

UNIVERSIDADE FEDERAL DO PARANÁ

NELSON GERALDO DE ALMEIDA

METODOLOGIA PARA APOIO AO PLANEJAMENTO E OPERAÇÃO DE REDES
DE DISTRIBUIÇÃO ATIVAS RECONFIGURÁVEIS

CURITIBA

2020

NELSON GERALDO DE ALMEIDA

METODOLOGIA PARA APOIO AO PLANEJAMENTO E OPERAÇÃO DE REDES
DE DISTRIBUIÇÃO ATIVAS RECONFIGURÁVEIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas de Energia, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Odilon Luis Tortelli

CURITIBA

2020

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

A447m Almeida, Nelson Geraldo de
Metodologia para apoio ao planejamento e operação de redes de distribuição ativas reconfiguráveis [recurso eletrônico] / Nelson Geraldo de Almeida. – Curitiba, 2020.

Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, 2020.

Orientador: Odilon Luis Tortelli.

1. Algoritmos. 2. Algoritmos genéticos. 3. Geração distribuída de energia elétrica. I. Universidade Federal do Paraná. II. Tortelli, Odilon Luis. III. Título.

CDD: 621.3191

Bibliotecária: Vanusa Maciel CRB- 9/1928



TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA ELÉTRICA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **NELSON GERALDO DE ALMEIDA** intitulada: **Metodologia para apoio ao planejamento e operação de redes de distribuição ativas reconfiguráveis**, sob orientação do Prof. Dr. ODILON LUIS TORTELLI, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 30 de Julho de 2020.

Assinatura Eletrônica
31/07/2020 10:08:40.0
ODILON LUIS TORTELLI
Presidente da Banca Examinadora

Assinatura Eletrônica
02/08/2020 15:38:06.0
NASTASHA SALAME DA SILVA
Avaliador Externo (UNIVERSIDADE TECNOLÓGICA FEDERAL DO
PARANÁ)

Assinatura Eletrônica
30/07/2020 20:46:03.0
ROMAN KUIAVA
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
31/07/2020 10:54:55.0
THELMA SOLANGE PIAZZA FERNANDES
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

AGRADECIMENTOS

Ao meu orientador Professor Doutor Odilon Luis Tortelli, por todos os conhecimentos compartilhados, por toda a gentileza que sempre teve em nossas reuniões e por ter me aceitado nesse desafio. Muito obrigado!

A minha namorada Gisele pelo apoio, carinho e paciência não só em todo esse projeto mas desde que nos conhecemos. Quando estou com você não há nenhum outro lugar onde eu gostaria de estar.

Aos meus pais por todos os esforços e sacrifícios que efetuaram para a minha formação pessoal e acadêmica e por sempre terem me incentivado a seguir o caminho dos estudos. Em todos os meus passos eu vejo a presença de vocês.

“A vida é um soco no estômago.”

Clarice Lispector

RESUMO

Este trabalho tem como objetivo o desenvolvimento de uma ferramenta de otimização para a reconfiguração de redes de distribuição além de otimizar também a alocação de chaves nesse tipo de sistema. A reconfiguração de redes de distribuição tem se mostrado eficiente na busca de uma melhor condição operacional do sistema, porém sem uma alocação de chaves adequada sua eficiência fica limitada. Assim, a ferramenta proposta visa tratar essas duas partes de forma conjunta. Além disso, diferentemente de trabalhos anteriores, a ferramenta busca conciliar o uso do fluxo de potência não iterativo, utilizado para verificar o desempenho de cada nova configuração, com os algoritmos evolutivos, utilizados para a busca da melhor solução entre todas as possíveis. O fato de ser necessário calcular o fluxo de potência para cada configuração candidata a solução do sistema faz com que a utilização da abordagem não iterativa traga inúmeros benefícios. Para que seja possível a utilização desse método de cálculo de fluxo de potência, utiliza-se a normalização complexa diferentemente da normalização convencional, modificando assim, artificialmente, a relação R/X do sistema. Apesar da utilização de um método não iterativo, a natureza exponencial das possíveis soluções faz com que uma ferramenta de otimização seja necessária para buscar a melhor solução sem ter que testar todas as combinações possíveis. Com isso, são utilizados os algoritmos genéticos e diferencial evolutivo para auxiliar no processo de otimização. Os resultados das simulações evidenciam a eficiência e robustez da metodologia proposta sendo possível a sua utilização em diversos tipos de arranjos e cenários diferentes. Isso a torna ideal para uso no apoio ao planejamento de redes de distribuição, verificando dentre os diferentes locais possíveis para a alocação das chaves, os que apresentam o melhor desempenho. Além disso, a metodologia apresentada também consegue, partindo de um sistema com as chaves já alocadas, otimizar sua configuração. Nessa otimização, busca-se encontrar a solução que apresente o melhor desempenho de acordo com o parâmetro desejado, podendo auxiliar assim na operação do sistema.

Palavras-chave: Sistemas de distribuição. Reconfiguração ótima. Alocação ótima de chaves. Fluxo de potência não iterativo. Algoritmos genéticos. Algoritmo diferencial evolutivo.

ABSTRACT

This work presents an optimization tool for distribution networks reconfiguration, as well as optimizing the switches placement in this kind of system. The distribution networks reconfiguration has been shown efficient in the search for a better system operational condition, however, without an adequate switch placement, its efficiency is limited. Therefore, the proposed tool aims to treat these two parts together. Furthermore, unlike previous work, this tool makes the combined use of a non-iterative method of power flow analysis, used to verify the performance of each new configuration, with the evolutionary algorithms, used to search for the best solution among all possible ones. The fact that it is necessary to calculate the power flow for each candidate configuration for the system solution means that the use of the non-iterative approach brings numerous benefits. In order to make it possible to use this method of power flow analysis, complex normalization is used instead of a conventional normalization, modifying artificially the R/X ratio of the system. Despite this, the exponential nature of the possible solutions makes an optimization tool necessary to search for the best solution without having to test all possible combinations. Simulation results show the efficiency and robustness of the proposed methodology, making it possible to use it in different types of arrangements and different scenarios. This makes it ideal for use in planning distribution networks, checking among the different possible locations for switches placement, which one has the best performance. In addition, the presented approach can also manages, starting from a system with the switches already allocated, to optimize its configuration. In this optimization, it aims to find the solution that presents the best performance according to a desired parameter, being able to assist in the operation of the system.

Key words: Distribution Systems. Optimal Reconfiguration. Optimal Switch Allocation. Non-iterative Power Flow Analysis. Genetic Algorithms. Differential Evolution Algorithm.

LISTA DE ILUSTRAÇÕES

FIGURA 1 - REPRESENTAÇÃO SIMPLIFICADA DE UMA LINHA DE DISTRIBUIÇÃO NORMALIZADA	30
FIGURA 2 – RELAÇÃO ENTRE O ÂNGULO θ_{base} E AS IMPEDÂNCIAS DAS LINHAS EM Ω E cpu	31
FIGURA 3 - REPRESENTAÇÃO SIMPLIFICADA DE UM SISTEMA DE DISTRIBUIÇÃO COM DUAS BARRAS.....	32
FIGURA 4 - FLUXOGRAMA DO ALGORITMO GENÉTICO APRESENTADO	41
FIGURA 5 - FLUXOGRAMA DO ALGORITMO DIFERENCIAL EVOLUTIVO APRESENTADO	45
FIGURA 6 - FLUXOGRAMA DA FERRAMENTA DE RECONFIGURAÇÃO ÓTIMA.	47
FIGURA 7 - CODIFICAÇÃO DOS INDIVÍDUOS - SISTEMA EXEMPLO	48
FIGURA 8 - FLUXOGRAMA DA FERRAMENTA DE ALOCAÇÃO ÓTIMA	52
FIGURA 9 - SISTEMA PARA EXEMPLO DA CODIFICAÇÃO DOS INDIVÍDUOS NA ALOCAÇÃO	53
FIGURA 10 - DIAGRAMA UNIFILAR PARA O SISTEMA TESTE DE 33 BARRAS ..	56
FIGURA 11 - COMPARATIVO ENTRE OS PERFIS DE TENSÃO DOS MÉTODOS NÃO ITERATIVO E NEWTON-RAPHSON – 33 BARRAS	57
FIGURA 12 - PERFIL DOS ERROS DE TENSÃO COM A UTILIZAÇÃO DO MÉTODO NÃO ITERATIVO – 33 BARRAS	58
FIGURA 13 - DIAGRAMA UNIFILAR ADAPTADO PARA O SISTEMA TESTE DE 33 BARRAS.....	59
FIGURA 14 - COMPARATIVO DOS PERFIS DE TENSÃO APRESENTADOS PARA CADA TOPOLOGIA DO SISTEMA DE 33 BARRAS.....	60
FIGURA 15 - QUANTIDADE DE BARRAS VIOLANDO O LIMITE DE TENSÃO – 33 BARRAS.....	60
FIGURA 16 - MÁXIMO VALOR DE DESVIO DE TENSÃO PARA CADA TOPOLOGIA – 33 BARRAS.....	61
FIGURA 17 - COMPARAÇÃO ENTRE OS PERFIS DE PERDAS E ΔV MÁXIMO NOS DIFERENTES CASOS – 33 BARRAS	62
FIGURA 18 – NOVA POSIÇÃO DE RAMOS CHAVEÁVEIS NO SISTEMA TESTE DE 33 BARRAS.....	64

FIGURA 19 - MÁXIMO VALOR DE DESVIO DE TENSÃO PARA CADA TOPOLOGIA NA NOVA ALOCAÇÃO DAS CHAVES DO SISTEMA DE 33 BARRAS.....	65
FIGURA 20 - COMPARAÇÃO ENTRE OS PERFIS DE PERDAS E ΔV MÁXIMO NOS DIFERENTES CASOS COM A NOVA ALOCAÇÃO DE CHAVES – 33 BARRAS	66
FIGURA 21 – RAMOS CHAVEÁVEIS CONSIDERADOS PARA ALOCAÇÃO DE CHAVES NO SISTEMA TESTE DE 33 BARRAS	67
FIGURA 22 – SISTEMA TESTE IEEE EUROPEU 906 BARRAS	70
FIGURA 23- COMPARATIVO ENTRE OS PERFIS DE TENSÃO DOS MÉTODOS NÃO ITERATIVO E NEWTON-RAPHSON – 906 BARRAS	71
FIGURA 24 - PERFIL DOS ERROS DE TENSÃO COM A UTILIZAÇÃO DO MÉTODO NÃO ITERATIVO – 906 BARRAS	72
FIGURA 25 - COMPARATIVO DOS PERFIS DE TENSÃO APRESENTADOS PARA CADA CASO DO SISTEMA DE 906 BARRAS.....	74
FIGURA 26 - MÁXIMO VALOR DE DESVIO DE TENSÃO PARA CADA CASO DO SISTEMA DE 906 BARRAS	74
FIGURA 27 - COMPARAÇÃO ENTRE OS PERFIS DE PERDAS E ΔV MÁXIMO NOS DIFERENTES CASOS - 906 BARRAS	75
FIGURA 28 – BARRAS DO SISTEMA TESTE DE 906 BARRAS COM APENAS UMA CONEXÃO	79
FIGURA 29 - EVOLUÇÃO DO <i>FITNESS</i> COM O AUMENTO DO N° DE CHAVES ALOCADAS.....	81

LISTA DE TABELAS

TABELA 1 - ESTADO DOS ELEMENTOS CHAVEÁVEIS NAS DIFERENTES CONFIGURAÇÕES.....	59
TABELA 2 - RESULTADO PARA RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 33 BARRAS COM O ALGORITMO GENÉTICO	63
TABELA 3 - RESULTADO PARA RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 33 BARRAS COM O ALGORITMO DIFERENCIAL EVOLUTIVO	64
TABELA 4 – RECONFIGURAÇÃO ÓTIMA APLICADA A NOVA CONFIGURAÇÃO DO SISTEMA TESTE DE 33 BARRAS.	66
TABELA 5 - RELAÇÃO DE RAMOS CHAVEÁVEIS COM SUAS RESPECTIVAS BARRAS.....	68
TABELA 6 - RESULTADO DA ALOCAÇÃO ÓTIMA PARA O SISTEMA DE 33 BARRAS CONSIDERANDO OS DIFERENTES CENÁRIOS COM O ALGORITMO GENÉTICO.....	69
TABELA 7 - RAMOS CHAVEÁVEIS INSERIDOS NO SISTEMA TESTE DE 906 BARRAS.....	72
TABELA 8 - ESTADO DOS ELEMENTOS CHAVEÁVEIS NOS 4 CASOS DIFERENTES.....	73
TABELA 9 - RESULTADO PARA A RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 906 BARRAS COM O ALGORITMO GENÉTICO	76
TABELA 10 - RESULTADO PARA A RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 906 BARRAS COM O ALGORITMO DIFERENCIAL EVOLUTIVO	76
TABELA 11 – RECONFIGURAÇÃO ÓTIMA - 906 BARRAS - 7 CHAVES	77
TABELA 12 - RECONFIGURAÇÃO ÓTIMA - 906 BARRAS - 8 CHAVES	77
TABELA 13 - RELAÇÃO DE RAMOS CHAVEÁVEIS PARA O SISTEMA DE 906 BARRAS.....	78
TABELA 14 – ALOCAÇÃO ÓTIMA APLICADA AO SISTEMA TESTE DE 906 BARRAS.....	80
TABELA 15 – EVOLUÇÃO DO <i>FITNESS</i> COM O AUMENTO DO NÚMERO DE CHAVES ALOCADAS – DIFERENCIAL EVOLUTIVO.....	80
TABELA 16 – EVOLUÇÃO DO <i>FITNESS</i> COM O AUMENTO DO NÚMERO DE CHAVES ALOCADAS – ALGORITMO GENÉTICO.....	81

TABELA 17 - RESULTADO PARA OTIMIZAÇÃO DO SISTEMA DE 33 BARRAS COM O ALGORITMO GENÉTICO COM EXECUÇÃO DE 100 VEZES	90
TABELA 18 - RESULTADO PARA OTIMIZAÇÃO DO SISTEMA DE 33 BARRAS COM O ALGORITMO DIFERENCIAL EVOLUTIVO COM EXECUÇÃO DE 100 VEZES ...	92

LISTA DE SIGLAS

RD	–	Redes de distribuição
FPDC	–	Fluxo de Potência DC ou Linearizado
Cpu	–	Normalização complexa por unidade
AG	–	Algoritmo genético
DE	–	Algoritmo diferencial evolutivo
GD	–	Geração distribuída

SUMÁRIO

1	INTRODUÇÃO	15
1.1	CONTEXTO DA PROPOSTA	15
1.2	OBJETIVOS	17
1.2.1	Objetivo geral	17
1.2.2	Objetivos específicos	17
1.3	ESTRUTURA DA DISSERTAÇÃO	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	RECONFIGURAÇÃO DE REDES DE DISTRIBUIÇÃO	19
2.2	ALOCAÇÃO DE CHAVES EM REDES DE DISTRIBUIÇÃO	21
2.3	FORMULAÇÃO BÁSICA DO FLUXO DE POTÊNCIA	22
2.4	FLUXO DE POTÊNCIA LINEARIZADO	25
2.5	FLUXO DE POTÊNCIA NÃO ITERATIVO	28
2.6	CONSIDERAÇÕES FINAIS DO CAPÍTULO	34
3	ALGORITMOS EVOLUTIVOS	35
3.1	ALGORITMOS GENÉTICOS	35
3.1.1	Codificação de indivíduos	37
3.1.2	População inicial	37
3.1.3	Função objetivo	37
3.1.4	Operadores genéticos	37
3.1.4.1	Crossover	38
3.1.4.2	Mutação	39
3.1.4.3	Seleção	39
3.2	ALGORITMO DIFERENCIAL EVOLUTIVO	41
3.2.1	Operadores genéticos	42
3.2.1.1	Mutação	42
3.2.1.2	Crossover	43
3.2.1.3	Seleção	44
3.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	45
4	METODOLOGIA	46
4.1	RECONFIGURAÇÃO ÓTIMA DE SISTEMAS DE DISTRIBUIÇÃO	46
4.1.1	Codificação dos indivíduos para utilização dos algoritmos evolutivos	48
4.1.2	Função objetivo da reconfiguração	49

4.1.3	Considerações quanto aos operadores genéticos para a reconfiguração....	50
4.2	ALOCAÇÃO ÓTIMA DE CHAVES EM SISTEMAS DE DISTRIBUIÇÃO.....	51
4.2.1	Codificação dos indivíduos para a alocação de chaves	52
4.2.2	Função objetivo da alocação.....	54
4.2.3	Operadores genéticos na alocação de chaves	54
4.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	55
5	ANÁLISE DOS RESULTADOS E DISCUSSÃO	56
5.1	VALIDAÇÃO DA FERRAMENTA EM UM SISTEMA DE MENOR PORTE ..	56
5.1.1	Reconfiguração ótima	58
5.1.2	Alocação ótima de chaves	67
5.2	SISTEMA TESTE DE 906 BARRAS	70
5.2.1	Reconfiguração ótima	72
5.2.2	Alocação ótima de chaves	77
5.3	CONSIDERAÇÕES FINAIS DO CAPÍTULO	82
6	CONSIDERAÇÕES FINAIS	83
6.1	CONCLUSÕES DO TRABALHO	83
6.2	TRABALHOS FUTUROS	83
	REFERÊNCIAS.....	85
	APÊNDICES	90
	APÊNDICE 1 – DEMONSTRAÇÃO DA CONVERGÊNCIA DAS FERRAMENTAS	
	PROPOSTAS.....	90

1 INTRODUÇÃO

1.1 CONTEXTO DA PROPOSTA

A presença cada vez maior de geração distribuída e a necessidade de uma maior confiabilidade e eficiência na operação do sistema elétrico de potência faz com que as redes de distribuição (RD) necessitem de aprimoramentos constantes para atender os cenários atuais e futuros do setor elétrico. A configuração radial amplamente utilizada nessa parte do sistema, mostra-se não suficientemente adequada para sustentar e mesmo ampliar, os níveis de confiabilidade do fornecimento de energia elétrica. Além disso, essa configuração não é a mais apropriada para aproveitar de forma mais eficiente e segura a crescente presença da geração distribuída, que faz com que o fluxo de potência não seja mais unicamente unidirecional. Nesse sentido, os sistemas de distribuição tendem a assumir novas configurações topológicas e operativas, desde a adoção de arranjos em anel ou malha, até a interconexão de *microgrids*, passando a ter cada vez mais semelhança com topologias de rede comumente observadas em sistemas de transmissão (DURCE et al., 2015).

Nesse cenário, a reconfiguração de RDs, tanto no sentido da recomposição do sistema após uma falha, como na alteração da configuração da rede para auxiliar na melhoria de aspectos operativos do sistema, e assim ampliando sua eficiência, passa a ter importância fundamental na operação de sistemas de distribuição modernos.

O processo de reconfiguração de redes elétricas pode envolver diferentes critérios de decisão e a avaliação de um número elevado de soluções possíveis e que aumenta exponencialmente com o aumento da quantidade de elementos de manobra. Com isso, os métodos heurísticos vêm sendo sugeridos como alternativas efetivas para resolver este tipo de problema (LI, 2010), (KASHEM et al., 2000), (SYAHPUTRA et al., 2014), (LARIMI et al., 2016), (BOTEJA et al., 2012), (ZIDAN; EL-SAADANY, 2012) e (TSAI, 2008).

Nesses estudos abordando reconfiguração de redes elétricas, podem-se verificar duas questões principais: (i) a que envolve a escolha de locais para alocação de chaves na rede elétrica, que se caracteriza como um estudo de planejamento de expansão de redes e (ii) a que se relaciona à procura pela melhor configuração

topológica possível após as chaves já estarem alocadas, o que se constitui num problema relativa à operação de redes (KARAAOM et al., 2020). Cabe ressaltar que no processo de alocação de chaves, na etapa de planejamento do sistema, onde busca-se verificar quais locais seriam mais interessantes para receberem as chaves, deve-se levar em conta as possíveis variações de cenário operativo.

Outro elemento crucial para determinar o bom desempenho do processo de reconfiguração é a eficiência na avaliação do estado de operação da rede elétrica, que deve ser realizada a cada nova situação topológica. Tal avaliação é usualmente feita através do cálculo do fluxo de potência. Assim, uma abordagem de cálculo de fluxo de potência eficiente trará enormes benefícios no desempenho e efetividade do processo de reconfiguração.

Com respeito à análise de fluxo de potência em redes de distribuição, muitas novas abordagens foram propostas. Melhorias nos métodos clássicos como o Newton-Raphson (LOURENÇO et al., 2010a), (YANG et al., 2008) e (LEÓN; SEMLYEN, 2002), fluxo de carga desacoplado rápido (TORTELLI et al., 2015) e (LOURENÇO et al., 2009) e algoritmos de varredura (MASHHOUR; MOGHADDAS-TAFRESHI, 2009) são apresentados, além da proposta de análise unificada dos sistemas de transmissão e distribuição superando problemas de convergência (PORTELINHA et al., 2019), (LI et al., 2015), (SUN et al., 2015) e (LOURENÇO et al., 2010b). Ainda nesse cenário de métodos de análise em regime permanente para sistemas elétricos de distribuição, uma inovadora abordagem para avaliação rápida e efetiva do estado de operação da rede elétrica, inspirada no tradicional método de fluxo de potência linearizado, é proposta em (AMBRÓSIO; TORTELLI, 2017) baseada na técnica de normalização complexa (LOURENÇO et al., 2010b). Apesar de ter sua inspiração no método linearizado, essa nova abordagem se caracteriza como um sistema quadrático, sendo resolvido de maneira não iterativa.

