



Universidade Federal de Goiás – UFG

Escola de Engenharia Elétrica, Mecânica e de Computação

Programa de Pós-Graduação em Engenharia Elétrica e de Computação

Josephy Dias Santos

Algoritmos Bioinspirados Aplicados ao Problema de Alocação de Geração Distribuída

Goiânia
2023



UNIVERSIDADE FEDERAL DE GOIÁS
ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

1. Identificação do material bibliográfico

Dissertação Tese Outro*: _____

*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

Exemplos: Estudo de caso ou Revisão sistemática ou outros formatos.

2. Nome completo do autor

Josephy Dias Santos

3. Título do trabalho

Algoritmos Bioinspirados Aplicados ao Problema de Alocação de Geração Distribuída

4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento SIM NÃO¹

[1] Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

a) consulta ao(a) autor(a) e ao(a) orientador(a);

b) novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.



Documento assinado eletronicamente por **Lina Paola Garcés Negrete, Professora do Magistério Superior**, em 08/05/2023, às 10:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Josephy Dias Santos, Técnico de Laboratório**, em 08/05/2023, às 11:30, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3729350** e o código CRC **F5CC9386**.

Josephy Dias Santos

Algoritmos Bioinspirados Aplicados ao Problema de Alocação de Geração Distribuída

Dissertação apresentada ao Programa de Pós-Graduação *Stricto Sensu* em Engenharia Elétrica e de Computação como requisito para a obtenção do Título de Mestre em Engenharia Elétrica.

Área de Concentração: Engenharia Elétrica/ Sistemas Eléctro-Eletrônicos

Universidade Federal de Goiás – UFG

Escola de Engenharia Elétrica, Mecânica e de Computação

Programa de Pós-Graduação em Engenharia Elétrica e de Computação

Orientador: Lina Paola Garcés Negrete

Goiânia

2023

Ficha de identificação da obra elaborada pelo autor, através do
Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Santos, Josephy Dias

Algoritmos Bioinspirados Aplicados ao Problema de Alocação de
Geração Distribuída [manuscrito] / Josephy Dias Santos. - 2023.
CXXIV, 124 f.: il.

Orientador: Prof. Dr. Lina Paola Garcés Negrete.

Dissertação (Mestrado) - Universidade Federal de Goiás, Escola
de Engenharia Elétrica, Mecânica e de Computação (EMC), Programa
de Pós-Graduação em Engenharia Elétrica e de Computação, Goiânia,
2023.

Bibliografia. Anexos. Apêndice.

Inclui siglas, fotografias, abreviaturas, símbolos, gráfico, tabelas,
algoritmos, lista de figuras, lista de tabelas.

1. Algoritmo Genético de Chu-Beasley. 2. Symbiotic Organisms
Search. 3. Algoritmo de Otimização do Coronavírus. 4. Geração
Distribuída. 5. Sistemas Elétricos de Potência. I. Negrete, Lina Paola
Garcés, orient. II. Título.

CDU 621.3



UNIVERSIDADE FEDERAL DE GOIÁS

ESCOLA DE ENGENHARIA ELÉTRICA, MECÂNICA E DE COMPUTAÇÃO

ATA DE DEFESA DE DISSERTAÇÃO

Ata nº 01 da sessão de Defesa de Dissertação de **Josephy Dias Santos**, que confere o título de Mestre em **Engenharia Elétrica e de Computação**, na área de concentração em **Engenharia Elétrica**.

Aos **dois dias do mês de fevereiro do ano de dois mil e vinte e três**, a partir das **09h00min.**, realizou-se a sessão pública de Defesa de Dissertação intitulada “**Algoritmos Bioinspirados Aplicados ao Problema de Alocação de Geração Distribuída**”. Os trabalhos foram instalados pela Orientadora, Professora Doutora **Lina Paola Garcés Negrete - (EMC/UFG)**, com a participação dos demais membros da Banca Examinadora: Professor Doutor **Edmarcio Antonio Belati - (CECS/UFABC)**, membro titular externo; Professor Doutor **Jesus Maria López Lezama - (UdeA/Colômbia)**, membro titular externo e Professor Doutor **Leonardo da Cunha Brito - (EMC/UFG)**, membro titular interno, **cujas participações ocorreram através de videoconferência pelo link: <https://meet.google.com/dgx-gunu-kvq>**. Durante a arguição os membros da banca **não fizeram** sugestão de alteração do título do trabalho. A Banca Examinadora reuniu-se em sessão secreta a fim de concluir o julgamento da Dissertação, tendo sido o candidato **aprovado** pelos seus membros. Proclamados os resultados pela Professora Doutora Lina Paola Garcés Negrete, Presidente da Banca Examinadora, foram encerrados os trabalhos e, para constar, lavrou-se a presente ata que é assinada pelos Membros da Banca Examinadora, aos dois dias do mês de fevereiro do ano de dois mil e vinte e três.

TÍTULO SUGERIDO PELA BANCA



Documento assinado eletronicamente por **Leonardo Da Cunha Brito, Professor do Magistério Superior**, em 02/02/2023, às 11:37, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Lina Paola Garcés Negrete, Professora do Magistério Superior**, em 02/02/2023, às 11:37, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Edmarcio Antonio Belati, Usuário Externo**, em 02/02/2023, às 11:42, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Jesús María López Lezama, Usuário Externo**, em 02/02/2023, às 11:44, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Josephy Dias Santos, Técnico de Laboratório**, em 02/02/2023, às 11:45, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site

[https://sei.ufg.br/sei/controlador_externo.php?](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento_conferir&id_orgao_acesso_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **3491723** e o código CRC **55340C41**.

Referência: Processo nº 23070.002549/2023-13

SEI nº 3491723

Dedico este trabalho à minha esposa, aos meus familiares, meus amigos e aqueles que estiveram ao meu lado durante essa jornada.

Agradecimentos

Agradeço à Deus por caminhar ao meu lado durante esta jornada, me dando paciência, calma e determinação para atingir a avaliação final do título de mestre.

Agradeço à minha esposa, Monika Chauny que sempre me apoiou e me incentivou, me dando condições de continuar estudando e qualificando, agradeço à minha família, minha mãe Suelene, meu pai Adriano e meu irmão Jonathan que me manteve motivado em continuar seguindo em frente. Agradeço pelos amigos que me ajudaram, sobretudo ao Rogério Batista, Caio Póvoa, Gilberto Filho e Frederico Marques que se dispuseram a me ajudar quando não via mais solução.

Agradeço aos professores que contribuíram para o meu aprendizado durante todo o mestrado, agradecendo em especial a minha orientadora Lina Paola que sempre se dispôs me instruir, tornando mais que uma orientadora ou colega de trabalho, sendo uma amiga me aconselhando e auxiliando a ser consistente.

Por fim, agradeço à Escola de Engenharia Elétrica, Mecânica e de Computação da Universidade Federal de Goiás pelo programa de pós-graduação instituído e pela oportunidade de me qualificar e poder retornar à sociedade o desenvolvimento profissional recebido.

“A educação é o nosso passaporte para o futuro, pois, o amanhã pertence às pessoas que se preparam hoje.”
(Malcolm X)

Resumo

Este trabalho apresenta uma comparação do desempenho de diferentes meta-heurísticas, sendo duas clássica e uma moderna, na solução do problema de alocação de geração distribuída (GD) em redes de distribuição de energia elétrica. Especificamente, o estudo realizado confronta as seguintes técnicas computacionalmente aplicadas em algoritmos classificados como bioinspirados: o Algoritmo Genético Chu-Beasley (AGCB), o *Symbiotic Organisms Search* (SOS) e o Algoritmo de Otimização do Coronavírus (CVOA).

A alocação de unidades de GD no Sistema Elétrico de Potência (SEP) confere ao sistema vantagens e desvantagens. Dentre as vantagens podemos citar: redução de perdas de potência, ampliação de investimentos no setor elétrico, expansão e diversificação da matriz elétrica, em sua maioria, utilização de energia limpa e benefícios indiretos como geração de empregos. Entre as desvantagens, há as dificuldades na cobrança pelo uso do sistema elétrico, eventual incidência de tributos indevidos, necessidade de alteração dos procedimentos operacionais, elevação indiscriminada do perfil de tensão se o fator de penetração for elevado e a alocação de GD for aleatório, elevação dos níveis de curto-circuito, falhas na operação da proteção, entre outros.

As condições de operação da rede são verificadas através do método de varredura direta e inversa, especificamente usando o Método de Soma das Potências (MSP). A função objetivo, no modelo de otimização para a alocação de geração distribuída, corresponde à minimização das perdas totais de potência ativa no sistema. Para as implementações é considerada a alocação de módulos de geração distribuída com potência unitária de 100, 200 e 500kW, sendo que a quantidade máxima desses módulos a ser instalada é limitada pelo fator de penetração de cada rede.

Os algoritmos especializados são testados em quatro sistemas elétricos: 10, 34, 70 e 126 barras. Os resultados obtidos mostram a rápida convergência e a robustez do AGCB quando comparado com os outros algoritmos implementados, o mesmo não pode ser dito a respeito do SOS que teve desempenho intermediário. O CVOA como contribuição inédita neste trabalho, apresentou desempenho inferior ao esperado, muito em razão de sua natureza e arquitetura da modelagem proposta.

Palavras-chave: Algoritmo Genético de Chu-Beasley. *Symbiotic Organisms Search*. Algoritmo de Otimização do Coronavírus. Geração Distribuída. Sistemas Elétricos de Potência

Abstract

This work presents the performance comparison of different meta-heuristics, two classic and one modern. The implemented optimization algorithms aim to solve the distributed generation allocation problem in electricity distribution networks widely known in the literature. The study confronts the following computational techniques applied in algorithms classified as bioinspired: the Chu-Beasley Genetic Algorithm (AGCB), the Symbiotic Organisms Search (SOS) and the Coronavirus Optimization Algorithm (CVOA).

The allocation of DG units in the Electric Power System gives the system advantages and disadvantages. Among the advantages we can mention: reduction of power losses, expansion of investments in the electrical sector, expansion and diversification of the electrical matrix, mostly, use of clean energy and indirect benefits such as job creation. Among the disadvantages are difficulties in charging for the use of the electrical system, possible incidence of undue taxes, need to change operating procedures, indiscriminate elevation of the voltage profile if the penetration factor is high and the allocation of DG is random, increase in short circuit levels, failures in the protection operation, among others.

The network operating conditions are verified through the forward and reverse sweep method, specifically using the Power Sum Method. The objective function, in the optimization model for the allocation of distributed generation, aims to minimize the total losses of active power in the system. For the implementations, the allocation of modules (100, 200 and 500kW) of distributed generation is considered, with the number of these modules limited by the penetration factor of each network.

The specialized algorithms are tested on four electrical systems: 10, 34, 70 and 126 buses. The results obtained show the rapid convergence and robustness of the AGCB of the implemented algorithms, the same cannot be said about SOS, which had an intermediate performance. The CVOA, as an unprecedented contribution in this work, presented a lower performance than expected, largely due to its nature and architecture of the proposed modeling.

Keywords: Chu-Beasley Genetic Algorithm. Symbiotic Organisms Search. Coronavirus Optimization Algorithm. Distributed generation. Electrical Power Systems

Lista de ilustrações

Figura 2.1 – Modelo de Geração Distribuída Conectada à Rede Elétrica - CGH (Central Geradora Hidroelétrica), EOL (Central Geradora Eólica), UFV (Central Geradora Solar Fotovoltaica) e UTE (Usina Termelétrica) . . .	27
Figura 2.2 – Participação em Potência de GD	33
Figura 2.3 – Participação em Energia de GD	33
Figura 2.4 – Projeção da Capacidade Instalada Acumulada	33
Figura 2.5 – Participação em Potência Projeção	33
Figura 2.6 – Número de citações por ano de cada meta-heurística analisada.	42
Figura 3.1 – Componentes gerais de sistemas elétricos de potência	44
Figura 3.2 – Modelo π equivalente	44
Figura 3.3 – Elemento série de um ramo genérico $k - m$	46
Figura 3.4 – Diagrama unifilar da rede exemplo.	49
Figura 3.5 – Esquema da rede exemplo com o estado das tensões de barra iniciais.	52
Figura 3.6 – Esquema da rede com as tensões de barra e admitância dos ramos.	55
Figura 3.7 – Exemplo de método de seleção por roleta.	62
Figura 3.8 – Processo de recombinação	63
Figura 3.9 – Mutação no AGCB	63
Figura 3.10–Fluxograma do AGCB	64
Figura 3.11–Indivíduos simbióticos vivendo juntos em um ecossistema	67
Figura 3.12–Fluxograma do AGCB	69
Figura 3.13–Exemplo matriz de alocação de GD	76
Figura 3.14–Exemplo de Realocação (A), Troca (B) e Mutação (C)	77
Figura 3.15–Exemplo de novas infecções	77
Figura 3.16–Fluxograma do CVOA	79
Figura 4.1 – Sistema de 10 barras	84
Figura 4.2 – Sistema de 10 barras com alocação de GD	85
Figura 4.3 – Perfil de tensão do sistema teste de 10 barras sem e com GD	85
Figura 4.4 – Sistema de 34 barras	86
Figura 4.5 – Sistema de 34 barras com alocação de GD	87
Figura 4.6 – Perfil de tensão do sistema teste de 34 barras sem e com GD	88
Figura 4.7 – Sistema de 70 barras	88
Figura 4.8 – Sistema de 70 barras com alocação de GD	89
Figura 4.9 – Perfil de tensão do sistema teste de 70 barras sem e com GD	89
Figura 4.10–Sistema de 126 barras	90
Figura 4.11–Sistema de 126 barras com alocação de GD	91
Figura 4.12–Perfil de tensão do sistema teste de 126 barras sem e com GD	92

Figura 4.13–Gráfico de <i>Boxplot</i> dos sistemas de 10 e 34 barras	93
Figura 4.14–Gráfico de <i>Boxplot</i> dos sistemas de 70 e 126 barras	94

Lista de tabelas

Tabela 2.1 – Parâmetros Econômicos por Tipo de Oferta	31
Tabela 2.2 – Fonte de Geração	32
Tabela 2.3 – Tipo de Geração	32
Tabela 2.4 – Exemplos de trabalhos referentes a otimização mono ou multiobjetivo de <i>sizing and siting</i> de GD.	38
Tabela 3.1 – Dados de barra da rede exemplo.	49
Tabela 3.2 – Dados de ramos da rede exemplo.	49
Tabela 3.3 – Dados de barra da rede exemplo normalizados.	50
Tabela 3.4 – Dados de ramos da rede exemplo normalizados.	50
Tabela 3.5 – Modelagem do Problema de Alocação de GD (Alocação e Tamanho)	60
Tabela 3.6 – Barras Candidatas dos Sistemas Teste	60
Tabela 3.7 – Exemplo de Geração de Indivíduo para um Caso Hipotético	60
Tabela 4.1 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 10 barras.	84
Tabela 4.2 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 34 barras.	86
Tabela 4.3 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 70 barras	86
Tabela 4.4 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 126 barras	90
Tabela 4.5 – Resultado das meta-heurísticas implementadas para o sistema teste de 10 barras	91
Tabela 4.6 – Resultado das meta-heurísticas implementadas para o sistema teste de 34 barras	92
Tabela 4.7 – Resultado das meta-heurísticas implementadas para o sistema teste de 70 barras	92
Tabela 4.8 – Resultado das meta-heurísticas implementadas para o sistema teste de 126 barras	93
Tabela A.1 – Resultados da alocação de GD para o sistema de 10 barras	105
Tabela B.1 – Resultados da alocação de GD para o sistema de 34 barras	106
Tabela C.1 – Resultados da alocação de GD para o sistema de 70 barras	107
Tabela D.1 – Resultados da alocação de GD para o sistema de 126 barras	110
Tabela A.1 – Dados de Potência do Sistema de 10 Barras	115
Tabela A.2 – Dados de Ramos do Sistema de 10 Barras	115
Tabela B.1 – Dados de Potência do Sistema de 34 Barras	116
Tabela B.2 – Dados de Ramos do Sistema de 34 Barras	117

Tabela C.1–Dados de Potência do Sistema de 70 Barras	118
Tabela C.2–Dados de Ramos do Sistema de 70 Barras	119
Tabela D.1–Dados de Potência do Sistema de 126 Barras	120
Tabela D.2–Dados de Ramos do Sistema de 126 Barras	122

Lista de abreviaturas e siglas

ABC	<i>Artificial Bee Colony</i>
ABG	<i>Algoritmo de Busca Gravitacional</i>
ACSO	<i>Ant Colony Search Optimization</i>
AEV	<i>Algoritmo de Otimização de Enxame De Vagalume</i>
AG	<i>Algoritmo Genético</i>
AGCB	<i>Algoritmo Genético de Chu-Beasley</i>
ANEEL	<i>Agência Nacional de Energia Elétrica</i>
BH	<i>Método De Otimização Black Hole</i>
CC	<i>Corrente Contínua</i>
CCEE	<i>Câmara de Comercialização de Energia Elétrica</i>
CGA	<i>Algoritmo Genético Contínuo</i>
CGH	<i>Central Geradora Hidroelétrica</i>
CIGRE	<i>International Conference on High Voltage Electric Systems</i>
CMSOS	<i>Cloud Based Model Symbiotic Organism Search</i>
COA	<i>Coyote Optimization Algorithm</i>
COFINS	<i>Contribuição para o Financiamento da Seguridade Social</i>
Confaz	<i>Conselho Nacional de Política da Fazenda</i>
CSGA	<i>Chaotic Search Group Algorithm</i>
CSOS	<i>Chaotic Symbiotic Organism Search</i>
CVOA	<i>Algoritmo de Otimização do Coronavírus</i>
DPCA	<i>Distributed Power Coalition of America</i>
ECOA	<i>Enhanced Coyote Optimization Algorithm</i>
ED	<i>Algoritmo de Evolução Diferencial</i>

EOL	<i>Central Geradora Eólica</i>
EPE	<i>Empresa de Pesquisa Energética</i>
EPRI	<i>Electric Power Research Institute</i>
ESS	<i>Armazenamento de Energia</i>
FGTS	<i>Fundo de Garantia do Tempo de Serviço</i>
FO	<i>Função Objetivo</i>
FPA	<i>Flower Pollination Algorithm</i>
FPI	<i>Fluxo de Potência Intervalar</i>
GD	<i>Geração Distribuída</i>
HBB-BC	<i>Hybrid Big Bang-Big Crunch</i>
HSA	<i>Harmony Search Algorithm</i>
IEA	<i>International Energy Agency</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
INEE	<i>Instituto Nacional de Eficiência Energética</i>
IPTU	<i>Imposto Predial e Territorial Urbano</i>
IR	<i>Imposto de Renda</i>
ISOS	<i>Improved Symbiotic Organisms Search</i>
JDC	<i>Juros Durante a Construção</i>
MMGD	<i>Micro e Minigeração Distribuída</i>
MOPSO	<i>Multiobjective Particle Swarm Optimization Algorithm</i>
MSFLA	<i>Modified Shuffled Frog Leaping</i>
MSP	<i>Método da Soma de Potência</i>
OM	<i>Operação e Manutenção</i>
OMS	<i>Organização Mundial da Saúde</i>
ONS	<i>Operador Nacional do Sistema</i>
PFC	<i>Problema de Fluxo de Potência</i>

