proporcionando modelagens individuais das funções de probabilidade dos dados de entrada de forma individual para cada hora do dia.
- Foi avaliado um método simples e eficaz para determinar o número de *clusters* necessário para obter precisão suficiente, tendo em vista a aplicação do FPP em problemas de otimização, em que o tempo computacional é um entrave primordial.
- Foi criado um problema de otimização multi-estágio para alocar capacitores fixos e chaveados em sistemas de distribuição desequilibrados. Em todos os casos, puderam ser vistas reduções de valores esperados de perdas para todas as horas do dia, além do

aprimoramento do perfil de tensão, eliminando subtensões que ocorriam em determinados cenários críticos de carga.

- A técnica elaborada foi testada em três sistemas-testes do IEEE, incluindo o IEEE 123, que apresenta grande porte. Portanto, pode-se dizer que o método para avaliar o FPTPO desenvolvido apresenta a robustez necessária para ser aplicada em sistemas de portes variados.
- Os sistemas foram simulados utilizando a técnica proposta em comparação com o MMC. Através de índices estatísticos previamente definidos, pode ser constatado que o método sugerido apresentou eficácia suficiente.

De acordo com todos os pontos levantados, conclui-se que o trabalho alcançou todos os objetivos propostos. Além disso, é ressaltado que a consideração de uma ferramenta capaz de lidar com estados probabilísticos de redes trifásicas, em união às técnicas de otimização utilizadas, engloba uma importante contribuição ao estado da arte de análise de sistemas desequilibrados. Frisa-se, em adição à consideração anterior, que os resultados se tornam mais relevantes à medida que um detalhamento maior é conferido às simulações. Logo, infere-se que a adoção de técnicas probabilísticas para formular o FP foi capaz de fornecer resultados altamente relevantes também para o estado da arte do FPO.

5.2 TRABALHOS FUTUROS

Para dar sequência ao trabalho elaborado, são destacados alguns possíveis desdobramentos. A saber:

- Criação de um modelo capaz de considerar correlações probabilísticas de duas ou mais variáveis aleatórias, como irradiação solar, velocidade dos ventos para estimar as potências de saída de geradores fotovoltaicos e eólicos, respectivamente.
- Utilização de mais de uma variável aleatória para caracterizar demandas de acordo com sua localização espacial da topologia.
- Emprego de curvas de carga de natureza industrial e comercial.
- Realizar a técnica de *clustering* diferenciando comportamentos para diferentes tipos de dias: dias úteis, sexta-feira, sábado, domingo/feriado.

- Avaliação do FPTPO sob a perspectiva de outras funções objetivo, tais como: viabilidade financeira, índice de desequilíbrio, custos de operação, entre outras.
- Adotar outros critérios para estimar o número de *clusters* e comparar os resultados.
- Utilizar outros algoritmos de otimização e comparar os resultados.
- Utilização da teoria de probabilidade em espaços complexos para calcular as médias e os desvios padrões das grandezas fasoriais.
- A avaliação do ponto ótimo sem desacoplar o problema em etapas, unindo as quatro etapas em uma única estrutura de otimização.

REFERÊNCIAS BIBLIOGRÁFICAS

AHMED, Walaa *et al*, Probabilistic Load Flow Solution Considering Optimal Allocation of SVC in Radial Distribution System, **International Journal of Interactive Multimedia and Artificial Intelligence**, v. 5, n. 3, p. 152, 2018.

ALLAN, R.N.; DA SILVA, A.m.; BURCHETT, R.C., Evaluation Methods and Accuracy in Probabilistic Load Flow Solutions, **IEEE Transactions on Power Apparatus and Systems**, v. PAS-100, n. 5, p. 2539–2546, 1981.

ANEEL. Aprimoramento da metodologia de cálculo de perdas na distribuição regulamentada no Módulo 7 – Cálculo de Perdas na Distribuição do PRODIST. Nota Técnica no 0057/2014-SRD/ANEEL. Brasília, Brasil. 11 jun. 2014.

ANEEL. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST**. 2021.

BONELA, Ramesh *et al*, Techno-Economic planning framework of three phase unbalanced distribution system using multiple DG and Capacitor, *in*: **2021 1st Odisha International Conference on Electrical Power Engineering, Communication and Computing Technology (ODICON)**, Bhubaneswar, Índia: IEEE, 2021, p. 1–6.

BORKOWSKA, Barbara, Probabilistic Load Flow, **IEEE Transactions on Power Apparatus and Systems**, v. PAS-93, n. 3, p. 752–759, 1974.

CAI, Defu; SHI, Dongyuan; CHEN, Jinfu, Probabilistic load flow computation using Copula and Latin hypercube sampling, **IET Generation, Transmission & Distribution**, v. 8, n. 9, p. 1539–1549, 2014.

CAI, Defu; SHI, Dongyuan; CHEN, Jinfu, Probabilistic load flow with correlated input random variables using uniform design sampling, **International Journal of Electrical Power & Energy Systems**, v. 63, p. 105–112, 2014.

CARPINELLI, Guido *et al*, Taguchi's method for probabilistic three-phase power flow of unbalanced distribution systems with correlated Wind and Photovoltaic Generation Systems, **Renewable Energy**, v. 117, p. 227–241, 2018.

CASELLA, George; BERGER, Roger L. Inferência estatística. **São Paulo: Cengage Learning**, 2010.

CONSTANTE-FLORES, Gonzalo Esteban; ILLINDALA, Mahesh S., Data-Driven Probabilistic Power Flow Analysis for a Distribution System With Renewable Energy Sources Using Monte Carlo Simulation, **IEEE Transactions on Industry Applications**, v. 55, n. 1, p. 174–181, 2019.

CREDER, H. **Instalações Elétricas**. 16a. ed. Rio de Janeiro: Livros Técnicos e Científicos Editora Ltda, 2016.

DELGADO, C.; DOMÍNGUEZ-NAVARRO, J.A., Point estimate method for probabilistic load flow of an unbalanced power distribution system with correlated wind and solar sources, **International Journal of Electrical Power & Energy Systems**, v. 61, p. 267–278, 2014.

DENG, Xiaoyang *et al*, Probabilistic load flow method considering large-scale wind power integration, **Journal of Modern Power Systems and Clean Energy**, v. 7, n. 4, p. 813–825, 2019.

DOPAZO, J.F.; KLITIN, O.A.; SASSON, A.M., Stochastic load flows, **IEEE Transactions on Power Apparatus and Systems**, v. 94, n. 2, p. 299–309, 1975.

DRINEAS, P. *et al*, Clustering Large Graphs via the Singular Value Decomposition, **Machine Learning**, v. 56, n. 1–3, p. 9–33, 2004.

EL-HAWARY, M.E.; MBAMALU, G.A.N., A comparison of probabilistic perturbation and deterministic based optimal power flow solutions, **IEEE Transactions on Power Systems**, v. 6, n. 3, p. 1099–1105, 1991.

FERRAZ, Bibiana P. *et al*, Analysis of Distribution System Considering Load Uncertainties: a K-Means Clustering Approach, *in*: **2019 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)**, Gramado, Brazil: IEEE, 2019, p. 1–6.

GALLEGO, Luis Alfonso; ECHEVERRIA, Mauricio Granada; PADILHA-FELTRIN, Antonio. Fluxo de potência trifásico probabilístico para redes de distribuição usando o método de estimação por pontos. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 23, p. 179-189, 2012.

GALLEGO, Luis A.; FRANCO, John F.; CORDERO, Luis G., A fast-specialized point estimate method for the probabilistic optimal power flow in distribution systems with renewable distributed generation, **International Journal of Electrical Power & Energy Systems**, v. 131, p. 107049, 2021.

GIRALDO, Juan S. *et al*, Probabilistic OPF Model for Unbalanced Three-Phase Electrical Distribution Systems Considering Robust Constraints, **IEEE Transactions on Power Systems**, v. 34, n. 5, p. 3443–3454, 2019.

GUPTA, Neeraj; DARATHA, Novalio, Probabilistic three-phase load flow for unbalanced electrical systems with wind farms, **International Journal of Electrical Power & Energy Systems**, v. 87, p. 154–165, 2017.

HONG, H.P., An efficient point estimate method for probabilistic analysis, **Reliability Engineering & System Safety**, v. 59, n. 3, p. 261–267, 1998.

IEEE. IEEE PES AMPS DSAS Test Feeder Working Group,. **IEEE Test Feeders**, 31 de Outubro 2019. Disponível em: <<https://site.ieee.org/pes-testfeeders/resources/>>.

JAIN, Anil K., Data clustering: 50 years beyond K-means, **Pattern Recognition Letters**, v. 31, n. 8, p. 651–666, 2010.

JAIN, Anil K.; DUBES, Richard C., **Algorithms for clustering data**, Englewood Cliffs, N.J: Prentice Hall, 1988.

JAIN, Naveen; SINGH, S.N.; SRIVASTAVA, S.C., PSO based placement of multiple wind DGs and capacitors utilizing probabilistic load flow model, **Swarm and Evolutionary Computation**, v. 19, p. 15–24, 2014.

JIANCHANG MAO; JAIN, A.K., A self-organizing network for hyperellipsoidal clustering (HEC), **IEEE Transactions on Neural Networks**, v. 7, n. 1, p. 16–29, 1996.

KARAKATSANIS, T.S.; HATZIARGYRIOU, N.D., Probabilistic constrained load flow based on sensitivity analysis, **IEEE Transactions on Power Systems**, v. 9, n. 4, p. 1853–1860, 1994.

KARMARKAR, N., A new polynomial-time algorithm for linear programming, **Combinatorica**, v. 4, n. 4, p. 373–395, 1984.

KE, Deping; CHUNG, C. Y.; SUN, Yuanzhang, A Novel Probabilistic Optimal Power Flow Model With Uncertain Wind Power Generation Described by Customized Gaussian Mixture Model, **IEEE Transactions on Sustainable Energy**, v. 7, n. 1, p. 200–212, 2016.

KRISHNA, Attoti Bharath *et al*, Probabilistic power flow in radial distribution systems using point estimate methods, *in*: **2017 4th International Conference on Advanced Computing and Communication Systems (ICACCS)**, Coimbatore, India: IEEE, 2017, p. 1–6.