Neste contexto, este trabalho propõe uma metodologia para apoio a estudos de operação e planejamento de redes de distribuição reconfiguráveis a partir do emprego do método de cálculo de fluxo de potência não iterativo desenvolvido em (AMBRÓSIO; TORTELLI, 2017) aliado à representação de dispositivos de chaveamento, normalmente não considerada nas abordagens convencionais, buscando agilizar a avaliação dos diversos arranjos topológicos decorrentes do processo de reconfiguração, incluindo arranjos radiais e malhados, bem como diferentes níveis de participação de geração distribuída.

Além disso, a ferramenta computacional que orientará a busca pela definição da melhor condição topológica da rede de distribuição, sem que se tenha necessidade de testar todas as possibilidades que a reconfiguração pode apresentar, é desenvolvida a partir de uma rotina de otimização baseada em algoritmos evolutivos.

1.2 OBJETIVOS

Os objetivos deste trabalho estão divididos em geral e específicos. O objetivo geral apresenta o tema principal do trabalho, enquanto os objetivos específicos apresentam os principais caminhos a serem seguidos para a garantia de que os resultados esperados possam ser alcançados.

1.2.1 Objetivo geral

Desenvolver uma ferramenta computacional para apoio ao planejamento e operação de redes de distribuição ativas reconfiguráveis.

1.2.2 Objetivos específicos

- Incorporar elementos chaveáveis ao modelo computacional de sistemas de potência;
- Adequar os parâmetros de sistemas de distribuição através da aplicação da técnica de normalização complexa para viabilizar a utilização do fluxo de potência não iterativo nesses sistemas;
- Incorporar o método de cálculo de fluxo de potência não iterativo ao processo de reconfiguração de redes de distribuição para aumentar a eficiência do processo;
- Estudar os algoritmos evolutivos e sua relação com processos de otimização;
- Implementar uma metodologia de otimização ao processo de reconfiguração de redes ativas de distribuição de energia elétrica, procurando assim a melhor configuração topológica possível após as chaves já estarem alocadas;
- Implementar uma metodologia de otimização ao processo de alocação de chaves em sistemas de distribuição de energia, escolhendo os locais que trarão

os maiores benefícios para alocação das chaves na rede elétrica, o que está associado ao estudo de planejamento de expansão de redes.

1.3 ESTRUTURA DA DISSERTAÇÃO

A estruturação deste trabalho foi efetuada da seguinte maneira:

O Capítulo 1 apresenta a introdução com um contexto geral do problema, os objetivos gerais e específicos e a justificativa da metodologia que define a proposta de desenvolvimento do trabalho.

O Capítulo 2 apresenta uma revisão bibliográfica, a qual ressalta os trabalhos mais relevantes que ajudaram na base da metodologia proposta.

O Capítulo 3 apresenta os dois algoritmos evolutivos que serão utilizados como ferramentas de otimização na metodologia.

O Capítulo 4 disserta sobre a metodologia proposta. As subseções apresentarão as modelagens utilizadas para a certificação da correta utilização dos algoritmos evolutivos, bem como a integração dos mesmos com o fluxo de potência não iterativo.

No Capítulo 5 são apresentados os resultados. Esse capítulo subdivide-se em duas partes: a primeira apresenta todo o potencial e resultados obtidos pelas ferramentas de otimização da reconfiguração e de alocação de chaves em redes de distribuição para um sistema de menor porte, enquanto na segunda parte as ferramentas são validadas em um sistema de grande porte.

No Capítulo 6 são apresentadas as considerações finais. Esse capítulo subdivide-se em dois menores, apresentando as conclusões acerca do trabalho, assim como as vantagens na utilização da metodologia proposta, além de apresentar alguns possíveis temas para a execução de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os temas principais utilizados como base para a implementação dessa proposta. Para facilitar o entendimento, esse capítulo foi subdividido em cinco seções, apresentando primeiramente um estudo sobre a reconfiguração e também sobre a alocação de chaves em redes de distribuição, na primeira e segunda seção, respectivamente. A terceira e quarta seção apresentam a formulação básica do fluxo de potência e do fluxo de potência linearizado, respectivamente. Já na quinta seção é apresentado a formulação para o método de cálculo de fluxo de potência não iterativo.

2.1 RECONFIGURAÇÃO DE REDES DE DISTRIBUIÇÃO

A reconfiguração de redes de distribuição está sempre em pauta entre as maiores preocupações do setor de energia elétrica, devido a direta relação entre a sua capacidade de garantir um melhor aproveitamento e qualidade da energia elétrica ofertada aos vários tipos de consumidores. Isso se deve muito ao fato de elas estarem próximas às cargas e muito susceptíveis a faltas (RODRIGUES et al., 2019). O fato das redes de distribuição serem a parte do sistema de energia mais próxima das cargas também faz com que ela esteja mais susceptível a desequilíbrios de tensão ocasionados pelo carregamento desigual entre as fases (BENITEZ et al., 2020).

Além disso, o custo gerado pelas perdas ocasionadas com o efeito Joule fazem com que as concessionárias de energia tenham um gasto pelo qual não recebem quando cobram a energia utilizada pelos clientes. Esse fenômeno contínuo de perda de energia faz com que a reconfiguração através da mudança de *status* entre aberto e fechado das chaves presentes no sistema seja uma das maneiras mais confiáveis e econômicas para se lidar com esse tipo de problema (GEREZ et al., 2019).

Outra situação que vêm ocorrendo é a ampliação do número de geração distribuída nos sistemas de distribuição devido principalmente à sua característica renovável e à redução dos custos atrelados a ela. Essa ampliação vem sendo estimulada pelas concessionárias devido à melhora no nível de confiabilidade do sistema. Com isso, o aumento no número de geração distribuída nos sistemas de

distribuição acarreta em uma mudança técnica, econômica e ambiental sobre o sistema (GONG et al., 2018).

Essas relações fazem com que a otimização da reconfiguração de redes de distribuição traga inúmeros benefícios (HAIJUN; HONG, 2019). Seus objetivos principais ao longo do tempo vem sendo a melhora do perfil de tensão na rede, a minimização de perdas, a manutenção de uma distribuição equilibrada de energia ao longo do sistema, o aprimoramento dos critérios de qualidade além da melhora na confiabilidade do sistema de energia como um todo (AKRAMI et al., 2020).

Devido aos benefícios gerados, a reconfiguração de redes de distribuição vem sendo estudada há muito tempo. Os primeiros trabalhos realizados nessa área remetem às décadas de 70 e 80 (GEREZ et al., 2019). Na década de 90, surgiram os primeiros trabalhos utilizando metaheurísticas e algoritmos evolutivos na busca de solução para esse tipo de problema, sendo cada vez mais utilizados posteriormente. A taxa de convergência que esses algoritmos conseguem alcançar e o tempo de processamento necessário traz alguns empecilhos para esse tipo de abordagem. Com isso, a busca por novas ferramentas e melhorias nos tempos de execução das mesmas apresenta um vasto campo de busca para melhores soluções.

Independentemente do método de reconfiguração escolhido, a relação de configurações possíveis é sempre de 2^n , sendo n o número de chaves presentes no sistema. Devido a essa característica exponencial, dependendo do número de chaves alocadas no sistema fica muito difícil testar todas as combinações possíveis para verificar qual traria a melhor solução de acordo com o parâmetro desejado.

Para contornar esse problema, alguns algoritmos utilizam a técnica de diminuir o espaço de busca, como foi sugerido por Gerez et al. (2019). Nesse caso, a utilização de uma metaheurística baseada no movimento e interação social do vagalume conseguiu reduzir o espaço de busca inicial a partir da análise do número de chaves presentes no sistema em comparação com uma análise das malhas.

Alguns autores buscam correlacionar as diferentes possibilidades de configuração do sistema com os custos envolvidos nos chaveamentos. É o caso apresentado por Rodrigues et al. (2019). Para essa abordagem, são considerados todos os eventos que ocorrem após uma falta como, por exemplo, a atuação de disjuntores, fusíveis e religadores em conjunto ou não com as ações de manobra de chaves que possam vir a isolar áreas de falta. Com isso, é possível apresentar para cada diferente configuração os custos que estarão relacionados às mesmas.

2.2 ALOCAÇÃO DE CHAVES EM REDES DE DISTRIBUIÇÃO

A instalação de chaves nos sistemas de distribuição busca aprimorar a confiabilidade e a eficiência operacional de uma rede de distribuição. Esses equipamentos são fundamentais para que a restauração/reconfiguração possa ocorrer visando o maior número de consumidores com o menor tempo possível (ALVES, 2012).

O sucesso da alocação de chaves junto com a quantidade das mesmas impacta diretamente no sucesso obtido pela reconfiguração do sistema. Tradicionalmente, experiências passadas, estudos de engenharia entre outras informações relevantes têm sido utilizadas para determinar o número e local das chaves em sistemas de distribuição.

Uma alocação correta de chaves pode trazer inúmeros benefícios, como redução no tempo médio de falhas, melhora na qualidade de energia, redução do custo com perdas de energia, além de redução do custo com encargos devido a violação dos padrões de confiabilidade do sistema (ASSIS et al., 2015).

Métodos de otimização vêm sendo utilizados para determinar as configurações possíveis de acordo com o *status* dos dispositivos de chaveamento. Porém, apenas determinar o *status* ótimo das chaves após essas já estarem alocadas pode acabar não fornecendo a melhor configuração possível devido à limitação da localização desses dispositivos (KARAAOM et al., 2020).

Com isso, diversos estudos vêm sendo direcionados a esse problema com várias técnicas diferentes tendo sido aplicadas. Em alguns casos, é efetuada a combinação de técnicas de alocação de chaves com alocação de geração distribuída (ZARE et al., 2018). Outros estudos priorizam a confiabilidade do sistema, orientando a alocação de modo a garantir os menores tempos de interrupção após uma falta (GALIAS, 2019).

Devido à natureza combinatorial desse tipo de problema, tem se destacado também a utilização de metaheurísticas para encontrar a melhor solução possível. Os resultados têm demonstrado que esses métodos possuem um desempenho muito bom, mesmo para problemas intratáveis utilizando abordagens exatas (BAHRAMABADI et al., 2018).

Diferentes soluções de função objetivo e método de otimização vêm sendo estudadas. A utilização de lógica *Fuzzy* combinada com algoritmos genéticos é

apresentada por Alves (2012). Nesse caso, a escolha da função objetivo passa pela utilização de um índice de sensibilidade da alocação, o qual apresenta a taxa de falhas, o índice de confiabilidade e o índice de prioridade dos consumidores de cada seção do sistema para verificar se compensa ou não instalar uma chave nesse local.

Outro estudo que também utiliza os algoritmos genéticos é apresentado por Assis et al. (2015). Neste caso, também é considerada a confiabilidade do sistema para a definição da alocação, porém com a análise do tempo de interrupção após uma falha sendo a variável a ser otimizada. Essa análise de tempo de interrupção após uma falha também é apresentada em (GALIAS, 2019). Porém, nesse caso, para a ferramenta de otimização é utilizado um algoritmo determinístico baseado na estrutura de árvores.

Em Bahramabadi et al. (2018), a escolha dos melhores locais para a alocação leva em consideração a quantidade de consumidores afetados com a ocorrência de fenômenos naturais, principalmente furacões.

A análise do custo que a interrupção no fornecimento de energia ocasiona é efetuada em (ZARE et al., 2018). Além disso, as perdas totais do sistema, juntamente com os desvios de tensão máximos, são analisados em uma função multi-objetivo. Nesse caso, é utilizado um algoritmo de otimização baseado na colônia de abelhas (ABC). Também considerando a redução das perdas, é apresentado em Karaaom et al. (2020) um estudo com a utilização de um algoritmo baseado no enxame de partículas (PSO).

2.3 FORMULAÇÃO BÁSICA DO FLUXO DE POTÊNCIA

Estudos de fluxo de potência são muito relevantes no planejamento da expansão e na determinação das melhores soluções de operação em sistemas elétricos de potência. Sua solução visa auxiliar os operadores para que possa ser efetuada a análise de carregamento de geradores, perdas de transmissão, manutenção das magnitudes de tensão nas barras próximas aos seus valores nominais, garantia no fornecimento de energia e operação dos equipamentos e linhas de transmissão sem estarem sobrecarregados (DURCE, 2012).

Após a análise do fluxo de potência, o estado do sistema é obtido e com isso as magnitudes de tensão e os ângulos de fase das tensões em cada barra do sistema são conhecidos. Uma vez conhecidas essas condições de operação da rede, torna-

se possível determinar os fluxos de potência ativa e reativa nas linhas que conectam cada barra, além de diversas outras informações importantes ao operador do sistema (AMBRÓSIO, 2018).

Para se efetuar o cálculo do fluxo de potência, a modelagem é considerada estática, ou seja, em estado equilibrado e livre de transitórios, com a rede elétrica sendo representada por equações algébricas. Essas equações, não lineares, equivalem à aplicação da Primeira Lei de Kirchhoff no sistema elétrico, sendo os nós representados pelas barras e os ramos pelas linhas de transmissão. Na obtenção dessas equações é considerado a condição de conservação das potências ativa e reativa em cada nó da rede, ou seja, a soma das potências que fluem pelos componentes internos conectados a um determinado nó deve ser igual a potência líquida injetada nele.

Na formulação básica do fluxo de potência, são associadas a cada barra da rede elétrica quatro variáveis, sendo duas consideradas como incógnitas e duas como dados do problema (MONTICELLI, 1983). Essas variáveis são apresentadas abaixo:

V_k – magnitude da tensão nodal da barra k ;

θ_k – ângulo da tensão nodal na barra k ;

P_k – geração líquida (geração menos carga) de potência ativa da barra k ;

Q_k – geração líquida de potência reativa da barra k .

Cada barra do sistema recebe uma classificação de acordo com as variáveis consideradas para a mesma. Essas classificações são apresentadas abaixo:

- Barras tipo PQ – são informados P_k e Q_k e calculados V_k e θ_k ;
- Barras tipo PV – são informados P_k e V_k e calculados Q_k e θ_k ;
- Barra tipo $V\theta$ ou barra de referência – são informados V_k e θ_k e calculados P_k e Q_k .

As barras PQ correspondem tipicamente às barras de carga, enquanto às barras PV estão associadas as barras de geração. Já a barra $V\theta$ está associada com a referência angular do sistema ($\theta_k = 0$) e também a uma grande capacidade de geração, permitindo assim o fechamento do balanço de potência do sistema. Devido

a essa última característica ela também é conhecida como barra de folga ou *slack* em inglês.

As equações algébricas que representam essas relações são apresentadas nas equações (1) e (2), para a potência ativa e reativa, respectivamente:

$$P_k = \sum_{m \in \Omega_k} P_{km}(V_k, V_m, \theta_k, \theta_m) \quad (1)$$

$$Q_k + Q_k^{sh}(V_k) = \sum_{m \in \Omega_k} Q_{km}(V_k, V_m, \theta_k, \theta_m) \quad (2)$$

onde:

$k = 1, \dots, NB$, sendo NB o número de barras presentes na rede;

Ω_k – conjunto de barras vizinhas à barra k ;

V_k, V_m – magnitude das tensões das barras terminais do ramo $k - m$;

θ_k, θ_m – ângulo das tensões das barras terminais do ramo $k - m$;

P_{km} – fluxo de potência ativa do ramo $k - m$;

Q_{km} – fluxo de potência reativa do ramo $k - m$;

Q_k^{sh} – injeção de potência devida ao elemento shunt da barra k .

Com isso, as injeções de potência ativa e reativa de cada barra do sistema são dadas por:

$$P_k = V_k \sum_{m \in \Omega_k} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \quad (3)$$

$$Q_k = V_k \sum_{m \in \Omega_k} V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km}) \quad (4)$$

onde:

k – conjunto de barras adjacentes à barra k , incluindo a mesma;

G_{km}, B_{km} – coeficientes reais e imaginários da matriz de admitância.

2.4 FLUXO DE POTÊNCIA LINEARIZADO

O fluxo de potência linearizado é um método de cálculo não iterativo para solução de fluxo de potência de sistemas de transmissão. Esse método é bastante disseminado principalmente pela sua simplicidade e robustez (MONTICELLI, 1983).

Este método tradicional é também conhecido como Fluxo de Potência DC (FPDC). Isso se deve ao fato de que, ao efetuar-se uma comparação por analogia com circuitos elétricos em corrente contínua (circuitos DC, do inglês *Direct Current*), o fluxo de corrente corresponde ao fluxo de potência e a queda de tensão corresponde à diferença angular entre as tensões terminais da linha (abertura angular da linha).

Assim, em linhas de transmissão, em função da característica baixa relação R/X de seus parâmetros, o fluxo de potência ativo é fortemente influenciado pela abertura angular na linha (acoplamento P- θ), fluindo da barra com maior ângulo de tensão para a de menor ângulo, como demonstrado pelo equacionamento a seguir.

A relação do fluxo de potência P_{km} em uma linha de transmissão, é dada pela equação (5):

$$P_{km} = V_k^2 g_{km} - V_k V_m g_{km} \cos\theta_{km} - V_k V_m b_{km} \sin\theta_{km} \quad (5)$$

Se for considerado o fluxo no extremo oposto dessa linha, temos a relação apresentada em (6):

$$P_{mk} = V_m^2 g_{km} - V_k V_m g_{km} \cos\theta_{km} + V_k V_m b_{km} \sin\theta_{km} \quad (6)$$

Com isso, a soma dos fluxos na linha (perdas ativas) é dada por:

$$P_{km} + P_{mk} = g_{km}(V_k^2 + V_m^2 - 2V_k V_m \cos\theta_{km}) \quad (7)$$

Desprezando-se os termos correspondentes às perdas nas expressões (5) e (6) tem-se a relação apresentada na expressão (8):

$$P_{km} = -P_{mk} = -V_k V_m b_{km} \sin\theta_{km} \quad (8)$$

Além disso, consideram-se as seguintes simplificações, apresentadas em (9), (10), e (11):

$$V_k \cong V_m \cong 1 \text{ pu} \quad (9)$$

$$\text{sen}\theta_{km} \cong \theta_{km} \quad (10)$$

$$b_{km} \cong \frac{-1}{x_{km}} \quad (11)$$

Assim, é possível obter-se a seguinte relação:

$$P_{km} = x_{km}^{-1} \theta_{km} = \frac{\theta_k - \theta_m}{x_{km}} \quad (12)$$

A relação apresentada em (12) tem a mesma forma da Lei de Ohm aplicada a um resistor percorrido por corrente contínua, onde:

P_{km} é análogo à intensidade de corrente;

θ_k e θ_m são análogos às tensões terminais;

x_{km} é análogo à resistência.

Para a injeção de potência ativa numa barra k , tem-se a relação apresentada em (13):

$$P_k = \sum_{m \in \Omega_k} x_{km}^{-1} \theta_{km} \quad (k = 1, \dots, NB) \quad (13)$$

A expressão (13) pode ser reescrita conforme apresentado em (14):

$$P_k = \left(\sum_{m \in \Omega_k} x_{km}^{-1} \right) \theta_k + \sum_{m \in \Omega_k} (-x_{km}^{-1} \theta_m) \quad (14)$$

Ao representar-se a equação (14) na forma matricial tem-se a seguinte relação, que se constitui na equação fundamental do método FPDC:

$$\bar{P} = B' \bar{\theta} \quad (15)$$

onde:

$\bar{\theta}$ – vetor dos ângulos das tensões nodais θ_k ;

\bar{P} – vetor das injeções líquidas de potência ativa;;

B' – matriz tipo admitância nodal;

Os elementos da matriz B' são representados pela expressão (16):

$$\begin{aligned} B'_{km} &= -x_{km}^{-1} \\ B'_{kk} &= \sum_{m \in \Omega_k} x_{km}^{-1} \end{aligned} \quad (16)$$

Devido às perdas de transmissão terem sido desprezadas, a soma dos componentes de \bar{P} é nula, o que faz com que a matriz B' seja singular. Para resolver esse problema, é necessário a eliminação de uma das equações do sistema apresentado na equação (15), adotando-se a barra correspondente como referência angular ($\theta_k = 0$).

Com isso, o sistema passa a ser não singular com dimensão de NB-1 e os ângulos das NB-1 barras adicionais, que são as variáveis de estado do problema, podem ser determinados a partir da resolução do sistema linear representado pela equação (15).

Dessa forma, o FPDC consegue estimar com boa precisão e bastante simplicidade matemática, a distribuição dos fluxos de potência ativa em uma rede de transmissão.

No FPDC, não são consideradas no cálculo as magnitudes de tensão nodal, as potências reativas e os *taps* dos transformadores. Devido a essa simplificação, esse método não pode substituir integralmente os métodos não-lineares do fluxo de carga.

Assim, o método de fluxo de potência linearizado é capaz de fornecer uma solução que pode servir como indicativo do que está ocorrendo na rede. Para que isso ocorra, é necessário que a matriz B' não seja singular, o que sempre ocorre quando a rede é conexa.

Recentemente foi proposta em Yuan et al. (2018) uma nova abordagem para cálculo linearizado de fluxo de potência aplicável a sistemas ativos de distribuição.

2.5 FLUXO DE POTÊNCIA NÃO ITERATIVO

Devido à sua já conhecida característica de possuir uma elevada relação de R/X , as redes de distribuição necessitam de métodos diferenciados de resolução do problema de Fluxo de Potência. O forte acoplamento entre potência ativa e ângulo das tensões (acoplamento $P\theta$) presente nas redes de transmissão devido a sua característica de baixa relação R/X não se faz presente nesse caso. Com isso, o fluxo de potência ativa em redes de distribuição, depende majoritariamente, das magnitudes de tensão nodal presente em cada barra do sistema. Para esse caso, tem-se a magnitude da tensão como a principal variável a ser determinada.

Tendo isso em mente, foi proposto em Ambrósio e Tortelli (2017) uma metodologia que permitisse a obtenção das magnitudes das tensões nodais em sistemas de distribuição, baseando-se na mesma ideia utilizada pelo método linearizado (FPDC) para a obtenção dos ângulos das tensões nodais em sistemas de transmissão. Para possibilitar a utilização desse método, é necessário a aplicação da técnica de normalização complexa (cpu) que possibilita acentuar a alta relação R/X presente nas redes de distribuição melhorando assim a precisão dos resultados associados à magnitude das tensões nodais.