PIS	<i>Programa Integração Social</i>
PRODIST	<i>Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional</i>
ProGD	<i>Programa de Desenvolvimento da Geração Distribuída de Energia Elétrica</i>
PSO	<i>Particle Swarm Optimization</i>
PZ	<i>Paciente Zero</i>
QOCSOS	<i>Quasi-Oppositional Chaotic Symbiotic Organisms Search</i>
SA	<i>Simulated Annealing</i>
SDEE	<i>Sistemas de Distribuição de Energia Elétrica</i>
SEP	<i>Sistema Elétrico Brasileiro</i>
SGA	<i>Search Group Algorithm</i>
SIN	<i>Sistema Interligado Nacional</i>
SINIEF	<i>Sistema Nacional de Informações Econômicas Fiscais</i>
SIR	<i>Suscetíveis, Infectados, Recuperados</i>
SOA	<i>Sunflower Optimization</i>
SOS	<i>Symbiotic Organisms Search</i>
SSA	<i>Salp Swarm Algorithm</i>
TS	<i>Tabu search</i>
TTA	<i>Tiki-Taka Algorithm</i>
UFV	<i>Central Geradora Solar Fotovoltaica</i>
US. DOE	<i>US Department of Energy</i>
UTE	<i>Usina Termelétrica</i>
VCS	<i>Virus Colony Search</i>
VE	<i>Veículos Elétricos</i>
VNS	<i>Método de Pesquisa em Vizinhança Variável</i>
WOA	<i>Whale Optimization Algorithm</i>

Lista de símbolos

k	$1, \dots, NB$, sendo NB o número de barras da rede
Ω_k	Conjunto das barras vizinhas da barra k
V_k, V_m	Magnitude das tensões das barras terminais do ramo $k - m$
θ_k, θ_m	Ângulos das tensões das barras terminais do ramo $k - m$
\hat{S}_k	Injeção líquida de potência na barra k
P_k^G	Potência ativa (W) de geração na barra k
P_k^C	Potência ativa (W) de carga na barra k
Q_k^G	Potência reativa (var) de geração na barra k
Q_k^C	Potência reativa (var) de carga na barra k
Q_k^{sh}	Componente da injeção de potência reativa devida ao elemento shunt da barra k
\hat{S}_{km}^{perda} , \hat{P}_{km}^{perda} , \hat{Q}_{km}^{perda}	Perda de potência (VA , W ou var) no ramos km
S_{km} , P_{km} , Q_{km}	Fluxo de potência (VA , W ou var) do ramo km de k para m
S_{mk} , P_{mk} , Q_{mk}	Fluxo de potência (VA , W ou var) do ramo km de m para k
\hat{S}_k^{ac} , \hat{P}_k^{ac} , \hat{Q}_k^{ac}	Potência acumulada (VA , W ou var) na barra k
θ_{km}	Defasamento angular no ramo km
g_{km}	Condutância no ramo km
b_{km}	Susceptância no ramo km
y_{km}	Admitância no ramo km
A_m, B_m	Variáveis auxiliares para determinação da tensão da barra
ϕ_{km}	Defasagem angular no ramo km

Trabalhos Publicados

- SANTOS J. D., MARQUES F., NEGRETE L. P. G., BRIGATTO G. A. A., LÓPEZ-LEZAMA J. M., NUÑOZ-GALEANO N.. *A Novel Solution Method for the Distribution Network Reconfiguration Problem Based on Enhancement of Improved Harmony Search Algorithm. Energies*, v. 15, n. 6, 2022. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/15/6/2083>>.
- SANTOS J. D., NEGRETE L. P. G. and BRITO L. Da CUNHA, "Allocation of Distributed Generation in Distribution Networks Using Specialized Genetic Algorithms," 2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America), 2021, pp. 1-5, doi: 10.1109/ISGTLatinAmerica52371.2021.9543022.
- SANTOS J. D., NEGRETE L. P. G. Alocação de Geração Distribuída utilizando um Algoritmo Genético Compacto para Redução de Perdas de Energia Ativa. In: ANAIS DA XIV CONFERÊNCIA BRASILEIRA SOBRE QUALIDADE DA ENERGIA ELÉTRICA, 2021, Online. Anais eletrônicos... Campinas, Galoá, 2021. doi: 10.17648/cbqee-2021-130667. Disponível em: <<https://proceedings.science/cbqee-2021/papers/alocacao-de-geracao-distribuida-utilizando-um-algoritmo-genetico-compacto-para-reducao-de-perdas-de-energia-ativa>> Acesso em: 06 nov. 2022.

Sumário

1	Introdução	20
1.1	Justificativa	22
1.2	Objetivos	23
1.3	Divisão do Trabalho	24
2	Estado da Arte	25
2.1	Geração Distribuída	25
2.1.1	Incentivos para a Geração Distribuída no Brasil	26
2.1.2	Vantagens e Desvantagens da Geração Distribuída	28
2.1.3	Dados de Geração Distribuída	29
2.2	Revisão Bibliográfica	32
3	Problema de Alocação de GD	43
3.1	Método da Soma de Potência (MSP)	43
3.1.1	Exemplo de Cálculo do MSP	48
3.2	Algoritmos de Solução: Meta-heurística	57
3.2.1	Modelagem do Problema	59
3.2.2	Algoritmo Genético de <i>Chu-Beasley</i> (AGCB)	62
3.2.3	<i>Symbiotic Organisms Search</i> (SOS)	64
3.2.3.1	Mutualismo	67
3.2.3.2	Comensalismo	68
3.2.3.3	Parasitismo	69
3.2.4	Algoritmo de Otimização de Coronavírus (CVOA)	70
3.2.4.1	Metodologia	71
3.2.4.1.1	Etapas	71
3.2.4.1.2	Configuração de Parâmetros Sugeridos	73
3.2.4.1.3	Pseudocódigos	74
4	Testes e Resultados	83
4.1	Introdução	83
4.1.1	Sistema de 10 Barras	84
4.1.2	Sistema de 34 Barras	84
4.1.3	Sistema de 70 Barras	85
4.1.4	Sistema de 126 Barras	87
4.1.5	Resultados	89
5	Conclusão	95

Referências	97
-----------------------	----

Apêndices	104
------------------	------------

APÊNDICE A Resultado 10 Barras	105
--	-----

APÊNDICE B Resultado 34 Barras	106
--	-----

APÊNDICE C Resultado 70 Barras	107
--	-----

APÊNDICE D Resultado 126 Barras	110
---	-----

Anexos	114
---------------	------------

ANEXO A Sistema de 10 Barras	115
--	-----

ANEXO B Sistema de 34 Barras	116
--	-----

ANEXO C Sistema de 70 Barras	118
--	-----

ANEXO D Sistema de 126 Barras	120
---	-----

1 Introdução

As redes elétricas estão passando por uma transição de uma conexão vertical clássica, ou seja, unidirecional no sentido geração-carga, em que as usinas de geração estão situadas geograficamente a quilômetros de distância dos consumidores finais, para conexão horizontal, ou seja, bidirecional onde as cargas e geradores estão localizados mais próximos uns dos outros, (MONTTOYA et al., 2017). Essa mudança de padrão é motivada pelo acelerado avanço da eletrônica de potência e pela integração de recursos energéticos distribuídos em níveis de distribuição, (GRISALES-NOREÑA; MONTTOYA; RAMOS-PAJA, 2018; MONTTOYA et al., 2019). A integração destes dispositivos, tecnologias de geração renovável e armazenamento de energia, tem melhorado as condições técnicas de operação das redes de distribuição, em termos de melhoria do perfil de tensão, redução das perdas de potência ativa e reativa e a oportunidade de atender novos usuários, (SALKUTI; LHO, 2016).

Os recursos tradicionais de energia distribuída integrados às redes de distribuição incorporam geradores distribuídos que fornecem energia ativa para minimizar a perda total de energia, melhorar o perfil de tensão, entre outros. Em algumas situações, a geração distribuída fornece energia reativa, o que incrementa o impacto da redução das perdas de potência nos sistemas de distribuição, (BOCANEGRA; MONTTOYA, 2019). A inserção de geração distribuída (GD) nos sistemas de energia elétrica vem aumentando exponencialmente nos últimos anos, conforme é possível consultar em (ANEEL, 2022a).

Estudos indicam que a seleção inadequada de localização e tamanho da GD, pode ocasionar na elevação das perdas do sistema do que as perdas sem GD (MITHULANANTHAN; OO; PHU, 2015; GRIFFIN et al., 2000). As concessionárias que possuem problemas com elevadas perdas de energia e baixo perfil de tensão, não pode admitir qualquer aumento nas perdas. Ao realizar a alocação ótima, as concessionárias aproveitam a redução das perdas do sistema, a regulação dos níveis de tensão, a melhoria na confiabilidade do fornecimento, a capacidade de aliviar o sistema de transmissão e distribuição que resulta no adiamento de novos investimentos, (MITHULANANTHAN; OO; PHU, 2015; BORGES; FALCAO, 2003).

A GD pode ser considerada como uma das opções mais viáveis para mitigar alguns dos problemas enfrentados pelos sistemas elétricos, além de atender à crescente demanda de energia elétrica. Ademais, o tamanho modular e pequeno da GD facilitará ao planejamento realizar a instalação em um prazo menor em comparação com a solução convencional (usinas centralizadas). Em contrapartida, apresentada as opções, elas necessitam ser alocadas em locais apropriados com tamanhos adequados. Portanto, é necessário desenvolver ferramentas

para examinar locais e dimensionamento de tal instalação de GD, ([ACHARYA; MAHAT; MITHULANANTHAN, 2006](#)).

Existem vários desafios que necessitam ser encarados para a instalação de usinas em locais ótimos e sua operação em sistemas de distribuição de média tensão:

- Definir o local tão ótimo quanto possível das GDs em relação à topologia da rede e às condições de carga;
- Levar em consideração recursos de energia renovável com perfis diários de energia para fornecer um despacho de energia apropriado;
- Resolver o modelo de programação não linear inteira mista que representa a localização ótima e a operação do sistema de distribuição com tempos de processamento adequados.
- Considerar os problemas de convergência das técnicas de otimização meta-heurísticas que são muito utilizadas na solução deste problema. Essas técnicas podem introduzir incertezas no planejamento devido à sua estrutura não determinística

A alocação ótima de GD pode ser tratada como compensação de potência ativa ótima. Na Seção 3.1, o algoritmo de fluxo de potência é apresentado e na seção 3.2 as meta-heurísticas implementadas são expostas para encontrar o tamanho ótimo de GD em cada barra de carga candidata, assumindo que essas barras de cargas podem ter fonte de GD. Tal medida é necessária pois fatores técnicos, tais como, condições geográficas, investimentos financeiros elevados que inviabilizam a instalação de GD, entre outros, podem impedir a conexão de GD em qualquer barra do sistema.

Neste trabalho, são propostos três algoritmos bioinspirados, sendo eles, o Algoritmo Genético de Chu-Beasley (AGCB), o *Symbiotic Organisms Search* (SOS) e Algoritmo de Otimização do Coronavírus (CVOA), um algoritmo inspirado no COVID-19, para determinar o tamanho ótimo e uma metodologia eficaz para identificar a localização ideal para a alocação da GD. A inserção de GD é realizada no sistema de distribuição primária e seu objetivo é reduzir as perdas de potência ativa. O custo da GD e outros benefícios associados não foram considerados na solução do problema. O dimensionamento e posicionamento da GD é baseado em módulos de potência limitado ao fator de penetração de 30% da rede e a demanda do sistema é considerada fixa, em que não é levado em consideração as variações das cargas.

Conforme é possível verificar no *site* do ONS (Operador Nacional do Sistema Elétrico) ([ONS, 2023](#)), o consumo de energia elétrica é sazonal, ou seja, possui variações horárias de carga no decorrer do dia. A Resolução 1000/2023 ([ANEEL, 2023](#)) estabelece os postos tarifários e são definidos em Horário Ponta, Horário Fora Ponta e Horário Reservado,

em que o Horário de Ponta é aquele que há maior demanda de energia elétrica e o Fora Ponta e Horário Reservado são definidos quando o sistema está menos carregado. Essa definição é relevante, pois, em horário de elevado consumo as perdas nos sistemas elétricos são maiores, este trabalho não utiliza dessa informação porque seria necessário rodar o fluxo de carga para cada hora do dia o que aumentaria muito a quantidade de vezes que o cálculo de fluxo de potência seria executado. Como trabalho futuro será utilizado o sistema que teve melhor desempenho para determinar o módulo e posição de GD que minimiza as perdas do sistema levando em consideração a sazonalidade da carga.

1.1 Justificativa

O planejamento e a operação do sistema elétrico de potência (SEP) tem como propósito atender o contínuo crescimento dos consumidores assim como suas variações diárias e sazonais. Indústrias de grande porte, uma rede de distribuição de energia elétrica ou o Sistema Interligado Nacional (SIN) são exemplos de sistemas de potência. O atendimento das cargas (consumidores residenciais, comerciais e industriais) é uma atividade que requer a previsão de instalação de novos equipamentos e reforços nos sistemas de transmissão e distribuição, bem como sua apropriada utilização nos procedimentos operativos, (JÚNIOR, 2005).

A análise do fluxo de potência no atendimento das cargas, infere a disponibilidade de ferramentas apropriadas e confiáveis, principalmente quando o sistema compreendido é de grande porte. Para o dimensionamento da rede elétrica de maneira assertivo, de acordo com critérios vigentes e normas de projeto, é essencial comparar alternativas de transmissão e construção de novas linhas, planejar investimentos de geração, bem como adequar a compensação reativa necessária, (JÚNIOR, 2005).

No Brasil, diante do grande potencial hídrico existente, há a predominância da produção de energia elétrica por meio da transformação de energia hidráulica em elétrica, usinas hidroelétricas, de tal modo que os sistemas de geração, na maioria das situações, estão afastados geograficamente dos centros de consumo, é indispensável a existência de um elemento de interligação entre ambos que esteja apto a transportar a energia demandada, chamado de sistemas de transmissão, (KAGAN; OLIVEIRA; ROBBIA, 2005).

O sistema de transmissão (rede básica) tem por função fundamental o transporte de energia elétrica dos centros de produção aos de consumo, sendo necessário operar interligado, tal medida é necessária devido a confiabilidade e o intercâmbio de energia de diferentes partes do país, (KAGAN; OLIVEIRA; ROBBIA, 2005). Os sistemas de distribuição coletam a energia elétrica transportada dos sistemas de transmissão e através de subestações abaixadoras, atende os grandes centros de consumo, operando em média e baixa tensão.

O transporte de energia pela rede de transmissão ou de distribuição, inevitavelmente resulta em perdas técnicas relacionadas à conversão de energia elétrica em energia térmica nos condutores pelo efeito joule, perdas no núcleo dos transformadores, perdas dielétricas, dentre outros. As perdas não técnicas ou comerciais ocorrem principalmente do furto ou fraude de energia e ainda, erros de medição e faturamento, ([ANEEL, 2022c](#)).

As perdas na rede básica são calculadas pela diferença entre a energia gerada e a energia entregue ao sistema de distribuição, a apuração dessas perdas são averiguadas mensalmente pela Câmara de Comercialização de Energia Elétrica (CCEE) e o seu custo é dividido entre geração e consumidores, 50% para cada ([ANEEL, 2022c](#)). As perdas técnicas no sistema de distribuição são decompostas de acordo com os segmentos da rede de alta, média e baixa tensão, transformadores, ramais de ligação e medidores. São empregados modelos específicos para cada tipo de segmento, informações simplificadas das redes e equipamentos são aplicadas, tais como: comprimento e bitola dos condutores, potência dos transformadores e energia fornecida às unidades consumidoras. De posse dessas informações, estima-se o percentual de perdas técnicas eficientes relativas à energia injetada na rede elétrica. Os custos das perdas técnicas são levados em consideração na tarifa de energia elétrica, pois, em qualquer rede de distribuição elas não são eliminadas, ([PRODIST, 2022](#)).

Uma medida que a concessionária de energia elétrica pode tomar é a alocação de geração distribuída (GD) em nós estratégicos e potências ideais para a redução de perdas de energia elétrica nos sistemas de transmissão e distribuição, a inserção de GD pode ser realizada empregando soluções de engenharia com a utilização de ferramentas computacionais, tais como meta-heurísticas e inteligência artificial. O uso de tais ferramentas permite definir de modo otimizado o melhor nó e a melhor capacidade de geração para a injeção de potência que minimiza as perdas nos sistemas analisados.

1.2 Objetivos

Este trabalho tem por objetivo realizar o comparativo do desempenho computacional de cada meta-heurística implementada baseada em algoritmos bioinspirados, indicadores estatísticos e gráficos de *boxplot* são utilizados para trazer sensibilidade das respostas alcançadas. Para atingir esse objetivo, realizou-se a inserção de GDs com capacidade de geração modular em função do fator de penetração da rede de 30%, aproximadamente. Os sistemas testes analisados são amplamente conhecidos na literatura, sendo os sistemas de 10, 34, 70 e 126 barras, cujo módulo das GDs são de 500kW, 200kW, 100kW e 200kW, respectivamente. Os algoritmos bioinspirados aplicados ao problema de alocação de GD foram:

- Algoritmo Genético de Chu-Beasley (AGCB)

- *Symbiotic Organisms Search* (SOS)
- Algoritmo de Otimização do Coronavírus (CVOA)

A função objetivo dos algoritmos bioinspirados é a redução das perdas totais dos sistemas testes, ou seja, a função de avaliação que busca minimizar as perdas de potência ativa dos ramos de distribuição. Serão analisados, o perfil de tensão, as perdas totais dos sistemas, o desempenho (tempo de convergência, número de execuções, entre outros) e a comparação dos algoritmos implementados. Afinal, será apresentado a conclusão da meta-heurística que melhor se ajusta ao problema de alocação de GD.

1.3 Divisão do Trabalho

Para o melhor entendimento do trabalho, este será dividido em cinco capítulos.

- O Capítulo 1 apresenta a introdução do assunto, são expostas as justificativas com a descrição do problema e o objetivo a ser alcançado.
- O Capítulo 2 apresenta a revisão bibliográfica da geração distribuída, expondo dados e informações das GDs no Brasil. Esse capítulo também faz uma revisão dos trabalhos publicados relevantes ao tema proposto.
- O Capítulo 3 apresenta o problema de alocação de GD, é exposto o modelo e a equação de balanço utilizada para o cálculo de fluxo de potência (Método da Soma de Potência - MSP) com exemplo ilustrativo. São mostradas as filosofias, os pseudocódigos e fluxogramas das meta-heurísticas AGCB, SOS e CVOA.
- O Capítulo 4 evidencia os testes e resultados alcançados com a metodologia empregada para os sistemas testes de 10, 34, 70 e 126 barras analisados. Traçam-se gráficos e tabelas para o melhor entendimento e comparação dos algoritmos utilizados.
- O Capítulo 5 realiza o fechamento do trabalho com as conclusões dos assuntos discutidos, as considerações finais e os passos a serem seguidos para a próxima etapa.

2 Estado da Arte

2.1 Geração Distribuída

O termo "Geração Distribuída" vem se tornando cada vez mais popular, muito em razão da crescente demanda por energia elétrica que culminou no acelerado processo tecnológico da eletrônica no desenvolvido de novos equipamentos o que propiciou uma oferta correspondente às demandas do mercado. No entanto, é fundamental que esse termo seja devidamente definido, apesar de não haver consenso sobre essa definição. No Brasil, o termo Geração Distribuída é definido no Art. 14 da Decreto-Lei 5.163/2004, disponível em ([BRASIL, 2004](#)):

“Art. 14. Para os fins deste Decreto, considera-se geração distribuída a produção de energia elétrica proveniente de empreendimentos de agentes concessionários, permissionários ou autorizados, incluindo aqueles tratados pelo art. 8o da Lei no 9.074, de 1995, conectados diretamente no sistema elétrico de distribuição do comprador, exceto aquela proveniente de empreendimento:

I - hidrelétrico com capacidade instalada superior a 30 MW; e

II - termelétrico, inclusive de cogeração, com eficiência energética inferior a setenta e cinco por cento, conforme regulação da ANEEL, a ser estabelecida até dezembro de 2004.

Parágrafo único. Os empreendimentos termelétricos que utilizem biomassa ou resíduos de processo como combustível não estarão limitados ao percentual de eficiência energética prevista no inciso II do caput.”([BRASIL, 2004](#)).