LEHTONEN, Matti. A method for probabilistic harmonic load-flow analysis in power systems. **European transactions on electrical power**, v. 8, n. 1, p. 47-50, 1998.

LI, Quan; WANG, Xin; RONG, Shuaiang, Probabilistic Load Flow Method Based on Modified Latin Hypercube-Important Sampling, **Energies**, v. 11, n. 11, p. 3171, 2018.

LI, Yiming *et al*, Probabilistic Optimal Power Flow Considering Correlations of Wind Speeds Following Different Distributions, **IEEE Transactions on Power Systems**, v. 29, n. 4, p. 1847–1854, 2014.

LINDE, Y.; BUZO, A.; GRAY, R., An Algorithm for Vector Quantizer Design, **IEEE Transactions on Communications**, v. 28, n. 1, p. 84–95, 1980.

MALEKPOUR, Ahmad Reza *et al*, Multi-Objective Stochastic Distribution Feeder Reconfiguration in Systems With Wind Power Generators and Fuel Cells Using the Point Estimate Method, **IEEE Transactions on Power Systems**, v. 28, n. 2, p. 1483–1492, 2013.

MARTINS, Antonio Sobrinho Campolina *et al*, Capacitor Allocation in Unbalanced Systems Using a Three-Level Optimization Framework, **IEEE Latin America Transactions**, v. 19, n. 9, p. 1599–1607, 2021.

MONTICELLI, Alcir José. **Fluxo de carga em redes de energia elétrica**. E. Blucher, 1983.

MORALES, Juan. M.; PEREZ-RUIZ, Juan., Point Estimate Schemes to Solve the Probabilistic Power Flow, **IEEE Transactions on Power Systems**, v. 22, n. 4, p. 1594–1601, 2007.

MORSHED, Mohammad Javad; HMIDA, Jalel Ben; FEKIH, Afef, A probabilistic multi-objective approach for power flow optimization in hybrid wind-PV-PEV systems, **Applied Energy**, v. 211, p. 1136–1149, 2018.

PENIDO, Débora Rosana Ribeiro *et al*, A new tool for multiphase electrical systems analysis based on current injection method, **International Journal of Electrical Power & Energy Systems**, v. 44, n. 1, p. 410–420, 2013.

PENIDO, Debora Rosana Ribeiro *et al*, Three-Phase Power Flow Based on Four-Conductor Current Injection Method for Unbalanced Distribution Networks, **IEEE Transactions on Power Systems**, v. 23, n. 2, p. 494–503, 2008.

RAMADHANI, Umar Hanif *et al*, Review of probabilistic load flow approaches for power distribution systems with photovoltaic generation and electric vehicle charging, **International Journal of Electrical Power & Energy Systems**, v. 120, p. 106003, 2020.

REN, Zhouyang *et al*, Probabilistic Power Flow Analysis of Power Systems Incorporating Tidal Current Generation, **IEEE Transactions on Sustainable Energy**, v. 8, n. 3, p. 1195–1203, 2017.

ROSS, Sheldon. **Probabilidade: um curso moderno com aplicações**. Bookman Editora, 2009.

RUIZ-RODRIGUEZ, F. J.; JURADO, F.; GOMEZ-GONZALEZ, M., A hybrid method combining JFPO and probabilistic three-phase load flow for improving unbalanced voltages in distribution systems with photovoltaic generators, **Electrical Engineering**, v. 96, n. 3, p. 275–286, 2014.

SAUNDERS, Christopher Scott, Point Estimate Method Addressing Correlated Wind Power for Probabilistic Optimal Power Flow, **IEEE Transactions on Power Systems**, v. 29, n. 3, p. 1045–1054, 2014.

SHARGH, S. *et al*, Probabilistic multi-objective optimal power flow considering correlated wind power and load uncertainties, **Renewable Energy**, v. 94, p. 10–21, 2016.

SRITHAPON, Chitchai *et al*, Surrogate-Assisted Multi-Objective Probabilistic Optimal Power Flow for Distribution Network With Photovoltaic Generation and Electric Vehicles, **IEEE Access**, v. 9, p. 34395–34414, 2021.

STEINHAUS, Hugo *et al*. Sur la division des corps matériels en parties. **Bull. Acad. Polon. Sci**, v. 1, n. 804, p. 801, 1956.

SU, C.-L., Probabilistic Load-Flow Computation Using Point Estimate Method, **IEEE Transactions on Power Systems**, v. 20, n. 4, p. 1843–1851, 2005.

UNIYAL, Ankit; SARANGI, Saumendra, Optimal network reconfiguration and DG allocation using adaptive modified whale optimization algorithm considering probabilistic load flow, **Electric Power Systems Research**, v. 192, p. 106909, 2021.

XIE, Z. Q. *et al*, Quasi-Monte Carlo Based Probabilistic Optimal Power Flow Considering the Correlation of Wind Speeds Using Copula Function, **IEEE Transactions on Power Systems**, v. 33, n. 2, p. 2239–2247, 2018.

ANEXO A: CONCEITOS FUNDAMENTAIS

Neste anexo, serão apresentados os principais conceitos envolvidos no trabalho. A compreensão desses tópicos corrobora para o entendimento geral da dissertação. Primeiramente, serão introduzidos aspectos básicos de estatística. Posteriormente, a formulação matemática do método *K-Means* será mostrada. Por fim, serão abordados métodos de solução de FP para SDEE, assim como um breve arcabouço teórico acerca de métodos de otimização utilizados no presente trabalho.

A.1 CONCEITOS BÁSICOS DE ESTATÍSTICA

Esta subseção é destinada à apresentação de diversos conceitos do âmbito estatístico que foram empregados em diversas situações ao longo da presente dissertação. A principal referência utilizada foi o livro de Ross (2009).

A.1.1 ESPAÇO AMOSTRAL, EVENTOS E PROBABILIDADE

Dado um experimento cujo resultado é incerto, define-se o *espaço amostral* como o conjunto dos possíveis resultados desse experimento. Um *evento* é definido como qualquer subconjunto do espaço amostral. Se o resultado do experimento estiver contido no subconjunto do evento, pode-se afirmar que o evento ocorreu.

O conceito de *probabilidade* de um evento pode ser definido como a frequência relativa em que o evento ocorre. Em outras palavras, quantas vezes o referido evento ocorre em n repetições iguais do experimento. Segundo Ross (2009), a probabilidade P de um evento E ocorrer pode ser traduzida matematicamente por meio da expressão (A.1).

$$P(E) = \lim_{n \rightarrow \infty} \frac{n(E)}{n} \quad (\text{A.1})$$

Onde $n(E)$ é o número de vezes que o evento ocorre nas n primeiras execuções do experimento.

Segundo o mesmo autor, a suposição que tal limite convirja para uma constante é considerada um axioma. Tal equação também caracteriza a proporção de tempo que o evento ocorre e pode ser referida como a frequência limite de E (Ross, 2009).

Dados um experimento de espaço amostral S e um evento E , diz-se que P é a probabilidade de ocorrência de E se satisfizer as três condições a seguir.

- 1) A probabilidade $P(E)$ deve ser um número definido e constante entre 0 e 1.

$$0 \leq P(E) \leq 1 \quad (\text{A.2})$$

- 2) A probabilidade de ocorrer um evento $E=S$, ou seja, o próprio espaço amostral, é 1.

$$P(S) = 1 \quad (\text{A.3})$$

- 3) Dados eventos mutuamente exclusivos, isto é, que não apresentam interseção, a probabilidade de pelo menos um deles ocorrer é definida pela soma das suas probabilidades respectivas.

$$P\left(\bigcup_{i=1}^{\infty} E_i\right) = \sum_{i=1}^{\infty} P(E_i) \quad (\text{A.4})$$

Através das equações (A.2) e (A.3), prova-se que a probabilidade do evento *conjunto vazio* é nula (Ross, 2009).

A.1.2 VARIÁVEIS ALEATÓRIAS DISCRETAS

Muitas vezes deseja-se conhecer uma função do resultado de um experimento. Logo, analisam-se funções definidas no espaço amostral. Tais funções são chamadas de *variáveis aleatórias*. Como o valor da variável aleatória é atrelada ao resultado do experimento, é possível definir probabilidades ou possíveis valores para cada uma dessas variáveis (Ross, 2009).

Uma variável aleatória que pode ser caracterizada por um conjunto numerável de valores possíveis é chamada de *variável aleatória discreta*. A partir disso, define-se a *função de probabilidade* de uma variável discreta X .

$$p(a) = P\{X = a\} \quad (\text{A.5})$$

Ou seja, será observado o valor da variável aleatória igual ao valor a , somente quando o resultado do experimento aleatório for um valor s , contido no espaço amostral S , tal que

$$X(s) = a \quad (\text{A.6})$$

A função discreta de probabilidade $p(a)$ possui duas propriedades importantes. A saber:

- 1) A função é positiva para um número enumerável de valores de a . Além disso, é nula para todos os pontos fora do espaço amostral.
- 2) A soma de seus valores deve ser igual a 1.

Define-se a *distribuição cumulativa* de probabilidade tal como expresso na equação (A.7).

$$F(a) = P\{X \leq a\} = \sum_{\forall x \leq a} p(x) \quad (\text{A.7})$$

Essa função quantifica a probabilidade acumulada de determinada variável aleatória ser menor ou igual a um determinado valor a .

Se X é uma variável aleatória discreta com função de probabilidade $p(x)$, então a *esperança* ou o *valor esperado* de X , denotado por $E[X]$, pode ser definido por meio da equação (A.8).

$$E[X] = \sum_{x:p(x)>0} xp(x) \quad (\text{A.8})$$

Nota-se que o valor esperado de X é uma média ponderada dos possíveis valores atribuídos a X , sendo os fatores de ponderação suas respectivas probabilidades. O conhecimento desse valor é de extrema importância para a teoria de estatística, uma vez que fornece um valor médio da variável aleatória.