Na normalização complexa por unidade (cpu), utiliza-se uma potência base complexa, diferentemente da normalização convencional por unidade (pu) onde todos os valores base são números reais. É possível observar a relação da potência complexa em (17), onde ϑ_{base} é o ângulo da potência base complexa S_{base} .

$$S_{base} = |S_{base}|e^{-j\vartheta_{base}} \quad (17)$$

Como as bases de tensão continuam sendo números reais, a base de impedância passa a ter um valor complexo, possuindo o mesmo valor de ângulo base apresentado na potência complexa, conforme apresentado em (18):

$$Z_{\text{base}} = \frac{V_{\text{base}}^2}{S_{\text{base}}^*} = |Z_{\text{base}}|e^{-j(\varnothing_{\text{base}})} \quad (18)$$

Assim, os valores apresentados para a resistência e reatância do sistema, considerando a nova impedância base, serão determinados conforme as expressões (19) e (20):

$$R_{\text{cpu}} = |Z_{\text{pu}}|\cos(\theta + \varnothing_{\text{base}}) \quad (19)$$

$$X_{\text{cpu}} = |Z_{\text{pu}}|\sin(\theta + \varnothing_{\text{base}}) \quad (20)$$

onde θ é o ângulo da impedância série da linha de distribuição.


Com essas novas relações, pode-se obter o valor de R/X a partir da equação apresentada em (21):

$$\frac{X_{\text{cpu}}}{R_{\text{cpu}}} = \tan(\theta + \varnothing_{\text{base}}) \quad (21)$$

Conforme é possível observar em (21), a razão R/X das redes de distribuição pode ser agora modificada de acordo com a escolha do ângulo da potência base.

Com isso, utilizando um valor adequado para $\varnothing_{\text{base}}$, é possível ampliar a característica resistiva das linhas de distribuição, podendo então ser negligenciada sua característica reativa, assim como é feito na abordagem linearizada utilizada no cálculo do fluxo de potência para linhas de transmissão, onde negligencia-se sua resistência. Logo, a representação equivalente das linhas de distribuição pode ser então simplificada para puramente resistiva, conforme apresentado na FIGURA 1.

FIGURA 1 - REPRESENTAÇÃO SIMPLIFICADA DE UMA LINHA DE DISTRIBUIÇÃO NORMALIZADA



FONTE: Ambrósio e Tortelli (2017)

Existe mais de uma forma de se encontrar o ângulo da potência base para toda a rede. Neste trabalho, o ângulo base é obtido a partir da média dos ângulos individuais de cada ramo do sistema, conforme apresentado nas equações (22) e (23):

$$\alpha_{km} = \text{tang}^{-1} \left(\frac{x_{km}}{r_{km}} \right) \quad (22)$$

onde:

x_{km} – reatância série dos ramos;

r_{km} – resistência série dos ramos;


$$\emptyset_{\text{base}} = \frac{\sum \alpha_{km}}{N_t} \quad (23)$$

onde:

N_t – número total de ramos.

Para detalhar melhor como a média dos ângulos das linhas influencia o ângulo \emptyset_{base} , é apresentado na FIGURA 2 uma relação entre os ângulos de impedância de três linhas de distribuição com suas impedâncias correspondentes em Ω e cpu:

FIGURA 2 – RELAÇÃO ENTRE O ÂNGULO \varnothing_{base} E AS IMPEDÂNCIAS DAS LINHAS EM Ω E cpu



FONTE: Modificado de Gomes (2006)

É possível notar que após a normalização complexa, a aplicação do ângulo \varnothing_{base} faz com que as impedâncias em cpu encontrem-se próximas a um caso totalmente resistivo.

Devido à modificação na base da potência, é necessário também normalizar as injeções de potência com a mesma base, para que assim os valores obtidos na solução do fluxo de potência sejam coerentes. Pode-se notar essa relação em (24):

$$S_{cpu} = \frac{|S_{VA}|e^{j\delta}}{|S_{base}|e^{-j\varnothing_{base}}} = |S_{pu}|e^{j(\delta+\varnothing_{base})} \quad (24)$$

onde δ é o ângulo de potência das injeções.

Assim, é possível escrever as expressões para as injeções de potência ativa e reativa com relação ao ângulo da potência base conforme (25) e (26):


$$P_{cpu} = |S_{pu}|\cos(\delta + \varnothing_{base}) \quad (25)$$

$$Q_{cpu} = |S_{pu}|\sin(\delta + \varnothing_{base}) \quad (26)$$

Seguindo a lógica apresentada para o método FPDC, onde o acoplamento $P\theta$ é considerado, pode-se agora utilizar o acoplamento PV para considerar que apenas potência ativa está circulando pela linha de distribuição, já que o circuito equivalente é puramente resistivo. Com isso tem-se um circuito convencional em corrente contínua.

Para exemplificar a aplicação considerada, é apresentado como exemplo o circuito da linha de distribuição da FIGURA 3:

FIGURA 3 - REPRESENTAÇÃO SIMPLIFICADA DE UM SISTEMA DE DISTRIBUIÇÃO COM DUAS BARRAS



FONTE: Ambrósio e Tortelli, 2017

Considerando V_1 como sendo controlada, é possível obter a tensão na barra 2 aplicando-se a Lei de Kirchhoff das tensões, conforme apresentado na equação (27):

$$V_2 = V_1 - I G^{-1} \quad (27)$$

A corrente de carga que circula pela linha pode ser encontrada da seguinte maneira:

$$I = \frac{P_2}{V_2} \quad (28)$$

Utilizando-se a relação apresentada em (28) com a equação (27) tem-se o seguinte resultado:

$$V_2 = V_1 - \frac{P_2}{V_2} G^{-1} \quad (29)$$

Multiplicando-se os dois lados da equação (29) por V_2 , pode-se obter a seguinte relação (30):

$$V_2^2 + (-V_1)V_2 + P_2 G^{-1} = 0 \quad (30)$$

É possível verificar que a relação apresentada em (30) se trata de uma equação quadrática, sendo sua solução obtida através da utilização da fórmula de Baskhara. Essa solução pode ser verificada em (31):

$$V_2 = \frac{V_1 + \sqrt{(V_1^2 - 4P_2 G^{-1})}}{2} \quad (31)$$

Ainda conforme Ambrósio (2018), generalizando a solução apresentada em (31) para sistemas de distribuição com NB barras, é possível obter a relação apresentada em (32), na qual todos as matrizes e vetores apresentam dimensão igual a (NB-1):

$$[V] = \frac{[V_{\text{ref}}] + \sqrt{([V_{\text{ref}}]^2 - 4[G]^{-1}[P])}}{2} \quad (32)$$

onde:

[V]: vetor das variáveis de estado;

[V_{ref}]: vetor associado à tensão da barra de referência;

[P]: vetor das injeções de potência ativa;

[G]: matriz condutância da rede elétrica.

Para o vetor associado à tensão da barra de referência, temos a seguinte definição:

$$[V_{\text{ref}}] = [G]^{-1}[G'] V_A \quad (33)$$

onde:

[G']: submatriz das condutâncias associadas a barra de referência;

[V_A]: tensão da barra de referência.

Os componentes da submatriz G' são definidos utilizando-se apenas as barras de carga presentes no sistema. Suas linhas e colunas são compostas por números que referem-se às barras PQ sendo essa matriz sempre quadrada.

Assim, a partir da resolução da equação (32), é possível determinar o valor aproximado das magnitudes de tensão nodal para qualquer sistema de distribuição com qualquer topologia e condição operativa, através de um processo não iterativo, o que o torna muito atraente para utilização em estudos de planejamento da operação e expansão de redes elétricas de distribuição.

2.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram apresentados diversos estudos sobre os temas utilizados como base para este trabalho, ressaltando a utilização da reconfiguração e alocação de chaves em redes de distribuição, além de apresentar as metodologias do cálculo de fluxo de potência, com destaque para o método não iterativo e suas características quando utilizado em redes de distribuição.

3 ALGORITMOS EVOLUTIVOS

Os algoritmos de otimização buscam resolver de maneira efetiva problemas de grande complexidade (ELTAEIB; MAHMOOD, 2018). O desempenho de qualquer algoritmo de otimização depende da formulação apropriada do problema e requer o ajuste adequado de parâmetros próprios de cada algoritmo (DEB et al., 2018).

Dentre as diversas categorias de algoritmos de otimização, os algoritmos evolutivos vêm se consolidando como uma das ferramentas mais utilizadas para resolver problemas de grande porte ou que tenham dificuldades de serem modelados matematicamente. Esses algoritmos começaram a ser propostos a partir das décadas de 1950 e 1960 com foco na adaptação da teoria da evolução natural proposta por Darwin, como uma estratégia de otimização para resolução de problemas complexos. A ideia por trás dessas abordagens era que uma população de soluções candidatas de um dado problema poderia evoluir para a solução ótima usando operadores inspirados pela variação genética natural e pela seleção natural (MITCHELL, 1999).

Devido a sua robustez e sua capacidade adaptativa, esses algoritmos evolutivos têm encontrado uma vasta aplicação em problemas práticos e teóricos que envolvem tarefas de pesquisa e otimização.

Neste trabalho, dentre os diversos algoritmos evolutivos propostos, foram escolhidos dois para lidar com o problema de reconfiguração e alocação de chaves em sistemas de distribuição: Algoritmos Genéticos e Algoritmo Diferencial Evolutivo. Ambos serão detalhados nas próximas seções.

3.1 ALGORITMOS GENÉTICOS

Os Algoritmos Genéticos foram apresentados por Holland em 1975 (HOLLAND, 1975). Apesar de ter uma motivação mais específica na área científica tentando entender e conectar diversos tipos de fenômenos naturais, Holland também tinha como objetivo desenvolver sistemas artificiais que conseguissem reter os mesmos mecanismos apresentados em sistemas naturais. Assim, com as simulações dos sistemas artificiais, seria possível imitar o mecanismo de evolução das espécies presentes na seleção natural proposta por Charles Darwin além do mecanismo de transferência dos fatores hereditários apresentado por Gregor Mendel (FOGAÇA, 2009). Com esse processo, os indivíduos geneticamente mais adaptados ao ambiente

tem mais chance de permanecerem vivos e de se reproduzirem transmitindo suas características para as futuras gerações.

Pela sua característica geral de utilização e adaptação, houve um crescimento grande do uso do Algoritmo Genético (AG) se tornando a abordagem mais utilizada para evolução computacional (DAVIS, 1998). Com isso ocorreu a sua divisão em diversas subespécies. Uma das maiores divisões é entre pesquisas com AGs como ferramentas de engenharia e também como modelo científico de processos evolutivos.

Devido a serem uma classe de procedimentos com diversos passos separados e possuindo estes passos diversas variações possíveis, os pesquisadores sempre se referem aos Algoritmos Genéticos como uma classe de procedimentos e não apenas “ao Algoritmo Genético” (FOGAÇA, 2009).

Um típico Algoritmo Genético possui as seguintes características:

1. Uma população de possíveis soluções para o problema e não apenas uma única solução;
2. Uma forma de calcular quão boa ou ruim é cada solução dentro da população;
3. Um método de misturar fragmentos da melhor solução para formar novas soluções;
4. Um operador de mutação para evitar a perda permanente de diversidade dentro das soluções.

Em um problema de otimização ou busca numérica, uma lista de possíveis soluções é pesquisada de maneira a encontrar a solução que melhor descreve o problema em questão. Um dado problema ainda pode conter máximos ou mínimos locais, o que dificulta a obtenção da solução global. Além disso, as ferramentas de otimização normalmente possuem uma sensibilidade em relação ao ponto inicial de busca. Isso faz com que muitos dos métodos de otimização tradicionais possam encontrar dificuldades na busca pelo máximo global.

Para não ser atingido por esses problemas, os Algoritmos Genéticos utilizam uma população inicial de possíveis soluções ao invés de um único ponto. O processo de busca é assim multidirecional, mantendo soluções candidatas e encorajando troca de informações entre todas as direções.

3.1.1 Codificação de indivíduos

Cada indivíduo de uma determinada população representa uma possível solução do problema abordado. Para que a utilização dessa população de indivíduos seja possível é necessária a codificação de cada indivíduo, ou seja é necessário a representação deles em uma cadeia cromossômica. Essa codificação é uma das etapas mais críticas na definição do algoritmo genético, podendo levar a problemas de convergência caso sejam definidos de forma inadequada (ZUBEN, 2011).

3.1.2 População inicial

Como as características das soluções candidatas são sempre transferidas para as próximas gerações, a escolha da população inicial impacta diretamente no número de gerações necessárias para encontrar a melhor solução.

Essa escolha pode ser feita de forma aleatória (método mais comum) ou também de forma controlada a ponto de se direcionar a população inicial dentro do espaço de busca, caso algum conhecimento inicial a respeito do problema estiver disponível e possa auxiliar esse direcionamento. Para este trabalho foi considerada a forma aleatória de formação da população inicial.

3.1.3 Função objetivo

Para medir a qualidade de cada uma das soluções analisadas é necessário a utilização de uma função objetivo, também comumente chamada de *fitness*. Essa função deve possibilitar a escolha adequada das melhores soluções para que o processo de seleção seja eficiente.

3.1.4 Operadores genéticos

Existem três operadores que são frequentemente mais utilizados nos algoritmos genéticos sendo estes *crossover*, mutação e seleção. A seguir serão apresentados os principais aspectos de cada um.

3.1.4.1 Crossover

O operador de *crossover* ou recombinação cria novos indivíduos a partir da combinação de dois ou mais indivíduos. Seu principal objetivo é a troca de informações entre diferentes candidatos a solução.

É possível encontrar diversas formas de recombinação, sendo as mais comuns *crossover* de um ponto e *crossover* disperso.

Para a aplicação do *crossover* de um ponto, são selecionados dois indivíduos (pais) e a partir de seus cromossomos são gerados dois novos indivíduos (filhos). Para se efetuar essa geração de filhos, um ponto de corte é selecionado aleatoriamente nos cromossomos dos pais, com os segmentos criados a partir do ponto de corte sendo trocados para cada filho. Para exemplificar esse tipo de recombinação, é apresentado o exemplo a seguir. Dois indivíduos são selecionados como pais e um ponto de corte é escolhido aleatoriamente.

Pai 1: [1 0 1 0 1]

Pai 2: [1 1 0 0 0]

Definindo o ponto de corte como 3, tem-se os seguintes segmentos em cada um dos pais:

Pai1: segmento 1 = [101] e segmento 2 = [01]

Pai2: segmento 1 = [110] e segmento 2 = [00]

Após a operação de *crossover* ser efetuada, tem-se os seguintes indivíduos filhos:

Filho 1: [1 0 1 0 0]

Filho 2: [1 1 0 0 1]

Nesse caso, o Filho 1 foi formado pelo segmento 1 do Pai 1 e pelo segmento 2 do Pai 2, enquanto o Filho 2 foi formado pelo segmento 1 do Pai 2 e pelo segmento 2 do Pai 1.

Já para a aplicação do *crossover* disperso, segue-se a mesma lógica de definição de dois indivíduos pais, porém é formado apenas um filho a partir destes. Para a seleção de qual ponto do cromossomo de cada pai será herdado para o filho, é utilizado um vetor de *crossover* binário gerado aleatoriamente e de mesmo comprimento que os pais. Então, de acordo com o valor binário apresentado no vetor de *crossover* é que são escolhidos os valores dos genes do indivíduo filho. Para

exemplificar essa situação, utilizam-se os mesmos pais do exemplo apresentado na definição do *crossover* de um ponto, ou seja:

Pai 1: [1 0 1 0 0]

Pai 2: [1 1 0 0 1]

Agora, como exemplo, tem-se o seguinte vetor de *crossover*:

Vetor de *crossover*: [1 0 0 1 1]

Como definição, pode-se utilizar que sempre que o vetor de *crossover* apresentar o valor 1 o indivíduo filho receberá o valor de gene referente ao Pai 1, e quando o vetor de *crossover* apresentar o valor 0 o indivíduo filho receberá o valor de gene referente ao Pai 2. Com isso, o vetor filho apresentará a seguinte configuração:

Filho 1: [1 1 0 0 0]

Diversos outros tipos de *crossover* têm sido propostos na literatura. No entanto, não existe consenso sobre um operador de *crossover* que apresente claramente um desempenho superior aos demais. Com isso, cada operador de *crossover* pode ser particularmente eficiente para determinada classe de problema e ineficiente para outras. Para o presente trabalho, foi considerado a aplicação do *crossover* disperso.

3.1.4.2 Mutação

O operador de mutação tem o objetivo de modificar um ou mais valores de genes de determinado indivíduo, de acordo com a taxa de mutação. Com isso, é possível criar uma variabilidade adicional na população, evitando principalmente que o algoritmo convirja prematuramente.

Para a execução da mutação, é selecionado um gene do indivíduo ao qual irá passar pelo processo de mutação, tendo este gene o seu valor trocado. Para codificação binária dos indivíduos, caso o gene apresente o valor 1 antes da mutação passará a ter o valor zero após a mutação.

3.1.4.3 Seleção

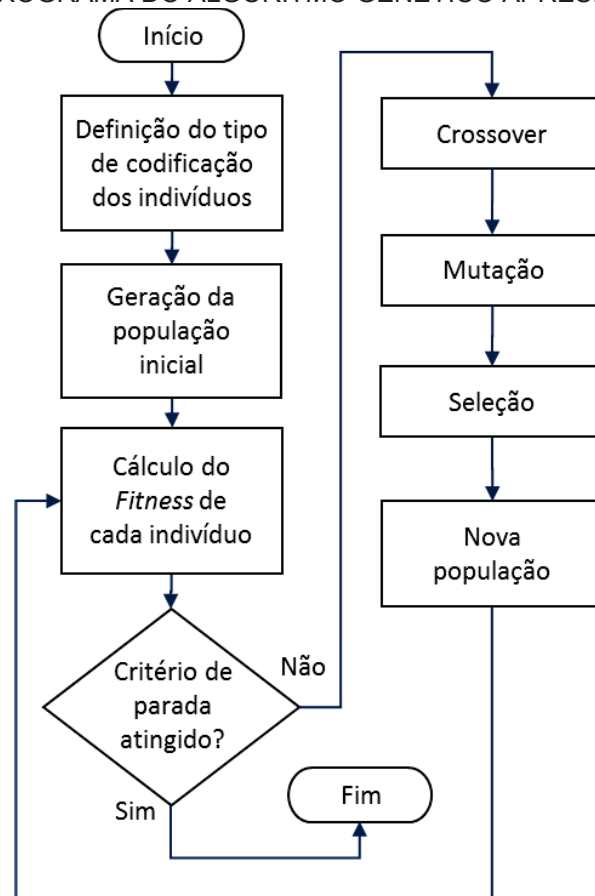
O operador de seleção consiste em selecionar os indivíduos mais aptos da população para que passem para a próxima geração.

Na estratégia original do algoritmo genético, é utilizado o esquema de seleção chamado de *roulette wheel* (ZUBEN, 2011). Para esse método de seleção, é atribuído uma probabilidade de passar para a próxima geração a cada indivíduo da população. Essa probabilidade está associada ao *fitness* de cada indivíduo, ou seja, os indivíduos com maior *fitness* têm uma probabilidade maior de continuar nas próximas gerações. Dessa forma, o indivíduo com melhor *fitness* na população atual pode não ser selecionado para a próxima geração com esse método de seleção.

Para contornar esse problema, existe um outro método de seleção chamado de elitismo. Nesse método, é definido uma taxa de elitismo a qual definirá quantos entre os melhores indivíduos da população atual se manterão para as próximas gerações. Isso faz com que o melhor indivíduo de cada geração sempre esteja presente na geração futura. Para o presente trabalho, foi utilizado o método de seleção baseado no elitismo.

Após a execução de todos os passos mencionados, é verificado a convergência do algoritmo de acordo com o critério definido para satisfazer o problema abordado. Caso o critério não seja atingido o algoritmo avalia a próxima geração, efetuando todos os passos novamente. Ao atingir o critério de parada, sendo este o critério de convergência escolhido ou o número máximo de gerações, o algoritmo termina sua execução. Para o critério de convergência, usualmente é verificado como o *fitness* se comporta em cada geração comparando-a com as anteriores. Caso este não esteja mais evoluindo além de um valor especificado o algoritmo encerra sua execução. Na FIGURA 4 é possível analisar um fluxograma com as etapas mencionadas para os algoritmos genéticos:

FIGURA 4 - FLUXOGRAMA DO ALGORITMO GENÉTICO APRESENTADO



FONTE: O Autor, (2020).

3.2 ALGORITMO DIFERENCIAL EVOLUTIVO

Apresentado por Price e Storn em 1997 como um método heurístico de otimização, o algoritmo diferencial evolutivo (DE) também está presente na classe dos algoritmos evolutivos (PRICE e STORN, 1997). Ele também utiliza um sistema baseado em uma população de possíveis soluções para buscar o ótimo de uma função dentro de um espaço multi-dimensional (ROCCA et al., 2011). Sua característica principal está no fato de utilizar diferenças entre pares de vetores para guiar o operador de mutação ao invés de utilizar funções de distribuição de probabilidade como em outros algoritmos evolutivos (WONG e DONG, 2005).

Muitos estudos demonstraram que o DE converge rapidamente e é robusto, além de possuir uma simples implementação e uso, requerendo apenas alguns parâmetros de controle (KIM et al., 2007). Suas principais vantagens também incluem:

- Efetiva capacidade de otimização global;
- Algoritmo eficiente sem ordenação ou multiplicação de matrizes;

- Operação de mutação auto referenciável;
- Capacidade de fornecer várias soluções em uma única execução e eficaz em problemas de otimização de restrições não lineares com funções de penalidade.