No entanto, a REN 482/2012 e suas alterações (687/2017) não define geração distribuída propriamente dito, mas sim microgeração distribuída e minigeração distribuída, conforme apresentado no Art. 2º, inciso I e II ([BRASIL, 2012](#))

"I - microgeração distribuída: central geradora de energia elétrica, com potência instalada menor ou igual a 75 kW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras; (Redação dada pela REN ANEEL 687, de 24.11.2015.)

II - minigeração distribuída: central geradora de energia elétrica, com potência instalada superior a 75 kW e menor ou igual a 5MW e que utilize cogeração qualificada, conforme regulamentação da ANEEL, ou fontes renováveis de energia elétrica, conectada na rede de distribuição por meio de instalações de unidades consumidoras; (Redação dada pela REN ANEEL 786, de 17.10.2017)". ([BRASIL, 2012](#))

O trabalho de ([GONZALEZ-LONGATT; FORTOUL, 2005](#)) fornece uma revisão bibliográfica dos conceitos de geração distribuída fornecidos por institutos internacionais e

regionais em todo o mundo, entre a revisão são apresentados as definições de *Distributed Power Coalition of America* (DPCA), *International Conference on High Voltage Electric Systems* (CIGRE), *International Energy Agency* (IEA), *US Department of Energy* (US. DOE), *Electric Power Research Institute* (EPRI), *Institute of Electrical and Electronic Engineers* (IEEE), *American Gas Association* (AGA), entre outros.

Apesar da grande quantidade de definições de GD, não há um consenso claro e universal para todos os países, alguns países levam em consideração:

- Nível de tensão,
- Localidade e a conectividade com o sistema;
- Fonte primária (renovável ou cogeração);
- Fontes não despacháveis e
- Potência máxima


Assim, diante das diversas definições apresentadas pelos principais institutos em todo o mundo, ([GONZALEZ-LONGATT; FORTOUL, 2005](#)) define (GD) de forma ampla e qualitativa, que assimila a validade contextual de todos os demais conceitos vigentes como uma fonte de energia elétrica conectada à rede de distribuição ou no local do cliente, suficientemente menor que as usinas geradoras centrais. Essa definição é a mais próxima do Instituto Nacional de Eficiência Energética (INEE) que define GD como geração elétrica realizada junto ou próximo dos consumidores, independente da potência, tecnologia e fonte de energia, a [Figura 2.1](#) ilustra a definição apresentada. As tecnologias de GD tem avançado para incluir potências cada vez menores, ([INEE, 2022](#)). A GD inclui:

- Cogeração
- Central Geradora Hidroelétrica (CGH)
- Central Geradora Eólica (EOL)
- Central Geradora Solar Fotovoltaica (UFV)
- Usina Termelétrica (UTE)

2.1.1 Incentivos para a Geração Distribuída no Brasil

Com a crescente demanda por GD, vários incentivos foram concedidos para esse tipo de geração, tornando o setor cada vez mais aquecido, entre elas, pode-se citar:

Figura 2.1 – Modelo de Geração Distribuída Conectada à Rede Elétrica - CGH (Central Geradora Hidroelétrica), EOL (Central Geradora Eólica), UFV (Central Geradora Solar Fotovoltaica) e UTE (Usina Termelétrica)



Fonte: O autor

- O Conselho Nacional de Política da Fazenda (Confaz), por meio do Ajuste SINIEF (Sistema Nacional de Informações Econômicas Fiscais), revogou o convênio que instruía a tributação da energia injetada na rede. Com isso, cada estado da federação passou a decidir a tributação, ou não, da energia injetada. Até a escrita desse trabalho, os seguintes estados aderiram: SP, PE, GO, CE, TO, RN, MT, BA, DF, MA, RJ, RS, RR, AC, AL e MG;
- O Governo Federal, através da Lei nº 13.169, de 6 de outubro de 2015, isentou o PIS e o COFINS da energia injetada na rede;
- O Governo Federal criou o Programa de Desenvolvimento da Geração Distribuída de Energia Elétrica (ProGD) com objetivo de estimular a geração distribuída no Brasil;
- Alguns municípios que utilizam o programa IPTU verde englobam as instalações de energia solar entre as práticas sustentáveis elegíveis para a concessão de desconto no imposto de seus contribuintes.
- Dedução de Imposto de Renda (IR) por amortização de equipamentos;
- A Comissão de Serviços de Infraestrutura do Senado aprovou o Projeto de Lei nº 371, de 2015, que permite o uso de recursos do Fundo de Garantia do Tempo de Serviço (FGTS) na aquisição e na instalação de equipamentos destinados à geração própria de energia elétrica em residências.

- No mercado estão disponíveis várias linhas de financiamento de geração distribuída: Mais Alimentos (Pronaf), Economia Verde (Desenvolve SP), Finem (BNDES), PE Solar (Agefepe), Crédito Produtivo Energia Solar (Goiás Fomento), FNE Sol (BNB), Construcard (Caixa Econômica Federal), CDC Eficiência Energética (Santander), Proger (Banco do Brasil), Consórcio Sustentável (Sicredi), além das empresas que estão oferecendo soluções financiadas por meio de contratos de performance (ESCO) e alugueis. (SOLAR, 2022b)

2.1.2 Vantagens e Desvantagens da Geração Distribuída

Os estímulos à geração distribuída se justificam pelos potenciais benefícios que tal modalidade pode proporcionar ao sistema elétrico. O trabalho de (FILHO; AZEVEDO,) apresentam as vantagens e desvantagens de ter essas tecnológicas conectadas à rede. Entre as vantagens dos pontos de vista econômico, ambiental e social, temos:

- Redução de perdas: com a descentralização da geração, a energia pode ser gerada no próprio local ou muito próximo do local de consumo. Desta maneira, evita-se a perda de energia por efeito joule nos condutores dos sistemas de transmissão/distribuição por transportar eletricidade por longas distâncias, tornando o sistema elétrico mais eficiente;
- Ampliação de investimentos: a GD estimula pessoas e empresas a produzir sua própria energia. O aporte financeiro é realizado com capital próprio ou financiamento, evitando que o governo e as concessionárias precisem investir ou promover leilões demorados e burocráticos para a construção de grandes usinas ou melhoramento e investimento na infraestrutura de rede, (SOLAR, 2022a);
- Expansão da matriz elétrica: a GD proporciona a rápida expansão da oferta de eletricidade no país, o que ocasiona na redução do custo e o aumento da disponibilidade de energia no país, (SOLAR, 2022a).
- Energia limpa: apesar de não ser regra, a GD prioriza a utilização de fontes limpas e renováveis, tornando a produção de energia ambientalmente correta;
- Geração de emprego: ao estimular a instalação de centenas de milhares de pequenos geradores de energia elétrica, a GD distribui investimentos, cria empregos local e movimentando diversos setores da economia, desde a fabricação até a instalação dos sistemas, (ABSOLAR, 2022).

Por outro lado, existem algumas desvantagens relacionadas ao aumento da quantidade dos GD conectadas na rede de distribuição, sendo elas:

- Dificuldade na cobrança pelo uso do sistema elétrico: as leis e os incentivos existentes de GD tem tornado o equacionamento complexo e com muitos parênteses, não há uma uniformidade de regras entre entes federados e muito menos segurança jurídica, (EPBR, 2022);
- Eventual incidência de tributos: algumas concessionárias do país estão aplicando tributos sobre a energia gerada, e não a energia injetada na rede, ou seja, tarifando a geração própria de energia, sem haver comercialização ou transporte de energia na rede elétrica, (EPBR, 2022).
- Necessidade de alteração dos procedimentos das distribuidoras: com a mudança do fluxo de potência na rede de distribuição, passando por uma transição unidirecional para bidirecional, requer das distribuidoras operar, controlar e proteger suas redes, com equipamentos modernos e mais sensíveis a fim de manter a saúde do sistema e de seus profissionais;
- Elevação de tensão: a alocação indiscriminada de geração distribuída com alto fator de penetração pode elevar os níveis de tensão do sistema para valores superiores ao limite permitido, o que pode tornar inoperantes alguns sistemas devido à transgressão do nível de tensão, (SANTOS; NEGRETE; BRITO, 2021).
- Níveis de curto-circuito: as GDs de pequeno porte não causa impacto significativo para as contribuições de curto-circuito, no entanto, a associação de pequenas GDs, ou até mesmo GDs de médio porte, tem a capacidade de influenciar nos níveis de curto-circuito, de modo a causar problemas na coordenação da proteção de redes de distribuição, (QUIRIOGA, 2019).
- Sistema de proteção: como apresentado no item anterior, a potência da GD e sua localização afeta as contribuições de curto-circuito, essa alteração provoca problemas na proteção, alterando a coordenação, a seletividade e a sensibilidade, sendo necessário a modernização da proteção para sistemas microprocessados, (Júnior; FERREIRA, 2017).

2.1.3 Dados de Geração Distribuída

Diante do exposto nas seções anteriores, a regulamentação do setor, os incentivos fiscais e políticos e o alto custo da geração através de combustíveis fósseis, que se reflete na fatura de energia elétrica através das bandeiras tarifárias amarela e vermelha, vem estimulando os consumidores a repensar uma maneira de reduzir custo, e por diversas ocasiões optam pela geração da própria energia com compensação dos créditos de energia gerada. Esse processo de instalação de GD tem tornado esse mercado cada vez mais atrativo,

uma vez que a oferta tem aumentado e os valores dos investimentos têm diminuído, tornando a geração distribuída cada vez mais acessível.

Cabe ao investidor a iniciativa de instalação da GD, este deve analisar a relação custo/benefício para a instalação de geradores, de acordo com as diversas variáveis: tipo de fonte de energia (usina solar fotovoltaica, usina eólica, geradores de biomassa, entre outros), tecnologia dos equipamentos, porte da unidade geradora, localização (rural ou urbana), valor da tarifa em está submetido e condições de pagamento/financiamento do projeto, (ANEEL, 2022b).

Pensando nisso, a EPE (Empresa de Pesquisa Energética) elaborou o Custos de Geração por tipo de fonte, (BRASIL, 2021a), a Tabela 2.1 apresenta os parâmetros econômicos por tipo de oferta. O CAPEX inclui todos os custos diretos (obras civis, equipamentos, conexão e meio ambiente) e indiretos do empreendimento, sem juros durante a construção (JDC), tendo como referência o mês de dezembro/2019. O O&M (Operação e Manutenção) reflete a soma dos gastos (custos e despesas) fixos e variáveis. A vida útil econômica considerada para cada fonte é atribuída levando em conta a vida útil dos equipamentos utilizados nas usinas e os prazos contratuais estabelecidos para cada uma das fontes nos leilões de energia.

Analisando a Tabela 2.1, podemos inferir que a biomassa (bagaço da cana) e a fotovoltaica apresentam as menores faixas CAPEX e fator de capacidade médio iguais, no entanto, o O&M e os Encargos/Imposto da USF são menores, ou seja, após instalação, os custos para manter esse gerador são os menores.

Em (ANEEL, 2022a) é possível encontrar diversos dados de GD, pode-se citar: agente, região, modalidade de geração, ano de conexão, grupo de tensão, faixa de potência, município, fonte de geração, classe de consumo, estados e tipo de geração. A Tabela 2.2 apresenta a fonte de geração e seu respectivo combustível, mostrando a quantidade e potência instalada de cada uma delas. A Tabela 2.3 realiza a consolidação da Tabela 2.2, expondo em valores totais a quantidade e potência instalada por tipo de geração, vale ressaltar que a base de dados está acumulada desde o ano de 2008. Destaca-se a elevada quantidade e potência instalada das USF, em termos totais, ela corresponde a 99,96% da quantidade de GD e 98,46% da potência instalada.

A Figura 2.2, elaborado pela (EPE, 2022) com dados da (ANEEL, 2022a) até o ano de 2021, apresenta a participação de potência de cada fonte de GD em termos percentuais, de maneira acumulativa. Pode-se perceber que no ano de 2021 a fonte USF ocupa quase que a totalidade em potência instalada. O Relatório Síntese 2022 (ano base 2021), (BRASIL, 2021c) apresenta que a micro e minigeração distribuída (MMGD) em 2021 apresentou um aumento de 84% em relação a 2020, esse fato vem sendo construído ao longo do tempo, em que o crescimento da USF está em ritmo superior às demais fontes. O adicional de capacidade instalada de MMGD se concentra, sobretudo, na região centro-sul

Tabela 2.1 – Parâmetros Econômicos por Tipo de Oferta

Tipo de Oferta	Vida útil econômica [anos]	Faixas de CAPEX, mín e máx [R\$/kW]	CAPEX Referência, sem JDC [R\$/kW]	Fator de Capacidade médio	O&M [R\$/kW/ano]	Encargos/ Impostos [R\$/kW/ano]
Biomassa (Bagaço de Cana)	20	2.000 a 5.500	4.000	30%	90	190
Biomassa (Cavaco de Madeira)	20	4.000 a 8.000	6.000	30%	12	250
Biogás	20	3.000 a 10.000	7.500	80%	500	300
Biogás (RSU)	20	14.500 a 27.000	19.600	70%	600	750
Eólica Onshore	20	3.200 a 5.500	4.500	38% - 47%	90	180
Eólica Offshore	20	9.800 a 18.600	12.250	32% - 62%	490	450
Fotovoltaica	20	3.000 a 5.000	4.000	30%	50	150
Fotovoltaica Flutuante	20	3.800 a 6.500	5.000	24%	65	180
Gás Natural (Ciclo Combinado)	20	3.400 a 5.900 (apenas a UTE)	4.100	-	80 (UTE) + 80 (Regas)	250
Gás Natural (Ciclo Aberto)	20	2.900 a 4.700	3.400	-	80 (UTE) + 160 (Regas Terceiros)	230
Gás Natural (C Combinado Pré-sal)	20	3.400 a 5.900 (apenas a UTE)	5.100	-	150	280
PCH (CAPEX Baixo)	30	3.500 a 6.500	5.000	46% - 50%	90	180
PCH (CAPEX Médio)	30	6.500 a 8.500	7.500	46% - 50%	90	230
PCH (CAPEX Alto)	30	8.500 a 11.500	1.000	46% - 50%	90	300

Fonte:(BRASIL, 2021a) Adaptado

do país, (BRASIL, 2021c). A Figura 2.3 apresenta a participação em energia das fontes de GD, percebe-se que, apesar da USF representar aproximadamente 98% da potência instalada, sua geração em kWh equivale a 92% do total de energia gerada, isso está relacionado com as características dessa fonte e sua sazonalidade, que possui fator de capacidade médio de 30%, conforme apresentado na Tabela 2.1.

Anualmente a EPE realiza o Plano Decenal de Expansão de Energia, (BRASIL, 2021b), que indica a perspectiva da expansão do setor de energia nos próximos dez anos dentro de uma visão integrada para diversos recursos energéticos. Os estudos do plano subsidiam decisões de política energética e fornecem ao mercado informações que permitem a análise do desenvolvimento do sistema elétrico e das condições de adequabilidade de suprimento sob diferentes cenários futuros possíveis. Nesse cenário, a EPE elaborou a projeção da capacidade instalada acumulada até o ano de 2031, apresentada na Figura 2.4, em que as previsões apontam que em 2031 as GDs terão uma potência instalada de aproximadamente 37.218 MW (Referência), (BRASIL, 2021b; EPE, 2022). A Figura 2.5 mostra que a USF ainda será a MMGD de maior dominância do recursos distribuídos, com destaque para o ligeiro aumento das UTEs.

Tabela 2.2 – Fonte de Geração

Tipo	Combustível	Qtd GD	Pot. Instalada (kW)
CGH	Potencial hidráulico	77	75.921,67
EOL	Cinética do Vento	91	17.179,85
USF	Radiação solar	1.412.353	14.799.060,33
UTE	Bagaço e Cana de Açúcar	15	8.417,96
UTE	Biogás - Floresta	13	4.608,40
UTE	Biogás - RA	247	43.309,21
UTE	Biogás - RU	73	35.089,79
UTE	Biogás - AGR	30	11.982,84
UTE	Casca de Arroz	5	6.246,40
UTE	Gas de Alto Forno - Biomassa	7	12.880,00
UTE	Gás Natural	13	3.121,76
UTE	Resíduos Florestais	6	10.860,00
UTE	Resíduos Sólidos Urbanos RU	6	1.876,00
Total		1.412.936,00	15.030.554,21

Fonte:([ANEEL, 2022a](#))

Tabela 2.3 – Tipo de Geração

Tipo	QTD	Pot. Instalada (kW)
CGH	77	75.921,67
EOL	91	17.179,85
USF	1.412.353	14.799.060,33
UTE	415	138.392,36

Fonte:([ANEEL, 2022a](#))

2.2 Revisão Bibliográfica

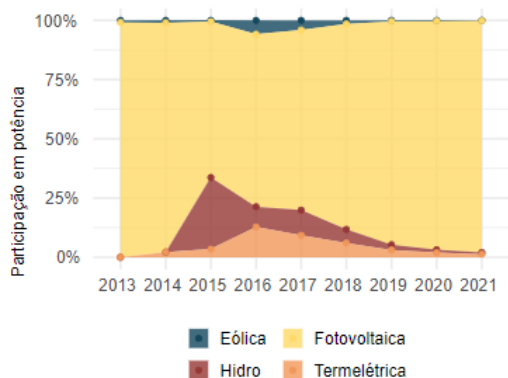
Nesta seção é apresentada uma revisão bibliográfica nas temáticas que envolvem este trabalho, utilização de algoritmos bioinspirados para problemas de otimização, alocação de geração distribuída e *sizing and siting* de GD. Este tema desperta interesse na comunidade acadêmica visto que há vários trabalhos sobre essa temática.

Além da técnica de otimização meta-heurística que será discutida em 3.2, há ainda outras metodologias, entre elas pode-se citar: busca exaustiva, algoritmos exatos, algoritmo híbrido e algoritmo composto.

A busca exaustiva, também conhecida como força bruta, é um tipo de algoritmo que consiste em realizar a varredura de todo espaço de busca e testar todas as soluções possíveis. Esse algoritmo possui elevado custo computacional, pois geralmente há um altíssimo número de soluções candidatas.


Algoritmos exatos visam encontrar a solução ótima para um problema, mas isso pode ser computacionalmente caro e demorado, especialmente para problemas de grande

Figura 2.2 – Participação em Potência de GD




Fonte: (EPE, 2022)

Figura 2.3 – Participação em Energia de GD



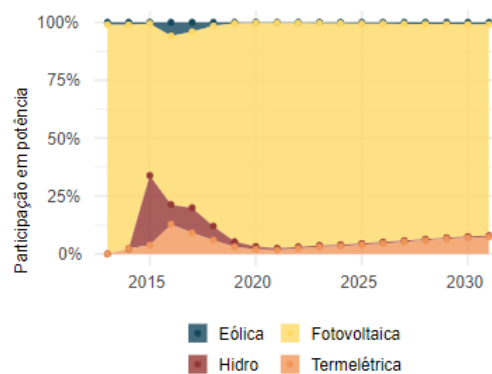
Fonte: (EPE, 2022)

Figura 2.4 – Projeção da Capacidade Instalada Acumulada



Fonte: (EPE, 2022)

Figura 2.5 – Participação em Potência Projeção



Fonte: (EPE, 2022)

escala. Essa técnica normalmente explora todo o espaço de solução, que pode ser muito grande para alguns problemas, e requer o uso de técnicas matemáticas complexas para encontrar a solução ótima. Os modelos matemáticos são baseados em um conjunto de restrições e funções objetivas que definem o problema a ser resolvido. No entanto, essa rigidez pode dificultar a abordagem de características ou restrições específicas de problemas que não são facilmente capturadas pelo modelo matemático.

Algoritmo híbrido é um algoritmo que combina dois ou mais algoritmos que resolvem o mesmo problema, escolhendo um com base em alguma característica dos dados ou alternando entre eles ao longo do algoritmo. Isso geralmente é feito para combinar os recursos desejados de cada um, de modo que o algoritmo geral seja melhor do que os componentes individuais. Algoritmo híbrido não se refere simplesmente à combinação de vários algoritmos para resolver um problema, muitos algoritmos podem ser considerados como combinações de peças mais simples, mas apenas à combinação de algoritmos que resolvem o mesmo problema, mas diferem em outras características, especificamente o

desempenho.