Uma propriedade das esperanças é aquela que mostra que o valor esperado de uma soma de variáveis aleatórias é igual à soma de suas esperanças. Isso é devido à linearidade do operador que determina o valor médio de uma variável aleatória (Ross, 2009).

$$E\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n E[X_i] \quad (\text{A.9})$$

Todavia, o valor esperado não informa como se comporta a dispersão desses valores. Desta forma, busca-se uma maneira de descobrir o quanto os valores possíveis de uma variável aleatória estão, em média, dispersos em relação à sua esperança.

Se X é uma variável aleatória com valor esperado μ , então define-se a *variância* de X , denotada por $var(X)$, por meio da equação (A.10).

$$var(X) = E[(X - \mu)^2] \quad (\text{A.10})$$

Em outras palavras, a variância de X é a esperança da diferença entre X e sua média (Ross, 2009).

Uma maneira mais fácil de calcular a variância é por meio da equação (A.11), manipulando matematicamente (A.10) através da definição apresentada em (A.8).

$$var(X) = E[X^2] - (E[X])^2 \quad (\text{A.11})$$

A raiz quadrada de $var(X)$ é chamada de *desvio padrão* da variável aleatória X , denotado por $\sigma(X)$, tal como definido em (A.12).

$$\sigma(X) = \sqrt{var(X)} \quad (\text{A.12})$$


A.1.3 VARIÁVEIS ALEATÓRIAS CONTÍNUAS

As variáveis aleatórias cujos valores possíveis são infinitos e incontáveis são chamadas de *variáveis aleatórias contínuas*. Diz-se que X é uma variável aleatória contínua se existe uma função f tal que, para todo $x \in \{-\infty, \infty\}$:

$$P\{X \in \Omega_B\} = \int_{\Omega_B} f(x) dx \quad (\text{A.13})$$

Nesse caso, a função f é chamada de *função densidade de probabilidade* da variável aleatória X . A equação (A.13) indica que a probabilidade de X estar no conjunto Ω_B é igual à área sobre a curva que representa a função densidade de probabilidade ao longo do intervalo que define o conjunto Ω_B . A Figura 59 ilustra esse conceito, considerando um intervalo exemplo de $\Omega_B = \{1,2\}$.

Figura 59 - Probabilidade calculada através da integração da função densidade de probabilidade



Fonte: elaborado pelo autor (2022).

A função densidade de probabilidade deve satisfazer algumas condições:

- 1) A sua integral considerando o intervalo de integração $\{-\infty, \infty\}$ deve ser igual a 1, pois corresponde à probabilidade de o evento estar contido no próprio espaço amostral. Logo:

$$P\{X \in (-\infty, \infty)\} = \int_{-\infty}^{\infty} f(x)dx = 1 \quad (\text{A.14})$$

- 2) A probabilidade de uma variável contínua assumir qualquer valor específico é nula, pois:

$$P\{X = a\} = \int_a^a f(x)dx = 0 \quad (\text{A.15})$$

- 3) Para qualquer variável contínua aleatória, define-se a função de probabilidade acumulada, denotada por $F(x)$.

$$P\{X < a\} = P\{X \leq a\} = \int_{-\infty}^a f(x)dx = F(a) \quad (\text{A.16})$$

De forma análoga ao caso discreto, é possível calcular o valor esperado ou esperança para uma variável aleatória contínua. Tal parâmetro pode ser determinado via equação (A.17).

$$E[X] = \int_{-\infty}^{\infty} xf(x)dx \quad (\text{A.17})$$

A variância de uma variável aleatória contínua é determinada da mesma maneira em relação ao caso discreto. Isto é, calcula-se a esperança da diferença entre X e sua esperança. Isto é mostrado por meio das expressões (A.10) e (A.11). O desvio padrão pode ser igualmente determinado sobre essas premissas tal como mostrado na equação (A.12).

A.1.4 VARIÁVEIS ALEATÓRIAS CONTÍNUAS NORMAIS


Variáveis aleatórias são, muitas vezes, classificadas de acordo com suas funções de probabilidade. Muitas delas, sejam discretas ou contínuas, podem ser vistas com detalhes em Ross (2009) e em Casella e Berger (2010). Todavia, uma das mais utilizadas é a *variável aleatória normal*.

Uma variável aleatória contínua X , com valor esperado μ e desvio padrão σ , é dita normalmente distribuída se a sua função densidade de probabilidade é dada pela equação (A.18).

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(x-\mu)^2/2\sigma^2} \quad (\text{A.18})$$

A curva formada por tal equação é em forma de sino, sendo simétrica em relação ao valor esperado μ (Ross, 2009). A Figura 60 apresenta um exemplo de como essa função se comporta, considerando $\mu = 0$ e $\sigma = 1$.

Figura 60 - Exemplo de função densidade de probabilidade normal




Fonte: elaborado pelo autor (2022).

A função de distribuição acumulada pode ser definida pela integração da mesma, tal como expresso na equação (A.16). A Figura 61 apresenta a integral da curva apresentada na Figura 60, como forma de exemplificar seu comportamento. É possível notar que a curva converge para o valor unitário, o que está em conformidade com (A.14).

Por questões de simplicidade, a função densidade de probabilidade é indicada pela sigla PDF (do inglês: *Probability Density Function*). Já a função de probabilidade acumulada é referida pela sigla CDF (do inglês: *Cumulative Distribution Function*).

Figura 61 - Exemplo de função de probabilidade acumulada normal



Fonte: elaborado pelo autor (2022).

A.2 DATA CLUSTERING E O ALGORITMO K-MEANS

O objetivo de agrupar dados em *clusters* é associar naturalmente subconjuntos de forma que apresentem um padrão definido. Uma definição concreta é sugerida em (Jain, 2010): dada a representação de n objetos, o objetivo é encontrar k grupos baseados em medidas de similaridade, de tal forma que os objetos contidos em um mesmo grupo apresentem afinidade alta e objetos de grupos diferentes apresentem similaridade baixa.

A análise via *clusters* pode ser utilizada em três situações principais, que estão listadas a seguir (Jain, 2010).

- 1) *Underlying structure* ou estrutura subjacente: empregada quando se deseja obter informações sobre os dados, detectar anomalias e identificar características atípicas (Jain, 2010).
- 2) *Natural classification* ou classificação natural: empregada quando deseja-se identificar graus de similaridade entre formas ou organismos (Jain, 2010).
- 3) *Compression* ou compressão: utilizado como método para organizar um conjunto de dados ou para resumi-los por meio de *clusters*.

Os algoritmos de *cluster* podem ser divididos entre hierárquicos e particionais. O primeiro grupo é caracterizado por localizar recursivamente os *clusters*, podendo ser

aglomerativo, quando cada ponto do banco de dados original corresponde inicialmente a um *cluster*, ou divisivo, quando todos os pontos estão agrupados inicialmente em um mesmo *cluster*. Já o segundo grupo é aquele que busca encontrar todos os *clusters* simultaneamente através da partição dos dados, não impondo uma estrutura hierárquica (Jain, 2010). Dentre todos os algoritmos particionais, destaca-se a técnica *K-Means*.

O algoritmo *K-Means* foi proposto há mais de 60 anos, por Steinhaus (1956), e continua sendo uma das principais ferramentas de *clustering* utilizadas na literatura. Isso é devido à sua fácil implementação, simplicidade, eficiência e sucesso empírico (Jain, 2010).

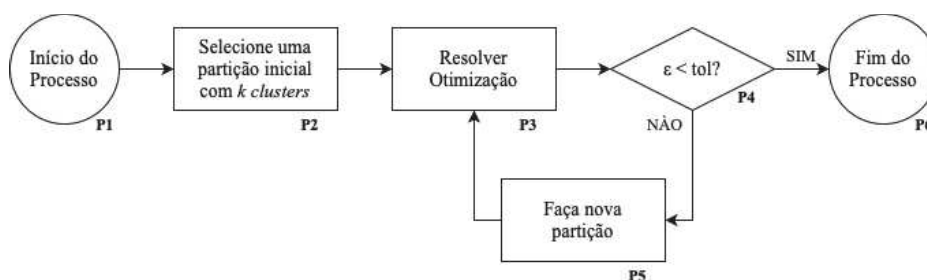
Seja Ω um conjunto de n dados, representado por $\Omega = \{\omega_i: i = 1, \dots, n\}$. O objetivo é classificar cada um desses dados a um grupo, chamado *cluster*, totalizando k grupos. O conjunto de *clusters*, denotado por C , é definido por $C = \{c_j: j = 1, \dots, k\}$. Cada um dos elementos c_j é um subconjunto de Ω , que armazena elementos similares entre si. A partir disso, o algoritmo *K-Means* tem como objetivo determinar uma partição que minimiza o erro quadrático entre uma média empírica de um *cluster* j , denotada por μ_j e também chamada de *centroide* do *cluster* j , e os pontos nele contidos. Dessa forma, o erro médio quadrático entre μ_j e os pontos contidos no *cluster* c_j é dado pela equação (A.19).

$$J(c_j) = \sum_{\omega_i \in c_j} |\omega_i - \mu_j|^2 \quad (\text{A.19})$$

Como o objetivo do algoritmo *K-Means* é reduzir a soma do erro quadrático de todos os *clusters*, formula-se um problema de otimização cuja FOB é a minimização da equação (A.20).

$$J(c) = \sum_{j=1}^k \sum_{\omega_i \in c_j} |\omega_i - \mu_j|^2 \quad (\text{A.20})$$

Os principais passos do algoritmo são apresentados no fluxograma da Figura 62 (Jain e Dubes, 1988).

Figura 62 - Fluxograma do algoritmo *K-Means*

Fonte: elaborado pelo autor (2022). Baseado em Jain e Dubes (1988).

Em **P1** ocorre o início do processo. Há a leitura do banco de dados e são informados o número de *clusters* e a tolerância que mensura a convergência do algoritmo. Em **P2**, há a partição inicial dos dados do conjunto informado nos k *clusters*. Em **P3**, o problema de otimização cuja FOB é expressa pela equação (A.20) é solucionado dada a partição inicial. O objetivo é determinar os novos centroides para cada grupo, de acordo com a proximidade dos elementos de cada um deles. Verifica-se o critério de convergência em **P4** através da consideração do parâmetro ϵ , dado pelo erro relativo da FOB da presente iteração em relação à FOB da iteração anterior. Caso não haja convergência, é feita uma nova partição tendo como referência os centroides atualizados e retorna-se ao passo **P3**. Caso haja convergência, o problema é encerrado em **P6**, possuindo como variáveis de saída os k grupos, os elementos de cada grupo e seus respectivos centroides.