O algoritmo diferencial evolutivo segue as mesmas regras de codificação dos indivíduos, formação da população inicial e definição da função objetivo que os algoritmos genéticos.

Sua população inicial também é desenvolvida mais frequentemente de forma aleatória (MOHAMED, 2018) sendo considerado NP indivíduos dentro das possíveis restrições do problema. O *fitness* definido pela função objetivo é o fator determinante para a avaliação de cada possível solução.

3.2.1 Operadores genéticos

Assim como no algoritmo genético, o algoritmo diferencial evolutivo também utiliza três operadores principais: *crossover*, mutação e seleção. Porém, esses operadores são definidos de forma diferente, conforme será abordado nas seções a seguir.

3.2.1.1 Mutação

Para cada indivíduo da população inicial NP, será gerado um novo indivíduo através do processo de mutação. O vetor com os indivíduos da população inicial e atual de cada geração recebe o nome de x . No processo de mutação, são escolhidos três indivíduos doadores da população atual x (x_{n1} , x_{n2} e x_{n3}) sendo os três diferentes entre si. Após a escolha dos três indivíduos, tem-se a criação do indivíduo gerado pela mutação, a partir da equação (34):

$$v_i^{G+1} = x_{n1}^G + F \cdot (x_{n2}^G - x_{n3}^G) \quad (34)$$

onde:

G é o número da geração atual do algoritmo;

F é o fator de mutação, com range de aplicação no intervalo (0,2];

i é o contador de indivíduos variando entre 1 e NP.

Com isso, cada indivíduo do vetor atual de mutação terá seus valores de gene formados a partir dos valores de gene dos seus pais x_{n1} , x_{n2} e x_{n3} .

Após a execução deste processo para todos os indivíduos da população NP, tem-se o vetor de mutação v com mesma dimensão de NP.

3.2.1.2 Crossover

O operador de *crossover* é gerado utilizando os vetores da população atual x e o vetor de mutação v . Cada indivíduo do vetor de *crossover* u , receberá como pai um indivíduo da população atual junto com o correspondente do vetor de mutação v .

Para o processo de definição de qual indivíduo pai irá doar seu gene para o indivíduo filho do vetor u , é efetuada uma verificação de acordo com a taxa de *crossover* CR. Esta taxa é um valor real presente no intervalo $[0,1]$ e definida no começo do algoritmo.

Com isso, para cada gene do indivíduo filho, é gerado um número real aleatório no intervalo $[0,1]$ e de acordo com a comparação desse número e a taxa de CR, é determinado se o filho receberá o gene do indivíduo da mutação ou da população atual. Esta relação é apresentada na equação (35):

$$u_{j,i}^{G+1} = \begin{cases} v_{j,i}^{G+1}, & \text{se } rand_{j,i}[0,1] \leq CR \text{ ou } j = k \\ x_{j,i}^G, & \text{caso contrário} \end{cases} \quad (35)$$

onde i é o contador de indivíduos variando entre 1 e NP e j é o contador de genes de cada indivíduo variando de 1 até o número de genes definido na codificação dos indivíduos.

Após a execução deste processo para todos os indivíduos da população NP, tem-se o vetor de *crossover* u com mesma dimensão de NP e v .

3.2.1.3 Seleção

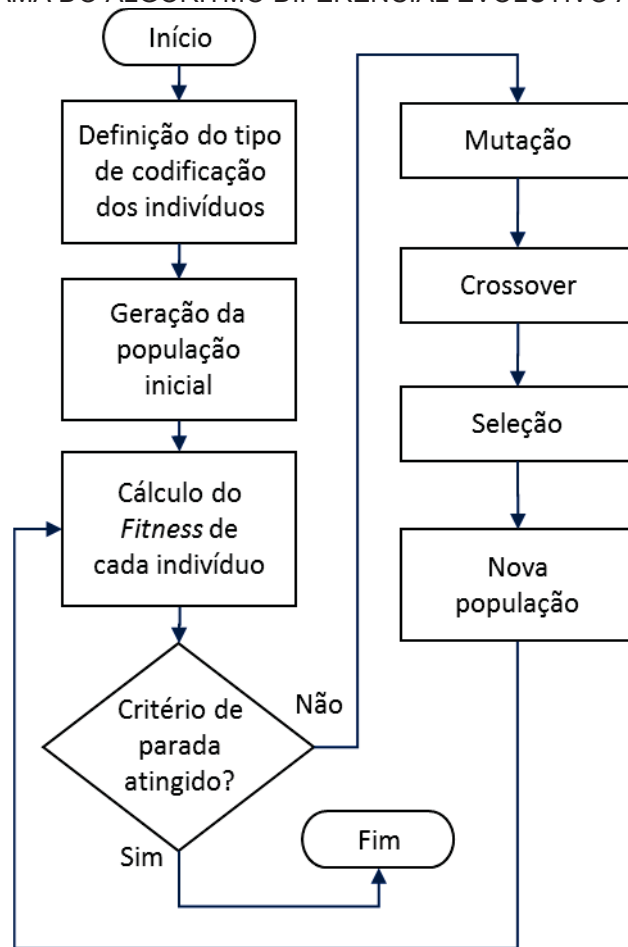
Para decidir a população da próxima geração, são comparados os *fitness* de cada indivíduo do vetor de população atual x com seu indivíduo correspondente no vetor de *crossover* u . O indivíduo que possuir o maior *fitness* segue para a população da próxima geração. Essa relação é apresentada na equação (36):

$$x_i^{G+1} = \begin{cases} u_i^{G+1}, & \text{se } f(u_i^{G+1}) \leq f(x_i^G) \\ x_i^G, & \text{caso contrário} \end{cases} \quad (36)$$

Após o processo de seleção é formada uma nova população que será testada na próxima geração.

Com a execução de todos os passos mencionados, é verificado a convergência do algoritmo de acordo com o critério definido para satisfazer o problema abordado. Na FIGURA 5 é possível analisar um fluxograma com as etapas mencionadas para o algoritmo diferencial evolutivo:

FIGURA 5 - FLUXOGRAMA DO ALGORITMO DIFERENCIAL EVOLUTIVO APRESENTADO



FONTE: O Autor, (2020).

3.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foi feita uma abordagem geral sobre o que são os algoritmos evolutivos, como surgiram e como vem sendo utilizados para estudos de otimização.

Além disso, foi feito um descritivo mais detalhado sobre os algoritmos genéticos e o algoritmo diferencial evolutivo, escolhidos como ferramenta de otimização para essa proposta.

4 METODOLOGIA

Neste capítulo será apresentada a metodologia proposta para a ferramenta computacional de otimização para reconfiguração de redes de distribuição, considerando duas aplicações distintas: a primeira, associada no apoio ao planejamento da operação, que busca a determinação do *status* ótimo de chaves previamente alocadas e; a segunda, relacionada à expansão de redes, que tem como objetivo a alocação ótima de chaves em sistemas de distribuição.

Conforme mencionado anteriormente, o processo de definição do *status* ótimo de cada chave e a alocação de chaves em sistemas de distribuição pode gerar ganhos diversos para o sistema elétrico em questão.

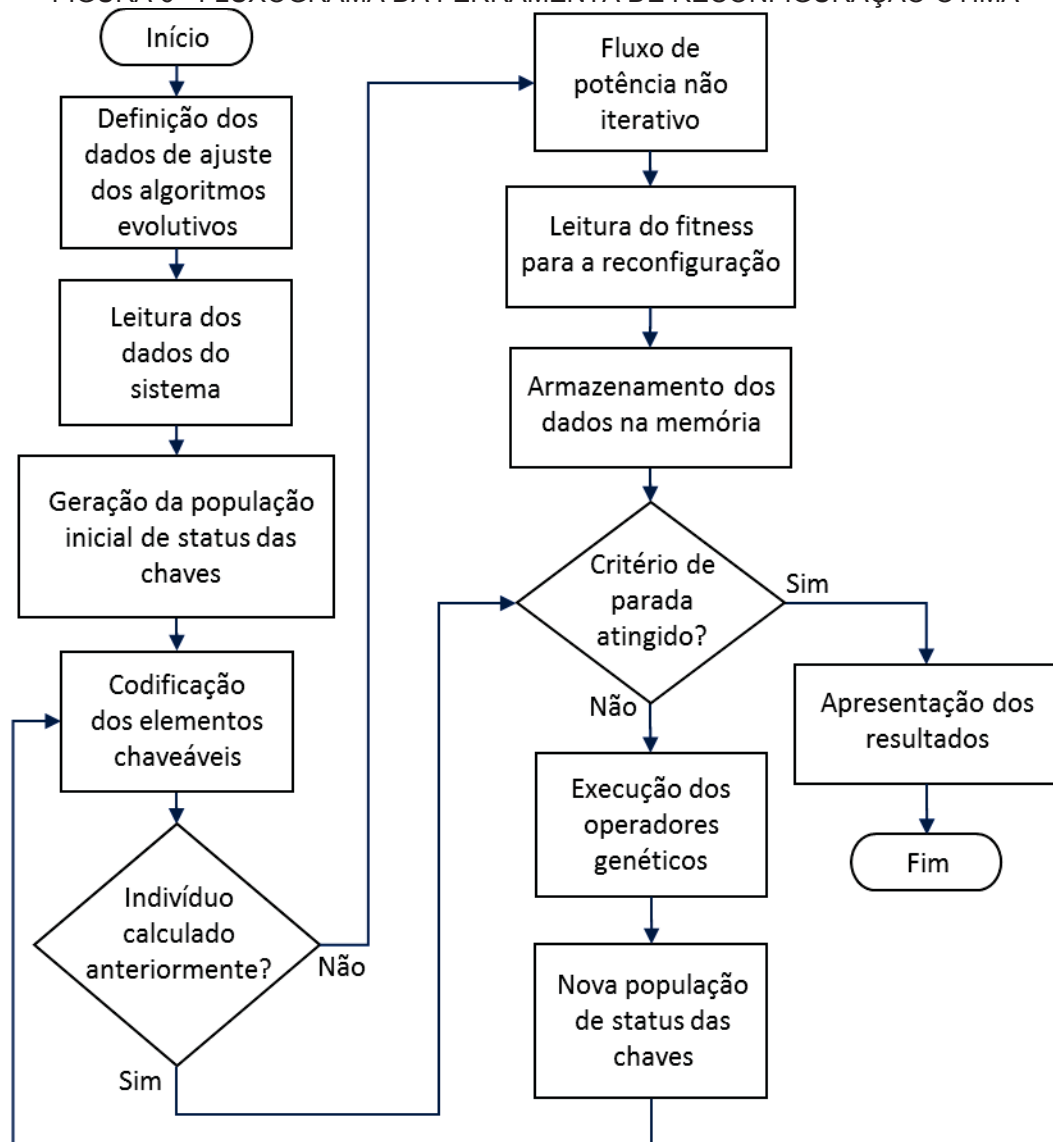
4.1 RECONFIGURAÇÃO ÓTIMA DE SISTEMAS DE DISTRIBUIÇÃO

Para a ferramenta computacional de otimização para apoio à reconfiguração de sistemas de distribuição, parte-se do princípio de que as chaves já estejam alocadas no sistema. Assim, é necessário que sejam apresentados previamente nos dados do sistema, quais ramos possuem chaves alocadas. Com isso, o intuito da metodologia proposta é encontrar a melhor configuração entre aberto ou fechado para cada chave do sistema, a partir da avaliação da função objetivo estabelecida para a operação da rede elétrica.

A ferramenta computacional desenvolvida prevê que o processo de otimização possa ser conduzido pelos dois algoritmos evolutivos considerados neste trabalho, ou seja tanto usando Algoritmos Genéticos como a técnica de Evolução Diferencial, sendo que a escolha cabe ao usuário.

Para um melhor entendimento da ferramenta proposta para a reconfiguração ótima, é apresentado na FIGURA 6 um fluxograma cujas etapas principais são descritas nas próximas subseções.

FIGURA 6 - FLUXOGRAMA DA FERRAMENTA DE RECONFIGURAÇÃO ÓTIMA



FONTE: O Autor, (2020).

A execução dos operadores genéticos ou mesmo da escolha aleatória da população inicial faz com que o número de gerações necessárias para alcançar a convergência do algoritmo possa não refletir diretamente o número de indivíduos avaliados, já que é possível a análise de um mesmo indivíduo mais de uma vez durante o processo.

Assim, a ferramenta proposta conta com um sistema de memória que armazena os dados de cada indivíduo avaliado, eliminando com isso a necessidade de reavaliá-lo caso seja apresentado novamente.

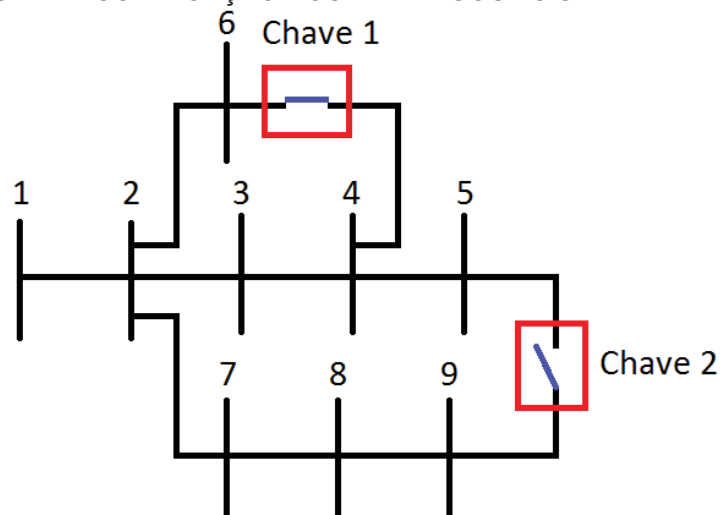
4.1.1 Codificação dos indivíduos para utilização dos algoritmos evolutivos

Conforme citado anteriormente, a forma de codificação dos indivíduos presentes na população dos algoritmos evolutivos é de extrema relevância para a convergência ou não do processo de otimização.

A configuração do *status* de cada chave, deve prever as duas condições possíveis: chave aberta e chave fechada. Com isso, a codificação dos indivíduos associados a cada chave deve ser na forma binária. Assim, para uma determinada chave na condição aberta atribui-se o valor 0 enquanto na condição fechada atribui-se o valor 1.

Para exemplificar a codificação utilizada, é apresentado o sistema de 9 barras e dois ramos chaveáveis da FIGURA 7:

FIGURA 7 - CODIFICAÇÃO DOS INDIVÍDUOS - SISTEMA EXEMPLO



FONTE: O Autor, (2020).

Para a configuração do sistema exemplo apresentado na FIGURA 7, tem-se que a chave 1 encontra-se fechada e com isso receberia o valor 1 para o seu gene correspondente. Consequentemente, como a chave 2 encontra-se aberta, receberia o valor 0, gerando assim o seguinte indivíduo:

$$\text{Indivíduo_exemplo} = [1 \ 0]$$

Assim, todos os genes, que simbolizam o *status* das chaves, apresentam valores 0 ou 1, tanto para os valores aleatórios da população inicial como após as operações de mutação e *crossover* presentes no decorrer do processo evolutivo.

Após a definição do *status* de cada chave, a ferramenta computacional proposta atribui para as chaves indicadas fechadas um valor de impedância muito baixo para a realização da simulação que determina o estado de operação da rede. Já nos casos onde as chaves estão abertas, os seus respectivos ramos são apenas desconsiderados do cálculo.

4.1.2 Função objetivo da reconfiguração

Para o cálculo da função *fitness* que alimenta cada geração nos algoritmos de otimização, foi utilizado a diferença de tensão entre as barras com maior e menor tensão em todo o sistema, conforme descrito na equação (37)

$$fitness_i^G = V_{m\acute{a}x}^i - V_{m\acute{i}n}^i \quad (37)$$

onde:

$fitness_i^G$: Valor a ser otimizado. É calculado para cada indivíduo i da população atual G ;

$V_{m\acute{a}x}^i$: Tensão na barra com maior tensão em todo o sistema, calculada através do fluxo de potência não iterativo para cada indivíduo i ;

$V_{m\acute{i}n}^i$: Tensão na barra com menor tensão em todo o sistema, calculada através do fluxo de potência não iterativo para cada indivíduo i ;

Conforme será apresentado no capítulo de resultados, o máximo desvio de tensão apresenta uma relação direta com as perdas totais no sistema. Para a obtenção dos valores de tensão de cada barra, foi realizado o cálculo do fluxo de potência para cada configuração candidata a solução. Dentre os métodos de cálculo de fluxo de potência, foi escolhido o modelo não iterativo apresentado na seção 3. Essa escolha possibilitou um ganho no quesito de tempo de convergência do algoritmo, visto que o processo não iterativo consegue obter o resultado do fluxo de potência do sistema mais rapidamente, com resultado coerente com a aplicação em questão. Para a obtenção do ângulo base do sistema (θ_{base}) foi considerada a média dos ângulos de cada linha, conforme apresentado na equação (23).

4.1.3 Considerações quanto aos operadores genéticos para a reconfiguração

Na utilização do algoritmo genético como forma de otimização, foram necessárias pequenas adaptações nos seus operadores genéticos. Na mutação, não houve nenhuma modificação no modelo original do algoritmo. Já para a operação de *crossover*, foram selecionados sempre dois pais aleatórios para cada novo indivíduo. Com isso, as mesmas restrições de codificação quanto aos genes de cada indivíduo utilizadas na definição da população inicial foram utilizadas nessa etapa. Na composição da nova população em cada geração foi utilizado uma composição entre elitismo, *crossover* e mutação, com as porcentagens de cada um sendo definidas no início da utilização do algoritmo.

Já na utilização do algoritmo diferencial evolutivo, a mutação exige adaptações. Em cada cálculo dos genes dos indivíduos, é necessário restringir os valores pois esses podem ser negativos, não inteiros e maior que 1. Assim, foi utilizada as restrições apresentadas na equação (38):

$$v_i^{G+1} = \begin{cases} v_i^{G+1}, & \text{se } v_i^{G+1} = 0 \text{ ou } 1 \\ 0, & \text{se } v_i^{G+1} < 0 \\ 1, & \text{se } v_i^{G+1} > 1 \end{cases} \quad (38)$$

Com isso, as condições de codificação são respeitadas e os valores de cada gene sempre representarão o *status* aberto ou fechado de cada chave.

Para o *crossover* do algoritmo diferencial evolutivo, não foram necessárias modificações no processo em si. Porém, foi verificado que quando determinada população apresentava todos os seus indivíduos iguais, o algoritmo não conseguia mais apresentar nenhum indivíduo diferente e seguia com essa população de indivíduos iguais até um dos critérios de parada ser atingido. Isso impactava negativamente o algoritmo pois ele não conseguia encontrar o ótimo em todas as vezes que era executado. Essa população com todos os indivíduos iguais podia acontecer durante o processo de formação aleatória da população inicial ou também após os operadores genéticos na formação de uma população das gerações posteriores.

Esse problema de o algoritmo não conseguir mais gerar novos indivíduos quando a população atual possui todos os indivíduos iguais se deve ao fato de que na

formação do vetor de mutação, a diferença entre os vetores selecionados x_{n2} e x_{n3} sempre vai ser nula, já que os mesmos são iguais. Com isso a mutação apenas repetirá o vetor x_{n1} que neste caso também é igual aos outros, apresentando um vetor literalmente igual ao vetor da população atual. Assim, como o *crossover* é efetuado considerando como pais do novo indivíduo a ser formado, indivíduos do vetor da população atual e do vetor de mutação, todos os seus indivíduos também serão iguais entre si e iguais aos outros dois vetores. Então, a seleção sempre irá comparar vetores com todos os indivíduos iguais e não conseguirá selecionar nenhum indivíduo diferente para a nova população.

Para contornar esse problema, foi inserida uma verificação dentro do *crossover*, com a finalidade de adicionar uma perturbação no processo. Com isso, caso a verificação notasse que ambos os indivíduos correspondentes do vetor da população atual e do vetor de *crossover* eram iguais, um dos genes do vetor de *crossover*, selecionado aleatoriamente, tinha seu valor trocado. Com isso, na seleção da população, nunca ocorreria a comparação de indivíduos iguais entre *crossover* e população atual e conseqüentemente possibilitando o algoritmo de seguir na sua busca normalmente.