O algoritmo composto é formado por módulos de grupos de comandos que constitui um trecho de algoritmo com uma função bem definida e independente das demais partes do algoritmo. Cada módulo, durante a execução do algoritmo, realiza uma tarefa específica da solução do problema, podendo ter o auxílio de outros módulos do algoritmo. Assim, a execução do algoritmo composto pode ser visto como um processo cooperativo.

Este trabalho utiliza algoritmos meta-heurísticos e, portanto, serão apresentados trabalhos que utilizam este método de otimização para alcançar seu objetivo, que é encontrar a solução mais ótima possível, garantindo economia computacional e de tempo.

O trabalho de (MACHAVA; KABERERE; VILANCULO, 2022) apresenta um método para alocação ótima de geradores distribuídos em redes de distribuição de energia para minimização de perdas totais usando algoritmos genéticos (AG) com a função de restrição de tensão mínima e máxima em cada barra, o fluxo de carga é implementado no OpenDSS e integrado ao AG. No processo de otimização, foram consideradas as curvas de carga com o objetivo de representar adequadamente a real operação do sistema de distribuição, o que permite uma avaliação mais criteriosa da barra ótima para alocar a GD. A abordagem proposta foi implementada nos sistemas de teste de 13, 34 e 126 barras do IEEE.

O artigo produzido por (PRADO; GARCES, 2013) apresenta uma metodologia para alocação eficiente de unidades de geração distribuída (GD), baseada no algoritmo genético de Chu-Beasley. Segundo o autor, este algoritmo apresenta bom desempenho e obtém soluções precisas resolvendo o problema de alocação de GD quando utilizado em sistemas de distribuição de pequeno e médio porte. Os resultados mostraram que ao aumentar a complexidade do sistema o algoritmo proposto se torna mais vantajoso, frente à busca exaustiva. A metodologia proposta foi aplicada em três sistemas de distribuição, contendo 10, 34 e 70 barras, respectivamente. Foram analisados cenários para a inserção de uma ou duas unidades de GD em cada sistema. Adotou-se o Método de Soma de Corrente (MSI) para rodar os fluxos de carga. O principal resultado são as alocações de GD considerando minimizar as perdas de potência ativa, e a respectiva melhoria nos níveis de tensões das barras.

O artigo escrito por (LEZAMA; GALEANO; DUQUE, 2020) apresenta uma abordagem de AG para determinar a alocação ótima de GD utilizando a meta-heurística PSO em sistemas elétricos de potência considerando múltiplos cenários operacionais. Vários índices desenhados para a avaliação da rede em termos de limites de tensão e carregamento foram definidos para orientar o algoritmo meta-heurística. Esses índices medem violações nos limites de carga e tensão para diferentes cenários operacionais. A função objetivo consiste em minimizar os impactos das contingências no carregamento da rede e no perfil de tensão dos sistemas elétricos. Para mostrar a aplicação e eficácia da abordagem proposta, vários

testes foram realizados nos sistemas de testes de 30 e 57 da IEEE. Os autores apresentam os resultados que mostram que a abordagem proposta permite encontrar a alocação de GD que maximize seus impactos positivos em termos de perfil de tensão e carregamento.

O trabalho produzido por (BARBOSA et al., 2019) apresenta uma metodologia para a alocação ótima de GD no sistema de distribuição usando o algoritmo Polinização por Flores (FPA). A metodologia proposta foi aplicada em dois sistemas contendo 34 e 70 barras, respectivamente. O método proposto foi validado a análise de sensibilidade (AS). Os autores concluem que os resultados numéricos mostram que o desempenho do método FPA proposto é melhor do que outros métodos comparados.

A dissertação de mestrado de (NOGUEIRA, 2021) apresenta uma metodologia de otimização capaz de considerar incertezas no problema de alocação e dimensionamento de geração distribuída em redes de distribuição de energia elétrica. A metodologia proposta utiliza o fluxo de potência intervalar (FPI) com o intuito de adicionar as incertezas no problema de otimização combinatória que é resolvido através das meta-heurísticas *Symbiotic Organism Search* (SOS) e *Particle Swarm Optimization* (PSO) para fins de comparação de desempenho. Por fim, conclui que o SOS tem desempenho mais robusto que o PSO, pois, o último apresenta resultados menos satisfatórios.

O artigo de (THE; QUOC; NGOC, 2020) propõe o algoritmo SOS para encontrar a configuração ótima da rede e o posicionamento de unidades de geração distribuída (GD) que minimizem a perda potência em redes radiais de distribuição. O algoritmo proposto simula relações simbióticas como mutualismo, comensalismo e parasitismo para resolver os problemas de otimização. No processo de otimização, o problema de reconfiguração produz um grande número de configurações de rede inviáveis. Para reduzir esses indivíduos inviáveis e garantir a topologia radial da rede, a teoria dos grafos foi aplicada durante o fluxo de potência. A implementação do algoritmo SOS proposto foi realizada em redes de distribuição de 33 barras, 69 barras, 84 barras e 119 barras considerando sete cenários diferentes. Resultados de simulação e comparação de desempenho com outros métodos de otimização mostraram que a abordagem baseada em SOS foi muito eficaz na resolução de problemas de reconfiguração de rede e alocação de GD, especialmente para redes de distribuição complexas e de grande porte.

O artigo apresentado por (ABU-MOUTI; EL-HAWARY, 2011) mostra uma abordagem de otimização que emprega um algoritmo de colônia de abelhas artificial (do inglês, ABC) para determinar o tamanho, o fator de potência e a localizações ideais da unidade GD, a fim de minimizar a perda total de potência real do sistema. O algoritmo ABC é uma meta-heurística baseada em população inspirada no comportamento de forrageamento inteligente do enxame de abelhas. Para revelar a validade do algoritmo ABC, sistemas de alimentação de distribuição radial de amostra são examinados com diferentes casos de teste. Os autores constataram que os resultados apresentados pelo algoritmo ABC são

eficiente, robusto e capaz de lidar com problemas de otimização não linear inteiros mistos.

O trabalho escrito por (HOSSEINI et al., 2018) investiga o efeito de unidades de geração distribuída na confiabilidade do sistema elétrico. O algoritmo *Virus Colony Search* (VCS) é empregado para determinar a localização e o tamanho ótimos dos geradores distribuídos sujeitos a melhorar os índices de confiabilidade. A simulação é realizada em uma rede de teste IEEE de 34 barras. Os resultados de otimização também são comparados com os resultados de AG, algoritmo PSO, algoritmo de evolução diferencial (ED), algoritmo de otimização de enxame de partículas multiobjetivo (MOPSO), algoritmo *Modified Shuffled Frog Leaping* (MSFLA), Algoritmo de Busca Gravitacional (ABG), Algoritmo de Otimização Baseada em Biogeografia (ABB), Algoritmo *Hybrid Big Bang-Big Crunch* (HBB-BC) e Algoritmo de Otimização de Enxame de Vagalumes (AEV). Os resultados apresentados nesse artigo apontam além do aumento da confiabilidade, a redução de custo de interrupção do sistema, operação mais econômica da rede de distribuição e melhor desempenho, precisão e velocidade do VCS em relação ao demais.

O trabalho de (TRUONG et al., 2020), propõe um novo esquema baseado em um método meta-heurístico aprimorado para determinar o número ideal de unidades de GD a serem instaladas em redes de distribuição para máxima penetração de GD. O método meta-heurístico proposto é o, do inglês, *Quasi-Oppositional Chaotic Symbiotic Organisms Search* (QOCSOS), que é a versão melhorada do algoritmo SOS original. O QOCSOS integra duas estratégias de pesquisa, incluindo aprendizado baseado em quase oposição e pesquisa local caótica no SOS para obter melhor desempenho. Neste artigo, o QOCSOS foi implementado para encontrar o número ideal, localização, tamanho e fator de potência de unidades GD considerando diferentes valores de fator de potência GD (unitário e não unitário), com o objetivo de reduzir ao máximo a perda de potência ativa. A eficácia do método proposto foi validada nas redes de distribuição radial IEEE padrão, incluindo redes de teste de 33, 69 e 118 barras. Os resultados obtidos pelo QOCSOS foram comparados com os de outros métodos disponíveis na literatura e com o algoritmo SOS padrão. Segundo os autores, os resultados comparativos revelaram que o QOCSOS obteve melhores soluções do que outros métodos comparados, e teve desempenho superior ao SOS.

O artigo apresentado por (LOPEZ et al., 2019) realiza a comparação de técnicas meta-heurísticas para localização e dimensionamento de GD em alimentadores de distribuição. A função objetivo minimiza as perdas de potência ativa em um sistema de distribuição radial incluindo GD. *Tabu Search* (TS), *Scatter Search* e *Ant Colony* foram as técnicas utilizadas para comparar os resultados na minimização de perdas e melhoria dos perfis de tensão em nós críticos quando a geração distribuída foi incluída no alimentador de distribuição. Critérios como transgressão dos limites de tensão e carregamento das linhas são adotadas para dimensionamento e posicionamento das GDs. A análise compara o desempenho das técnicas em termos de precisão e tempos de execução. O autor conclui

que o *Scatter Search* apresenta desempenho superior aos demais aplicados.

O trabalho exposto por (HUY et al., 2022) traz um novo algoritmo, denominado *Chaotic Search Group Algorithm* (CSGA), que é proposto neste estudo em questão para o problema simultâneo de reconfiguração de rede e alocação de GD com o objetivo de perda mínima de potência ativa na rede de distribuição radial. O CSGA é um algoritmo meta-heurístico aprimorado, no qual uma estratégia de busca local caótica é incorporada ao *Search Group Algorithm* (SGA) original, para melhorar seu desempenho de busca. O CSGA proposto foi estudado em reconfigurações de redes de 33, 69, 84 e 118 barras com três níveis de carga. Após a aplicação da reconfiguração de rede e alocação de GD, o perfil de tensão e a perda de potência ativa do sistema melhoraram significativamente. Os resultados produzidos pelo CSGA foram comparados com os obtidos do SGA original e outras técnicas descritas na literatura. Os achados comparativos revelaram que CSGA rendeu melhor qualidade de solução do que SGA e outras técnicas. Portanto, para este estudo, o CSGA é a melhor técnica para resolver o problema apresentado acima.

O artigo apresentado por (HASSAN; SUN; WANG, 2020) traz diversas contribuições para sistema elétrico, sobretudo a respeito das GDs. Este artigo avalia técnicas de ponta para *sizing and siting* de unidades de GD a partir de fontes renováveis de energia com base em trabalhos recentes que já foram aplicados à otimização do sistema de distribuição. Além disso, este artigo apontou os *drivers* ambientais, econômicos, tecnológicos e regulatórios que levam a um rápido interesse no sistema GD baseado em fontes renováveis. Um resumo das ferramentas de otimização meta-heurísticas populares discutidas em forma de tabela com méritos e deméritos foi implementada, entre elas estão: *Simulated Annealing* (SA), PSO, TS, *Ant Colony Search Optimization* (ACSO), ABC, *Firefly search Algorithm* e *Cuckoo search*.

O artigo apresentado por (PHAM; NGUYEN; DINH, 2021) propõe um novo algoritmo de otimização eficaz chamado *Enhanced Coyote Optimization algorithm* (ECOA). Este método proposto é aplicado para selecionar de maneira otimizada a posição e capacidade dos DGs em redes de distribuição radial. É um problema de otimização multi-objetivo onde a instalação adequada de DGs deve simultaneamente reduzir a perda de energia, os custos operacionais, bem como melhorar a estabilidade da tensão. Com base no algoritmo original *Coyote Optimization Algorithm* (COA), ECOA foi desenvolvido para ser capaz de expandir a área de busca e manter um bom grupo de solução em cada geração. Inclui duas modificações para melhorar a eficiência da abordagem COA original onde a primeira substitui a solução central pela melhor solução atual na primeira técnica de geração de nova solução e a segunda centra-se na redução da carga computacional e do tempo de processo na segunda etapa de geração de nova solução. Nesta investigação, várias experiências foram implementadas aplicando ECOA, COA, bem como *Salp Swarm Algorithm* (SSA), *Sunflower Optimization (SOA)* para três redes de distribuição do IEEE com 33,

69 e 85 barras. Os resultados obtidos foram analisados estatisticamente para investigar os parâmetros de controle apropriados e para verificar o desempenho do método ECOA proposto. Além disso, o desempenho do ECOA é também comparado com vários métodos meta-heurísticos semelhantes, tais como AG, PSO, SA, algoritmo de otimização de forragens bacterianas, algoritmo de otimização de pesquisa de retrocesso, HSA and *Whale Optimization Algorithm* (WOA). O autor realiza comparações detalhadas e demonstra que o ECOA pode determinar a localização e tamanho mais eficazes dos DGs com maior velocidade do que outros métodos.

A [Tabela 2.4](#) apresenta vários trabalhos referentes à otimização mono ou multi-objetivo relacionados ao tema desse trabalho, que influenciaram direta ou indiretamente este trabalho, mostrando a(s) função(ões) objetivo e as restrições adotadas e comentários relevantes para a modelagem e o método de solução adotado.

Tabela 2.4 – Exemplos de trabalhos referentes a otimização mono ou multiobjetivo de *sizing and siting* de GD.

Referência	Função(ões)	Restrições	Comentários	Método de Solução
(RUPOLO; MANTOVANI; JUNIOR, 2019)	Minimizar custos com subestações, infraestrutura de rede tais como alimentadores, postes e isoladores, custos com compras de energia, energia não fornecida, instalação de armazenamento de energia (ESS) e gases de efeito estufa	Físicas e elétricas, ajuste do TAP do transformador, capacidade máxima de cada subestação, limites máximos de corrente nos alimentadores, limites máximos e mínimos de tensão, limite orçamentário, radicalidade do sistema e ciclo de carga e descarga das baterias.	Planejamento em média e baixa tensão de sistemas de distribuição de energia elétrica com GD, (ESS) e veículos elétricos (VE).	<i>General Variable Neighborhood Search</i> (GVNS), CBGA

(GRISALES-NORENã et al., 2019)	Minimizar as perdas totais de potência.	Limites máximos e mínimos de tensão em cada barra, ampacidade dos condutores, limites máximos de GDs de acordo com a potência em cada barra e a penetração na rede.	Método de mestres-escravo para localização e dimensionamento ótimo de GDs em redes de corrente contínua (CC).	AGCB, Algoritmo Genético Contínuo (CGA), método de otimização <i>Black Hole</i> (BH), PSO
(GRISALES et al., 2018)	Minimizar perdas de potência na rede.	Algoritmo mono-objetivo com pesos ponderados, perdas, níveis de tensão e menor custo possível de implementação.	Planejamento e operação de sistemas de distribuição em um ambiente de redes inteligentes. Localização e dimensionamento de GD, ESS, religadores automáticos e proteção para isolamento de falta.	AG e PSO
(LÓPEZ-LEZAMA; CONTRERAS; PADILHA-FELTRIN, 2012)	Maximização dos lucros pelo proprietário, minimização dos pagamentos incorridos para atender a demanda prevista pela distribuidora. O problema modelado deixa implícito que a redução das perdas na rede também é atingida.	Mais de uma GD não pode ser alocada no mesmo barramento, limite de potência ativa e reativa, limite de tensão no sistema.	Programação não linear especializado para determinar a localização e o preço de contrato de unidades de GD despacháveis em sistemas de distribuição.	AG

(HUY, 2023)	Minimizar a perda de potencia ativa da rede.	Restrições nos limites de tensão, do fluxo de potência para não exceder a ampacidade dos condutores, limite de penetração de 10% a 60% e critérios de radialidade	Este trabalho apresenta um SOS melhorado para o problema de reconfiguração de rede a alocação de GD. O ISOS proposto combinou a estratégia de interpolação quadrática simples no SOS para melhorar o processo de busca	<i>Improved Symbiotic Organisms Search</i> (ISOS)
(KAWAMBWA et al., 2022)	Minimizar as perdas de potência na rede de distribuição	Balanço de potência e limites máximos e mínimos dos níveis de tensão	Este trabalho propõe uma versão melhorada do SOS, na fase do mutualismo um operador de número aleatório da teoria baseada em nuvens é aplicada.	<i>Cloud Based Model Symbiotic Organism Search</i> (CMSOS)
(JAMATIA; BHATTA-CHARJEE; SHARMA, 2022)	Algoritmo multi-objetivo que visa minimizar a perda do sistema e garantir a estabilidade da rede.	Balanço de potência, limites máximos e mínimos e ampacidade dos condutores	Algoritmo implementação para determinar a localização de VEs e GDs em sistemas testes de 15, 33, 69 e 85 barras, de maneira otimizada.	SOS e PSO

(OMAR; SAIDA; NOURED- DINE, 2022)	Minimizar o custo operacional total da rede.	Limites do sistema de armazenamento e limites máximos e mínimos de geração	<i>Chaotic Symbiotic Organism Search</i> (CSOS) implementado para resolver o problema de otimização de gerenciamento de energia em micro redes contendo recursos de DG e ESS	CSOS, AG e PSO
(RASTGOU; MOSH- TAGH; BAH- RAMARA, 2018)	Minimizar as perdas da rede e melhorar o perfil de tensão.	Limites máximos e mínimos de tensão.	Autor apresenta que a longo prazo, as redes de distribuição não estarão preparadas para o aumento de consumo, assim, realiza o planejamento da rede alocando GDs.	HSA
(IVANOV et al., 2022)	Minimizar a soma das perdas de potência ativa em todos os ramos alocando GDs.	Limites de corrente, tensão e potência dos geradores são utilizados como fatores restritivos	Realiza o comparativo de meta-heurísticas novas contra algoritmos clássicos. O desempenho é analisado sob a mesma ótica, ou seja, utiliza-se dos mesmo parâmetros iniciais	PSO, <i>Tiki-Taka Algorithm</i> (TTA), <i>Archimedes Optimization Algorithm</i> (AOA)

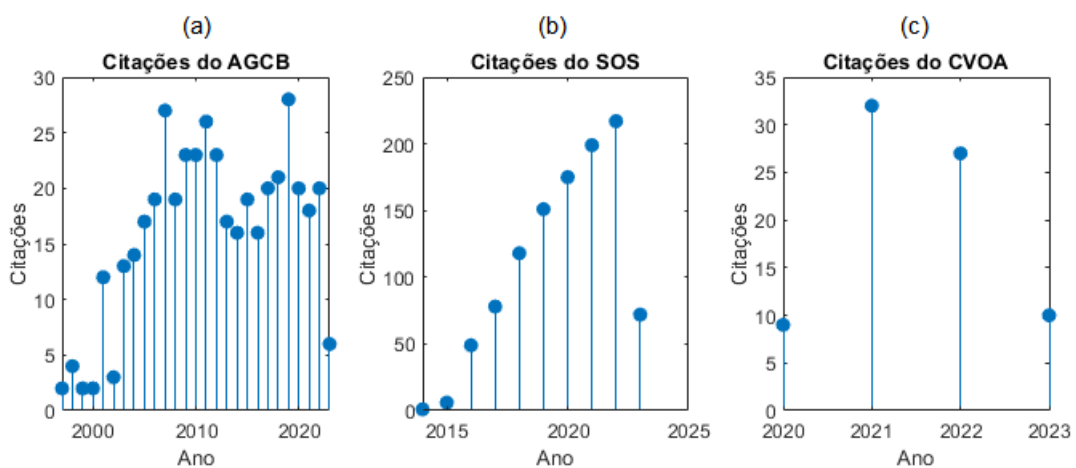
Fonte: O autor

De maneira geral, os trabalhos apresentados acima buscam, sobretudo, minimizar perdas ativas de energia, melhorar o perfil de tensão, aumentar a confiabilidade do sistema e trazer economia, entre outros objetivos. Assim, alinhado a esses objetivos, este trabalho busca contribuir com novas soluções por meio do uso de meta-heurísticas em sistemas de teste de 10, 34, 70 e 126 barras, utilizando as técnicas AGCB, SOS e CVOA. Este último não foi encontrado em nenhum dos trabalhos pesquisados no meio científico e acadêmico,

tornando essa uma contribuição inédita.