Minimizar a FOB expressa por (A.20) requer técnicas de otimização não linear, representando um problema computacional complexo. Como o algoritmo *K-Means* é fortemente atrelado à partição inicial, tem-se que o mesmo só pode convergir para um ótimo local (Drineas, 1999).

Em termos computacionais, o algoritmo exige quatro parâmetros de entrada do usuário. A saber: o conjunto original Ω , o número de *clusters*, a partição inicial e a métrica para computar a distância entre os pontos.

O banco de dados é fornecido de acordo com os critérios e os objetivos do usuário. A escolha do número de *clusters* é crítica. Apesar de não existir um método matemático que esteja apto a determinar idealmente o valor de k , há diversas heurísticas na literatura para alcançar tal propósito. O método desenvolvido para este trabalho foi exposto na seção 2.4.

A inicialização da partição dos *clusters* também é um fator importante. Devido à sua aptidão de convergência local, execuções distintas do algoritmo *K-Means* oriundas de um

mesmo conjunto Ω podem gerar *clusterings* diferentes. Uma maneira de refinar o resultado é executar muitas vezes o mesmo problema, com diferentes partições iniciais, e escolher a configuração que apresenta menor erro quadrático médio (Jain, 2010).

Em relação à métrica utilizada, é usual a adoção da métrica euclidiana. Outras métricas podem ser utilizadas como Mahalanobis (Mao e Jain, 1996) ou Itakura-Saito (Linede, 1980).

A.3 SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA E O FLUXO DE POTÊNCIA MULTIFÁSICO

Os SDEE são os responsáveis por entregar a energia elétrica aos consumidores finais. Esses sistemas se originam em uma subestação, que abaixará a tensão do sistema de transmissão, originando as redes de distribuição primárias. Posteriormente, há um novo abaixamento de tensão, por meio dos transformadores de distribuição, para atender aos consumidores, originando as redes de distribuição secundárias (Creder, 2016).

Geralmente, os circuitos das redes primárias são trifásicos a três fios e são submetidos à média tensão. Já os circuitos das redes secundárias são trifásicos a quatro fios (fases a, b e c além do condutor neutro) e são submetidos à baixa tensão. Os ramais laterais podem ser monofásicos, bifásicos ou trifásicos. Essas redes são caracterizadas por serem extensas e suas características físicas e elétricas conferem-lhes grande razão R/X , de forma que uma modelagem apropriada não pode desprezar as resistências dos alimentadores. Além disso, há uma grande importância em representar adequadamente a indução mútua entre os circuitos, que ocorre de maneira desequilibrada entre as fases e descredencia a modelagem via sequência positiva ou até mesmo por meio de componentes simétricas (Penido *et al*, 2010).

Outro fator complicador que dificulta a representação matemática desses sistemas é o comportamento da demanda. Há um grande desequilíbrio de carga entre as fases devido à maneira através da qual esses sistemas são projetados e operados. Apesar dos projetos tenderem a equilibrar a distribuição de cargas igualmente entre as fases, isso não ocorre com perfeita precisão. Além disso, não se pode prever o comportamento do consumidor em relação a quais equipamentos serão utilizados nas residências, comércios e indústrias, causando fases mais sobrecarregadas do que outras.

Tendo em vista essas características inerentes aos SDEE, é imprescindível que sejam utilizadas ferramentas adequadas para representar esses fenômenos da maneira mais fidedigna possível. Logo, isso requer uma modelagem multifásica. Neste trabalho, foram empregadas

duas estratégias para simular o FP multifásico: via Método de Injeção de Correntes a N Condutores e via *software OpenDSS* (do inglês: *Open Distribution System Simulator*).

A.3.1 MÉTODO DE INJEÇÃO DE CORRENTES A N CONDUTORES

O método desenvolvido por Penido *et al* (2010) alcançou sucesso para modelar sistemas elétricos multifásicos. É denominado Método de Injeção de Correntes a N Condutores, ou MICN. Nesse desenvolvimento matemático, cada nó é caracterizado por ser o ponto de encontro entre elementos elétricos, sendo cada um deles tratado de maneira individualizada, permitindo a representação multifásica do sistema. Calcula-se a injeção de correntes de cada elemento, em coordenadas retangulares, para cada nó, criando-se, por conseguinte, um sistema não linear baseado na lei de Kirchhoff dos nós. As variáveis do referido sistema são as componentes reais e imaginárias das tensões de cada nó, além das variáveis de controle que porventura possam existir.

É um método amplamente flexível para representação de topologias e permite a consideração de quaisquer elementos elétricos. Nesse trabalho, foram estudadas topologias que contenham a subestação, alimentadores, transformadores, cargas e capacitores. Cada um desses elementos possui sua modelagem própria para computar as respectivas injeções de corrente. As equações para cada elemento elétrico podem ser vistas em Penido *et al* (2010).

De forma geral, o sistema não linear construído pelo MICN pode ser descrito matematicamente através das equações (A.21) a (A.24).

$$\text{real} \sum_{i \in \Omega_K} I_k^i(V_{km}^{\text{Re}}, V_{km}^{\text{Im}}, x^{\text{Re}}, x^{\text{Im}}) = 0 \quad (\text{A.21})$$

$$\text{imag} \sum_{i \in \Omega_K} I_k^i(V_{km}^{\text{Re}}, V_{km}^{\text{Im}}, x^{\text{Re}}, x^{\text{Im}}) = 0 \quad (\text{A.22})$$

$$\text{real}(g(V_{km}^{\text{Re}}, V_{km}^{\text{Im}}, x^{\text{Re}}, x^{\text{Im}})) = 0 \quad (\text{A.23})$$

$$\text{imag}(g(V_{km}^{\text{Re}}, V_{km}^{\text{Im}}, x^{\text{Re}}, x^{\text{Im}})) = 0 \quad (\text{A.24})$$

Onde:

- I_k é a injeção de corrente correspondente ao elemento elétrico i no nó k .
- Ω_K é o conjunto de todos os elementos conectados ao nó k .
- V_{km}^{Re} e V_{km}^{Im} são, respectivamente, as componentes real e imaginária da diferença de potencial entre os nós k e m .
- x^{Re} e x^{Im} são, respectivamente, as componentes real e imaginária das variáveis de controle que podem existir devido a algum elemento elétrico específico.
- g refere-se às equações de controle.

A.3.2 SOFTWARE *OPENDSS*

O *OpenDSS* é um *software* aberto para simular SDEE. Ele possui aptidão para modelar sistemas multifásicos, fazendo o tratamento individual de cada fase. O *software* apresenta uma biblioteca ampla de componentes elétricos, tais como geradores, alimentadores de distribuição, cargas, capacitores, transformadores, reguladores de tensão, baterias, unidades de GD entre muitas outras.

Esta ferramenta é utilizada em muitos trabalhos na literatura (Bonela *et al*, 2021; Martins *et al*, 2021) e é recomendada pela Agência Nacional de Energia Elétrica (ANEEL) para calcular perdas em SDEE (ANEEL, 2018), o que lhe confere grande credibilidade. Existe uma vasta possibilidade de simulações contidas nas suas opções internas, de acordo com os desígnios do usuário: cálculo do FP multifásico, modo de simulação harmônico, FP sequenciais (diários, anuais), abordagem *Quasi-Static Time Series*, análise de curtos-circuitos entre outras.

Uma das vantagens do *OpenDSS* é a sua integração com outros *softwares*, por meio de sua interface denominada *Component Object Model* (COM). Nesse sentido, é possível operá-lo por meio de outras plataformas, como o *MatLab* (do inglês: *Matrix Laboratory*), o *Python* e o *Microsoft Excel*. Logo, as possibilidades de simulação aumentam com a integração de *softwares* de programação.

A.4 FLUXO DE POTÊNCIA ÓTIMO E MÉTODOS DE OTIMIZAÇÃO

Chama-se Fluxo de Potência Ótimo (FPO) qualquer formulação de problema de otimização cujas restrições englobam as equações do FP. Nesse sentido, busca-se o estado ótimo da rede sob a ótica de uma Função Objetivo (FOB). O problema que contém as equações do FP trifásico como restrições pode ser denominado Fluxo de Potência Trifásico Ótimo

(FPTO). Um problema clássico de FPO consiste na alocação de recursos para aprimorar o desempenho da rede de alguma forma. Podem ser utilizados capacitores, unidades de GD, STATCOMs, baterias, entre muitos outros equipamentos.

Pode ser vista na literatura uma infinidade de diferentes FOBs adotadas para esses casos, tais como: redução de perdas, regulação de tensão, redução de emissões poluentes, aprimoramento da margem de estabilidade de tensão, melhora do fator de potência, redução de custos de geração, e assim por diante, tal como visto na seção 1.3, por exemplo.

Os problemas de alocação de recursos pertencem à classe de problemas de otimização não linear. As não linearidades são provenientes das equações do FP. Além disso, as posições dos recursos na rede devem ser modeladas por variáveis inteiras, de forma que a formulação do problema passa a ser chamada de “não-linear inteira mista” (MINLP, do inglês: *Mixed Integer Non-Linear Programming*).

Muitos autores discutem qual a melhor forma de solucionar esse tipo de problema. Desenvolvimentos baseados em metaheurísticas ganharam força na última década, pois conseguem alcançar bons resultados em formulações de natureza altamente combinatória. Entretanto, existe o risco de uma convergência prematura, não garantindo otimalidade global. Outros autores preferem a resolução via técnicas clássicas. Entretanto, para problemas de grande porte, o tempo computacional tende a ser um complicador, sobretudo para problemas que considerem o FP multifásico.

No presente trabalho, foram empregadas técnicas clássicas para reduzir o espaço de busca e, posteriormente, técnicas metaheurísticas para solucionar o FPO. Nas próximas subseções, serão caracterizados os dois algoritmos utilizados: o Método dos Pontos Interiores (MPI) e os Algoritmos Genéticos (AG).