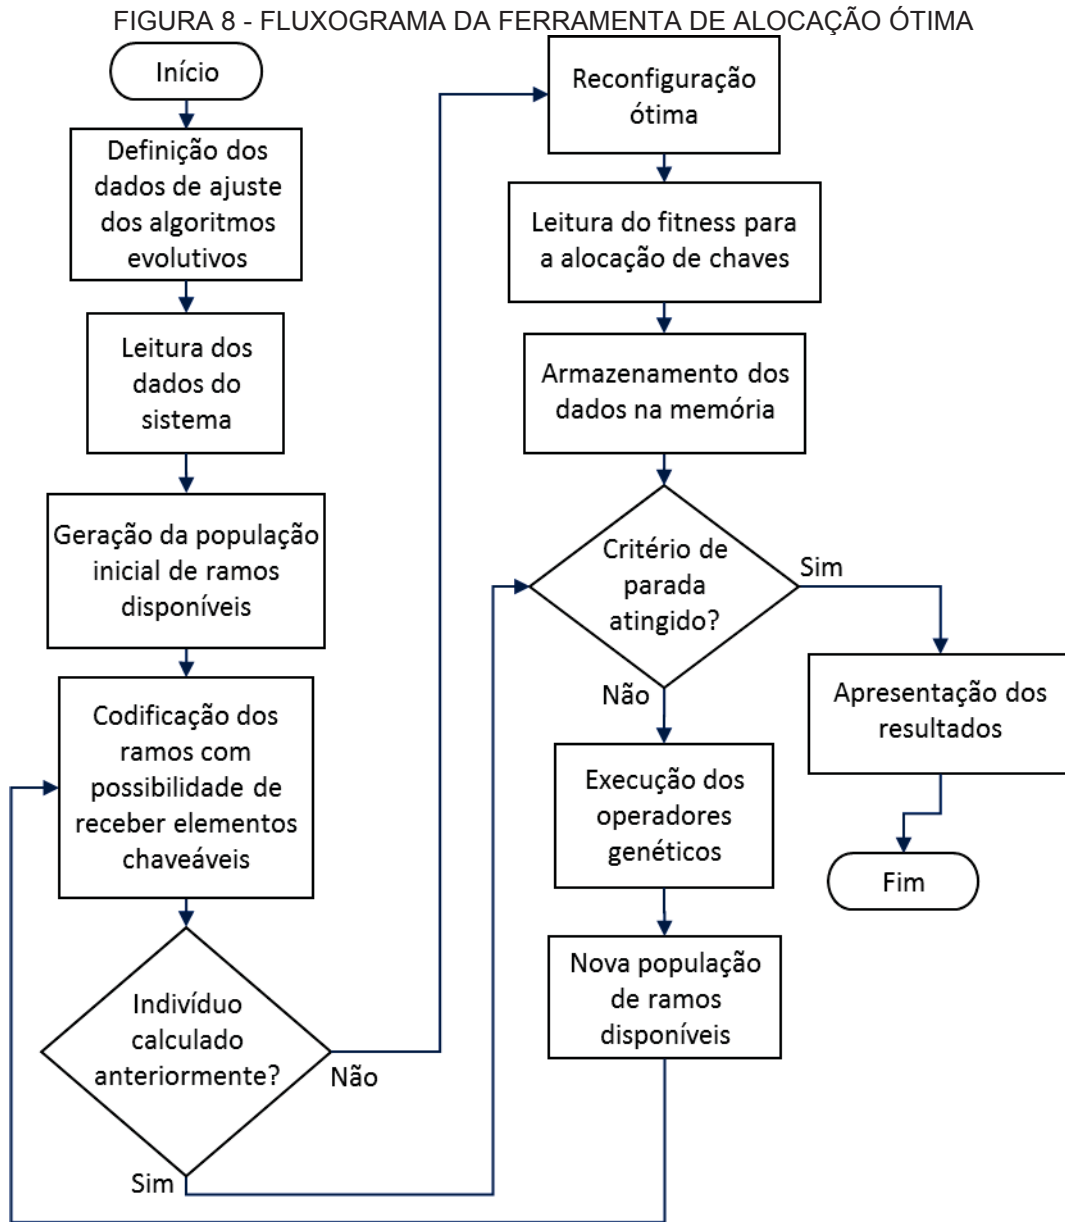
4.2 ALOCAÇÃO ÓTIMA DE CHAVES EM SISTEMAS DE DISTRIBUIÇÃO

Na ótica do planejamento de redes elétricas, a alocação de chaves em sistemas de potência, objetiva verificar em quais ramos dentre os que apresentem disponibilidade para receberem chaves, é melhor alocá-las para conseguir o melhor desempenho. Para que isso seja possível, é necessária a informação prévia de quais ramos podem ser utilizados como ramos chaveáveis e de quantas chaves serão alocadas em cada sistema. Para o número de chaves a serem alocadas foi atribuído a notação n_{CH} .

Na ferramenta proposta, não foram considerados critérios como distribuição geográfica das barras ou custos com implementação de cada ramo disponível para alocação. Essa abordagem foi utilizada considerando-se que essas informações já seriam obtidas pela concessionária de energia, ficando a critério da ferramenta a obtenção dos melhores ramos para alocação, dentre os ramos apresentados como possíveis.

Na alocação de chaves, a ferramenta computacional proposta também permite utilizar ambos os algoritmos evolutivos tratados nesse trabalho.

O fluxograma apresentado na FIGURA 8 apresenta os passos previstos para a metodologia de alocação, que serão melhor descritos nas seções subsequentes.



FONTE: O Autor, (2020).

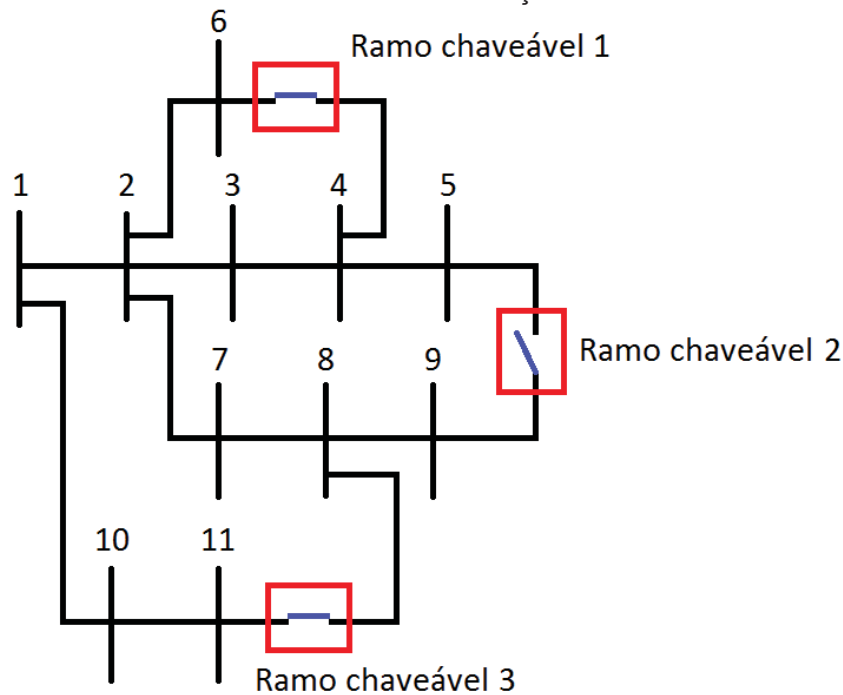
4.2.1 Codificação dos indivíduos para a alocação de chaves

Como na alocação ótima o objetivo é encontrar os ramos que melhor se adaptam com a presença das chaves, cada gene dos indivíduos da população receberá um número correspondente a um dos ramos em questão.

Assim, cada indivíduo candidato à solução será formado por nCH genes, sendo que cada um desses genes representará um dos ramos chaveáveis presentes no sistema. Para o número de ramos chaveáveis presentes no sistema, temos a indicação de $nRCH$.

Para exemplificar a codificação utilizada na alocação, é apresentado o sistema de 11 barras com três ramos chaveáveis da FIGURA 9:

FIGURA 9 - SISTEMA PARA EXEMPLO DA CODIFICAÇÃO DOS INDIVÍDUOS NA ALOCAÇÃO



FONTE: O Autor, (2020).

Para a configuração apresentada e considerando que duas chaves fossem ser alocadas, existiriam as seguintes possibilidades de indivíduos:

Indivíduo_exemplo_1 = [1 2]

Indivíduo_exemplo_2 = [1 3]

Indivíduo_exemplo_3 = [2 3]

Após a definição da população, o próximo passo da ferramenta é testar cada um dos seus indivíduos. Para efetuar esse passo, a ferramenta de alocação utiliza a ferramenta de otimização descrita na seção 5.1. Assim, para cada conjunto de ramos a serem testados em cada geração, a ferramenta de alocação utiliza a reconfiguração ótima para achar o melhor resultado possível com as chaves alocadas nessas posições, apresentando, ao final do algoritmo, não apenas os ramos em que as chaves seriam melhor alocadas mas também qual o *status* ótimo de cada uma.

4.2.2 Função objetivo da alocação

A mesma definição de *fitness* utilizada para a otimização da reconfiguração foi utilizada na alocação de chaves, sendo esta a diferença de tensão entre as barras de maior e menor tensão do sistema.

Então, em cada geração do algoritmo de alocação, é efetuado a análise de todos os indivíduos da população com seus respectivos ramos a serem testados. Nessa análise, é realizada a reconfiguração ótima dos ramos de cada indivíduo, até que se chegue no melhor valor de *fitness* possível na reconfiguração. Esse valor será armazenado e utilizado como o *fitness* da alocação.

Como em cada geração da alocação tem-se a execução de diversas vezes a ferramenta de reconfiguração ótima, a utilização do fluxo de potência não iterativo se faz ainda mais necessária para que o tempo de convergência total do algoritmo de alocação fique em valores aceitáveis.

4.2.3 Operadores genéticos na alocação de chaves

Para a ferramenta de alocação, a utilização do algoritmo genético como forma de otimização necessita também de algumas adequações no algoritmo original. Na mutação, a seleção de um gene para sofrer modificação ocorre ainda de forma aleatória, sendo que o gene poderá receber qualquer valor entre 1 e o número de ramos chaveáveis presentes no sistema. A única restrição nesse caso é que o novo valor de gene não pode ser igual ao antigo. Já a operação de *crossover*, apenas necessita que as mesmas condições de restrição quanto aos genes de cada indivíduo utilizadas na definição da população inicial sejam utilizadas novamente. Assim como na ferramenta de reconfiguração, aqui também é utilizado uma composição entre elitismo, *crossover* e mutação, para gerar as novas populações em cada geração.

Na utilização do algoritmo diferencial evolutivo, a mutação permanece exigindo adaptações. Dessa vez, as restrições de valores que os genes podem assumir necessitam estar no intervalo $[1 \ nRCH]$. A equação (39) apresenta as restrições em questão:

$$v_i^{G+1} = \begin{cases} v_i^{G+1}, & \text{se } v_i^{G+1} \in [1 \ nRCH] \\ 1, & \text{se } v_i^{G+1} < 1 \\ nRCH, & \text{se } v_i^{G+1} > nRCH \end{cases} \quad (39)$$

Com isso, as condições de codificação são respeitadas e os valores de cada gene sempre apresentarão ramos chaveáveis a serem testados em cada indivíduo da população atual. Aqui também não foram necessárias adaptações para o *crossover* em si do algoritmo diferencial evolutivo. Porém, permanece o problema da ferramenta não conseguir gerar mais indivíduos diferentes caso uma população possua todos os indivíduos iguais. Com isso, a mesma solução de inserir uma verificação de igualdade entre vetor de *crossover* e vetor da população atual se faz necessária, com a inserção de uma perturbação em um dos genes do indivíduo do vetor de *crossover* caso os indivíduos correspondentes desses dois vetores sejam iguais.

4.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foi apresentada a metodologia desenvolvida para a utilização da ferramenta de otimização proposta.

Foram abordados aspectos da codificação de cada otimização para a sua utilização nos tipos de problemas propostos, além da apresentação do *fitness* utilizado para a otimização bem como a forma de mesclar esse estudo com o fluxo de potência não iterativo.

5 ANÁLISE DOS RESULTADOS E DISCUSSÃO

Este capítulo destina-se a apresentação dos resultados obtidos com as metodologias propostas, de forma a avaliar seu desempenho e funcionalidade. Esta apresentação é feita em duas partes. Na primeira parte serão apresentados os resultados considerando um sistema teste de 33 barras e, na sequência, serão apresentados os resultados para um sistema teste de 906 barras.


Ambos os sistemas serão avaliados tanto em relação ao uso da ferramenta de reconfiguração ótima, onde as chaves do sistema já se encontram alocadas, quanto em relação à ferramenta de alocação ótima, que busca indicar os melhores locais para a localização das chaves.

Todas as simulações foram executadas utilizando um notebook Dell Inspiron 2017, com sistema operacional Windows 10 64 bits, processador Intel(R) Core(TM) i7-7500 CPU 2.70 GHz, memória RAM instalada de 8 GB (utilizável 7,88 GB) e disco rígido tecnologia convencional com 1 TB de capacidade.

5.1 VALIDAÇÃO DA FERRAMENTA EM UM SISTEMA DE MENOR PORTE

Para a primeira parte das simulações, foi escolhido um sistema teste menor, com 33 barras. A topologia original desse sistema é apresentada na FIGURA 10. Os resultados obtidos para as simulações desse sistema serão apresentados na sequência.


FIGURA 10 - DIAGRAMA UNIFILAR PARA O SISTEMA TESTE DE 33 BARRAS



FONTE: Adaptado de Eminoglu et al., (2009)

Para validar a utilização do método de cálculo de fluxo de potência não iterativo como meio de obtenção do *fitness* da ferramenta proposta, foi verificado como seria o seu comportamento no sistema teste proposto. A FIGURA 11 apresenta um comparativo entre os valores de tensão obtidos com o método não iterativo e com o método tradicional Newton-Raphson:

FIGURA 11 - COMPARATIVO ENTRE OS PERFIS DE TENSÃO DOS MÉTODOS NÃO ITERATIVO E NEWTON-RAPHSON – 33 BARRAS




FONTE: O autor, (2020)

Comparando os resultados obtidos em ambos os métodos, é possível verificar como o método não iterativo apresenta uma excelente aproximação na obtenção dos valores de tensão de cada barra do sistema.

Para ampliar a forma de comparação entre os dois métodos, é apresentado na FIGURA 12 um perfil associado aos erros provenientes do cálculo da tensão de cada barra:

FIGURA 12 - PERFIL DOS ERROS DE TENSÃO COM A UTILIZAÇÃO DO MÉTODO NÃO ITERATIVO – 33 BARRAS




FONTE: O autor, (2020)

Ao analisar-se a FIGURA 12 é possível verificar que os maiores erros encontrados com a utilização do método não iterativo estão abaixo de 0,24%, o que justifica sua utilização na ferramenta proposta, já que se trata de um erro baixo se comparado aos benefícios que o método pode trazer nas ferramentas de otimização.

5.1.1 Reconfiguração ótima

Para aumentar a diversidade de arranjos topológicos para esse sistema, foi considerada a inclusão de três novas linhas de distribuição, com elementos chaveáveis, conectando às barras 22-26, 15-33 e 8-25. Essa configuração pode ser verificada na FIGURA 13, onde os ramos chaveáveis estão destacados na cor azul. Com isso o sistema passa a contar com diversas condições topológicas possíveis, passando da configuração radial convencional até uma topologia em malha. Além disso, foi considerada a presença de geração distribuída nas barras 5, 18 e 31.

FIGURA 13 - DIAGRAMA UNIFILAR ADAPTADO PARA O SISTEMA TESTE DE 33 BARRAS



FONTE: Modificado de Eminoglu et al., (2009)

Num primeiro momento, foram avaliadas para o sistema em questão, todas as oito possíveis topologias que os diferentes chaveamentos podem proporcionar, o que servirá de base para a aferição da ferramenta computacional desenvolvida. Assim, na sequência, são apresentadas os resultados obtidos com a mesma.

i) Avaliação exaustiva

A relação do estado de cada elemento chaveável nos diferentes casos é apresentada na TABELA 1, sendo o sistema radial assumido como caso base, onde todas as chaves encontram-se abertas.


TABELA 1 - ESTADO DOS ELEMENTOS CHAVEÁVEIS NAS DIFERENTES CONFIGURAÇÕES

Casos	Caso 1 (base)	Caso 2	Caso 3	Caso 4	Caso 5	Caso 6	Caso 7	Caso 8
Chave	<i>Status</i>							
1	Aberta	Fechada	Aberta	Aberta	Fechada	Aberta	Fechada	Fechada
2	Aberta	Aberta	Fechada	Aberta	Fechada	Fechada	Aberta	Fechada
3	Aberta	Aberta	Aberta	Fechada	Aberta	Fechada	Fechada	Fechada

FONTE: O autor (2020)

Para cada diferente caso, foi efetuado o cálculo do fluxo de potência não iterativo. O gráfico da FIGURA 14 apresenta o perfil de tensão obtido considerando as diferentes topologias do sistema:


FIGURA 14 - COMPARATIVO DOS PERFIS DE TENSÃO APRESENTADOS PARA CADA TOPOLOGIA DO SISTEMA DE 33 BARRAS



FONTE: O autor (2020)

Com a robustez e agilidade possibilitada pelo uso do fluxo de potência não iterativo, é possível verificar também, na FIGURA 15, a quantidade de barras que violam limites estabelecidos de tensão (nesse caso assumiu-se um desvio máximo de 5% em relação ao nominal).

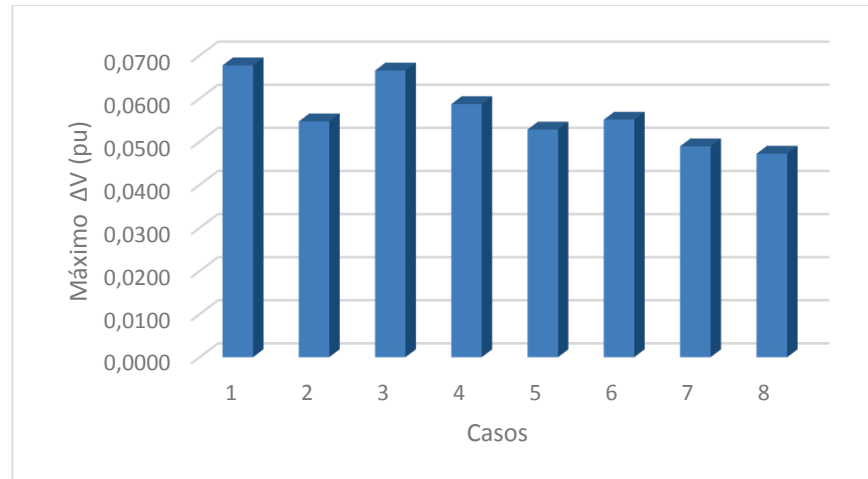
FIGURA 15 - QUANTIDADE DE BARRAS VIOLANDO O LIMITE DE TENSÃO – 33 BARRAS



FONTE: O autor (2020)

Outra importante informação obtida para o processo de reconfiguração, foi a máxima variação de tensão observada no sistema para cada arranjo topológico. Como as perdas apresentadas em cada cenário e consequentemente a eficiência de cada topologia guarda relação com os desníveis de tensão, essa informação se torna extremamente útil para a análise da melhor topologia a ser utilizada. A FIGURA 16 apresenta as máximas variações de tensão observadas nos cenários avaliados.

FIGURA 16 - MÁXIMO VALOR DE DESVIO DE TENSÃO PARA CADA TOPOLOGIA – 33 BARRAS




FONTE: O autor (2020)

Conforme explicado no Capítulo 4, essa informação de máximo desvio de tensão é utilizada nos algoritmos de otimização como *fitness* para a busca da melhor solução. É possível observar que após a análise de todos os casos, a configuração com menor desvio de tensão é quando todas as chaves encontram-se fechadas. Assim, essa informação servirá de referência para a verificação da convergência ótima dos algoritmos de otimização.

A fim de se avaliar a correspondência entre o máximo desvio de tensão e outro elemento comum de interesse num processo de otimização que são as perdas do sistema, o comportamento destas foi verificado com o método tradicional Newton-Raphson para todos os casos apresentados anteriormente. A relação entre essas grandezas pode ser verificada na FIGURA 17:

FIGURA 17 - COMPARAÇÃO ENTRE OS PERFIS DE PERDAS E ΔV MÁXIMO NOS DIFERENTES CASOS – 33 BARRAS



FONTE: O autor (2020)

É possível verificar que as perdas ativas apresentam variação muito semelhante ao observado com o máximo desvio de tensão para as diferentes configurações, o que justifica a utilização deste como *fitness* do processo de otimização, indicando que, ao reduzir-se o desvio de tensão, tem-se também uma configuração com menores perdas ativas.

ii) Avaliação da ferramenta computacional

Após a verificação da configuração ótima para esse sistema, foi então executado a ferramenta de reconfiguração ótima desenvolvida considerando, num primeiro momento, o Algoritmo Genético como método de busca. Para esse método, os valores de ajuste da ferramenta foram configurados da seguinte forma:

- Tamanho da população = 4 indivíduos;
- Taxa de Elitismo = 10 %;
- Taxa de *Crossover* = 50 %;
- Taxa de Mutação = Taxa de Elitismo - Taxa de *Crossover*;
- Tolerância para verificar a convergência = 10^{-6} ;
- Número máximo de gerações = 50.

Para avaliar o comportamento da ferramenta computacional, foi efetuada a execução da mesma por 10 vezes verificando-se a convergência e o *status* ótimo alcançado. Esses resultados são apresentados na TABELA 2:

TABELA 2 - RESULTADO PARA RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 33 BARRAS COM O ALGORITMO GENÉTICO

Nº da execução	Status ótimo			Fitness ótimo	Menor tensão		Nº de gerações p/ convergência
	Chave 1	Chave 2	Chave 3		Barra	V (pu)	
1	1	1	1	0,0472	33	0,9528	17
2	1	1	1	0,0472	33	0,9528	17
3	1	1	1	0,0472	33	0,9528	17
4	1	1	1	0,0472	33	0,9528	18
5	1	1	1	0,0472	33	0,9528	18
6	1	1	1	0,0472	33	0,9528	17
7	1	1	1	0,0472	33	0,9528	17
8	1	1	1	0,0472	33	0,9528	17
9	1	1	1	0,0472	33	0,9528	17
10	1	1	1	0,0472	33	0,9528	17

FONTE: O autor (2020)

É possível notar que em todas as simulações o algoritmo convergiu para a mesma solução, que foi a configuração com as três chaves fechadas. Essa é a mesma configuração encontrada quando analisaram-se todas as possibilidades. No Apêndice 1 é possível verificar a robustez da ferramenta comparando a sua execução por 100 vezes, quando levou um tempo total de 4,29 segundos. Considerando que o algoritmo sempre convergiu para a mesma solução, e que cada simulação individual leva em torno de 0,05 segundos, tem-se uma indicação para a utilização em aplicações de tempo real.

Após a execução com o algoritmo genético, foi efetuada também a execução da ferramenta de otimização com o algoritmo Diferencial Evolutivo como método de busca. Para esse método, os valores de ajuste foram configurados da seguinte forma:

- Tamanho da população = 4 indivíduos;
- Coeficiente de variação diferenciável $F=0.6$;
- Constante de cruzamento $CR=0.5$;
- Tolerância para verificar a convergência = 10^{-6} ;
- Número máximo de gerações = 50.