As técnicas de otimização aqui adotadas utilizam-se de 2 (duas) meta-heurísticas tradicionais (AGCB e SOS) e 1 (uma) meta-heurística nova (CVOA), com anos de publicação, respectivamente datado de 1997, 2014 e 2020. A [Figura 2.6](#) apresenta o número de citações por ano de cada meta-heurística aqui analisada. Observando a figura acima, é possível concluir que o AGBC apresentado na [Figura 2.6\(a\)](#) está em estabilidade de citações desde o ano 2005, não há crescimento de trabalhos relacionados a essa otimização que totaliza 430 citações. O SOS apresentado na [Figura 2.6\(b\)](#) está em constante crescimento, sendo aproximadamente linear, sendo este o trabalho com mais citações, totalizando 1066 trabalhos relacionados, já o CVOA, apresentado na [Figura 2.6\(c\)](#) apresenta considerável número de citações (78) dado sua recente publicação, muito em decorrência da pandemia que vivemos nos anos passados.

Figura 2.6 – Número de citações por ano de cada meta-heurística analisada.



Fonte: O autor

3 Problema de Alocação de GD

3.1 Método da Soma de Potência (MSP)

O cálculo do problema de fluxo de potência (PFC) apresenta fundamentalmente as condições de operação de um SEP em regime permanente, em que, conhecida a topologia do sistema e uma certa condição de geração e carga, a solução do PFC resulta em obter o estado das tensões de barras (módulo e ângulo de fase) do sistema, assim como demais variáveis não conhecidas previamente, como por exemplo potências geradas, transmitidas e dissipadas., (MONTICELLI, 1983).

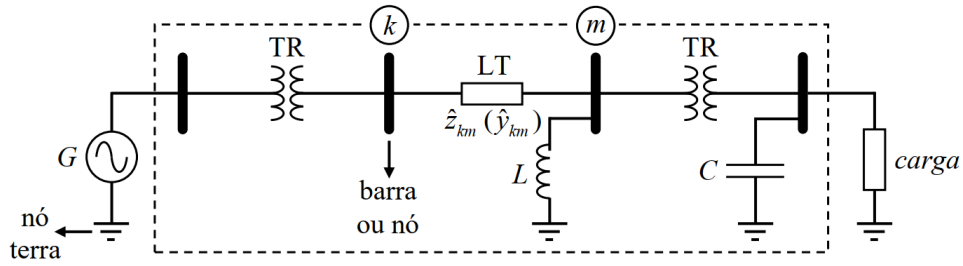
Para a elaboração do PFC, atribui-se um comportamento estático para a rede elétrica em estudo, de modo que os efeitos transitórios podem ser desconsiderados, assume-se que o sistema é equilibrado, a representação por fase considerando tensões de linha e resultados em potências totais no diagrama unifilar é suficiente, (BRIGATTO, 2021).

O modelo convencional do PFC é formado por um conjunto de equações e inequações algébricas não-lineares, que constituem o modelo estático do problema e a solução é revelada empregando-se métodos iterativos desenvolvidos especialmente para a solução deste conjunto de equações e suas incógnitas, (MONTICELLI, 1983; BRIGATTO, 2021).

Os elementos de rede podem ser classificados em dois grupos, elementos de barra e elementos de ramos, conforme sua função e localização no sistema. Os elementos de barra são formados por componentes ligados em derivação ao nó de referência de tensão da rede elétrica, geralmente o nó terra. São formados por geradores e cargas da rede (parte externa do sistema) e modelados por injeções líquidas de potência nas barras, assim como componentes capacitivos e indutivos denominados elementos *shunt* de barra (parte interna do sistema), esses elementos desempenham a função de regulação de tensão na barra em que estão localizados. Os elementos de ramos são formados por componentes conectados entre duas barras, são compostos por linhas de transmissão e/ou distribuição e transformadores do sistema. A Figura 3.1 apresenta a ilustração dos elementos de rede de um SEP e um ramo genérico $k-m$.

O sistema elétrico, por sua vez, pode ser representado através do modelo π equivalente, este traz parâmetros das linhas que estão espalhados ao longo do trajeto entre os pontos de conexão, em que este concentra a representação da linha de transmissão e seus efeitos resistivos e indutivos ao longo dos cabos, bem como pelos efeitos capacitivos entre os cabos e o terra. A Figura 3.2 mostra a representação do modelo π de linhas de transmissão em um ramo genérico $k - m$, em que seus efeitos resistivos e indutivos são modelados por um elemento série \hat{y}_{km} , e seus efeitos capacitivos modelados por admitâncias *shunt* jb_{km}^{sh}


Figura 3.1 – Componentes gerais de sistemas elétricos de potência



Fonte: (BRIGATTO, 2021) adaptado

em cada barra, onde a susceptância *shunt* b_{km}^{sh} corresponde à metade da susceptância *shunt* total $b_{km}^{sh,T}$ da linha, tal que: $b_{km}^{sh} = b_{km}^{sh,T} / 2$.

Figura 3.2 – Modelo π equivalente



Fonte: (BRIGATTO, 2021) adaptado

Na formulação do PFC, a cada barra da rede são relacionadas quatro variáveis, sendo que duas delas entram no problema como dados e as outras duas como incógnitas, a saber:

- V_k - Magnitude da tensão nodal (barra k)
- θ_k - Ângulo da tensão nodal
- P_k - Geração líquida de potência ativa
- Q_k - Geração líquida de potência reativa

A injeção líquida mencionada acima, refere-se ao cálculo de geração menos carga. A depender de quais variáveis nodais entram como dados e quais são vistas como incógnitas, classifica-se três tipos de barras:

- Barras tipo PQ: são dados P_k e Q_k , calcula-se V_k e θ_k
- Barras tipo PV: são dados P_k e V_k , calcula-se Q_k e θ_k

- Barras tipo $V\theta$ (barra de referência): são dados V_k e θ_k , calcula-se P_k e Q_k

As barras dos tipos PQ e PV são empregadas para representar barras de cargas e barras de geração, respectivamente, as barras tipo $V\theta$ tem a dupla função de fornecer a referência angular do sistema e é utilizada para fechar o balanço de potência do sistema, considerando as perdas de transmissão e/ou distribuição não conhecidas antes de se ter a solução final do problema, (BRIGATTO, 2021).

O conjunto de equações do PFC é formado por duas equações para cada barra, cada uma delas denotando o fato de as potências ativas e reativas injetadas em uma barra serem iguais à soma dos fluxos correspondentes que deixam a barra através de linhas de transmissão (BRIGATTO, 2021), pode ser expresso matematicamente como se segue:

$$P_k = \sum_{m \in \Omega_k} P_{km}(V_k, V_m, \theta_k, \theta_m) \quad (3.1)$$

$$Q_k + Q_k^{sh}(V_k) = \sum_{m \in \Omega_k} (V_k, V_m, \theta_k, \theta_m) \quad (3.2)$$

em que

k - 1, ..., NB, sendo NB o número de barras da rede

Ω_k - Conjunto das barras vizinhas da barra k

V_k, V_m - Magnitude das tensões das barras terminais do ramo $k - m$

θ_k, θ_m - Ângulos 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} - Componente da injeção de potência reativa devida ao elemento *shunt* da barra k

Os sistemas de distribuição de energia elétrica (SDEE) possuem a característica de serem tipicamente radiais, em que é necessário basicamente uma subestação (nó fonte) como ponto de recebimento de potência da rede básica a montante e as barras de atendimento de carga, que atendem os consumidores finais a jusante. Logo, na ausência de geração relevante na rede, os fluxos de potência são caracterizados como sistemas unidirecionais.


As redes de distribuição frequentemente apresentam trechos de pequena extensão, sendo classificada como linha curta e possui as seguintes características:

- distâncias menores que 80 km;
- tensão de atendimento menor que 34 kV;
- efeitos capacitivos desprezados ($b_{km}^{sh} = 0$);

- não há o emprego de transformadores defasadores ($\phi_{km} = 0$) e
- ausência de reguladores de tensão ($\alpha_{km} = 0$)

O modelo de ramos em redes de distribuição se resume ao elemento série (\hat{y}_{km}), tal como mostrado na [Figura 3.3](#). Redes de distribuição caracterizam-se por apresentar baixas relações entre resistência e reatância, tal que o acoplamento $Q - V$ é mais fraco do que em redes de alta tensão. O modelo de redes de distribuição geralmente classifica as barras como sendo do tipo carga PQ , exceto o nó fonte que é classificado como sendo $V\theta$, pois esta exerce um controle de tensão bem como a referência angular para as demais barras da rede, devido ao efeito arraste da rede, ([BRIGATTO, 2021](#)).

Figura 3.3 – Elemento série de um ramo genérico $k - m$



Fonte: ([BRIGATTO, 2021](#))

O método da soma de potência (MSP) é fundamentado em um equacionamento em termos de potência e é baseado em métodos de varredura de ramos e barras da rede elétrica, são processos iterativamente repetitivos até que algum critério de parada seja atingido. O método de varredura inversa é um processo acumulativo de potências ativas e reativas nas barras (exceto na barra fonte), adquirida com base no último estado de tensões de barras, partindo dos nós a jusante para os nós a montante (dos nós das extremidades para o nó fonte). A varredura direta é o processo corretivo do módulo da tensão e do ângulo das barras, partindo dos dados previamente conhecido do nó fonte em direção aos nós terminais da rede.

Para a execução do MSP, implementou-se os equacionamentos [Equação 3.3](#) à [Equação 3.19](#). A [Equação 3.3](#) é utilizada para calcular a injeção líquida de potência \hat{S}_k na barra k .

$$\hat{S}_k = (P_k^G - P_k^C) + j(Q_k^G - Q_k^C) \quad (3.3)$$

A [Equação 3.4](#) apresenta a perda de potência no ramos km , somando-se os fluxos de potência da barra k para a barra m e da barra m para a barra k .

$$\hat{S}_{km}^{perda} = S_{km} - S_{mk} \quad (3.4)$$

A [Equação 3.5](#) apresenta a potência acumulada na barra k como sendo a injeção líquida de potência da referida barra mais o somatório das potências acumuladas das barras à

jusante e as perdas de potência dos ramos.

$$\hat{S}_k^{ac} = \hat{S}_k + \sum_{m \in \Omega_k} (\hat{S}_m^{ac} - \hat{S}_{km}^{perdas}) \quad (3.5)$$

A Equação 3.6 determina a abertura angular do ramo em questão.

$$\theta_{km} = \theta_k - \theta_m \quad (3.6)$$

As equações 3.7 e 3.8 expressam as perdas ativas e reativas do ramo km .

$$\hat{P}_{km}^{perdas} = (V_k^2 + V_m^2)g_{km} - 2V_m V_k g_{km} \cos \theta_{km} \quad (3.7)$$

$$\hat{Q}_{km}^{perdas} = -(V_k^2 + V_m^2)b_{km} + 2V_m V_k b_{km} \cos \theta_{km} \quad (3.8)$$

As equações 3.9 e 3.10 são variáveis auxiliares para determinar a tensão na barra (Equação 3.11) e seu respectivo defasamento angular (Equação 3.12).

$$A_m = \frac{2(Q_m^{ac} b_{km} - P_m^{ac} g_{km})}{y_{km}} - V_k^2 \quad (3.9)$$

$$B_m = \frac{(P_m^{ac})^2 + (Q_m^{ac})^2}{y_{km}} \quad (3.10)$$

$$V_m = \sqrt{\frac{1}{2}(\sqrt{A_m^2 - 4B_m} - A_m)} \quad (3.11)$$

$$\theta_m = \theta_k + \phi_{km} + \tan^{-1} \left(\frac{-V_m^2 b_{km} - Q_m^{ac}}{V_m^2 g_{km} - P_m^{ac}} \right) \quad (3.12)$$

As equações 3.13 e 3.14 determina a injeção líquida de potência ativa e reativa, respectivamente, no no fonte.

$$P_k = \sum_{m \in \Omega_k} P_{km} \quad (3.13)$$

$$Q_k = \sum_{m \in \Omega_k} Q_{km} \quad (3.14)$$

As equações 3.15 e 3.16 determinam o fluxo de potência ativa no sentido $k - m$ e $m - k$, respectivamente, assim como as equações 3.17 e 3.18 para a potência reativa.

$$P_{km} = V_k^2 g_{km} - V_k V_m g_{km} \cos \theta_{km} - V_k V_m b_{km} \sin \theta_{km} \quad (3.15)$$

$$P_{mk} = V_m^2 g_{km} - V_k V_m g_{km} \cos \theta_{km} + V_k V_m b_{km} \sin \theta_{km} \quad (3.16)$$

$$Q_{km} = -V_k^2 b_{km} - V_k V_m g_{km} \sin \theta_{km} + V_k V_m b_{km} \cos \theta_{km} \quad (3.17)$$

$$Q_{mk} = -V_m^2 b_{km} + V_k V_m g_{km} \sin \theta_{km} + V_k V_m b_{km} \cos \theta_{km} \quad (3.18)$$

A Equação 3.19 determina a perda de potência ativa total do sistema por meio da soma das perdas de potência dos ramos do sistema.

$$P_{Total}^{perda} = \sum_{m \in \Omega_k} P_{km}^{perdas} \quad (3.19)$$

Das equações acima, temos que:

- \hat{S}_k - Injeção líquida de potência na barra k
- P_k^G - Potência ativa (W) de geração na barra k
- P_k^C - Potência ativa (W) de carga na barra k
- Q_k^G - Potência reativa (var) de geração na barra k
- Q_k^C - Potência reativa (var) de carga na barra k
- \hat{S}_{km}^{perda} , \hat{P}_{km}^{perda} , \hat{Q}_{km}^{perda} - Perda de potência (VA, W ou var) no ramos km
- S_{km} , P_{km} , Q_{km} - Fluxo de potência (VA, W ou var) do ramo km de k para m
- S_{mk} , P_{mk} , Q_{mk} - Fluxo de potência (VA, W ou var) do ramo km de m para k
- \hat{S}_k^{ac} , \hat{P}_k^{ac} , \hat{Q}_k^{ac} - Potência acumulada (VA, W ou var) na barra k
- θ_{km} - Defasamento angular no ramo km
- g_{km} - Condutância no ramo km
- b_{km} - Susceptância no ramo km
- y_{km} - Admitância no ramo km
- A_m, B_m - Variáveis auxiliares para determinação da tensão da barra
- ϕ_{km} - Defasagem angular no ramo km

Para demonstrar o método apresentado, na seção 3.1.1 é exposto um exemplo de uma rede didática para explicitar as equações acima apresentadas.

3.1.1 Exemplo de Cálculo do MSP

Esta seção tem como objetivo exemplificar didaticamente a solução do problema do fluxo de carga para uma rede elétrica fictícia, com base no MSP.

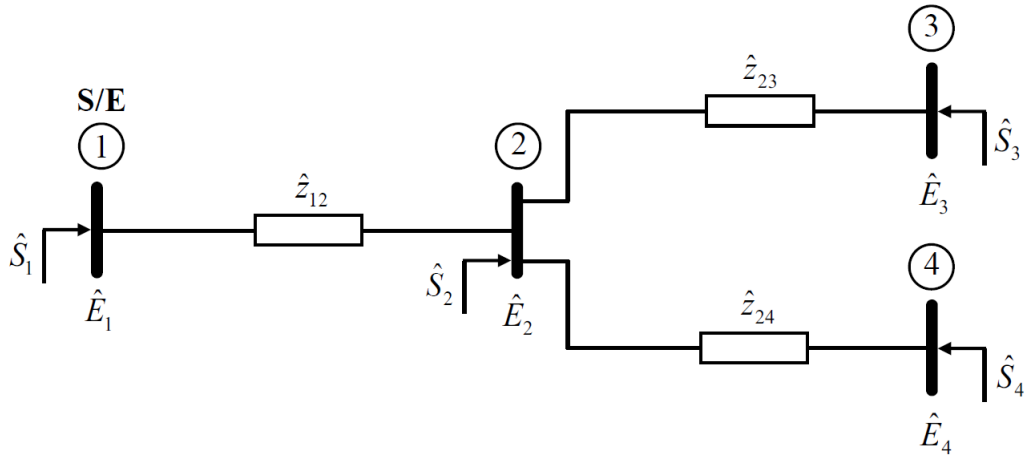
A Figura 3.4 apresenta o diagrama unifilar de uma rede de distribuição fictícia constituída por 4 barras e 3 ramos, a ser utilizada como exemplo para o cálculo do PFC. As Tabelas 3.1 e 3.2 exibem as informações de barra e de ramos, respectivamente, da rede fictícia, onde os valores indicados por (*) são incógnitas da rede elétrica a serem resolvidas, sendo seus dados fornecidos apenas para complemento da Tabela 3.1. Para os cálculos do PFC da rede exemplo em pu será adotado os valores de base: $V_{base} = 13,8kV$ e $S_{base} = 1MVA$.

- **Normalização dos dados de barras em pu - resumo na Tabela 3.3:**

- Módulo de tensão na barra 1 (subestação - barra fonte):

$$V_1^{pu} = \frac{V_1}{V_{base}} = \frac{14.076}{13.800} = 1,02pu$$

Figura 3.4 – Diagrama unifilar da rede exemplo.



Fonte: (BRIGATTO, 2021)

Tabela 3.1 – Dados de barra da rede exemplo.

Barra (k)	Tipo	$V_k(kV)$	$\theta_k(rad)$	$P_k^G(kW)$	$Q_k^G(kvar)$	$P_k^C(kW)$	$Q_k^C(kvar)$
1	2 ($V\theta$)	14,076	0,0	0,0*	0,0*	0,0*	0,0*
2	0 (PQ)	13,8*	0,0*	0,0	0,0	300	100
3	0 (PQ)	13,8*	0,0*	0,0	0,0	500	200
4	0 (PQ)	13,8*	0,0*	200	100	900	400

Tabela 3.2 – Dados de ramos da rede exemplo.

Barra inicial (k)	Barra final (m)	$r_{km}(\Omega)$	$x_{km}(\Omega)$
1	2	4,0	6,0
2	3	7,0	10,0
2	4	6,0	12,0

– Injeções líquidas de potência de barras com base na Equação 3.3:

* Barra 1 (tipo $V\theta$): P_1 e Q_1 será determinado adiante.