A.4.1 MÉTODO DOS PONTOS INTERIORES

O Método dos Pontos Interiores (MPI) é um método de otimização que busca determinar o ponto ótimo dentro da solução de viabilidade. Ao contrário do método simplex, que varre as suas fronteiras, o MPI as evita por meio de uma função barreira logarítmica. Foi proposto por Karmakar (1984) e logo foi amplamente empregado para solucionar problemas de programação linear de grande porte. Atualmente, os principais pacotes comerciais de otimização contêm o MPI para solucionar problemas de otimização lineares e não lineares. Neste trabalho, o MPI é utilizado por meio da *toolbox* de otimização não linear *fmincon* do *Matlab*.

A.4.2 ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos (AG) são considerados algoritmos metaheurísticos pela literatura. Fazem parte dos algoritmos evolucionários e, portanto, não possuem garantia de otimalidade global.

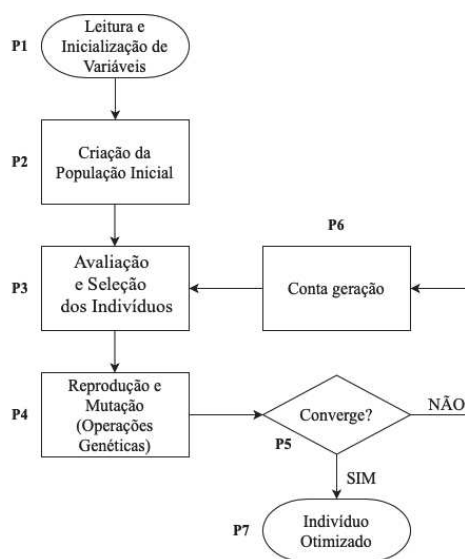
Os AG baseiam-se na Teoria da Evolução, de Charles Darwin. Segundo essa teoria, as espécies mantêm um processo de evolução a partir do qual os indivíduos mais aptos e mais adaptados em relação ao meio no qual se encontram apresentam maior probabilidade de transferir suas características para os indivíduos da próxima geração. Os mais fracos sucumbem ao processo de Seleção Natural.

Apresentando uma analogia com a teoria evolucionista de Darwin, os AG baseiam-se na evolução de possíveis soluções de um problema de otimização, sendo que as melhores perpetuam no processo evolucionário e as piores são descartadas.

Para melhor entendimento, aqui é explicada a nomenclatura própria do algoritmo:

- As variáveis de decisão são formadas por um ou mais *genes*, que podem ser partes de uma variável (no caso de representação binária, por exemplo) ou pode ser a própria variável.
- O conjunto das variáveis de decisão é chamado *cromossomo*, sendo cada cromossomo correspondente a um *indivíduo*, que consiste em uma possível solução para o problema de otimização.
- O conjunto de indivíduos é chamado de *população*.
- O conjunto de populações é chamado de *geração*.
- Para fabricação de novas gerações a partir das anteriores, são realizadas *operações genéticas*, que consistem na permutação de genes para se formar um novo indivíduo. As operações genéticas podem ser chamadas também de operações de *crossover*.
- Após a convergência do método, diz-se que foi obtido o *indivíduo ótimo*, que é aquele que conseguiu minimizar ou maximizar a FOB.

Figura 63 - Fluxograma do AG



Fonte: elaborado pelo autor (2022).

Após a introdução da nomenclatura própria, são apresentados os principais passos que o AG percorre até atingir a resposta ótima, representados por intermédio da Figura 63.

Em **P1**, ocorre a leitura e a inicialização de variáveis. Em **P2**, há a definição das variáveis de decisão e a formação do cromossomo a ser implementado na otimização genética, assim como a formulação aleatória da população inicial, respeitando os respectivos limites mínimos e máximos de cada variável de decisão. Em **P3**, aplica-se cada indivíduo da população inicial à FOB. Ou seja, cada indivíduo da população estará associado a um valor da FOB. Os melhores indivíduos serão selecionados mediante critério pré-estabelecido e os piores serão descartados. Em **P4** são realizadas as operações genéticas, isto é, haverá recombinação de genes das respostas selecionadas no passo anterior, gerando novos indivíduos para formarem uma nova população. Em **P5** é feito o teste de convergência. Diz-se que ocorreu a convergência quando o número de gerações ultrapassa um valor pré-estabelecido ou quando há a estagnação da população, na ocasião em que a melhor FOB é obtida por um número estabelecido de gerações. Caso haja convergência, o algoritmo se encerra no passo **P7**, onde é determinado o indivíduo ótimo. Caso contrário, uma nova geração é simulada e o processo retorna ao passo **P3**.

ANEXO B: BANCO DE DADOS DOS FATORES DE CARGA

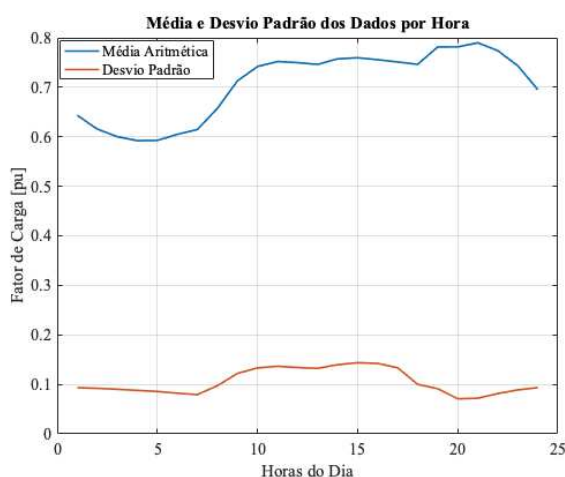
Conforme mencionado nos capítulos 2, 3 e 4, o método para avaliar o FPP por aproximações baseado em *K-Means* tem como base um banco de dados que contém fatores proporcionais de carga que mapeiam o comportamento das demandas durante as horas do dia. Nesse sentido, é representado por uma matriz denominada cuja dimensão é $n \times 24$. Ou seja, para cada uma das 24 horas do dia, existem n medições, que indicam os n comportamentos distintos da demanda em uma série histórica.

Esse banco de dados foi confeccionado através do sorteio de valores mediante o conhecimento dos valores médios e desvios padrões dos fatores proporcionais de carga para cada hora do dia. Sob essa premissa, é possível montar um banco de dados para qualquer valor de n desejado.

O valor adotado para n foi igual a 365 para representar as curvas de carga anuais, onde deseja-se comprimir tais dados para um número menor de curvas, tal como visto pela lógica *K-Means*. Entretanto, foram avaliados bancos de dados de até 5000 valores na seção 2.4.

A Figura 64 contém os dados de média e desvio padrão do banco de dados utilizado. Tais valores foram adotados de acordo com os conhecimentos práticos do autor. Foi objetivo representar uma curva de caráter residencial. A permutação das curvas de carga em nada altera a formulação e execução geral dos métodos desenvolvidos e aplicados no presente trabalho.


Figura 64 - Dados estatísticos do banco de dados utilizado



Fonte: elaborado pelo autor (2022).

Já a Figura 65 apresenta, na cor cinza, todas as 365 curvas de carga, com todos os cenários possíveis para as 24 horas.


Figura 65 - Cenários possíveis



Fonte: elaborado pelo autor (2022).

Com os dados de média e desvio padrão, é possível obter uma distribuição normal para o comportamento de cada fator proporcional de carga horário. Essas PDFs podem ser verificadas na Figura 66. Logo, os dados que compõem a matriz nada mais são do que amostras dessas funções de probabilidade, obtidas mediante sorteio tal que sua probabilidade de escolha é proporcional à sua respectiva PDF.

Figura 66 - PDFs dos fatores proporcionais de carga



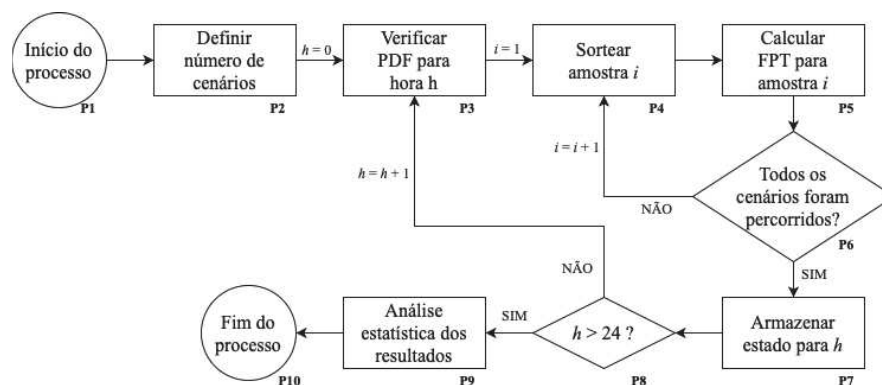
Fonte: elaborado pelo autor (2022).

ANEXO C: ALGORITMO DO MÉTODO DE MONTE CARLO

Conforme detalhado no capítulo 2, o Método de Monte Carlo (MMC) é caracterizado por ser um método probabilístico numérico, uma vez que se baseia na execução repetitiva do problema determinístico ponderado por amostras da PDF dos dados de entrada. Este anexo tem o intuito de apresentar minuciosamente o algoritmo implementado para calcular o FPP sob essa perspectiva.

O fluxograma apresentado na Figura 67 objetiva mostrar cada um dos passos percorridos.

Figura 67 - Fluxograma do MMC para calcular FPP



Fonte: elaborado pelo autor (2022).

Cada um dos passos será explicado a seguir.