Seguindo a mesma lógica utilizada para o algoritmo genético, foi efetuada a execução da ferramenta com o algoritmo diferencial evolutivo também por 10 vezes para comparar se a convergência ótima era alcançada em todas elas. Esses resultados são apresentados na TABELA 3:

TABELA 3 - RESULTADO PARA RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 33 BARRAS COM O ALGORITMO DIFERENCIAL EVOLUTIVO


Nº da execução	Status ótimo			Fitness ótimo	Menor tensão		Nº de gerações p/ convergência
	Chave 1	Chave 2	Chave 3		Barra	V (pu)	
1	1	1	1	0,0472	33	0,9528	17
2	1	1	1	0,0472	33	0,9528	17
3	1	1	1	0,0472	33	0,9528	17
4	1	1	1	0,0472	33	0,9528	17
5	1	1	1	0,0472	33	0,9528	17
6	1	1	1	0,0472	33	0,9528	17
7	1	1	1	0,0472	33	0,9528	17
8	1	1	1	0,0472	33	0,9528	17
9	1	1	1	0,0472	33	0,9528	20
10	1	1	1	0,0472	33	0,9528	17

FONTE: O autor (2020)

É possível notar que em todas as simulações o algoritmo convergiu para a mesma solução. No Apêndice 1 também é apresentado a comparação da ferramenta sendo utilizada por 100 vezes. Nessa quantidade, o tempo de execução total foi de 6,45 segundos, e para cada simulação individual em torno de 0,07 segundos o que também pode indicar sua utilização em aplicações de tempo real.

A fim de se avaliar um outro cenário para reconfiguração, foi utilizada uma nova configuração de chaveamento, como indicado na FIGURA 18. Para essa situação estão sendo consideradas as mesmas definições de carga e geração distribuída apresentadas anteriormente.

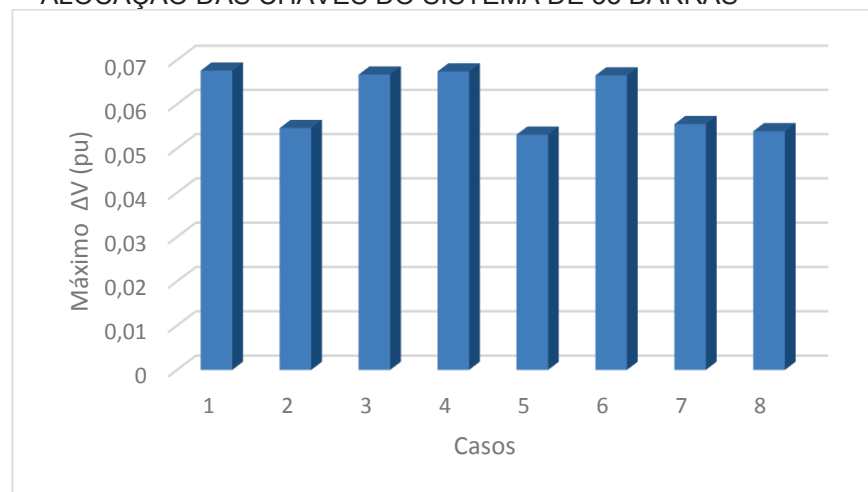
FIGURA 18 – NOVA POSIÇÃO DE RAMOS CHAVEÁVEIS NO SISTEMA TESTE DE 33 BARRAS



FONTE: Adaptado de Eminoglu et al., (2009)

Como nessa situação o número de chaves continua sendo três, o número total de diferentes combinações de chaveamento também é oito. Na FIGURA 19 é possível verificar quais os valores máximos de desvio de tensão em cada uma dessas configurações. Os casos apresentados são os mesmos que foram demonstrados na TABELA 1.

FIGURA 19 - MÁXIMO VALOR DE DESVIO DE TENSÃO PARA CADA TOPOLOGIA NA NOVA ALOCAÇÃO DAS CHAVES DO SISTEMA DE 33 BARRAS




FONTE: O autor (2020)

É possível verificar que a configuração com menor desvio máximo de tensão acontece no caso 5, que corresponde à situação onde as chaves 1 e 2 encontram-se fechadas e a chave 3 encontra-se aberta. Nas condições apresentadas, essa configuração é a solução ótima mesmo se comparada com a topologia malhada representada pelo caso 8.

Assim como no caso anterior, também foi verificado a correspondência entre o máximo desvio de tensão com as perdas do sistema, utilizando o método Newton-Raphson para todos os casos apresentados. Essa relação pode ser verificada na FIGURA 20:

FIGURA 20 - COMPARAÇÃO ENTRE OS PERFIS DE PERDAS E ΔV MÁXIMO NOS DIFERENTES CASOS COM A NOVA ALOCAÇÃO DE CHAVES – 33 BARRAS



FONTE: O autor (2020)

Para essa nova configuração também é possível notar um comportamento muito semelhante entre as perdas totais do sistema e o máximo desvio de tensão de cada caso, certificando assim a escolha do *fitness* utilizado.

Assim, foi utilizado a ferramenta de reconfiguração ótima para essa situação, afim de se verificar se ela também poderia identificar essa mesma condição. Os ajustes nos parâmetros dos algoritmos evolutivos foram os mesmos apresentados na seção 5.1.1. Com isso, foram obtidos os resultados apresentados na TABELA 4:

TABELA 4 – RECONFIGURAÇÃO ÓTIMA APLICADA A NOVA CONFIGURAÇÃO DO SISTEMA TESTE DE 33 BARRAS.

Algoritmo de otimização	Status ótimo			Fitness ótimo	Menor tensão		Nº de gerações	Tempo médio de execução
	Chave 1	Chave 2	Chave 3		Barra	V (pu)		
Algoritmo Genético	1	1	0	0,0531	15	0,9469	20	0,08 s
Algoritmo Diferencial Evolutivo	1	1	0	0,0531	15	0,9469	20	0,12 s

FONTE: O autor (2020)

Analisando os resultados da TABELA 4 é possível notar que a ferramenta de reconfiguração ótima conseguiu encontrar a melhor solução mesmo quando essa não apresenta todas as chaves fechadas. Ambos os algoritmos de otimização conseguiram convergir para o ótimo, diferenciando-se apenas no tempo de execução. O algoritmo genético converge mais rápido nessa situação devido ao fato de que a seleção para uma nova população de indivíduos do algoritmo diferencial evolutivo obriga-o a calcular o *fitness* tanto para a população atual como para a população de


cruzamento a cada geração, enquanto o algoritmo genético calcula apenas para a população atual.

Porém, essa desvantagem de tempo é compensada em sistemas de grande porte, já que justamente por verificar duas populações em cada geração, o algoritmo diferencial evolutivo converge mais rapidamente quando o problema apresenta um número elevado de possíveis soluções. Isso ficará mais evidente com a utilização de um sistema de grande porte para as simulações.

5.1.2 Alocação ótima de chaves

Para a metodologia proposta para a alocação ótima de chaves, foram efetuadas adaptações no sistema teste de 33 barras da FIGURA 10. Nesse caso, o intuito é o de verificar entre determinados possíveis ramos para a alocação de chaves, quais resultariam no melhor desempenho do sistema considerando a alocação de três chaves. Com isso em mente, foram inseridos quinze ramos entre as barras do sistema, como sendo os ramos candidatos a receberem chaves, como indicado em azul na FIGURA 21.

FIGURA 21 – RAMOS CHAVEÁVEIS CONSIDERADOS PARA ALOCAÇÃO DE CHAVES NO SISTEMA TESTE DE 33 BARRAS



FONTE: Adaptado de Eminoglu et al., (2009)

Vale ressaltar que a determinação dos ramos apresentados como aptos a receberem chaves foi feita aleatoriamente, não levando em consideração aspectos geográficos ou econômicos, considerando que essa avaliação seja feita pela concessionária de energia.

Como o resultado obtido através da alocação de chaves irá apresentar os ramos selecionados para a alocação, é necessário apresentar uma indicação para cada ramo, associando o mesmo às barras em que está conectado. Essa relação é apresentada na TABELA 5.

TABELA 5 - RELAÇÃO DE RAMOS CHAVEÁVEIS COM SUAS RESPECTIVAS BARRAS

Ramo	Barra de origem	Barra de destino
1	4	20
2	5	21
3	6	22
4	7	26
5	8	25
6	9	28
7	10	29
8	11	30
9	12	31
10	13	32
11	14	33
12	15	33
13	4	23
14	5	24
15	22	26

FONTE: O autor (2020)

Com a utilização efetiva da ferramenta de alocação ótima, após a inserção dos ramos, buscou-se determinar a configuração que apresentava melhor desempenho com a alocação de três chaves. Além disso, combinando a alocação ótima com a reconfiguração ótima, foi possível verificar também o *status* de cada chave na melhor configuração.

Para efetuar o teste da ferramenta de alocação, foi considerado o sistema proposto na FIGURA 21. Porém, para inserir mais diversidade na análise, foram considerados diferentes cenários na realização dos testes. Para cada cenário foi atribuído um peso sendo que a composição do *fitness* final de cada alocação é a soma da multiplicação do peso de cada cenário pelo seu respectivo *fitness*. Os cenários utilizados são apresentados a seguir:

- Cenário 1 – Caso base
 - Peso = 0,5;
 - Número de barras com GD = 3;
 - Carga nominal do sistema teste.

- Cenário 2 – Alta carga e geração nominal
 - Peso = 0,2;
 - Número de barras com GD = 3;
 - Aumento de carga de 30% em todas as barras com carga no sistema.

- Cenário 3 – Baixa carga e alta geração
 - Peso = 0,2;
 - Número de barras com GD = 32;
 - Diminuição de carga de 30% em todas as barras com carga no sistema.

Com isso, foram efetuados os testes considerando o algoritmo genético como ferramenta de otimização da alocação. Os valores de ajuste do algoritmo genético são apresentados abaixo:

- Tamanho da população = 4 indivíduos;
- Taxa de Elitismo = 10 %;
- Taxa de *Crossover* = 50 %;
- Taxa de Mutação = Taxa de Elitismo - Taxa de *Crossover*;
- Tolerância para verificar a convergência = 10^{-6} ;
- Número máximo de gerações = 1000.

Para a ferramenta de reconfiguração ótima, foram utilizados os mesmos valores apresentados na seção anterior. Então, com o mesmo intuito de demonstrar a capacidade de convergência da ferramenta de alocação, foi considerada sua execução por dez vezes, para poder comparar se os resultados se mantinham em cada execução. Esses resultados podem ser conferidos na TABELA 6.

TABELA 6 - RESULTADO DA ALOCAÇÃO ÓTIMA PARA O SISTEMA DE 33 BARRAS CONSIDERANDO OS DIFERENTES CENÁRIOS COM O ALGORITMO GENÉTICO.

Nº da execução	Ramos selecionados para alocação de chaves			<i>Fitness</i> ótimo	Nº de gerações p/ convergência
1	5	12	15	0,0465	462
2	5	12	15	0,0465	433
3	5	12	15	0,0465	474
4	5	12	15	0,0465	433
5	5	12	15	0,0465	434

6	5	15	12	0,0465	435
7	5	15	12	0,0465	454
8	5	12	15	0,0465	466
9	5	12	15	0,0465	451
10	5	12	15	0,0465	775

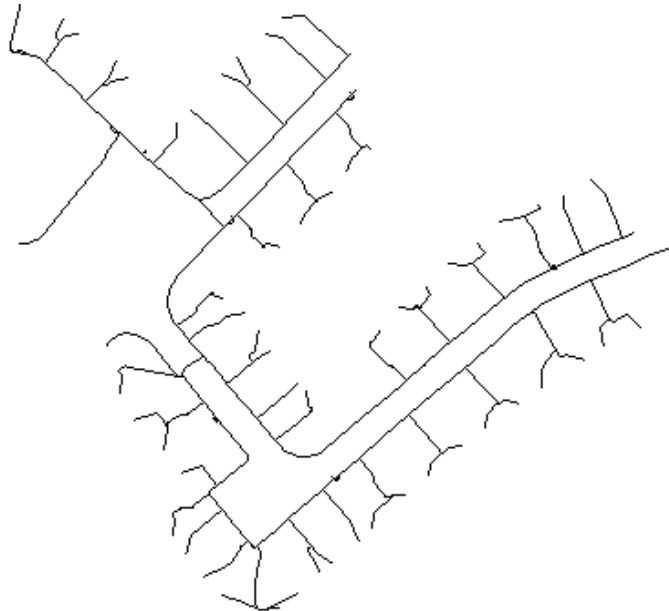
FONTE: O autor (2020)

É possível verificar que em todas as execuções a ferramenta convergiu para a mesma solução. Vale salientar que para os resultados apresentados na TABELA 6, o *fitness* não representa diretamente uma grandeza elétrica como anteriormente, já que é o resultado da composição dos *fitness* de cada cenário.

5.2 SISTEMA TESTE DE 906 BARRAS

Após a consolidação dos resultados em um sistema teste de menor porte, foram efetuadas simulações com as ferramentas de otimização em um sistema teste de grande porte. Nessa análise, foi considerado o sistema teste Europeu de 906 barras apresentado na FIGURA 22:

FIGURA 22 – SISTEMA TESTE IEEE EUROPEU 906 BARRAS



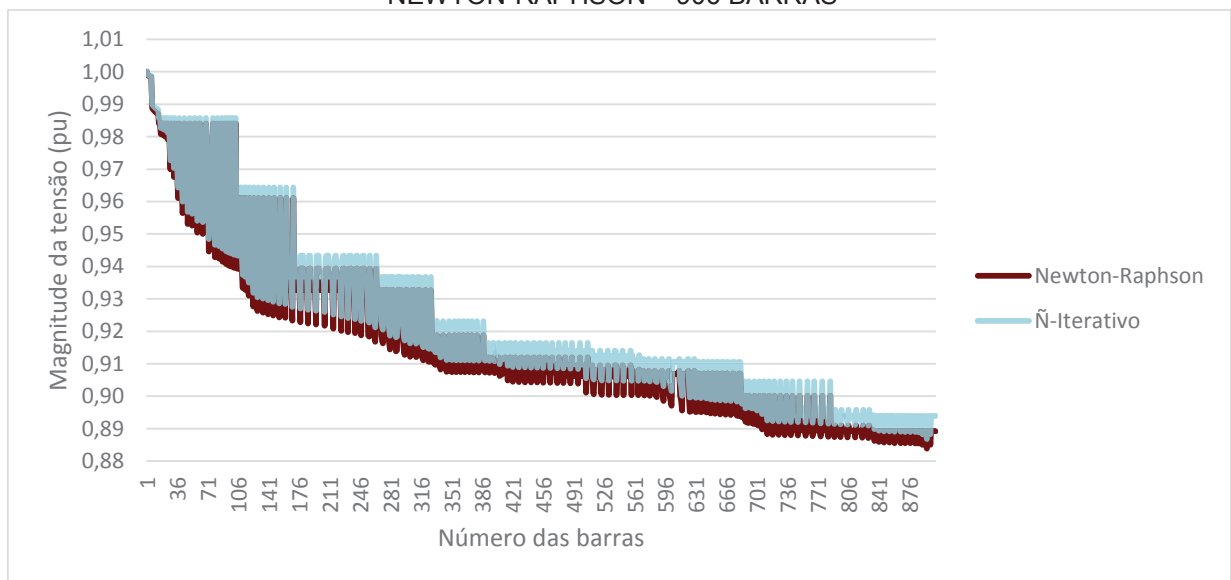
FONTE: IEE PES

Foram efetuadas algumas modificações nos dados do sistema teste original buscando proporcionar uma situação operativa mais extrema, com maior queda de tensão para o sistema. Assim, o baixo carregamento inicial foi aumentado em quatro

vezes e também foi considerado o aumento no comprimento de cada linha de distribuição, multiplicando os valores de resistências e reatâncias de cada linha por dois. Como as modificações foram feitas na mesma proporção tanto na resistência como na reatância das linhas, não houve nenhum impacto no ângulo base do sistema para a normalização complexa.

A FIGURA 23 apresenta o comparativo entre os valores de tensão obtidos com o método não iterativo e com o método tradicional Newton-Raphson:

FIGURA 23- COMPARATIVO ENTRE OS PERFIS DE TENSÃO DOS MÉTODOS NÃO ITERATIVO E NEWTON-RAPHSON – 906 BARRAS




FONTE: O autor, (2020)

No gráfico da FIGURA 23 os dois perfis de tensão apresentados aparecem sobrepostos para a maioria das barras. Por esse motivo, no perfil de tensão do método não iterativo foi aplicado um efeito de transparência para que seja possível observar ao fundo o perfil obtido com o método de Newton, quando este está sobreposto.

Além disso, é apresentado na FIGURA 24 o gráfico associado aos erros provenientes do cálculo da tensão de cada barra:

FIGURA 24 - PERFIL DOS ERROS DE TENSÃO COM A UTILIZAÇÃO DO MÉTODO NÃO ITERATIVO – 906 BARRAS



FONTE: O autor, (2020)

Analisando a comparação para esse sistema teste maior é possível novamente verificar que o método não iterativo apresenta uma excelente aproximação para os valores de magnitude de tensão de cada barra do sistema, mesmo nessa condição mais extrema de operação. Como os maiores erros encontrados com a utilização do método não iterativo estão abaixo de 0,5%, essa ferramenta continua sendo válida para o cálculo do *fitness* dos processos de otimização devido principalmente a grande agilidade que essa ferramenta traz.

5.2.1 Reconfiguração ótima

Assim como para o sistema teste de 33 barras, foram inseridos ramos chaveáveis entre algumas barras do sistema. Para essa topologia, foi considerada a inclusão de cinco chaves, conforme apresentado na TABELA 7:

TABELA 7 - RAMOS CHAVEÁVEIS INSERIDOS NO SISTEMA TESTE DE 906 BARRAS

Ramo	Barra de origem	Barra de destino
1	70	248
2	249	327
3	320	619
4	639	899
5	34	458

FONTE: O autor (2020)

Com a inclusão desses ramos o sistema passa a contar com trinta e duas condições topológicas possíveis, desde a sua configuração radial original até a topologia malhada. Para critério de comparação posterior com a ferramenta de reconfiguração ótima, serão analisados primeiramente alguns casos isolados desse sistema. Devido ao maior número de possibilidades, a comparação entre os diferentes casos levará em consideração apenas quatro dessas configurações, passando pelos casos mais extremos com todas as chaves abertas ou todas fechadas. A TABELA 8 apresenta os diferentes casos analisados, sendo o sistema radial assumido como caso base, onde todas as chaves encontram-se abertas.

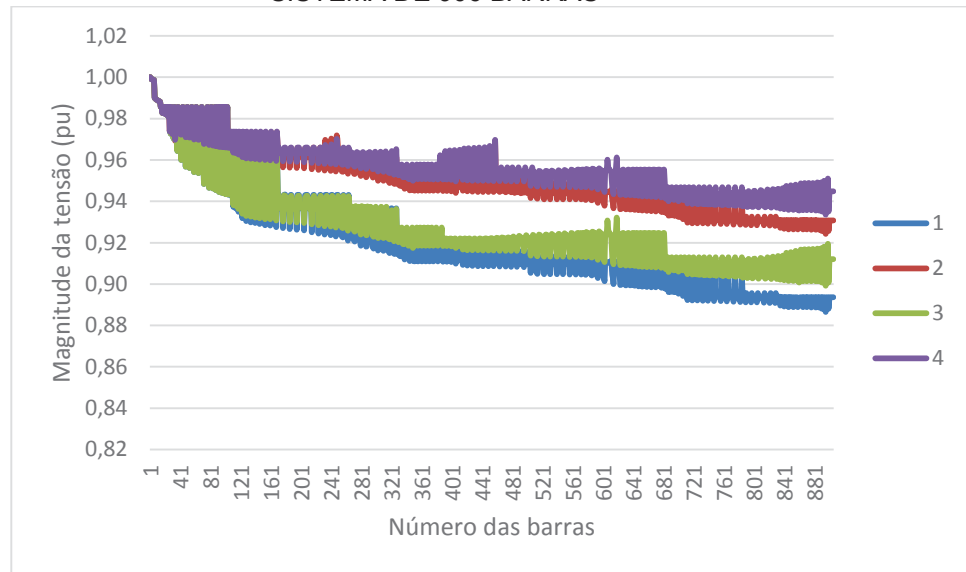
TABELA 8 - ESTADO DOS ELEMENTOS CHAVEÁVEIS NOS QUATRO CASOS DIFERENTES

Casos	Caso 1 (base)	Caso 2	Caso 3	Caso 4
Chave	<i>Status</i>			
1	Aberta	Fechada	Aberta	Fechada
2	Aberta	Aberta	Fechada	Fechada
3	Aberta	Aberta	Fechada	Fechada
4	Aberta	Aberta	Fechada	Fechada
5	Aberta	Fechada	Aberta	Fechada

FONTE: O autor (2020)

Para os quatro diferentes casos foi efetuado o cálculo do fluxo de potência não iterativo. O gráfico da FIGURA 25 apresenta o perfil de tensão obtido considerando as diferentes topologias do sistema. Devido ao número elevado de barras, são apresentadas apenas algumas barras do sistema:

FIGURA 25 - COMPARATIVO DOS PERFIS DE TENSÃO APRESENTADOS PARA CADA CASO DO SISTEMA DE 906 BARRAS



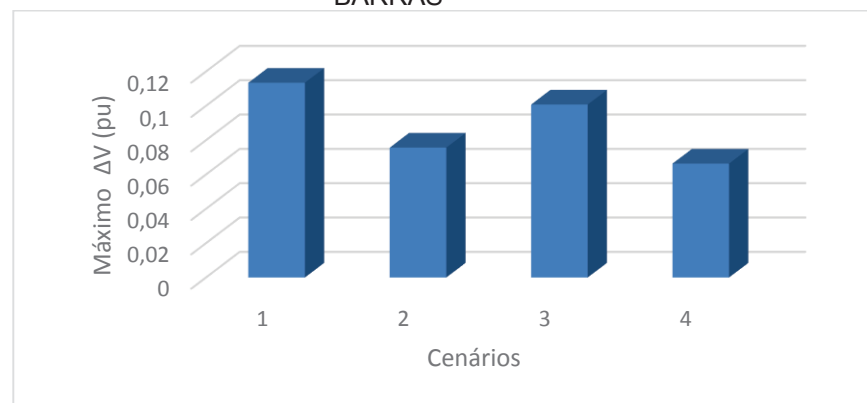
FONTE: O autor (2020)

É possível notar que o caso 4, apresenta a melhor condição de perfil de tensão. Comparado com o caso base, essa diferença se torna ainda mais significativa.