* Barra 2:

$$P_2 = \frac{P_2^G - P_2^C}{S_{base}} = \frac{0 - 300 \times 10^3}{10 \times 6} = -0,3 pu; \quad Q_2 = \frac{Q_2^G - Q_2^C}{S_{base}} = \frac{0 - 100 \times 10^3}{10 \times 6} = -0,1 pu$$

* Barra 3:

$$P_3 = \frac{P_3^G - P_3^C}{S_{base}} = \frac{0 - 500 \times 10^3}{10 \times 6} = -0,5 pu; \quad Q_3 = \frac{Q_3^G - Q_3^C}{S_{base}} = \frac{0 - 200 \times 10^3}{10 \times 6} = -0,2 pu$$

* Barra 4:

$$P_4 = \frac{P_4^G - P_4^C}{S_{base}} = \frac{(200 - 900) \times 10^3}{10 \times 6} = -0,7 pu; \quad Q_4 = \frac{Q_4^G - Q_4^C}{S_{base}} = \frac{(100 - 400) \times 10^3}{10 \times 6} = -0,3 pu$$

• Normalização dos dados de ramos em pu - resumo na Tabela 3.4:

– Cálculo da impedância de base: $Z_{base} = \frac{V_{base}^2}{S_{base}} = \frac{13.800^2}{10 \times 6} = 190,4 \Omega$

– Cálculo das impedâncias e admitâncias de ramos em pu:

$$\begin{aligned}
 & * \text{ Ramos 1-2: } \hat{z}_{12} = 4 + j6 \rightarrow \hat{z}_{12}^{pu} = \frac{\hat{z}_{12}}{Z_{base}} = \frac{4+j6}{190,4} = 0,0210 + j0,0315pu \\
 & \hat{y}_{12}^{pu} = \frac{1}{\hat{z}_{12}^{pu}} = \frac{1}{0,0210+j0,0315} = 14,65 - j21,97 = 26,41\angle -0,9828pu \\
 & * \text{ Ramos 2-3: } \hat{z}_{23} = 7 + j10 \rightarrow \hat{z}_{23}^{pu} = \frac{\hat{z}_{23}}{Z_{base}} = \frac{7+j10}{190,4} = 0,0368 + j0,0525pu \\
 & \hat{y}_{23}^{pu} = \frac{1}{\hat{z}_{23}^{pu}} = \frac{1}{0,0368+j0,0525} = 8,947 - j12,78 = 15,60\angle -0,9601pu \\
 & * \text{ Ramos 2-4: } \hat{z}_{24} = 6 + j12 \rightarrow \hat{z}_{24}^{pu} = \frac{\hat{z}_{24}}{Z_{base}} = \frac{6+j12}{190,4} = 0,0315 + j0,0630pu \\
 & \hat{y}_{24}^{pu} = \frac{1}{\hat{z}_{24}^{pu}} = \frac{1}{0,0315+j0,0630} = 6,348 - j12,69 = 14,19\angle -1,1071pu
 \end{aligned}$$

Tabela 3.3 – Dados de barra da rede exemplo normalizados.

Barra (k)	Tipo	V_k (pu)	θ_k (rad)	P_k (pu)	Q_k (pu)
1	2 ($V\theta$)	1,02	0,0	P_1	Q_1
2	0 (PQ)	V_2	θ_2	-0,3	-0,1
3	0 (PQ)	V_3	θ_3	-0,5	-0,2
4	0 (PQ)	V_4	θ_4	-0,7	-0,3

Tabela 3.4 – Dados de ramos da rede exemplo normalizados.

Barra inicial (k)	Barra final (m)	r_{km} (pu)	x_{km} (pu)	g_{km} (pu)	b_{km} (pu)	y_{km} (pu)	ϕ_{km} (rad)
1	2	0,0210	0,0315	14,65	-21,97	26,41	-0,9828
2	3	0,0368	0,0525	8,947	-12,78	15,60	-0,9601
2	4	0,0315	0,0630	6,348	-12,69	14,19	-1,1071

Tem-se a seguir o processo iterativo de cálculo do PFC da rede exemplo.

Iteração $i = 0$

- **Passo 1:** ler dados da rede. Inicializar incógnitas do sistema com o *flat-start*: $V^{(0)} = 1pu$ e $\theta^{(0)} = 0$ rad. A Figura 3.5 a seguir mostra um esquema inicial da rede exemplo, com dados de tensões e potências de barra (dados da Tabela 3.3), bem como admitâncias série de ramos (dados da Tabela 3.4) em pu.
- **Passo 2:** cálculo das perdas de potência ativa e reativa nos ramos da rede: visto que o estado da tensão nas barras 2, 3 e 4 são inicialmente iguais a $1\angle 0$, tem-se que as perdas nos ramos 2-3 e 2-4 são nulas, tal que:

$$\begin{aligned}
 P_{23}^{perdas} &= P_{24}^{perdas} = 0,0pu \\
 Q_{23}^{perdas} &= Q_{24}^{perdas} = 0,0pu
 \end{aligned}$$

- **Passo 3 (varredura inversa):** acúmulo de potências ativa e reativa nas barras, com exceção do nó raiz (Equação 3.5).

– Com base na Figura 3.5, tem-se que as potências acumuladas nas barras são calculadas genericamente por:

$$\begin{aligned}
P_4^{ac} &= P_4 = -0,7pu \text{ e } Q_4^{ac} = Q_4 = -0,3pu \\
P_3^{ac} &= P_3 = -0,5pu \text{ e } Q_3^{ac} = Q_3 = -0,2pu \\
P_2^{ac} &= P_2 + P_3^{ac} + P_4^{ac} - P_{23}^{perdas} - P_{24}^{perdas} = -0,3 - 0,5 - 0,7 - P_{23}^{perdas} - P_{24}^{perdas} = \\
&= -1,5 - P_{23}^{perdas} - P_{24}^{perdas} \\
Q_2^{ac} &= Q_2 + Q_3^{ac} + Q_4^{ac} - Q_{23}^{perdas} - Q_{24}^{perdas} = -0,1 - 0,2 - 0,3 - Q_{23}^{perdas} - Q_{24}^{perdas} = \\
&= -0,6 - Q_{23}^{perdas} - Q_{24}^{perdas}
\end{aligned}$$

Logo, para a iteração atual, tem-se que:

$$\begin{aligned}
P_4^{ac} &= -0,7pu \text{ e } Q_4^{ac} = -0,3pu \\
P_3^{ac} &= -0,5pu \text{ e } Q_3^{ac} = -0,2pu \\
P_2^{ac} &= -1,5 - P_{23}^{perdas} - P_{24}^{perdas} = -1,5 - 0,0 - 0,0 = -1,5pu \\
Q_2^{ac} &= -0,6 - Q_{23}^{perdas} - Q_{24}^{perdas} = -0,6 - 0,0 - 0,0 = -0,6pu
\end{aligned}$$

- **Passo 4 (varredura direta):** fazer $i = 1$ e corrigir o estado das barras da rede, com exceção do nó raiz:

- Ramo 1-2: cálculo da tensão $V_2 \angle \theta_2$ na barra 2 com o valor $V_1 \angle \theta_1 = 1,02 \angle 0$ da barra 1 conhecido, utilizando as equações 3.9 a 3.12:

$$\begin{aligned}
A_2 &= \frac{2(Q_2^{ac} b_{12} - P_2^{ac} g_{12})}{y_{12}} - V_1^2 = \frac{2[(-0,6) \times (-21,97) - (-1,5) \times 14,65]}{26,41^2} - 1,02^2 = -0,9396 \\
B_2 &= \frac{(P_2^{ac})^2 + (Q_2^{ac})^2}{y_{12}} = \frac{(-1,5)^2 + (-0,6)^2}{26,41^2} = 0,00374 \\
V_2 &= \sqrt{\frac{1}{2}(\sqrt{A_2^2 - 4B_2} - A_2)} = \sqrt{\frac{1}{2}(\sqrt{(-0,9396)^2 - 4 \times (0,00374)} - (-0,9396))} = \\
&= 0,9673pu \\
\theta_2 &= \theta_1 + \phi_{12} + \tan^{-1} \left(\frac{-V_2^2 b_{12} - Q_2^{ac}}{V_2^2 g_{12} - P_2^{ac}} \right) = 0 + (-0,9828) + \tan^{-1} \left(\frac{-0,9673^2 \times (-21,97) - (-0,6)}{0,9673^2 \times 14,65 - (-1,5)} \right) = \\
&= -0,035rad
\end{aligned}$$

- Ramo 2-3: cálculo de $V_3 \angle \theta_3$ na barra 3 com o valor $V_2 \angle \theta_2 = 0,9673 \angle -0,035$ da barra 2:

$$\begin{aligned}
A_3 &= \frac{2(Q_3^{ac} b_{23} - P_3^{ac} g_{23})}{y_{23}} - V_2^2 = \frac{2[(-0,2) \times (-12,78) - (-0,5) \times 8,947]}{15,60^2} - 0,9673^2 = -0,8778 \\
B_3 &= \frac{(P_3^{ac})^2 + (Q_3^{ac})^2}{y_{23}} = \frac{(-0,5)^2 + (-0,2)^2}{15,60^2} = 0,0012 \\
V_3 &= \sqrt{\frac{1}{2}(\sqrt{A_3^2 - 4B_3} - A_3)} = \sqrt{\frac{1}{2}(\sqrt{(-0,8778)^2 - 4 \times (0,0012)} - (-0,8778))} = \\
&= 0,9362pu \\
\theta_3 &= \theta_2 + \phi_{23} + \tan^{-1} \left(\frac{-V_3^2 b_{23} - Q_3^{ac}}{V_3^2 g_{23} - P_3^{ac}} \right) = \\
&= (-0,035) + (-0,9601) + \tan^{-1} \left(\frac{-0,9362^2 \times (-12,78) - (-0,2)}{0,9362^2 \times 8,947 - (-0,5)} \right) = -0,056rad
\end{aligned}$$

- Ramo 2-4: cálculo da tensão $V_4 \angle \theta_4$ na barra 4 com o valor $V_2 \angle \theta_2 = 0,9673 \angle -0,035$ da barra 2 conhecido:

$$\begin{aligned}
A_4 &= \frac{2(Q_4^{ac} b_{24} - P_4^{ac} g_{24})}{y_{24}} - V_2^2 = \frac{2[(-0,3) \times (-12,69) - (-0,7) \times 6,348]}{14,19^2} - 0,9673^2 = -0,8537 \\
B_4 &= \frac{(P_4^{ac})^2 + (Q_4^{ac})^2}{y_{24}} = \frac{(-0,7)^2 + (-0,3)^2}{14,19^2} = 0,0029 \\
V_4 &= \sqrt{\frac{1}{2}(\sqrt{A_4^2 - 4B_4} - A_4)} = \sqrt{\frac{1}{2}(\sqrt{(-0,8537)^2 - 4 \times (0,0029)} - (-0,8537))} = \\
&= 0,9221pu
\end{aligned}$$

$$\theta_4 = \theta_2 + \phi_{24} + \tan^{-1} \left(\frac{-V_4^2 b_{24} - Q_4^{ac}}{V_4^2 g_{24} - P_4^{ac}} \right) =$$

$$(-0,0351) + (-1,1071) + \tan^{-1} \left(\frac{-0,9221^2 \times (-12,69) - (-0,3)}{0,9221^2 \times 6,348 - (-0,7)} \right) = -0,074rad$$

- **Passo 5:** testar a convergência do processo com a tolerância adotada ($\varepsilon = 10^{-4}$), com base no módulo do maior erro $V\Delta$ das magnitudes de tensões de barra entre duas iterações sucessivas i e $i + 1$:

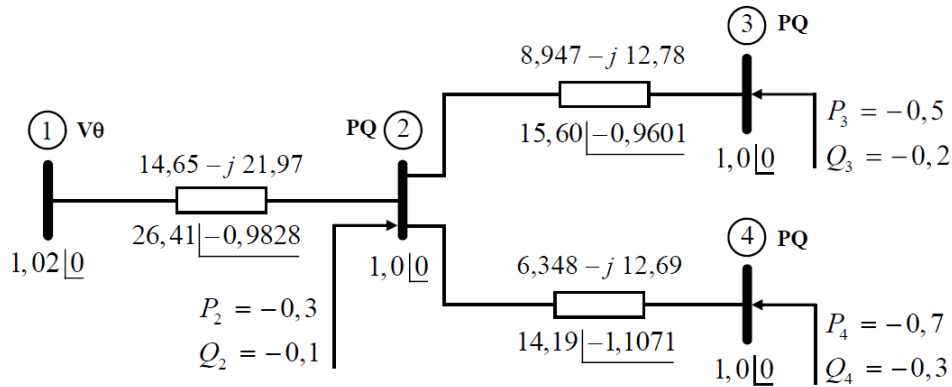
$$\Delta V_2 = |V_2^{(1)} - V_2^{(0)}| = |0,9673 - 1,0| = 0,0327$$

$$\Delta V_3 = |V_3^{(1)} - V_3^{(0)}| = |0,9362 - 1,0| = 0,0638$$

$$\Delta V_4 = |V_4^{(1)} - V_4^{(0)}| = |0,9221 - 1,0| = 0,0779$$

$\max(\Delta V) = 0,0779 > 10^{-4} \rightarrow$ não convergiu. Voltar ao passo 2.

Figura 3.5 – Esquema da rede exemplo com o estado das tensões de barra iniciais.



Fonte: (BRIGATTO, 2021)

Iteração $i = 1$

- Estado das tensões de barra atuais: $V_1 = 1,02pu$ e $\theta_1 = 0rad$; $V_2 = 0,9673pu$ e $\theta_2 = -0,035rad$; $V_3 = 0,9362pu$ e $\theta_3 = -0,056rad$; $V_4 = 0,9221pu$ e $\theta_4 = -0,074rad$

- **Passo 2:** cálculo das perdas de potência ativa e reativa nos ramos da rede:

- Aberturas angulares dos ramos 2-3 e 2-4 (Equação 3.6):

$$\theta_{23} = \theta_2 - \theta_3 = (-0,035) - (-0,056) = 0,021rad$$

$$\theta_{24} = \theta_2 - \theta_4 = (-0,035) - (-0,074) = 0,039rad$$

- Ramo 2-3 (cálculo das perdas no ramos utilizando as equações 3.7 e 3.8):

$$P_{23}^{perda} = (V_2^2 + V_3^2)g_{23} - 2V_2V_3g_{23} \cos \theta_{23} = (0,9673^2 + 0,9362^2 \times 8,947 - 2 \times 0,9673 \times 0,9362 \times 8,947 \times \cos(0,021) = 0,0122pu$$

$$Q_{23}^{perda} = -(V_2^2 + V_3^2)b_{23} + 2V_2V_3b_{23} \cos \theta_{23} = -(0,9673^2 + 0,9362^2 \times (-12,78) + 2 \times 0,9673 \times 0,9362 \times (-12,78) \times \cos(0,021) = 0,0174pu$$

– Ramo 2-4:

$$P_{24}^{perda} = (V_2^2 + V_4^2)g_{24} - 2V_4V_4g_{24} \cos \theta_{24} = (0,9673^2 + 0,9221^2 \times 6,348 - 2 \times 0,9673 \times 0,9221 \times 6,348 \times \cos(0,039) = 0,0215pu$$

$$Q_{24}^{perda} = -(V_2^2 + V_4^2)b_{24} + 2V_2V_4b_{24} \cos \theta_{24} = -(0,9673^2 + 0,9221^2 \times (-12,69) + 2 \times 0,9673 \times 0,9221 \times (-12,69) \times \cos(0,039) = 0,043pu$$

• **Passo 3:** acúmulo de potências nas barras, com exceção da barra fonte:

$$P_4^{ac} = P_4 = -0,7pu \text{ e } Q_4^{ac} = Q_4 = -0,3pu$$

$$P_3^{ac} = P_3 = -0,5pu \text{ e } Q_3^{ac} = Q_3 = -0,2pu$$

$$P_2^{ac} = -1,5 - P_{23}^{perdas} - P_{24}^{perdas} = -1,5 - 0,0122 - 0,0215 = -1,5337pu$$

$$Q_2^{ac} = -0,6 - Q_{23}^{perdas} - Q_{24}^{perdas} = -0,6 - 0,0174 - 0,043 = -0,6604pu$$

• **Passo 4 (varredura direta):** fazer $i = 2$ e corrigir o estado das barras da rede, com exceção do nó raiz:

– Ramo 1-2: cálculo da tensão $V_2 \angle \theta_2$ na barra 2 com o valor $V_1 \angle \theta_1 = 1,02 \angle 0$ da barra 1 conhecido:

$$A_2 = \frac{2(Q_2^{ac}b_{12} - P_2^{ac}g_{12})}{y_{12}} - V_1^2 = \frac{2[(-0,6604) \times (-21,97) - (-1,5337) \times 14,65]}{26,41^2} - 1,02^2 = -0,9344$$

$$B_2 = \frac{(P_2^{ac})^2 + (Q_2^{ac})^2}{y_{12}} = \frac{(-1,5337)^2 + (-0,6604)^2}{26,41^2} = 0,0040$$

$$V_2 = \sqrt{\frac{1}{2}(\sqrt{A_2^2 - 4B_2} - A_2)} = \sqrt{\frac{1}{2}(\sqrt{(-0,9344)^2 - 4 \times (0,0040)} - (-0,9344))} = 0,9644pu$$

$$\theta_2 = \theta_1 + \phi_{12} + \tan^{-1} \left(\frac{-V_2^2 b_{12} - Q_2^{ac}}{V_2^2 g_{12} - P_2^{ac}} \right) = 0 + (-0,9828) + \tan^{-1} \left(\frac{-0,9644^2 \times (-21,97) - (-0,6604)}{0,9644^2 \times 14,65 - (-1,5337)} \right) = -0,035rad$$

– Ramo 2-3: cálculo de $V_3 \angle \theta_3$ na barra 3 com o valor $V_2 \angle \theta_2 = 0,9644 \angle -0,035$ da barra 2:

$$A_3 = \frac{2(Q_3^{ac}b_{23} - P_3^{ac}g_{23})}{y_{23}} - V_2^2 = \frac{2[(-0,2) \times (-12,78) - (-0,5) \times 8,947]}{15,60^2} - 0,9644^2 = -0,8723$$

$$B_3 = \frac{(P_3^{ac})^2 + (Q_3^{ac})^2}{y_{23}} = \frac{(-0,5)^2 + (-0,2)^2}{15,60^2} = 0,0012$$

$$V_3 = \sqrt{\frac{1}{2}(\sqrt{A_3^2 - 4B_3} - A_3)} = \sqrt{\frac{1}{2}(\sqrt{(-0,8723)^2 - 4 \times (0,0012)} - (-0,8723))} = 0,9332pu$$

$$\theta_3 = \theta_2 + \phi_{23} + \tan^{-1} \left(\frac{-V_3^2 b_{23} - Q_3^{ac}}{V_3^2 g_{23} - P_3^{ac}} \right) =$$

$$(-0,035) + (-0,9601) + \tan^{-1} \left(\frac{-0,9332^2 \times (-12,78) - (-0,2)}{0,9332^2 \times 8,947 - (-0,5)} \right) = -0,056rad$$

– Ramo 2-4: cálculo da tensão $V_4 \angle \theta_4$ na barra 4 com o valor $V_2 \angle \theta_2 = 0,9644 \angle -0,035$ da barra 2 conhecido:

$$A_4 = \frac{2(Q_4^{ac}b_{24} - P_4^{ac}g_{24})}{y_{24}} - V_2^2 = \frac{2[(-0,3) \times (-12,69) - (-0,7) \times 6,348]}{14,19^2} - 0,9644^2 = -0,8482$$

$$B_4 = \frac{(P_4^{ac})^2 + (Q_4^{ac})^2}{y_{24}} = \frac{(-0,7)^2 + (-0,3)^2}{14,19^2} = 0,0029$$

$$V_4 = \sqrt{\frac{1}{2}(\sqrt{A_4^2 - 4B_4} - A_4)} = \sqrt{\frac{1}{2}(\sqrt{(-0,8482)^2 - 4 \times (0,0029)} - (-0,8482))} = 0,9191pu$$

$$\theta_4 = \theta_2 + \phi_{24} + \tan^{-1} \left(\frac{-V_4^2 b_{24} - Q_4^{ac}}{V_4^2 g_{24} - P_4^{ac}} \right) =$$

$$(-0,0351) + (-1,1071) + \tan^{-1} \left(\frac{-0,9191^2 \times (-12,69) - (-0,3)}{0,9191^2 \times 6,348 - (-0,7)} \right) = -0,074rad$$

- **Passo 5:** testar a convergência do processo com a tolerância adotada ($\varepsilon = 10^{-4}$), com base no módulo do maior erro $V\Delta$ das magnitudes de tensões de barra entre duas iterações sucessivas i e $i + 1$:

$$\Delta V_2 = |V_2^{(2)} - V_2^{(1)}| = |0,9644 - 0,9673| = 0,0029$$

$$\Delta V_3 = |V_3^{(2)} - V_3^{(1)}| = |0,9332 - 0,9362| = 0,0030$$

$$\Delta V_4 = |V_4^{(2)} - V_4^{(1)}| = |0,9191 - 0,9221| = 0,0030$$

$\max(\Delta V) = 0,0030 > 10^{-4} \rightarrow$ não convergiu. Voltar ao passo 2.