Em **P1** ocorre o início do processo, assim como a leitura dos dados das variáveis de entrada e suas respectivas PDFs. Em **P2** há a definição do número de cenários, denotado por n_{MMC} , que será o número de vezes que o FP determinístico será executado. Na verdade, como o horizonte de planejamento é diário e discretizado horariamente, este número de simulações será adotado para cada hora do dia. Portanto, o número de simulações do problema determinístico será 24 vezes n_{MMC} . Começando pela primeira hora do dia ($h = 0$), verifica-se a PDF das variáveis de entrada para essa hora em **P3**. Em **P4** há o sorteio de uma amostra i dessa PDF e em **P5** é simulado o FPT determinístico para essa amostra. Em **P6**, averigua-se se todos os n_{MMC} cenários foram considerados. Caso não seja verdade, o contador i é incrementado e é sorteada uma nova amostra em **P4**. Caso contrário, o processo segue para o passo **P7**, onde é armazenado todos os dados dos FPT determinísticos simulados para todas as amostras, considerando a hora h . Em seguida, verifica-se se o contador de horas h percorreu as 24 horas

do dia, em **P8**. Se não for o caso, incrementa-se o contador h e o processo retorna ao passo **P3**. Caso contrário, o processo segue para o passo **P9** com a análise estatística dos resultados. O algoritmo se encerra em **P10** onde os resultados finais são disponibilizados.

Dado um conjunto de variáveis de entrada aleatórias \mathbf{X} , o processo descrito fornece como saída um conjunto de variáveis aleatórias \mathbf{Y} . Nesse sentido, pode-se dizer que o valor esperado de determinada variável $y \in \mathbf{Y}$ pode ser definida por meio da equação (C.1).

$$E[y] = \frac{\sum_{i=1}^{n_{MMC}} \pi_i * y_i}{\sum_{i=1}^{n_{MMC}} \pi_i} \quad (C.1)$$

Onde:

y é a variável de saída aleatória e $E[y]$ seu valor esperado;

y_i é a variável de saída determinística, dada simulação da amostra i ;

π_i é a probabilidade de ocorrência da amostra i , dada pela equação (C.2).

$$\pi_i = \int_{t_0}^{t_1} PDF(\epsilon) d\epsilon = CDF(t_1) - CDF(t_0) \quad (C.2)$$

O desvio padrão de determinada variável $y \in \mathbf{Y}$ pode ser definido pela equação (C.3).

$$\sigma = \sqrt{\sum_{i=1}^{n_{MMC}} (y_i - E[y])^2 \pi_i} \quad (C.3)$$

Considerando o caso em que a única variável aleatória de entrada é a carga da topologia, pode-se assumir que a PDF que modela adequadamente esse comportamento é a distribuição normal. As variáveis aleatórias de saída y podem ser quaisquer variáveis de saída de um FP convencional, como tensões, correntes, perdas ativas e reativas, geração ativa ou qualquer outra variável de interesse.

Conforme mencionado no capítulo 2, o MMC requer um número elevado de amostras para fornecer resultados relevantes. Para este trabalho, foi considerado n_{MMC} igual a 10.000 amostras para simular cada hora do dia, totalizando 2.400.000 simulações no total.

ANEXO D: DADOS DAS TOPOLOGIAS

Este anexo tem como intuito apresentar os dados das topologias trabalhadas no presente trabalho de maneira mais detalhada. Todos os sistemas simulados são alimentadores de teste do IEEE, de forma que todas as especificações podem ser vistas em IEEE (online, 2021). Os reguladores de tensão foram desconsiderados para enaltecer os resultados proporcionados pela alocação capacitiva. Além disso, todas as cargas foram modeladas como “Potência Constante”, denotadas por PQ nas tabelas subsequentes.

A topologia IEEE 4 *Node Test-Feeder* apresenta os dados de condutores cujas impedâncias podem ser definidas tal como na Tabela 12.

Tabela 12 - Dados dos condutores para topologia IEEE 4

Condutor	$R_{matrix} (\Omega/mi)$	$X_{matrix} (\Omega/mi)$
402	$\begin{bmatrix} 0,4576 & 0,1559 & 0,1535 \\ 0,1559 & 0,4666 & 0,1580 \\ 0,1535 & 0,1580 & 0,4615 \end{bmatrix}$	$\begin{bmatrix} 1,0780 & 0,5017 & 0,3849 \\ 0,5017 & 1,0482 & 0,4236 \\ 0,3849 & 0,4236 & 1,0651 \end{bmatrix}$

Fonte: IEEE (online, 2021).

Os dados dos alimentadores de distribuição podem ser vistos na Tabela 13.

Tabela 13 - Dados de alimentadores para topologia IEEE 4

Número de fases	Barra “de” (origem)	Barra “para” (destino)	Código do condutor	Comprimento [ft]
3F	1	2	402	2000
3F	3	4	402	2500

Fonte: IEEE (online, 2021).

O transformador presente entre as barras 2 e 3 possui as características listadas na Tabela 14. A denominação “Y-at” indica a conexão do secundário em estrela com aterramento sólido.

Tabela 14 - Dados do transformador da topologia IEEE 4

Conexão	Resistência do enrolamento [%]	Reatância do enrolamento [%]	Tensão nominal [kV]	Potência [kVA]
Delta	0,5	3	12,47	6000
Y-at	0,5	3	4,16	6000

Fonte: IEEE (online, 2021).

Por fim, os dados das cargas nominais estão listados na Tabela 15. As cargas são modeladas por potência constante e são conectadas em estrela.

Tabela 15 - Dados das cargas para topologia IEEE 4

Nó	Carga	Ph-1	Ph-1	Ph-2	Ph-2	Ph-3	Ph-3
	Modelo	kW	kVAr	kW	kVAr	kW	kVAr
4	Y-PQ	1275	791	1800	873	2375	782

Fonte: IEEE (online, 2021).

Os dados para a topologia IEEE 13 estão dispostos nas Tabelas 16 a 19. A saber: dados de condutores, dados dos alimentadores, dados do transformador e dados das cargas, respectivamente.

Tabela 16 - Dados dos condutores para topologia IEEE 13

Condutor	R_{matrix} (Ω/mi)	X_{matrix} (Ω/mi)
601	$\begin{bmatrix} 0,3465 & 0,1560 & 0,1580 \\ 0,1560 & 0,3375 & 0,1535 \\ 0,1580 & 0,1535 & 0,3414 \end{bmatrix}$	$\begin{bmatrix} 1,0179 & 0,5017 & 0,4236 \\ 0,5017 & 1,0478 & 0,3849 \\ 0,4236 & 0,3849 & 1,0348 \end{bmatrix}$
602	$\begin{bmatrix} 0,7526 & 0,1580 & 0,1560 \\ 0,1580 & 0,7475 & 0,1535 \\ 0,1560 & 0,1535 & 0,7436 \end{bmatrix}$	$\begin{bmatrix} 1,1814 & 0,4236 & 0,5017 \\ 0,4236 & 1,1983 & 0,3849 \\ 0,5017 & 0,3849 & 1,2112 \end{bmatrix}$
603	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 1,3294 & 0,2066 \\ 0,0 & 0,2066 & 1,3238 \end{bmatrix}$	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 1,3471 & 0,4591 \\ 0,0 & 0,4591 & 1,3569 \end{bmatrix}$
604	$\begin{bmatrix} 1,3238 & 0,0 & 0,2066 \\ 0,0 & 0,0 & 0,0 \\ 0,2066 & 0,0 & 1,3294 \end{bmatrix}$	$\begin{bmatrix} 1,3569 & 0,0 & 0,4591 \\ 0,0 & 0,0 & 0,0 \\ 0,4591 & 0,0 & 1,3471 \end{bmatrix}$
605	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 1,3294 \end{bmatrix}$	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 1,3471 \end{bmatrix}$

606	$\begin{bmatrix} 0,7982 & 0,3192 & 0,2849 \\ 0,3192 & 0,7891 & 0,3192 \\ 0,2849 & 0,3192 & 0,7982 \end{bmatrix}$	$\begin{bmatrix} 0,4463 & 0,0328 & -0,0143 \\ 0,0328 & 0,4041 & 0,0328 \\ -0,0143 & 0,0328 & 0,4463 \end{bmatrix}$
607	$\begin{bmatrix} 1,4925 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$	$\begin{bmatrix} 0,6231 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$

Fonte: IEEE (online, 2021).

Tabela 17 - Dados de alimentadores para topologia IEEE 13

Número de fases	Barra “de” (origem)	Barra “para” (destino)	Comprimento [pés]	Código do condutor
2F	632	645	500	603
3F	632	633	500	602
2F	645	646	300	603
3F	650	632	2000	601
1F	684	652	800	607
3F	632	671	2000	601
2F	671	684	300	604
3F	671	680	1000	601
3F	671	692	0	Chave
1F	684	611	300	605
3F	692	675	500	606

Fonte: IEEE (online, 2021).

Tabela 18 - Dados do transformador para topologia IEEE 13

Conexão	Resistência do enrolamento [%]	Reatância do enrolamento [%]	Tensão nominal [kV]	Potência [kVA]
Y-at	0,55	1	4,16	500
Y-at	0,55	1	0,48	500

Fonte: IEEE (online, 2021).

Tabela 19 - Dados das cargas para topologia IEEE 13

Nó	Carga	Ph-1	Ph-1	Ph-2	Ph-2	Ph-3	Ph-3
	Modelo	kW	kVAr	kW	kVAr	kW	kVAr

634	Y-PQ	160	110	120	90	120	90
645	Y-PQ	0	0	170	125	0	0
646	D-PQ	0	0	230	132	0	0
652	Y-PQ	128	86	0	0	0	0
671	D-PQ	385	220	385	220	385	220
675	Y-PQ	485	190	68	60	290	212
692	D-PQ	0	0	0	0	170	151
611	Y-PQ	0	0	0	0	170	80
TOTAL		1158	606	973	627	1135	753

Fonte: IEEE (online, 2021).

Os dados para a topologia IEEE 37 estão dispostos nas Tabelas 20 a 23. A saber: dados de condutores, dados dos alimentadores, dados do transformador e dados das cargas, respectivamente. Os dados de carga sofreram um aumento de 40% em relação aos seus valores originais para aumentar o desafio do problema de otimização.