Já se compararmos os casos 2 e 3, é possível notar que mais chaves fechadas não necessariamente refletem um melhor resultado. O caso 2 apresenta um melhor resultado de perfil de tensão que o caso 3 mesmo possuindo uma chave fechada a menos. Essa constatação reforça a importância da verificação do melhor local para a alocação de chaves.

Além dos perfis de tensão de cada caso, também foram obtidos os máximos desvios de tensão, conforme apresentado na FIGURA 26:

FIGURA 26 - MÁXIMO VALOR DE DESVIO DE TENSÃO PARA CADA CASO DO SISTEMA DE 906 BARRAS




FONTE: O autor (2020)

É possível observar que a configuração com menor desvio de tensão também ocorre quando todas as chaves encontram-se fechadas. Essa informação será novamente utilizada como *fitness* dos algoritmos de otimização.

Assim como nos casos anteriores, também foram efetuadas simulações para verificar a correspondência entre perdas e máximo desvio de tensão, utilizando o método Newton-Raphson para os casos apresentados. Essa relação pode ser verificada na FIGURA 27:

FIGURA 27 - COMPARAÇÃO ENTRE OS PERFIS DE PERDAS E ΔV MÁXIMO NOS DIFERENTES CASOS - 906 BARRAS



FONTE: O autor (2020)

Assim como no sistema de menor porte, o comportamento das perdas se mostrou muito semelhante ao comportamento do máximo desvio de tensão.

Após a análise de alguns casos isolados, foi efetuada a simulação do sistema teste de 906 barras com a ferramenta de reconfiguração ótima, mantendo-se a posição de alocação das chaves apresentada na TABELA 7. Ambos os algoritmos de otimização utilizados na seção 5.1.1 foram utilizados novamente, com a única diferença nos parâmetros de configuração sendo realizada para o número de gerações máximas, que passou de 50 para 60.

Seguindo a lógica apresentada anteriormente, foram executadas 10 simulações para cada algoritmo, para se verificar se a solução ótima sempre era alcançada. Esses resultados podem ser verificados nas TABELA 9 e 10, respectivamente para o algoritmo genético e para o algoritmo diferencial evolutivo:

TABELA 9 - RESULTADO PARA A RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 906 BARRAS COM O ALGORITMO GENÉTICO

Nº da Execução	Status ótimo					Fitness ótimo	Menor tensão		Nº de gerações	Tempo (s)
	Chave 1	Chave 2	Chave 3	Chave 4	Chave 5		Barra	V (pu)		
1	1	1	1	1	1	0,0664	896	0,9336	27	263,00
2	1	1	1	1	1	0,0664	896	0,9336	22	219,30
3	1	1	1	1	1	0,0664	896	0,9336	20	252,60
4	1	1	1	1	1	0,0664	896	0,9336	20	259,60
5	1	1	1	1	1	0,0664	896	0,9336	21	348,10
6	1	1	1	1	1	0,0664	896	0,9336	29	244,83
7	1	1	1	1	1	0,0664	896	0,9336	21	227,00
8	1	1	1	1	1	0,0664	896	0,9336	20	227,79
9	1	1	1	1	1	0,0664	896	0,9336	33	263,79
10	1	1	1	1	1	0,0664	896	0,9336	20	255,39

FONTE: O autor (2020)

TABELA 10 - RESULTADO PARA A RECONFIGURAÇÃO ÓTIMA DO SISTEMA DE 906 BARRAS COM O ALGORITMO DIFERENCIAL EVOLUTIVO

Nº da Execução	Status ótimo					Fitness ótimo	Menor tensão		Nº de gerações	Tempo (s)
	Chave 1	Chave 2	Chave 3	Chave 4	Chave 5		Barra	V (pu)		
1	1	1	1	1	1	0,0664	896	0,9336	31	151,33
2	1	1	1	1	1	0,0664	896	0,9336	22	168,23
3	1	1	1	1	1	0,0664	896	0,9336	38	143,02
4	1	1	1	1	1	0,0664	896	0,9336	27	193,37
5	1	1	1	1	1	0,0664	896	0,9336	21	109,45
6	1	1	1	1	1	0,0664	896	0,9336	25	238,08
7	1	1	1	1	1	0,0664	896	0,9336	20	239,50
8	1	1	1	1	1	0,0664	896	0,9336	22	181,81
9	1	1	1	1	1	0,0664	896	0,9336	21	152,05
10	1	1	1	1	1	0,0664	896	0,9336	23	143,09

FONTE: O autor (2020)

Os resultados apresentados mostram a eficácia da ferramenta de reconfiguração ótima, já que com ambos os algoritmos de otimização, a ferramenta sempre converge para a solução malhada. Esse *status* ótimo já era esperado, devido a análise feita com os perfis de tensão e os máximos desvios de tensão, apresentadas anteriormente.

Conforme comentado no final da seção 5.1.2 é possível verificar que, diferentemente das simulações para o sistema teste de 33 barras, o algoritmo diferencial evolutivo leva, na média das execuções, um tempo menor de execução para chegar na solução ótima do sistema teste de 906 barras, se comparado com o

algoritmo genético, o que indica uma maior facilidade desse algoritmo em lidar com sistemas de maior porte.

Após as simulações com cinco chaves, foram efetuados testes com sete e oito chaves para verificar como o sistema se comportaria nessas situações. Nesses casos, o número de configurações possíveis passa a ser de 128 e 256 respectivamente. Esses resultados são apresentados nas TABELAS 11 e 12:

TABELA 11 – RECONFIGURAÇÃO ÓTIMA - 906 BARRAS - 7 CHAVES

Algoritmo Evolutivo	Status ótimo							Fitness ótimo	Nº de gerações	Tempo (s)
	Chave 1	Chave 2	Chave 3	Chave 4	Chave 5	Chave 6	Chave 7			
GA	1	1	1	1	1	1	1	0,0636	62	830
DE	1	1	1	1	1	1	1	0,0636	41	227,32

FONTE: O autor (2020)

TABELA 12 - RECONFIGURAÇÃO ÓTIMA - 906 BARRAS - 8 CHAVES

Algoritmo Evolutivo	Status ótimo - Chaves								Fitness ótimo	Nº de gerações	Tempo (s)
	Chave 1	Chave 2	Chave 3	Chave 4	Chave 5	Chave 6	Chave 7	Chave 8			
GA	1	1	1	1	1	1	1	1	0,0609	116	1682
DE	1	1	1	1	1	1	1	1	0,0609	43	294,03

FONTE: O autor (2020)

Pode-se verificar que ambos os algoritmos sempre evoluem para a mesma configuração que, nesses casos, também foi com todas as chaves fechadas.

É interessante notar que com o aumento no número de chaves, ambos os algoritmos necessitam de um número maior de gerações e um tempo maior de processamento para encontrar a solução ótima, o que era esperado. Porém, o algoritmo genético é muito mais sensível a essa mudança, o que novamente mostra como o algoritmo diferencial evolutivo tem mais facilidade em lidar com problemas onde o número de soluções possíveis é elevado.

5.2.2 Alocação ótima de chaves

Após a reconfiguração, foram efetuadas simulações para a alocação de chaves no sistema teste de 906 barras. Nesse caso, foram inseridos vinte

possibilidades diferentes para ramos chaveáveis, conforme é apresentado na TABELA 13:


TABELA 13 - RELAÇÃO DE RAMOS CHAVEÁVEIS PARA O SISTEMA DE 906 BARRAS

Ramo	Barra de origem	Barra de destino
1	70	248
2	47	208
3	83	225
4	73	264
5	249	327
6	178	320
7	314	611
8	289	563
9	276	337
10	387	629
11	320	619
12	639	899
13	34	458
14	74	556
15	522	349
16	406	860
17	629	896
18	502	835
19	562	898
20	676	886

FONTE: O autor (2020)

Para a definição desses ramos, foram consideradas apenas barras que tivessem somente uma conexão com outra barra, priorizando assim as barras localizadas nas partes extremas do sistema. A FIGURA 28 apresenta destacadas a maioria das barras com apenas uma ligação nesse sistema teste:

FIGURA 28 – BARRAS DO SISTEMA TESTE DE 906 BARRAS COM APENAS UMA CONEXÃO



FONTE: Adaptado de IEE PES

Para efetuar o teste da ferramenta de alocação nesse sistema, foram mantidos os parâmetros de ajuste dos algoritmos evolutivos utilizados na seção 5.1.2, considerando nesse caso três chaves para serem alocadas. Também foram inseridas geração distribuída em todas as barras com carga do sistema.

Além disso, foram considerados dois cenários diferentes, conforme apresentado abaixo:

- Cenário 1 – Alta carga e geração nominal
 - Peso = 0,5;
 - Número de barras com GD = 55;
 - Aumento de carga de 30% em todas as barras com carga no sistema.

- Cenário 2 – Baixa carga e alta geração
 - Peso = 0,5;
 - Número de barras com GD = 55, com aumento de 30% para cada GD em relação ao cenário anterior;
 - Diminuição de carga de 30% em todas as barras com carga no sistema.

Com isso, foram efetuadas as simulações da ferramenta de alocação ótima de chaves para o sistema teste de 906 barras. Os resultados podem ser verificados na TABELA 14:

TABELA 14 – ALOCAÇÃO ÓTIMA APLICADA AO SISTEMA TESTE DE 906 BARRAS.

Algoritmo de otimização	Ramos selecionados para alocação de chaves			Fitness ótimo	Nº de gerações
	13	16	17		
Algoritmo Genético	13	16	17	0,0565	269
Algoritmo Diferencial Evolutivo	13	16	17	0,0565	311

FONTE: O autor (2020)

Analisando os resultados, pode-se verificar que, com ambos os algoritmos de otimização, a ferramenta de alocação convergiu para os mesmos resultados, mostrando a eficiência na utilização de qualquer um deles. Como a modificação dos cenários ocorre de forma proporcional em todo o sistema, a convergência para o mesmo resultado nas diferentes situações era também esperada.

Para analisar-se como a alocação de chaves influencia o *fitness* foi verificado o comportamento do sistema para a alocação de diversos números de chaves diferentes. Esses resultados podem ser verificados nas TABELAS 15 e 16 para o algoritmo diferencial evolutivo e para o algoritmo genético, respectivamente:

TABELA 15 – EVOLUÇÃO DO *FITNESS* COM O AUMENTO DO NÚMERO DE CHAVES ALOCADAS – DIFERENCIAL EVOLUTIVO.

Número de chaves alocadas	Nº de combinações possíveis	Ramos selecionados	<i>Fitness</i> ótimo	Nº de gerações
1	20	13	0,0633	143
2	190	13-14	0,0592	157
3	1140	13-16-17	0,0565	249
4	4845	8-13-16-17	0,0531	212
5	15504	8-13-14-16-17	0,0506	182
6	38760	1-8-13-14-16-17	0,0482	327
7	77520	1-5-11-13-14-16-17	0,0469	247
8	125970	1-5-10-11-13-14-16-17	0,0456	275
9	167960	1-5-9-10-11-13-14-16-17	0,0445	319
10	184756	1-3-5-9-10-11-13-14-16-17	0,0434	323

FONTE: O autor (2020)

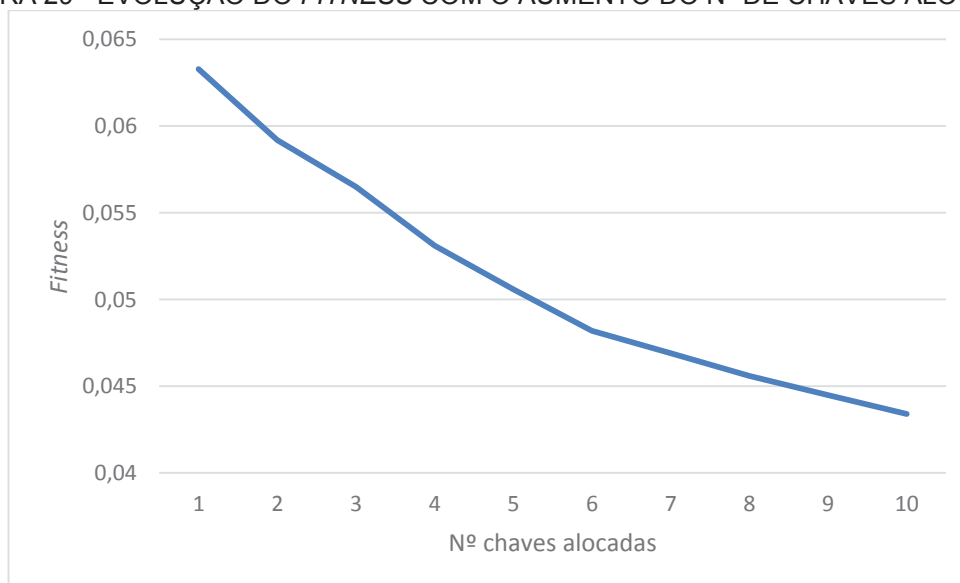
TABELA 16 – EVOLUÇÃO DO *FITNESS* COM O AUMENTO DO NÚMERO DE CHAVES ALOCADAS – ALGORITMO GENÉTICO.

Número de chaves alocadas	Nº de combinações possíveis	Ramos selecionados	<i>Fitness</i> ótimo	Nº de gerações
1	20	13	0,0633	147
2	190	13-14	0,0592	181
3	1140	13-16-17	0,0565	244
4	4845	8-13-16-17	0,0531	312
5	15504	8-13-14-16-17	0,0506	181
6	38760	1-8-13-14-16-17	0,0482	287
7	77520	1-5-11-13-14-16-17	0,0469	346
8	125970	1-5-10-11-13-14-16-17	0,0456	372
9	167960	1-3-5-9-11-13-14-16-17	0,0445	224
10	184756	1-3-5-9-10-11-13-14-16-17	0,0434	264

FONTE: O autor (2020)

Além disso, foi verificado também a evolução do *fitness* com o aumento do número de chaves em forma de gráfico. Esse resultado é apresentado na FIGURA 29.

FIGURA 29 - EVOLUÇÃO DO *FITNESS* COM O AUMENTO DO Nº DE CHAVES ALOCADAS



FONTE: O autor (2020)

É possível verificar que a partir de um determinado número de chaves a melhoria do *fitness* ótimo começa a ser menos significativa, o que pode servir como um indicador do número adequado de chaves a ser considerado para tal sistema

5.3 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Neste capítulo foram apresentadas as simulações da ferramenta proposta para dois sistemas teste diferentes, considerando também cenários para diversificar a sua aplicação.

Os resultados apresentados nas diversas situações evidenciam a eficiência da ferramenta proposta, no sentido de otimização da reconfiguração e da alocação de chaves em redes de distribuição.

6 CONSIDERAÇÕES FINAIS

6.1 CONCLUSÕES DO TRABALHO

Neste trabalho foi apresentado o comportamento de ferramentas de otimização para a reconfiguração e alocação de chaves em redes de distribuição utilizando algoritmos genéticos e o algoritmo diferencial evolutivo como métodos de busca da solução ótima.

Com a reconfiguração ótima é possível verificar a melhor solução para o *status* de cada chave presente no sistema, melhorando assim as condições de operação e aumentando a confiabilidade do sistema de energia como um todo.

Além disso, a alocação otimizada de chaves proporciona uma poderosa ferramenta para o estudo do planejamento de redes de distribuição, podendo efetuar a análise de diversos cenários diferentes simultaneamente, o que facilita a aproximação do estudo do planejamento aos casos reais frequentemente observados.

Com a utilização da normalização complexa foi possível adequar os parâmetros das redes de distribuição, possibilitando assim a utilização do fluxo de potência não iterativo para o cálculo das tensões nas barras presentes nesses sistemas.

Após o estudo dos algoritmos evolutivos foi verificado a facilidade desses algoritmos para a resolução de problemas com crescimento exponencial de soluções, fazendo com que sua aplicação traga inúmeros benefícios aos processos de reconfiguração e alocação de chaves.

Assim, a combinação do fluxo de potência não iterativo com as ferramentas de otimização baseadas nos algoritmos evolutivos resultou em uma robusta ferramenta de otimização para aplicação em sistemas de distribuição.

6.2 TRABALHOS FUTUROS

As metodologias apresentadas nesse trabalho possuem uma abrangência muito grande em relação à otimização aplicada a problemas de redes de distribuição. A seguir são apresentadas sugestões para a continuidade dos estudos nessa área específica:

- Aplicação da metodologia para apoio de estudos de reconfiguração / restauração ótima após a ocorrência de uma falta;
- Utilizar alguma técnica de detecção de ilhamento no sistema para confirmar a conectividade entre as barras em cada configuração diferente;
- Introduzir uma análise do custo de cada nova chave alocada e de perdas diretas para garantir que o ganho gerado pela alocação seja suficiente para justificar sua utilização;
- Aproveitar a ferramenta como apoio no estudo do número ideal de chaves a serem alocadas em cada sistema;
- Analisar os processos de alocação e reconfiguração de forma diferentes para verificar o melhor *fitness* a ser utilizado em cada um.
- Introduzir novas formas de *fitness* como perdas diretas e número de barras violando os limites de tensão para analisar cada nova configuração.

REFERÊNCIAS

- AKRAMI, A.; DOOSTIZADEH, M.; AMINIFAR F. Optimal Reconfiguration of Distribution Network Using μ PMU Measurements: A Data-Driven Stochastic Robust Optimization. **IEEE Transactions on smart grid**, v. 11, n. 1, pp. 420-428, 2020.
- ALVES, H. N. A Hybrid Algorithm for Optimal Placement of Switches Devices in Electric Distribution Systems. **IEEE LATIN AMERICA TRANSACTIONS**, v. 10, n. 6, pp. 2218-2223, 2012.
- AMBRÓSIO, B.A.S. **Método não-iterativo para determinação das tensões nodais em sistemas de distribuição ativos**. 2018. 87 f. Dissertação (mestrado em engenharia elétrica) - Setor de tecnologia Universidade Federal do Paraná, Curitiba (PR), 2018.
- AMBRÓSIO, B.A.S.; TORTELLI, O.L. A Non-iterative Method for Distribution Systems Power Flow Analysis. **The 12th Latin-American Congress on Electricity Generation and Transmission – CLAGTEE**, 2017.
- ASSIS, L.S.; GONZÁLEZ, J.F.V.; USBERTI, et al. Switch Allocation Problems in Power Distribution Systems. **IEEE Transactions on Power Systems**, v. 30, n. 1, pp. 246-253, 2015.
- BAHRAMABADI, M.Z.; ABBASPOUR, A.; FIRUZABAD, M.F.; AGHTAIE, M.M. Resilience-based framework for switch placement problem in power distribution systems. **IET Generation, Transmission & Distribution**, v. 12, i. 5, pp. 1223-1230, 2018.
- BENITEZ, I.; CHAPARRO, E.; BARÁN, B. Distribution System Operation and Expansion Planning Using Network Reconfiguration. **IEEE Latin America Transactions**, v. 18, n. 5, pp. 845-852, 2020.
- BOTEA, A.; RINTANEN, J.; BANERJEE D.. Optimal reconfiguration for supply restoration with informed a* search. **IEEE Trans. Smart Grid**, v. 3, n. 2, pp. 583–593, 2012.
- DAVIS, L. D. Handbook of Genetic Algorithms. **Artificial Intelligence 100**, pp. 325-330, 1998.
- DEB, A.; ROY, J. S.; GUPTA, B. A. Differential Evolution Performance Comparison. **IEEE Antennas & propagation magazine**, pp.51-61, 2018.
- DURCE, C.C.; TORTELLI, O L.; LOURENÇO, E.M.; LODDI, T. Complex normalization to perform power flow analysis in emerging distribution systems. **2012 3rd IEEE PES Innovative Smart Grid Technologies Europe**, 2012.
- DURCE, C.C. **Normalização complexa e cálculo de fluxo de potência para sistemas elétricos emergentes**. 2012. 110 f. Dissertação (mestrado em engenharia elétrica) - Setor de tecnologia Universidade Federal do Paraná, Curitiba (PR), 2012.

ELTAEIB, T.; MAHMOOD, A. Differential Evolution: A Survey and Analysis. **Applied Sciences**, v. 8, n. 10, 2018.

EMINOGLU, U.; GÖZEL, T.; HOCAOGLU, M.H. DSPFAP: Distribution Systems Power Flow Analysis Package Using Matlab Graphical User Interface (GUI). **Wiley Periodicals Inc**, 2009.

FOGAÇA, A.L. **Análise da alocação de controladores UPFC em sistemas de potência via algoritmos genéticos**. 2009. 73 f. Dissertação (mestrado em engenharia elétrica) - Setor de tecnologia Universidade Federal do Paraná, Curitiba (PR), 2009.

FONSECA, A.G.; TORTELLI, O.L.; LOURENÇO, E.M. Extended fast decoupled power flow for reconfiguration networks in distribution system. **IET Generation, Transmission & Distribution**, 2018.

GALIAS, Z. Tree-Structure Based Deterministic Algorithms for Optimal Switch Placement in Radial Distribution Networks. **IEEE Transactions on Power Systems**, v. 34, n. 6, pp. 4269-4278, 2019.

GARCIA, A.V. et al. Automatização da Distribuição de Energia Elétrica: Simulação Utilizando o Fluxo de Carga Desacoplado Rápido. **V Congresso Brasileiro de Automática / I Congresso Latino Americano de Automática**, pp.256-261, 1984.