Iteração $i = 2$

- Estado das tensões de barra atuais: $V_1 = 1,02pu$ e $\theta_1 = 0rad$; $V_2 = 0,9644pu$ e $\theta_2 = -0,035rad$; $V_3 = 0,9332pu$ e $\theta_3 = -0,056rad$; $V_4 = 0,9191pu$ e $\theta_4 = -0,074rad$

- **Passo 2:** cálculo das perdas de potência ativa e reativa nos ramos da rede:

– Ramo 2-3:

$$P_{23}^{perda} = 0,0122pu$$

$$Q_{23}^{perda} = 0,0175pu$$

– Ramo 2-4:

$$P_{24}^{perda} = 0,0216pu$$

$$Q_{24}^{perda} = 0,0433pu$$

- **Passo 3 (varredura inversa):** acúmulo de potências nas barras, com exceção da barra fonte:

$$P_4^{ac} = P_4 = -0,7pu \text{ e } Q_4^{ac} = Q_4 = -0,3pu$$

$$P_3^{ac} = P_3 = -0,5pu \text{ e } Q_3^{ac} = Q_3 = -0,2pu$$

$$P_2^{ac} = -1,5 - P_{23}^{perdas} - P_{24}^{perdas} = -1,5 - 0,0122 - 0,0216 = -1,5338pu$$

$$Q_2^{ac} = -0,6 - Q_{23}^{perdas} - Q_{24}^{perdas} = -0,6 - 0,0175 - 0,0433 = -0,6608pu$$

- **Passo 4 (varredura direta):** fazer $i = 3$ e corrigir o estado das barras da rede, com exceção do nó raiz:

– Ramo 1-2: cálculo da tensão $V_2 \angle \theta_2$ na barra 2: $V_2 \angle \theta_2 = 1,02 \angle -0,035rad$

– Ramo 2-3: cálculo da tensão $V_3 \angle \theta_3$ na barra 3: $V_3 \angle \theta_3 = 0,9332 \angle -0,056rad$:

– Ramo 2-4: cálculo da tensão $V_4 \angle \theta_4$ na barra 4: $V_4 \angle \theta_4 = 0,9191 \angle -0,074rad$

- **Passo 5:** testar a convergência do processo com a tolerância adotada ($\varepsilon = 10^{-4}$):

$$\Delta V_2 = |V_2^{(3)} - V_2^{(2)}| = |0,9644 - 0,9644| = 0,0$$

$$\Delta V_3 = |V_3^{(3)} - V_3^{(2)}| = |0,9332 - 0,9332| = 0,0$$

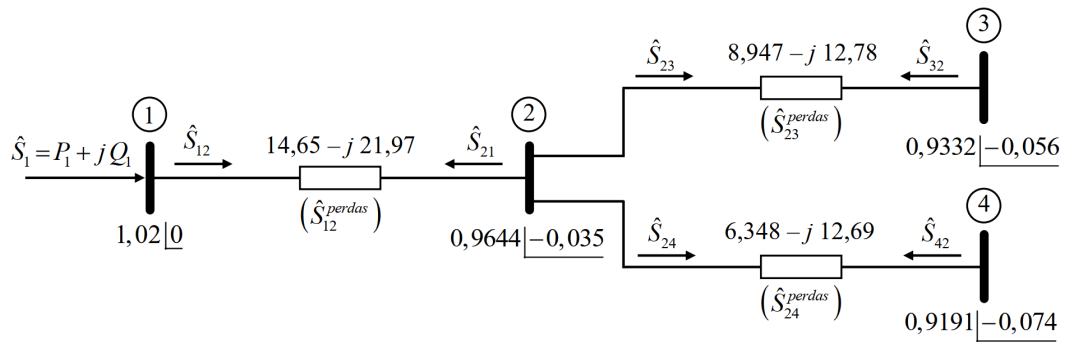
$$\Delta V_4 = |V_4^{(3)} - V_4^{(2)}| = |0,9191 - 0,9191| = 0,0$$

$\max(\Delta V) = 0,0 < 10^{-4} \rightarrow$ processo convergiu em 3 iterações.

Adotar $V_2 = 0,9644pu$, $\theta_2 = -0,035rad$, $V_3 = 0,9332pu$, $\theta_3 = -0,056rad$, $V_4 = 0,9191pu$, $\theta_4 = -0,074rad$.

Até aqui determinou-se o estado da tensão das barras, é necessário encontrar as outras incógnitas do sistema, tal como injeção líquida de potência ativa e reativa no nó fonte além dos fluxos e perdas de potência ativa e reativa nos ramos. Como apoio, o esquema apresentado na [Figura 3.6](#) fornece as informações da rede exemplo, como tensão nas barras e dados de admitâncias de ramos.

Figura 3.6 – Esquema da rede com as tensões de barra e admitância dos ramos.



Fonte: ([BRIGATTO, 2021](#))

- Injeção líquida de potência ativa e reativa na barra 1: $\hat{S}_1 = P_1 + jQ_1$

Utilizando as equações [3.13](#) e [3.14](#):

$$P_1 = \sum_{m \in \Omega_1} P_{1m} \rightarrow P_1 = P_{12}$$

$$Q_1 = \sum_{m \in \Omega_1} Q_{k1} \rightarrow Q_1 = Q_{12}$$

- Fluxos (nos dois sentidos) e perdas de potência ativa e reativa de ramos, conforme [Equação 3.4](#):

$$\text{Ramo 1-2: } \hat{S}_{12} = P_{12} + jQ_{12}, \hat{S}_{21} = P_{21} + jQ_{21}, \hat{S}_{12}^{perdas} = P_{12}^{perdas} + jQ_{12}^{perdas}$$

$$\text{Ramo 2-3: } \hat{S}_{23} = P_{23} + jQ_{23}, \hat{S}_{32} = P_{32} + jQ_{32}, \hat{S}_{23}^{perdas} = P_{23}^{perdas} + jQ_{23}^{perdas}$$

$$\text{Ramo 2-4: } \hat{S}_{24} = P_{24} + jQ_{24}, \hat{S}_{42} = P_{42} + jQ_{42}, \hat{S}_{24}^{perdas} = P_{24}^{perdas} + jQ_{24}^{perdas}$$

- Dados das condutâncias e susceptâncias série de ramos da rede:

$$\text{Ramo 1-2: } g_{12} = 14,65pu, b_{12} = -21,97pu$$

Ramo 2-3: $g_{23} = 8,947pu, b_{23} = -12,78pu$

Ramo 2-4: $g_{24} = 6,348pu, b_{24} = -12,69pu$

- Cálculo das aberturas angulares dos ramos da rede:

Ramos 1-2: $\theta_{12} = \theta_1 - \theta_2 = 0 - (-0,035) = 0,035rad$

Ramos 2-3: $\theta_{23} = \theta_2 - \theta_3 = (-0,035) - (-0,056) = 0,021rad$

Ramos 2-4: $\theta_{24} = \theta_2 - \theta_4 = (-0,035) - (-0,074) = 0,039rad$

- Cálculo dos fluxos de potência ativa P_{km} (Equação 3.15) no sentido k para m e P_{mk} (Equação 3.16) no sentido m para k , bem como das perdas de potência ativa nos ramos da rede (Equação 3.4):

Ramos 1-2:

$$P_{12} = V_1^2 g_{12} - V_1 V_2 g_{12} \cos \theta_{12} - V_1 V_2 b_{12} \sin \theta_{12} = V_1^2 g_{12} - V_1 V_2 (g_{12} \cos \theta_{12} + b_{12} \sin \theta_{12})$$

$$P_{12} = 1,02^2 \times 14,65 - 1,02 \times 0,9644 \times [14,65 \times \cos(0,035) + (-21,97) \times \sin(0,035)] = 1,5969pu$$

$$P_{21} = V_2^2 g_{12} - V_1 V_2 g_{12} \cos \theta_{12} + V_1 V_2 b_{12} \sin \theta_{12} = V_2^2 g_{12} - V_1 V_2 (g_{12} \cos \theta_{12} - b_{12} \sin \theta_{12})$$

$$P_{21} = 0,9644^2 \times 14,65 - 1,02 \times 0,9644 \times [14,65 \times \cos(0,035) - (-21,97) \times \sin(0,035)] = -1,5339pu$$

Aplicando a Equação 3.4.

$$P_{12}^{perdas} = P_{12} + P_{21} = 1,5969 + (-1,5339) = 0,063pu$$

Ramos 2-3:

$$P_{23} = V_2^2 g_{23} - V_2 V_3 g_{23} \cos \theta_{23} - V_2 V_3 b_{23} \sin \theta_{23} = V_2^2 g_{23} - V_2 V_3 (g_{23} \cos \theta_{23} + b_{23} \sin \theta_{23})$$

$$P_{23} = 0,9644^2 \times 8,947 - 0,9644 \times 0,9332 \times [8,947 \times \cos(0,021) + (-12,78) \times \sin(0,021)] = 0,5122pu$$

$$P_{32} = V_3^2 g_{23} - V_2 V_3 g_{23} \cos \theta_{23} + V_2 V_3 b_{23} \sin \theta_{23} = V_3^2 g_{23} - V_2 V_3 (g_{23} \cos \theta_{23} - b_{23} \sin \theta_{23})$$

$$P_{23} = 0,9332^2 \times 8,947 - 0,9644 \times 0,9332 \times [8,947 \times \cos(0,021) - (-12,78) \times \sin(0,021)] = -0,5pu$$

$$P_{23}^{perdas} = P_{23} + P_{32} = 0,5122 + (-0,5) = 0,0122pu$$

Ramos 2-4:

$$P_{24} = V_2^2 g_{24} - V_2 V_4 g_{24} \cos \theta_{24} - V_2 V_4 b_{24} \sin \theta_{24} = V_2^2 g_{24} - V_2 V_4 (g_{24} \cos \theta_{24} + b_{24} \sin \theta_{24})$$

$$P_{24} = 0,9644^2 \times 6,348 - 0,9644 \times 0,9191 \times [6,348 \times \cos(0,039) + (-12,69) \times \sin(0,039)] = 0,7216pu$$

$$P_{42} = V_4^2 g_{24} - V_2 V_4 g_{24} \cos \theta_{24} + V_2 V_4 b_{24} \sin \theta_{24} = V_4^2 g_{24} - V_2 V_4 (g_{24} \cos \theta_{24} - b_{24} \sin \theta_{24})$$

$$P_{24} = 0,9191^2 \times 6,348 - 0,9644 \times 0,9191 \times [6,348 \times \cos(0,039) - (-12,69) \times \sin(0,039)] = -0,7pu$$

$$P_{24}^{perdas} = P_{24} + P_{42} = 0,7216 + (-0,7) = 0,0216pu$$

- Cálculo dos fluxos de potência reativa Q_{km} (Equação 3.17) no sentido k para m e Q_{mk} (Equação 3.18) no sentido m para k , bem como das perdas de potência reativa nos ramos da rede (Equação 3.4):

Ramos 1-2:

$$Q_{12} = -V_1^2 b_{12} - V_1 V_2 g_{12} \sin \theta_{12} + V_1 V_2 b_{12} \cos \theta_{12} = -V_1^2 b_{12} - V_1 V_2 (g_{12} \sin \theta_{12} - b_{12} \cos \theta_{12})$$

$$Q_{12} = -1,02^2 \times (-21,97) - 1,02 \times 0,9644 \times [14,65 \times \sin(0,035) - (-21,97) \times \cos(0,035)] = 0,7552pu$$

$$Q_{21} = -V_2^2 b_{12} + V_1 V_2 g_{12} \sin \theta_{12} + V_1 V_2 b_{12} \cos \theta_{12} = -V_2^2 b_{12} + V_1 V_2 (g_{12} \sin \theta_{12} + b_{12} \cos \theta_{12})$$

$$Q_{21} = -0,9644^2 \times (-21,97) + 1,02 \times 0,9644 \times [14,65 \times \sin(0,035) + (-21,97) \times \cos(0,035)] = -0,6608pu$$

$$Q_{12}^{perdas} = Q_{12} + Q_{21} = 0,7552 + (-0,66075) = 0,0945pu$$

Ramos 2-3:

$$Q_{23} = -V_2^2 b_{23} - V_2 V_3 g_{23} \sin \theta_{23} + V_2 V_3 b_{23} \cos \theta_{23} = -V_2^2 b_{23} - V_2 V_3 (g_{23} \sin \theta_{23} - b_{23} \cos \theta_{23})$$

$$Q_{23} = -0,9644^2 \times (-12,78) - 0,9644 \times 0,9332 \times [8,947 \times \sin(0,021) - (-12,78) \times \cos(0,021)] = 0,2175pu$$

$$Q_{32} = -V_3^2 b_{23} + V_2 V_3 g_{23} \sin \theta_{23} + V_2 V_3 b_{23} \cos \theta_{23} = -V_3^2 b_{23} + V_2 V_3 (g_{23} \sin \theta_{23} + b_{23} \cos \theta_{23})$$

$$Q_{32} = -0,9332^2 \times (-12,78) + 0,9644 \times 0,9332 \times [8,947 \times \sin(0,021) + (-12,78) \times \cos(0,021)] = -0,2pu$$

$$Q_{23}^{perdas} = Q_{23} + Q_{32} = 0,2175 + (-0,2) = 0,0175pu$$

Ramos 2-4:

$$Q_{24} = -V_2^2 b_{24} - V_2 V_4 g_{24} \sin \theta_{24} + V_2 V_4 b_{24} \cos \theta_{24} = -V_2^2 b_{24} - V_2 V_4 (g_{24} \sin \theta_{24} - b_{24} \cos \theta_{24})$$

$$Q_{24} = -0,9644^2 \times (-12,69) - 0,9644 \times 0,9191 \times [6,348 \times \sin(0,039) - (-12,69) \times \cos(0,039)] = 0,3433pu$$

$$Q_{42} = -V_4^2 b_{24} + V_2 V_4 g_{24} \sin \theta_{24} + V_2 V_4 b_{24} \cos \theta_{24} = -V_4^2 b_{24} + V_2 V_4 (g_{24} \sin \theta_{24} + b_{24} \cos \theta_{24})$$

$$Q_{42} = -0,9191^2 \times (-12,69) + 0,9644 \times 0,9191 \times [6,348 \times \sin(0,039) + (-12,69) \times \cos(0,039)] = -0,3pu$$

$$Q_{24}^{perdas} = Q_{23} + Q_{32} = 0,3433 + (-0,3) = 0,04333pu$$

- Cálculo das injeções líquidas de potência na barra 1 (barra fonte - tipo $V\theta$):
Injeção líquida de potência ativa: $P_1 = P_{12} = 1,5969pu$
Injeção líquida de potência reativa: $Q_1 = Q_{12} = 0,7552pu$
- O cálculo das perdas totais do sistema é apresentado na [Equação 3.19](#), como segue:
 $P_{Total} = P_{12} + P_{23} + P_{24} = 0,063 + 0,0122 + 0,0216 = 0,0968 pu$.

3.2 Algoritmos de Solução: Meta-heurística

Meta-heurística é um termo frequentemente usado para descrever um subcampo principal de otimização estocástica. A otimização estocástica é a classe geral de algoritmos e técnicas que empregam algum grau de aleatoriedade para encontrar soluções tão ótimas

quanto possível para problemas complexos, são aplicadas a um amplo grupo de problemas, (LUKE, 2016).

As meta-heurísticas são implementadas quando se tem um grande problema para solucionar, quando há uma solução candidata, é possível testar, avaliar e analisar o quão bom é a solução de acordo com parâmetros e comparações determinadas. A situação mais simples que se pode empregar para a solução de problemas é a pesquisa aleatória, em que é empregado conjuntos de comportamentos aleatórios que no final irá retornar a melhor informação analisada, (LUKE, 2016).

Os algoritmos meta-heurísticos classificam-se nas seguintes categorias principais:

- Mono-objetivo: essas técnicas iniciam seu processo de otimização com uma solução e sua solução é atualizada durante as iterações. Pode levar a solução para ótimos locais e ter dificuldades em encontrar o ótimo global. É necessário aplicar técnicas para perturbar o sistema a fim de sair de ótimos locais.
- Multiobjetivo: inicialmente, esses algoritmos geram uma população de soluções e iniciam seu processo de otimização. Essa metodologia é aplicada quando o problema precisa convergir para objetivos combinados. A população de soluções é atualizada com o número de gerações/iterações. Os algoritmos são benéficos para evitar ótimos locais, pois várias soluções auxiliam umas às outras e têm uma grande exploração do espaço de busca. Eles também têm a qualidade de saltar para a parte promissora do espaço de busca, (AGRAWAL et al., 2021).

Os pesquisadores se atentam aos algoritmos meta-heurísticos por causa de suas características. Diversos algoritmos foram projetos para resolver diferentes tipos de problemas. Com base em seu comportamento, os algoritmos meta-heurísticos podem ser divididos em quatro categorias:

1. Algoritmos evolutivos: o processo evolutivo é considerado uma estratégia adaptativa e é tipicamente aplicado aos domínios de busca e otimização, (BROWNLEE, 2012). Algoritmos evolutivos populares incluem por exemplo o AG que investiga sistemas inspirados na teoria neodarwiniana da evolução por meio da seleção natural. Os AGs pressupõem que em determinada população, os melhores indivíduos têm maiores chances de sobrevivência e de gerarem filhos mais fortes e aptos, assim, a nova população que é a evolução da anterior conduz o problema para sua solução, passando pelos processos de seleção, cruzamento e mutação, (CARVALHO; ALMEIDA; ROCHA, 2020). Nessa categoria, além do AG, podemos citar a evolução estratégica, programação genética, busca tabu e ED (evolução diferencial), (AGRAWAL et al., 2021).

2. Algoritmos baseados em inteligência de enxame: Esses algoritmos são inspirados nos comportamentos sociais de insetos, animais, peixes ou pássaros, entre outros. A técnica popular é o PSO. Ele é inspirado no comportamento de um grupo de pássaros que voam pelo espaço de busca e encontram sua melhor localização (posição). Otimização de colônias de formigas, algoritmo de otimização de enxames de abelhas, otimização de macacos, entre outros, são exemplos de algoritmos de inteligência de enxames, (AGRAWAL et al., 2021).
3. Algoritmos baseados em física: Estes são inspirados nas regras da física no universo. O *Simulated annealing*, *Harmony Search*, entre outros, vêm sob algoritmos baseados em física.
4. Algoritmos relacionados com o comportamento humano: Estas técnicas são puramente inspiradas no comportamento humano. Cada ser humano tem sua maneira de fazer atividades que afetam seu desempenho. Isso motiva os pesquisadores a desenvolver os algoritmos. Os algoritmos populares *Teaching learning-based optimization* (TLBO), algoritmo *League Championship*, (AGRAWAL et al., 2021), entre outros existentes.

Além das quatro categorias citadas acima, há ainda, os algoritmos estocásticos, probabilísticos, imunológicos e neurais, (BROWNEE, 2012). O AGCB pertence a categoria dos algoritmos evolutivos, o SOS faz parte dos algoritmos de enxame e o CVOA é mais um dos recentes algoritmo desenvolvido no campos dos algoritmos virais.

3.2.1 Modelagem do Problema

Um cromossomo, também chamado de indivíduo, é uma solução candidata existente no espaço de busca do problema. Os indivíduos são submetidos a processos evolutivos e estão sujeitos a avaliação, seleção, recombinação (ou cruzamento) e mutação. Após várias iterações dos algoritmos, ao final, quando atingido algum critério de parada, a população deverá apresentar os indivíduos mais aptos.