Tabela 20 - Dados de condutores para topologia IEEE 37

Condutor	$R_{matrix} (\Omega/mi)$	$X_{matrix} (\Omega/mi)$
721	$\begin{bmatrix} 0,2926 & 0,0673 & 0,0337 \\ 0,0673 & 0,2646 & 0,0673 \\ 0,0337 & 0,0673 & 0,2926 \end{bmatrix}$	$\begin{bmatrix} 0,1973 & -0,0368 & -0,0417 \\ -0,0368 & 0,1900 & -0,0368 \\ -0,0417 & -0,0368 & 0,1973 \end{bmatrix}$
722	$\begin{bmatrix} 0,4751 & 0,1629 & 0,1234 \\ 0,1629 & 0,4488 & 0,1629 \\ 0,1234 & 0,1629 & 0,4751 \end{bmatrix}$	$\begin{bmatrix} 0,2973 & -0,0326 & -0,0607 \\ -0,0326 & 0,2678 & -0,0326 \\ -0,0607 & -0,0326 & 0,2973 \end{bmatrix}$
723	$\begin{bmatrix} 1,2936 & 0,4871 & 0,4585 \\ 0,4871 & 1,3022 & 0,4871 \\ 0,4585 & 0,4871 & 1,2936 \end{bmatrix}$	$\begin{bmatrix} 0,6713 & 0,2111 & 0,1521 \\ 0,2111 & 0,6326 & 0,2111 \\ 0,1521 & 0,2111 & 0,6713 \end{bmatrix}$
724	$\begin{bmatrix} 2,0952 & 0,5204 & 0,4926 \\ 0,5204 & 2,1068 & 0,5204 \\ 0,4926 & 0,5204 & 2,0952 \end{bmatrix}$	$\begin{bmatrix} 0,7758 & 0,2738 & 0,2123 \\ 0,2738 & 0,7398 & 0,2738 \\ 0,2123 & 0,2738 & 0,7758 \end{bmatrix}$

Fonte: IEEE (online, 2021).

Tabela 21 - Dados dos alimentadores para topologia IEEE 37

Número de fases	Barra “de” (origem)	Barra “para” (destino)	Comprimento [pés]	Código do condutor
3F	701	702	960	722

3F	702	705	400	724
3F	702	713	360	723
3F	702	703	1320	722
3F	703	727	240	724
3F	703	730	600	723
3F	704	714	80	724
3F	704	720	800	723
3F	705	742	320	724
3F	705	712	240	724
3F	706	725	280	724
3F	707	724	760	724
3F	707	722	120	724
3F	708	733	320	723
3F	708	732	320	724
3F	709	731	600	723
3F	709	708	320	723
3F	710	735	200	724
3F	710	736	1280	724
3F	711	741	400	723
3F	711	740	200	724
3F	713	704	520	723
3F	714	718	520	724
3F	720	707	920	724
3F	720	706	600	723
3F	727	744	280	723
3F	730	709	200	723
3F	733	734	560	723
3F	734	737	640	723
3F	734	710	520	724
3F	737	738	400	723
3F	738	711	400	723
3F	744	728	200	724
3F	744	729	280	724

3F 799 701 1850 721

Fonte: IEEE (online, 2021).

Tabela 22 - Dados do transformador para topologia IEEE 37

Conexão	Resistência do enrolamento [%]	Reatância do enrolamento [%]	Tensão nominal [kV]	Potência [kVA]
Delta	0,0045	0,905	4,8	500
Delta	0,0045	0,905	0,48	500

Fonte: IEEE (online, 2021).

Tabela 23 - Dados de cargas para topologia IEEE 37

Nó	Carga Modelo	Ph-1	Ph-1	Ph-2	Ph-2	Ph-3	Ph-3
		kW	kVAr	kW	kVAr	kW	kVAr
701	D-PQ	196	98	196	98	490	245
712	D-PQ	0	0	0	0	119	56
713	D-PQ	0	0	0	0	119	56
714	D-PQ	23,8	11,2	29,4	14	0	0
718	D-PQ	119	56	0	0	0	0
720	D-PQ	0	0	0	0	119	56
722	D-PQ	0	0	196	98	29,4	14
724	D-PQ	0	0	58,8	29,4	0	0
725	D-PQ	0	0	58,8	29,4	0	0
727	D-PQ	0	0	0	0	58,8	29,4
728	D-PQ	58,8	29,4	58,8	29,4	58,8	29,4
729	D-PQ	58,8	29,4	0	0	0	0
730	D-PQ	0	0	0	0	119	56
731	D-PQ	0	0	119	56	0	0
732	D-PQ	0	0	0	0	58,8	29,4
733	D-PQ	119	56	0	0	0	0
734	D-PQ	0	0	0	0	58,8	29,4
735	D-PQ	0	0	0	0	119	56
736	D-PQ	0	0	58,8	29,4	0	0
737	D-PQ	196	98	0	0	0	0

738	D-PQ	176,4	86,8	0	0	0	0
740	D-PQ	0	0	0	0	119	56
741	D-PQ	0	0	0	0	58,8	29,4
742	D-PQ	11,2	5,6	119	56	0	0
744	D-PQ	58,8	29,4	0	0	0	0
TOTAL		1017,8	499,8	894,6	439,6	1527,4	742

Fonte: IEEE (online, 2021 - alterado).

Os dados da topologia IEEE 123 estão dispostos nas Tabelas 24 a 27. A saber: dados de condutores, dados dos alimentadores, dados do transformador e dados das cargas, respectivamente.

Tabela 24 - Dados de condutores para topologia IEEE 123

Condutor	R_{matrix} (Ω/mi)	X_{matrix} (Ω/mi)
1	$\begin{bmatrix} 0,4576 & 0,1560 & 0,1535 \\ 0,1560 & 0,4666 & 0,1580 \\ 0,1535 & 0,1580 & 0,4615 \end{bmatrix}$	$\begin{bmatrix} 1,0780 & 0,5017 & 0,3849 \\ 0,5017 & 1,0482 & 0,4236 \\ 0,3849 & 0,4236 & 1,0651 \end{bmatrix}$
2	$\begin{bmatrix} 0,4666 & 0,1580 & 0,1560 \\ 0,1580 & 0,4615 & 0,1535 \\ 0,1560 & 0,1535 & 0,4576 \end{bmatrix}$	$\begin{bmatrix} 1,0482 & 0,4236 & 0,5017 \\ 0,4236 & 1,0651 & 0,3849 \\ 0,5017 & 0,3849 & 1,0780 \end{bmatrix}$
3	$\begin{bmatrix} 0,4615 & 0,1535 & 0,1580 \\ 0,1535 & 0,4576 & 0,1560 \\ 0,1580 & 0,1560 & 0,4666 \end{bmatrix}$	$\begin{bmatrix} 1,0651 & 0,3849 & 0,4236 \\ 0,3849 & 1,0780 & 0,5017 \\ 0,4236 & 0,5017 & 1,0482 \end{bmatrix}$
4	$\begin{bmatrix} 0,4615 & 0,1580 & 0,1535 \\ 0,1580 & 0,4666 & 0,1560 \\ 0,1535 & 0,1560 & 0,4576 \end{bmatrix}$	$\begin{bmatrix} 1,0651 & 0,4236 & 0,3849 \\ 0,4236 & 1,0482 & 0,5017 \\ 0,3849 & 0,5017 & 1,0780 \end{bmatrix}$
5	$\begin{bmatrix} 0,4666 & 0,1560 & 0,1580 \\ 0,1560 & 0,4576 & 0,1535 \\ 0,1580 & 0,1535 & 0,4615 \end{bmatrix}$	$\begin{bmatrix} 1,0482 & 0,5017 & 0,4236 \\ 0,5017 & 1,0780 & 0,3849 \\ 0,4236 & 0,3849 & 1,0651 \end{bmatrix}$
6	$\begin{bmatrix} 0,4576 & 0,1535 & 0,1560 \\ 0,1535 & 0,4615 & 0,1580 \\ 0,1560 & 0,1580 & 0,4666 \end{bmatrix}$	$\begin{bmatrix} 1,0780 & 0,3849 & 0,5017 \\ 0,3849 & 1,0651 & 0,4236 \\ 0,5017 & 0,4236 & 1,0482 \end{bmatrix}$
7	$\begin{bmatrix} 0,4576 & 0,0 & 0,1535 \\ 0,0 & 0,0 & 0,0 \\ 0,1535 & 0,0 & 0,4615 \end{bmatrix}$	$\begin{bmatrix} 1,0780 & 0,0 & 0,3849 \\ 0,0 & 0,0 & 0,0 \\ 0,3849 & 0,0 & 1,0651 \end{bmatrix}$
8	$\begin{bmatrix} 0,4576 & 0,1535 & 0,0 \\ 0,1535 & 0,4615 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$	$\begin{bmatrix} 1,0780 & 0,3849 & 0,0 \\ 0,3849 & 1,0651 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$
9	$\begin{bmatrix} 1,3292 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$	$\begin{bmatrix} 1,3475 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$

10	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 1,3292 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 1,3475 & 0,0 \\ 0,0 & 0,0 & 0,0 \end{bmatrix}$
11	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 1,3292 \end{bmatrix}$	$\begin{bmatrix} 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 0,0 \\ 0,0 & 0,0 & 1,3475 \end{bmatrix}$
12	$\begin{bmatrix} 1,5209 & 0,5198 & 0,4924 \\ 0,5198 & 1,5329 & 0,5198 \\ 0,4924 & 0,5198 & 1,5209 \end{bmatrix}$	$\begin{bmatrix} 0,7521 & 0,2775 & 0,2157 \\ 0,2775 & 0,7162 & 0,2775 \\ 0,2157 & 0,2775 & 0,7521 \end{bmatrix}$

Fonte: IEEE (online, 2021)

Tabela 25 - Dados dos alimentadores para topologia IEEE 123

Número de fases	Barra “de” (origem)	Barra “para” (destino)	Comprimento [pés]	Código do condutor
1F	1	2	175	10
1F	1	3	250	11
3F	1	7	300	1
1F	3	4	200	11
1F	3	5	325	11
1F	5	6	250	11
3F	7	8	200	1
1F	8	12	225	10
1F	8	9	225	9
3F	8	13	300	1
1F	9	14	425	9
1F	13	34	150	11
3F	13	18	825	2
1F	14	11	250	9
1F	14	10	250	9
1F	15	16	375	11
1F	15	17	350	11
1F	18	19	250	9
3F	18	21	300	2
1F	19	20	325	9
1F	21	22	525	10