GÜLER, T.; GROSS, G. Detection of island formation and identification of causal factors under multiple line outages. **IEEE Trans. Power Syst.**, pp. 22, 2007.

GEREZ, C.; SILVA, L.; BELATI, E.; SGUAREZI, A.J.F.; COSTA, E.M. Distribution Network Reconfiguration Using Selective Firefly Algorithm and a Load Flow Analysis Criterion for Reducing the Search Space. **IEEE Access**, v. 7, pp. 67874-67888, 2019.

GOMES, R.B. **Resolução do problema de fluxo de carga para redes de distribuição utilizando o método desacoplado rápido com rotação automática de eixos**. 2006. 90 f. Dissertação (mestrado em engenharia elétrica) - Faculdade de engenharia elétrica e computação da Universidade Estadual de Campinas, Campinas (SP), 2006.

GONG, Z.; CHEN, Q.; SUN, K. Novel methodology solving distribution network reconfiguration with DG placement. **The 14th IET International Conference on AC and DC Power Transmission**, v. 2019 i. 16, pp. 1668-1674, 2019.

IEEE PES. Distribution Systems Analysis Subcommittee Radial Test Feeders. Disponível em: <http://ewh.ieee.org/soc/pes/dsacom/testfeeders.html>.

KARAAOM, C.; JIRAPONG, P.; THARARAK, P.; TANTRAPON, K. Optimal Allocation of Tie Switch in Distribution Systems for Energy Loss Reduction Using Particle Swarm Optimization. **8th International Electrical Engineering Congress (iEECON)**, 2020.

KIM, H.; CHONG, J.; PARK, K.; LOWTHER, D. A. Differential Evolution Strategy for Constrained Global Optimization and Application to Practical Engineering Problems.

IEEE transactions on magnetics, v. 43, n. 4, 2007.

LARIMI, S.M.M.; HAGHIFAM, M.R.; MORADKHANI, A. Risk-based reconfiguration of active electric distribution networks. **IET Gener. Transm. Distrib.**, v. 10, n. 4, pp. 1006–1015, 2016.

LEÓN, F. e SEMLYEN, A.. Iterative solvers in the Newton power flow problem: preconditioners, inexact solutions, and partial Jacobian updates. **IEE Proc., Gener. Transm. Distrib.**, 149, 2002.

LI, J. **Reconfiguration of power networks based on graph-theoretic algorithms**. Dissertação de Ph.D., Iowa State University, Ames, IA, USA, 2010
Kashem, M.A., Ganapathy, V., Jasmon, G.B. Network reconfiguration for enhancement of voltage stability in distribution networks. **IEE Proc., Gener. Transm. Distrib.**, v. 147, n. 3, p. 171, 2000.

LI, Z.S., WANG, J.H., SUN, H.B., et al. Transmission contingency analysis based on integrated transmission and distribution power flow in smart grid. **IEEE Trans. Power Syst.**, pp. 3356–3367, 2015.

LOURENÇO, E.M., COSTA, A.S., PINTO JR, R.R., Steady-state solution for power networks modeled at bus section level. **IEEE Trans. Power Syst.**, pp. 10–20, 2010a.

LOURENÇO, E.M., DA SILVA, N. e COSTA, A.S.. Fast decoupled steady-state solution for power networks modeled at the bus section level. **IEEE Bucharest Power Tech Conf.**, 2009.

LOURENCO, E., LODDI, T. e TORTELLI, O.. Unified load flow analysis for emerging distribution systems. **Innovative Smart Grid Technologies Conf. Europe**, 2010b.

MASHHOUR, E. e MOGHADDAS-TAFRESHI, S.M.. Three-phase backward/forward power flow solution considering three-phase distribution transformers. **IEEE Int. Conf. on Industrial Technology**, 2009.

MITCHELL, M. **An introduction to genetic algorithms**. Cambridge: Mit Press, 1997.

MOHAMED, A.W. Differential Evolution (DE): A Short Review. **Robotics & Automation engineering journal**, v. 2, n. 1, 2018.

MONTICELLI, A.J. **Fluxo de Carga em Redes de Energia Elétrica**. São Paulo: Edgar Blücher, 1983.

MONTICELLI, A. **State estimation in electric power systems – a generalized approach**. Springer: Kluwer, 1999.

PORTELINHA, R.K.; DURCE, C.C.; TORTELLI, O.L.; LOURENCO, E.M.; PAL, B.C. Unified Transmission and Distribution Fast Decoupled Power Flow. **Journal of Control, Automation and Electrical Systems**, v. 30, p. 1051-1058, 2019.

ROCCA, P.; OLIVERI, G.; MASSA, A. Differential Evolution as Applied to

electromagnetics. **IEEE Antennas and Propagation Magazine**, v. 53, n. 1, 2011.

RODRIGUES, F.; ARAUJO, L.; PENIDO, D. Optimization of Reliability through Switch Reconfiguration in Distribution Systems. **IEEE Latin America Transactions**, v. 17, n. 6, pp. 972-982, 2019.

STAGG, G.W.; EI-ABIAD, A.H. **Computer methods in power system analysis**. McGraw-Hill, 1968.

STORN, R.; PRICE, K. Differential Evolution - A Simple and Efficient Heuristic for Global Optimization over Continuous Spaces. **Journal of Global Optimization**, 1997.

SUN, H.; GUO, Q.; ZHANG, B. et al. Master-slave-splitting based distributed global power flow method for integrated transmission and distribution analysis. **IEEE Trans. Smart Grid**, pp. 1484–1492, 2015.

SYAHPUTRA, R.; ROBANDI, I.; ASHARI, M. Optimal distribution network reconfiguration with penetration of distributed energy resources. **Int. Conf. on Information Technology, Computer and Electrical Engineering**, pp. 388–393 Q3, 2014.

TARJAN, R. Depth-first search and linear graph algorithms. **12th Annual Symp. on Switching and Automata Theory**, pp. 114–121, 1971.

TORTELLI, O.L.; LOURENÇO, E.M.; GARCIA, A.V.; PAL, B.C. Fast decoupled power flow to emerging distribution systems via complex pu normalization. **IEEE Transactions on Power Systems**, pp. 1351-1358, 2015.

TSAI, M.S., Development of an object-oriented service restoration expert system with load variations. **IEEE Trans. Power Syst.**, v. 23, n. 1, pp. 219– 225, 2008.

WONG, K.P.; DONG Z.Y. Differential Evolution, an Alternative Approach to Evolutionary Algorithm. **Proceedings of the 13th International Conference on, Intelligent Systems Application to Power Systems**, 2005.

XING, H.; HONG, S. Ordinal optimisation approach for complex distribution network reconfiguration. **The Journal of Engineering**, v. 2019 i. 18, pp. 5055-5058, 2019.

YANG, H., WEN, F., WANG, L., et al. Newton-downhill algorithm for distribution power flow analysis. **2nd IEEE Int. Conf. on Power and Energy**, 2008.

YUAN, H.; LI F.; WEI Y.; e ZHU J. Novel Linearized Power Flow and Linearized OPF Models for Active Distribution Networks With Application in Distribution LMP. **IEEE Transactions on Smart Grid**, v. 9, n. 1, pp. 438-448, 2018.

ZARE, M.; AZIZIPANAH-ABARGHOOEE, R.; HOOSHMAND, R.; MALEKPOUR, M. Optimal reconfigurattion of distribution systems by considering switch and wind turbine placements to enhance reliability and efficiency. **IET Generation, Transmission & Distribution**, v. 12, n. 6, pp. 1271-1284, 2018.

ZIDAN, A., EL-SAADANY, E.F.. A cooperative multiagent framework for self-healing mechanisms in distribution systems. **IEEE Trans. Smart Grid**, v. 3, n. 3, pp. 1525–1539, 2012.

ZUBEN, F.J.V. *Computação Evolutiva: Uma Abordagem Pragmática*. São Paulo: Unicamp, 2011.

APÊNDICES

APÊNDICE 1 – DEMONSTRAÇÃO DA CONVERGÊNCIA DAS FERRAMENTAS PROPOSTAS

Para confirmar a robustez das ferramentas de otimização apresentadas, foi efetuado a execução das mesmas por 100 vezes para critério de comparação entre execuções. O intuito era verificar se a ferramenta conseguia convergir sempre e para a mesma solução. Os resultados podem ser verificados nas TABELAS 17 e 18:

TABELA 17 - RESULTADO PARA OTIMIZAÇÃO DO SISTEMA DE 33 BARRAS COM O ALGORITMO GENÉTICO COM EXECUÇÃO DE 100 VEZES

Nº Execução	Status ótimo			Fitness ótimo	Maior tensão		Menor tensão		Nº de gerações p/ convergência
	Chave 1	Chave 2	Chave 3		Barra	V (pu)	Barra	V (pu)	
1	1	1	1	0,0472	1	1	33	0,9528	17
2	1	1	1	0,0472	1	1	33	0,9528	18
3	1	1	1	0,0472	1	1	33	0,9528	17
4	1	1	1	0,0472	1	1	33	0,9528	18
5	1	1	1	0,0472	1	1	33	0,9528	18
6	1	1	1	0,0472	1	1	33	0,9528	17
7	1	1	1	0,0472	1	1	33	0,9528	18
8	1	1	1	0,0472	1	1	33	0,9528	20
9	1	1	1	0,0472	1	1	33	0,9528	17
10	1	1	1	0,0472	1	1	33	0,9528	17
11	1	1	1	0,0472	1	1	33	0,9528	17
12	1	1	1	0,0472	1	1	33	0,9528	19
13	1	1	1	0,0472	1	1	33	0,9528	17
14	1	1	1	0,0472	1	1	33	0,9528	20
15	1	1	1	0,0472	1	1	33	0,9528	17
16	1	1	1	0,0472	1	1	33	0,9528	20
17	1	1	1	0,0472	1	1	33	0,9528	19
18	1	1	1	0,0472	1	1	33	0,9528	22
19	1	1	1	0,0472	1	1	33	0,9528	17
20	1	1	1	0,0472	1	1	33	0,9528	17
21	1	1	1	0,0472	1	1	33	0,9528	17
22	1	1	1	0,0472	1	1	33	0,9528	20
23	1	1	1	0,0472	1	1	33	0,9528	17
24	1	1	1	0,0472	1	1	33	0,9528	17
25	1	1	1	0,0472	1	1	33	0,9528	17
26	1	1	1	0,0472	1	1	33	0,9528	17
27	1	1	1	0,0472	1	1	33	0,9528	17
28	1	1	1	0,0472	1	1	33	0,9528	17

29	1	1	1	0,0472	1	1	33	0,9528	22
30	1	1	1	0,0472	1	1	33	0,9528	17
31	1	1	1	0,0472	1	1	33	0,9528	18
32	1	1	1	0,0472	1	1	33	0,9528	17
33	1	1	1	0,0472	1	1	33	0,9528	20
34	1	1	1	0,0472	1	1	33	0,9528	27
35	1	1	1	0,0472	1	1	33	0,9528	17
36	1	1	1	0,0472	1	1	33	0,9528	19
37	1	1	1	0,0472	1	1	33	0,9528	17
38	1	1	1	0,0472	1	1	33	0,9528	17
39	1	1	1	0,0472	1	1	33	0,9528	21
40	1	1	1	0,0472	1	1	33	0,9528	17
41	1	1	1	0,0472	1	1	33	0,9528	18
42	1	1	1	0,0472	1	1	33	0,9528	17
43	1	1	1	0,0472	1	1	33	0,9528	17
44	1	1	1	0,0472	1	1	33	0,9528	18
45	1	1	1	0,0472	1	1	33	0,9528	17
46	1	1	1	0,0472	1	1	33	0,9528	17
47	1	1	1	0,0472	1	1	33	0,9528	17
48	1	1	1	0,0472	1	1	33	0,9528	17
49	1	1	1	0,0472	1	1	33	0,9528	17
50	1	1	1	0,0472	1	1	33	0,9528	17
51	1	1	1	0,0472	1	1	33	0,9528	18
52	1	1	1	0,0472	1	1	33	0,9528	21
53	1	1	1	0,0472	1	1	33	0,9528	19
54	1	1	1	0,0472	1	1	33	0,9528	17
55	1	1	1	0,0472	1	1	33	0,9528	17
56	1	1	1	0,0472	1	1	33	0,9528	20
57	1	1	1	0,0472	1	1	33	0,9528	17
58	1	1	1	0,0472	1	1	33	0,9528	17
59	1	1	1	0,0472	1	1	33	0,9528	18
60	1	1	1	0,0472	1	1	33	0,9528	18
61	1	1	1	0,0472	1	1	33	0,9528	17
62	1	1	1	0,0472	1	1	33	0,9528	17
63	1	1	1	0,0472	1	1	33	0,9528	20
64	1	1	1	0,0472	1	1	33	0,9528	18
65	1	1	1	0,0472	1	1	33	0,9528	17
66	1	1	1	0,0472	1	1	33	0,9528	17
67	1	1	1	0,0472	1	1	33	0,9528	17
68	1	1	1	0,0472	1	1	33	0,9528	17
69	1	1	1	0,0472	1	1	33	0,9528	17
70	1	1	1	0,0472	1	1	33	0,9528	17
71	1	1	1	0,0472	1	1	33	0,9528	17
72	1	1	1	0,0472	1	1	33	0,9528	24
73	1	1	1	0,0472	1	1	33	0,9528	17
74	1	1	1	0,0472	1	1	33	0,9528	17

75	1	1	1	0,0472	1	1	33	0,9528	18
76	1	1	1	0,0472	1	1	33	0,9528	17
77	1	1	1	0,0472	1	1	33	0,9528	17
78	1	1	1	0,0472	1	1	33	0,9528	17
79	1	1	1	0,0472	1	1	33	0,9528	23
80	1	1	1	0,0472	1	1	33	0,9528	17
81	1	1	1	0,0472	1	1	33	0,9528	17
82	1	1	1	0,0472	1	1	33	0,9528	17
83	1	1	1	0,0472	1	1	33	0,9528	17
84	1	1	1	0,0472	1	1	33	0,9528	19
85	1	1	1	0,0472	1	1	33	0,9528	17
86	1	1	1	0,0472	1	1	33	0,9528	18
87	1	1	1	0,0472	1	1	33	0,9528	18
88	1	1	1	0,0472	1	1	33	0,9528	22
89	1	1	1	0,0472	1	1	33	0,9528	19
90	1	1	1	0,0472	1	1	33	0,9528	19
91	1	1	1	0,0472	1	1	33	0,9528	17
92	1	1	1	0,0472	1	1	33	0,9528	17
93	1	1	1	0,0472	1	1	33	0,9528	18
94	1	1	1	0,0472	1	1	33	0,9528	17
95	1	1	1	0,0472	1	1	33	0,9528	18
96	1	1	1	0,0472	1	1	33	0,9528	18
97	1	1	1	0,0472	1	1	33	0,9528	17
98	1	1	1	0,0472	1	1	33	0,9528	17
99	1	1	1	0,0472	1	1	33	0,9528	17
100	1	1	1	0,0472	1	1	33	0,9528	17

FONTE: O autor (2020)

TABELA 18 - RESULTADO PARA OTIMIZAÇÃO DO SISTEMA DE 33 BARRAS COM O ALGORITMO DIFERENCIAL EVOLUTIVO COM EXECUÇÃO DE 100 VEZES

Nº Execução	Status ótimo			Fitness ótimo	Maior tensão		Menor tensão		Nº de gerações p/ convergência
	Chave 1	Chave 2	Chave 3		Barra	V (pu)	Barra	V (pu)	
1	1	1	1	0,0472	1	1	33	0,9528	17
2	1	1	1	0,0472	1	1	33	0,9528	18
3	1	1	1	0,0472	1	1	33	0,9528	19
4	1	1	1	0,0472	1	1	33	0,9528	18
5	1	1	1	0,0472	1	1	33	0,9528	17
6	1	1	1	0,0472	1	1	33	0,9528	17
7	1	1	1	0,0472	1	1	33	0,9528	17
8	1	1	1	0,0472	1	1	33	0,9528	17
9	1	1	1	0,0472	1	1	33	0,9528	22
10	1	1	1	0,0472	1	1	33	0,9528	17
11	1	1	1	0,0472	1	1	33	0,9528	17
12	1	1	1	0,0472	1	1	33	0,9528	17
13	1	1	1	0,0472	1	1	33	0,9528	21
14	1	1	1	0,0472	1	1	33	0,9528	17

15	1	1	1	0,0472	1	1	33	0,9528	17
16	1	1	1	0,0472	1	1	33	0,9528	18
17	1	1	1	0,0472	1	1	33	0,9528	17
18	1	1	1	0,0472	1	1	33	0,9528	17
19	1	1	1	0,0472	1	1	33	0,9528	17
20	1	1	1	0,0472	1	1	33	0,9528	20
21	1	1	1	0,0472	1	1	33	0,9528	18
22	1	1	1	0,0472	1	1	33	0,9528	17
23	1	1	1	0,0472	1	1	33	0,9528	20
24	1	1	1	0,0472	1	1	33	0,9528	17
25	1	1	1	0,0472	1	1	33	0,9528	17
26	1	1	1	0,0472	1	1	33	0,9528	17
27	1	1	1	0,0472	1	1	33	0,9528	18
28	1	1	1	0,0472	1	1	33	0,9528	17
29	1	1	1	0,0472	1	1	33	0,9528	18
30	1	1	1	0,0472	1	1	33	0,9528	18
31	1	1	1	0,0472	1	1	33	0,9528	18
32	1	1	1	0,0472	1	1	33	0,9528	17
33	1	1	1	0,0472	1	1	33	0,9528	17
34	1	1	1	0,0472	1	1	33	0,9528	17
35	1	1	1	0,0472	1	1	33	0,9528	17
36	1	1	1	0,0472	1	1	33	0,9528	17
37	1	1	1	0,0472	1	1	33	0,9528	17
38	1	1	1	0,0472	1	1	33	0,9528	17
39	1	1	1	0,0472	1	1	33	0,9528	19
40	1	1	1	0,0472	1	1	33	0,9528	17
41	1	1	1	0,0472	1	1	33	0,9528	23
42	1	1	1	0,0472	1	1	33	0,9528	17
43	1	1	1	0,0472	1	1	33	0,9528	17
44	1	1	1	0,0472	1	1	33	0,9528	20
45	1	1	1	0,0472	1	1	33	0,9528	18
46	1	1	1	0,0472	1	1	33	0,9528	17
47	1	1	1	0,0472	1	1	33	0,9528	17
48	1	1	1	0,0472	1	1	33	0,9528	17
49	1	1	1	0,0472	1	1	33	0,9528	18
50	1	1	1	0,0472	1	1	33	0,9528	17
51	1	1	1	0,0472	1	1	33	0,9528	17
52	1	1	1	0,0472	1	1	33	0,9528	17
53	1	1	1	0,0472	1	1	33	0,9528	19
54	1	1	1	0,0472	1	1	33	0,9528	18
55	1	1	1	0,0472	1	1	33	0,9528	25
56	1	1	1	0,0472	1	1	33	0,9528	17
57	1	1	1	0,0472	1	1	33	0,9528	17
58	1	1	1	0,0472	1	1	33	0,9528	17
59	1	1	1	0,0472	1	1	33	0,9528	17
60	1	1	1	0,0472	1	1	33	0,9528	18

61	1	1	1	0,0472	1	1	33	0,9528	17
62	1	1	1	0,0472	1	1	33	0,9528	17
63	1	1	1	0,0472	1	1	33	0,9528	21
64	1	1	1	0,0472	1	1	33	0,9528	17
65	1	1	1	0,0472	1	1	33	0,9528	19
66	1	1	1	0,0472	1	1	33	0,9528	17
67	1	1	1	0,0472	1	1	33	0,9528	17
68	1	1	1	0,0472	1	1	33	0,9528	17
69	1	1	1	0,0472	1	1	33	0,9528	17
70	1	1	1	0,0472	1	1	33	0,9528	19
71	1	1	1	0,0472	1	1	33	0,9528	17
72	1	1	1	0,0472	1	1	33	0,9528	19
73	1	1	1	0,0472	1	1	33	0,9528	17
74	1	1	1	0,0472	1	1	33	0,9528	17
75	1	1	1	0,0472	1	1	33	0,9528	19
76	1	1	1	0,0472	1	1	33	0,9528	17
77	1	1	1	0,0472	1	1	33	0,9528	17
78	1	1	1	0,0472	1	1	33	0,9528	17
79	1	1	1	0,0472	1	1	33	0,9528	17
80	1	1	1	0,0472	1	1	33	0,9528	17
81	1	1	1	0,0472	1	1	33	0,9528	19
82	1	1	1	0,0472	1	1	33	0,9528	18
83	1	1	1	0,0472	1	1	33	0,9528	17
84	1	1	1	0,0472	1	1	33	0,9528	17
85	1	1	1	0,0472	1	1	33	0,9528	25
86	1	1	1	0,0472	1	1	33	0,9528	17
87	1	1	1	0,0472	1	1	33	0,9528	17
88	1	1	1	0,0472	1	1	33	0,9528	17
89	1	1	1	0,0472	1	1	33	0,9528	17
90	1	1	1	0,0472	1	1	33	0,9528	17
91	1	1	1	0,0472	1	1	33	0,9528	17
92	1	1	1	0,0472	1	1	33	0,9528	18
93	1	1	1	0,0472	1	1	33	0,9528	19
94	1	1	1	0,0472	1	1	33	0,9528	17
95	1	1	1	0,0472	1	1	33	0,9528	19
96	1	1	1	0,0472	1	1	33	0,9528	17
97	1	1	1	0,0472	1	1	33	0,9528	17
98	1	1	1	0,0472	1	1	33	0,9528	17
99	1	1	1	0,0472	1	1	33	0,9528	17
100	1	1	1	0,0472	1	1	33	0,9528	17

FONTE: O autor (2020)