3F	21	23	250	2
1F	23	24	550	11
3F	23	25	275	2
2F	25	26	350	7
3F	25	28	200	2
2F	26	27	275	7
1F	26	31	225	11
1F	27	33	500	9
3F	28	29	300	2
3F	29	30	350	2
3F	30	250	200	2
1F	31	32	300	11
1F	34	15	100	11
2F	35	36	650	8
3F	35	40	250	1
1F	36	37	300	9
1F	36	38	250	10
1F	38	39	325	10
1F	40	41	325	11
3F	40	42	250	1
1F	42	43	500	10
3F	42	44	200	1
1F	44	45	200	9
3F	44	47	250	1
1F	45	46	300	9
3F	47	48	150	4
3F	47	49	250	4
3F	49	50	250	4
3F	50	51	250	4
3F	51	151	500	4
3F	52	53	200	1
3F	53	54	125	1
3F	54	55	275	1

3F	54	57	350	3
3F	55	56	275	1
1F	57	58	250	10
3F	57	60	750	3
1F	58	59	250	10
3F	60	61	550	5
3F	60	62	250	12
3F	62	63	175	12
3F	63	64	350	12
3F	64	65	425	12
3F	65	66	325	12
1F	67	68	200	9
3F	67	72	275	3
3F	67	97	250	3
1F	68	69	275	9
1F	69	70	325	9
1F	70	71	275	9
1F	72	73	275	11
3F	72	76	200	3
1F	73	74	350	11
1F	74	75	400	11
3F	76	77	400	6
3F	76	86	700	3
3F	77	78	100	6
3F	78	79	225	6
3F	78	80	475	6
3F	80	81	475	6
3F	81	82	250	6
1F	81	84	675	11
3F	82	83	250	6
1F	84	85	475	11
3F	86	87	450	6
1F	87	88	175	9

3F	87	89	275	6
1F	89	90	225	10
3F	89	91	225	6
1F	91	92	300	11
3F	91	93	225	6
1F	93	94	275	9
3F	93	95	300	6
1F	95	96	200	10
3F	97	98	275	3
3F	98	99	550	3
3F	99	100	300	3
3F	100	450	800	3
1F	101	102	225	11
3F	101	105	275	3
1F	102	103	325	11
1F	103	104	700	11
1F	105	106	225	10
3F	105	108	325	3
1F	106	107	575	10
1F	108	109	450	9
3F	108	300	1000	3
1F	109	110	300	9
1F	110	111	575	9
1F	110	112	125	9
1F	112	113	525	9
1F	113	114	325	9
3F	135	35	375	4
3F	149	1	400	1
3F	152	52	400	1
3F	160	67	350	6
3F	197	101	250	3

Fonte: IEEE (online, 2021)

Tabela 26 - Dados do transformador para topologia IEEE 123

Conexão	Resistência do enrolamento [%]	Reatância do enrolamento [%]	Tensão nominal [kV]	Potência [kVA]
Delta	0,635	1,36	4,16	150
Delta	0,635	1,36	0,48	150

Fonte: IEEE (online, 2021).

Tabela 27 - Dados de cargas para topologia IEEE 123

Nó	Carga	Ph-1		Ph-2		Ph-3	
		kW	kVAr	kW	kVAr	kW	kVAr
1	Y-PQ	40	20	0	0	0	0
2	Y-PQ	0	0	20	10	0	0
4	Y-PQ	0	0	0	0	40	20
5	Y-PQ	0	0	0	0	20	10
6	Y-PQ	0	0	0	0	40	20
7	Y-PQ	20	10	0	0	0	0
9	Y-PQ	40	20	0	0	0	0
10	Y-PQ	20	10	0	0	0	0
11	Y-PQ	40	20	0	0	0	0
12	Y-PQ	0	0	20	10	0	0
16	Y-PQ	0	0	0	0	40	20
17	Y-PQ	0	0	0	0	20	10
19	Y-PQ	40	20	0	0	0	0
20	Y-PQ	40	20	0	0	0	0
22	Y-PQ	0	0	40	20	0	0
24	Y-PQ	0	0	0	0	40	20
28	Y-PQ	40	20	0	0	0	0
29	Y-PQ	40	20	0	0	0	0
30	Y-PQ	0	0	0	0	40	20
31	Y-PQ	0	0	0	0	20	10
32	Y-PQ	0	0	0	0	20	10
33	Y-PQ	40	20	0	0	0	0
34	Y-PQ	0	0	0	0	40	20

35	D-PQ	40	20	0	0	0	0
37	Y-PQ	40	20	0	0	0	0
38	Y-PQ	0	0	20	10	0	0
39	Y-PQ	0	0	20	10	0	0
41	Y-PQ	0	0	0	0	20	10
42	Y-PQ	20	10	0	0	0	0
43	Y-PQ	0	0	40	20	0	0
45	Y-PQ	20	10	0	0	0	0
46	Y-PQ	20	10	0	0	0	0
47	Y-PQ	35	25	35	25	35	25
48	Y-PQ	70	50	70	50	70	50
49	Y-PQ	35	25	70	50	35	20
50	Y-PQ	0	0	0	0	40	20
51	Y-PQ	20	10	0	0	0	0
52	Y-PQ	40	20	0	0	0	0
53	Y-PQ	40	20	0	0	0	0
55	Y-PQ	20	10	0	0	0	0
56	Y-PQ	0	0	20	10	0	0
58	Y-PQ	0	0	20	10	0	0
59	Y-PQ	0	0	20	10	0	0
60	Y-PQ	20	10	0	0	0	0
62	Y-PQ	0	0	0	0	40	20
63	Y-PQ	40	20	0	0	0	0
64	Y-PQ	0	0	75	35	0	0
65	D-PQ	35	25	35	25	70	50
66	Y-PQ	0	0	0	0	75	35
68	Y-PQ	20	10	0	0	0	0
69	Y-PQ	40	20	0	0	0	0
70	Y-PQ	20	10	0	0	0	0
71	Y-PQ	40	20	0	0	0	0
73	Y-PQ	0	0	0	0	40	20
74	Y-PQ	0	0	0	0	40	20
75	Y-PQ	0	0	0	0	40	20

76	D-PQ	105	80	70	50	70	50
77	Y-PQ	0	0	40	20	0	0
79	Y-PQ	40	20	0	0	0	0
80	Y-PQ	0	0	40	20	0	0
82	Y-PQ	40	20	0	0	0	0
83	Y-PQ	0	0	0	0	20	10
84	Y-PQ	0	0	0	0	20	10
85	Y-PQ	0	0	0	0	40	20
86	Y-PQ	0	0	20	10	0	0
87	Y-PQ	0	0	40	20	0	0
88	Y-PQ	40	20	0	0	0	0
90	Y-PQ	0	0	40	20	0	0
92	Y-PQ	0	0	0	0	40	20
94	Y-PQ	40	20	0	0	0	0
95	Y-PQ	0	0	20	10	0	0
96	Y-PQ	0	0	20	10	0	0
98	Y-PQ	40	20	0	0	0	0
99	Y-PQ	0	0	40	20	0	0
100	Y-PQ	0	0	0	0	40	20
102	Y-PQ	0	0	0	0	20	10
103	Y-PQ	0	0	0	0	40	20
104	Y-PQ	0	0	0	0	40	20
106	Y-PQ	0	0	40	20	0	0
107	Y-PQ	0	0	40	20	0	0
109	Y-PQ	40	20	0	0	0	0
111	Y-PQ	20	10	0	0	0	0
112	Y-PQ	20	10	0	0	0	0
113	Y-PQ	40	20	0	0	0	0
114	Y-PQ	20	10	0	0	0	0
TOTAL		1420	775	915	515	1155	630

Fonte: IEEE (online, 2021).

ANEXO E: REPETIBILIDADE DO FPTPO

O FPTPO proposto é composto por diferentes etapas, chamadas “Módulos”. Optou-se por fracionar a solução do problema visando ganhos computacionais. No entanto, perde-se a garantia de otimalidade. Além disso, algumas etapas envolvem técnicas evolutivas que não garantem que seus resultados sejam os pontos ótimos globais. É o caso do AG, empregado nos Módulos C e D, tal como visto nas seções 3.3.3 e 3.3.4.

Dessa forma, simular o problema muitas vezes torna-se necessário para averiguar soluções típicas e testar a sua repetibilidade, isto é, verificar com qual frequência o problema converge e constatar a qualidade das soluções apresentadas. Ademais, através da execução repetitiva do problema, pode-se refinar os resultados obtidos.

A partir dessas considerações, o FPTPO foi simulado 11 vezes para cada topologia. Com os dados obtidos, é possível realizar comparações de cunho estatístico. Para cada sistema-teste, foram verificados: melhor resposta, média das respostas, mediana das respostas, desvio padrão das respostas (referentes ao valor esperado de perdas totais), percentual das respostas que apresentam configurações livres de sobretensões ou subtensões e a média do tempo computacional demandado.

Tais itens de análise estão expostos na Tabela 28.

Tabela 28 - Repetibilidade do FPTPO

Topologia	Melhor Resposta [MW]	Média das Respostas [MW]	Mediana das Respostas [MW]	Desvio padrão das Respostas [MW]	Percentual das Respostas Livres de Distúrbios	Tempo Computacional Médio [s]
IEEE 13	1,3033	1,3236	1,3220	0,0115	100%	8217
IEEE 37	1,3622	1,4277	1,4171	0,0435	100%	16218
IEEE 123	1,1507	1,2039	1,1859	0,0756	82%	15582

Fonte: elaborado pelo autor (2022).

Com a posse dos dados revelados na Tabela 28, infere-se que o FPTPO é perfeitamente reproduzível. O baixo desvio padrão das respostas indicam que o AG fornece resultados próximos, chamados de “típicos”. Além disso, há altos percentuais de convergência para

respostas que respeitam as restrições impostas, o que sugere o correto ajuste das configurações internas do AG. Já em relação ao tempo computacional, ressalta-se que depende não só da complexidade do sistema, mas também de outros parâmetros como: necessidade de capacitores chaveados (o que definirá a necessidade do Módulo D que, por sua vez, demanda grande esforço computacional); número de capacitores fixos e chaveados efetivamente alocados (o que definirá o tamanho do cromossomo implementado) e de fatores aleatórios inerentes a algoritmos evolucionários.