Neste trabalho os indivíduos são representados por números inteiros que variam de 1 até a quantidade de GD (QntGD) por sistema teste, as QntGDs estão definidas em função da potência total do sistema, do seu respectivo FP e do módulo de GD associado. O módulo das GDs foi definido para não haver uma quantidade elevada de GDs, a fim de limitar o espaço de busca e acelerar o processo de otimização. A Tabela 3.5 apresenta a potência ativa total instalada, o FP de aproximadamente 30%, a potência dos módulos de GD e a QntDG.

A alocação de GD não ocorreu em todas as barras dos sistemas, mas sim em barras candidatas, de tal modo que haja restrição na população por fatores técnicos ou não técnicos para aproximar de situações reais, assim, as barras candidatas foram escolhidas

Tabela 3.5 – Modelagem do Problema de Alocação de GD (Alocação e Tamanho)

Sistema	Pot. Total [kW]	FP	Módulos de GD [kW]	QntGD
10 Barras	12.368,00	30%	500	7
34 Barras	4.636,50	35%	200	8
70 Barras	3802,19	35%	100	11
126 Barras	4230,00	35%	200	7

aleatoriamente cujo tamanho é igual a metade das barras totais do sistema. A [Tabela 3.6](#) mostra indivíduos gerados aleatoriamente para um sistema hipotético de 8 barras, 7 módulos de GD cujo módulo é de 300 kW. Cada número do vetor representa a quantidade dos módulos de GDs, ou seja, a QntGD que será alocada na referida barra. Dito isso, um indivíduo pode ser gerado de modo hipotético como mostrado na [Tabela 3.7](#), note que o indivíduo é limitado a 7 GDs, podendo ter alocação menor que a soma das 7 GDs que equivale a restrição do fator de penetração de 30% para esse caso exemplificativo. Assim, o indivíduo 1 gerado possui 2 módulos de GD na barra 7 e 5 módulos de GD na barra 8, com potência de geração de 300 kW e 1500 kW, respectivamente, o que resulta em uma perda total na rede de 0,30 kW.

Tabela 3.6 – Barras Candidatas dos Sistemas Teste

Sistema	Barras Candidatas	nº Barras Candidatas
10 Barras	3, 7, 8, 9, 10	5
34 Barras	2, 4, 5, 9, 12, 18, 19, 22, 24, 26, 27, 28, 30, 31, 32, 33, 34	17
70 Barras	7, 8, 9, 10, 12, 14, 15, 17, 20, 21, 23, 24, 25, 26, 27, 28, 29, 33, 34, 40, 43, 45, 47, 48, 50, 51, 53, 55, 57, 58, 60, 61, 64, 67, 70	35
126 Barras	3, 4, 5, 10, 11, 12, 17, 18, 20, 22, 24, 27, 29, 32, 33, 34, 36, 37, 38, 43, 46, 48, 51, 52, 55, 59, 60, 63, 64, 65, 66, 67, 68, 71, 73, 74, 77, 78, 82, 84, 85, 87, 88, 92, 93, 94, 96, 98, 99, 101, 102, 103, 104, 105, 110, 111, 112, 113, 117, 118, 119, 120, 125	63

Tabela 3.7 – Exemplo de Geração de Indivíduo para um Caso Hipotético

Barras	4	5	7	8	Função Objetivo [Perda (kW)]
Indivíduo 1	0	0	2	5	0,30
Indivíduo 2	1	1	3	0	0,60
Indivíduo 3	2	3	0	2	0,40
Indivíduo 4	0	0	2	2	0,55

Na literatura não existe um consenso sobre o limite adequado de penetração de GD na rede elétrica. Vários autores propuseram diversas definições para o FP que podem estar relacionadas ao valor percentual de três categorias distintas: ([ABREU; OLIVEIRA; GUERRA, 2010](#))


1. Fator de penetração como um percentual da:
 - Capacidade nominal do alimentador;
 - Capacidade instalada de transformação de uma concessionária;
 - Potência instalada do parque gerador nacional; ou
 - Potência de uma subestação.
2. Fator de penetração como um percentual da demanda máxima:
 - Da subestação;
 - Do alimentador; e
 - Da unidade consumidora
3. Fator de penetração diversos, como um percentual:
 - Da energia gerada pela geração centralizada; ou
 - Da queda de tensão no alimentador

Nota-se que as definições propostas são bem heterogêneas, visto que algumas propõem uma relação com a capacidade nominal, outras com a demanda, e outros com a energia. Pesquisas feitas desde 1985, sobre o impacto da penetração elevada de GD, indicam diversos limites de penetração, variando desde 5% até valores superiores a 50%. Tipicamente de 30% a 40% da potência nominal do transformador, não é necessário fazer reforço ou investimento na infraestrutura de rede, (ABREU; OLIVEIRA; GUERRA, 2010). Assim, esse trabalho considerou FP aproximadamente igual a 30% da demanda nominal da rede para anteder o critério acima.

Na literatura existem diversos métodos de seleção de indivíduo, podemos citar: seleção aleatória, seleção por roleta, seleção por classificação, seleção do torneio, seleção por *ranking*, seleção Boltzman, elitismo e corredor da fama, (JÚNIOR, 2018).

Neste trabalho, na [subseção 3.2.2](#) e [subseção 3.2.3](#), emprega-se o método de seleção por roleta. Este método consiste em realizar a soma de todas as avaliações, de tal modo que a soma represente 100% da roleta, em seguida, cada indivíduo da população recebe um valor proporcional ao valor de sua aptidão. Dessa forma, realiza-se o sorteio de forma aleatória e então um indivíduo é escolhido caso esteja dentro de sua faixa de proporcionalidade. Assim, para indivíduos com alta aptidão é dada uma porção maior da roleta, enquanto indivíduos com menor aptidão recebe um valor de proporcionalidade menor. A [Figura 3.7](#) ilustra o método de seleção por roleta, em que o indivíduo “1” possui melhor *fitness* (função objetivo - FO) e como consequência maior proporcionalidade na roleta, logo, este indivíduo tem mais chance de ser selecionado em relação aos demais, de modo oposto, o indivíduo “4” possui pior FO e menor chance de ser selecionado.

Figura 3.7 – Exemplo de método de seleção por roleta.



Fonte: O autor

Este trabalho tem como função objetivo minimizar as perdas de potência ativa dos ramos dos sistemas testes analisados de 10, 34, 70 e 126 barras, determinando a localização e a potência tão ótimo quanto possível de geradores distribuídos limitados ao FP de aproximadamente 30% da carga da rede, tal como segue na [Equação 3.20](#). Este trabalho não faz distinção do tipo de GD alocada. Será analisado ainda o perfil de tensão com e sem GD e o desempenho quanto ao tempo, número de iterações em termos do fluxo de potência (MSP) e a precisão das soluções para encontrar a convergência das redes teste em cada algoritmo implementado.

$$\text{Minimizar : } FO = \left(\sum_{(k,m) \in \Omega_k} P_{km}^{\text{perdas}} \right) \quad (3.20)$$

3.2.2 Algoritmo Genético de *Chu-Beasley* (AGCB)

O AGCB, proposto por ([CHU; BEASLEY, 1997](#)), foi desenvolvido em 1997 com o objetivo de resolver o problema de atribuição generalizada, em que consiste em encontrar atribuição de custo mínimo de n tarefas para m agentes de modo que cada tarefa seja atribuída a exatamente um agente, sujeito à capacidade de um agente. Esta meta-heurística é similar ao AG tradicional, com algumas melhorias.

Inicialmente é necessário definir uma população inicial do AGCB, neste trabalho a população depende da dimensão do sistema, em que corresponde ao total do número de barras dos sistemas teste, encontrou-se este valor após testes variando o tamanho da matriz população inicial, o valor citado acima forneceu os melhores resultados. A população inicial é composta pelas barras candidatas no formato de quantidade de módulos de GD que estão sujeitas à alocação, são formadas por processos aleatórios e posteriormente classificadas pela FO de modo decrescente, ou seja, do menor para o maior.

Posterior ao processo de gerar a população inicial, há o processo de seleção. O método de seleção empregado é o método da roleta, apresentado na [subseção 3.2.1](#), o

método da roleta é executado quantas vezes for necessária para a seleção dos indivíduos, assim seleciona-se dois indivíduos que serão os pais para a próxima etapa.

O processo seguinte é o de recombinação, que consiste em realizar um ponto de corte aleatório da dimensão do indivíduo dividindo cada cromossomo em duas partes. Cada descendente recebe parte dos pais, separadas pelo ponto de corte da recombinação conforme apresentando na [Figura 3.8](#), (PRADO; GARCES, 2013). Então os filhos são avaliados e aquele que possui a melhor FO, ou seja, menor perda, avança no processo, o pior avaliado é descartado.

Figura 3.8 – Processo de recombinação

	Ponto de corte				
	↓				
Pai 1	0	1	2	2	1
Pai 2	2	0	0	3	2
Filho 1	0	1	0	3	2
Filho 2	2	0	2	2	1

Fonte: (PRADO; GARCES, 2013)

O operador mutação introduz a manutenção da diversidade genética na população, alterando aleatoriamente dois componentes da estrutura escolhida, assim, fornece meios para inserção de novos indivíduos na população, (CHU; BEASLEY, 1997). Neste trabalho, a mutação ocorre alocando uma QntGD em qualquer posição das barras candidatas e remove outra unidade de GD das barras que são diferente de zero, ou seja, remove uma QntGD apenas das barras que possuem GD. Esse procedimento ocorre de modo aleatório e o algoritmo implementado garante que a barra que recebe uma GD seja diferente da barra que remove GD, a [Figura 3.9](#) ilustra como esse procedimento é realizado.

Figura 3.9 – Mutação no AGCB

Filho 1	0	1	0	3	2
Filho mutante	1	1	0	2	2

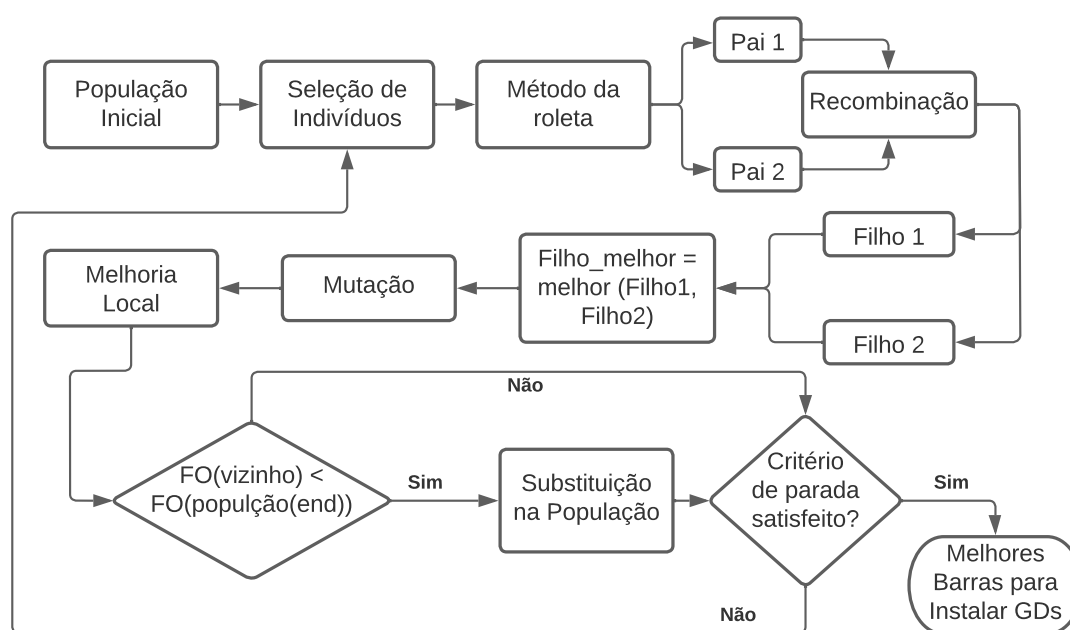
Fonte: (PRADO; GARCES, 2013) adaptado

Como última etapa, há a melhoria local imposta pelo AGCB. Posterior à fase de mutação, realiza-se o processo de análise local de nós vizinhos da alocação de GD da(s) barra(s) analisada(s), avalia-se a aptidão do(s) novo(s) indivíduo(s) e carrega o cromossomo para a próxima população do indivíduo com melhor *fitness*, (CHU; BEASLEY, 1997). A melhoria local ocorre em termos físicos, isto é, em um caso hipotético as barras 5 e 7

possuem 2 e 3 unidades de GD, respectivamente. A primeira barra possui como vizinho as barras 4 e 6 e a segunda as barras 6 e 8, a seleção do vizinho ocorre de forma aleatória em que a solução candidata vizinha pode ser as combinações: (4 e 6), (6 e 8) e (4 e 8), mas nunca (6 e 6), caso haja barra candidata repetida um novo vizinho é gerado. As unidades de GD alocadas nas novas barras também são realizadas de maneira aleatória, mas sempre limitada ao FP.

A nova solução candidata é levada para a próxima população somente se for melhor que algum indivíduo já presente na matriz de solução populacional, se isto se confirmar, o pior indivíduo é substituído da matriz supracitada, de modo oposto, caso seja pior ou igual a um indivíduo com a mesma FO, esta solução será descartada e o processo é reiniciado. A ideia geral do AGCB está apresentada no Pseudocódigo 1 e no fluxograma da Figura 3.10. O processo de recombinação e mutação são realizados em todas as iterações.

Figura 3.10 – Fluxograma do AGCB



Fonte: (PRADO; GARCES, 2013) adaptado

3.2.3 Symbiotic Organisms Search (SOS)

Na natureza, os organismos vivos estão constantemente interagindo uns com os outros. Essas interações recebem o nome de relações simbióticas e são classificadas de acordo com os efeitos causados no organismo. Uma relação simbiótica pode afetar os organismos envolvidos de três maneiras distintas, a saber: beneficiar, prejudicar ou ser neutra, (ANDRÉ, 2015).

Algorithm 1 Pseudocódigo Algoritmo Genético de *Chu-Beasley*

```

1: População Inicial
2: for  $i = 1 \rightarrow \text{size}(\text{Barras\_Candidatas})$  do
3:    $\text{pop\_inicial} \leftarrow \text{individuo}(i)$ 
4: end for
5:
6: Seleção de indivíduo
7:  $\text{pai}_1 \leftarrow \text{método\_roleta}(\text{pop\_inicial})$ 
8:  $\text{pai}_2 \leftarrow \text{método\_roleta}(\text{pop\_inicial})$ 
9:
10: Recombinação
11:  $\text{ponto\_corte} \leftarrow \text{randon}(0 \rightarrow \text{size}(\text{Barras\_Candidatas}))$ 
12:  $\text{filho}_1 = \text{pai}_1(\text{ponto\_corte}) + \text{pai}_2(1 - \text{ponto\_corte})$ 
13:  $\text{filho}_2 = \text{pai}_1(1 - \text{ponto\_corte}) + \text{pai}_2(\text{ponto\_corte})$ 
14:  $\text{avaliar}(\text{filho}_1, \text{filho}_2)$ 
15:
16: Ordenar os filhos baseado na avaliação
17:  $\text{filho\_melhor} \leftarrow \text{melhor}(\text{filho}_1, \text{filho}_2)$ 
18:  $\text{filho\_pior} \leftarrow \text{pior}(\text{filho}_1, \text{filho}_2)$ 
19: if  $\text{filho\_melhor} < \text{pop\_inicial}(\text{end}, \text{end})$  then
20:    $\text{pop\_inicial}(\text{end}, :) \leftarrow \text{filho\_melhor}$ 
21: end if
22:
23: Mutação
24:  $\text{mutação}1 \leftarrow \text{randon}(1 \rightarrow \text{size}(\text{Barras\_Candidatas}))$ 
25:  $\text{filho\_mutante}(i) \leftarrow \text{filho\_melhor}(\text{mutação}1) + 1$ 
26:  $\text{GD} \leftarrow \text{find}(\text{filho\_mutante} \neq 0)$ 
27:  $\text{mutação}2 \leftarrow \text{randon}(1 \rightarrow \text{size}(\text{GD})), |\text{mutação}2 \neq \text{mutação}1$ 
28:  $\text{filho\_mutante}(i) \leftarrow \text{filho\_melhor}(\text{mutação}2) - 1$ 
29:  $\text{avaliar}(\text{filho\_mutante})$ 
30: if  $\text{filho\_mutante} < \text{pop\_inicial}(\text{end}, \text{end})$  then
31:    $\text{pop\_inicial}(\text{end}, :) \leftarrow \text{filho\_mutante}$ 
32: end if
33:
34: Melhoria Local
35:  $\text{melhoria\_local} \leftarrow \text{vizinhos}(\text{filho\_mutante})$ 
36:  $\text{avaliar}(\text{melhoria\_local})$ 
37: if  $\text{melhoria\_local} < \text{pop\_inicial}(\text{end}, \text{end})$  then
38:    $\text{pop\_inicial}(\text{end}, :) \leftarrow \text{melhoria\_local}$ 
39: end if
40:
41: Verificar condição de parada
42: if  $\text{melhor\_solução} = \text{true}$  then
43:   return  $\text{solução}$ 
44: else
45:   volte para Seleção de indivíduos
46: end if

```

O micologista alemão, de Bary, utilizou pela primeira vez a palavra grega "simbiose" para descrever o comportamento de coabitação de organismos diferentes, atualmente, a simbiose refere-se a toda e qualquer associação permanente entre indivíduos de espécies diferentes que, geralmente, exerce influência recíproca no metabolismo, seja ela uma interação positiva ou negativa (SYST et al., 2022; CHENG; PRAYOGO, 2014; LOPES, 2006). As interações simbióticas são, geralmente, alienadas em dois tipos, a saber, obrigatórias e facultativas. Na primeira, ambos os organismos dependem totalmente um do outro para sua sobrevivência enquanto, na segunda, os organismos podem ou não depender um do outro. (SYST et al., 2022)


Os algoritmos meta-heurísticos atuais são baseados em fenômenos naturais, por exemplo, a ABC simula o comportamento de forrageamento de enxame de abelhas, PSO simula o comportamento de bandos de animais e o AG simula processo de evolução natural. Quase todos os algoritmos meta-heurísticos aplicam uma sucessão de operações às soluções em cada iteração, com o objetivo de gerar novas soluções para a próxima iteração. Um AG padrão possui dois operadores, recombinação e mutação. O HSA propõe três regras para improvisar uma nova harmonia: consideração de memória, ajuste de tom e escolha aleatória. Três fases foram introduzidas no algoritmo ABC para localizar a melhor fonte de alimento, essas fases são abelha empregada, abelha observadora e abelha exploradora, (CHENG; PRAYOGO, 2014).

Com base no descrito anteriormente, em 2014 (CHENG; PRAYOGO, 2014) desenvolveu o *Symbiotic Organism Search* (SOS) que simula as interações simbióticas dentro de uma relação de organismos em um mesmo ecossistema que são usados para buscar o organismo mais apto. No SOS, a geração de novas soluções é regida pela imitação da interação biológica entre dois organismos no ecossistema, três fases que se assemelham ao modelo de interação biológica do mundo real são introduzidas: fase de mutualismo, fase de comensalismo e fase de parasitismo. Como na natureza, o mutualismo é uma relação interespecífica em que ambos os organismos são beneficiados, o comensalismo apenas um organismo se beneficia, sem causar prejuízo ao outro, o parasitismo apenas um organismo se beneficia em prejuízo do outro, (CHENG; PRAYOGO, 2014; LOPES, 2006).

A Figura 3.11 ilustra um grupo de organismos simbióticos que coexistem em um ecossistema. De forma geral, os organismos desenvolvem relações simbióticas como uma estratégia para se adaptar às mudanças em seu ambiente. As relações simbióticas favorecem os organismos a aumentar sua aptidão e vantagem de sobrevivência a longo prazo. Assim, é correto concluir que a simbiose tem desempenhado um papel fundamental na construção e na moldagem de todos os ecossistemas modernos e continua a sustentá-los, (CHENG; PRAYOGO, 2014).

Semelhante a outros algoritmos baseados em população, o SOS usa iterativamente uma população de soluções candidatas para áreas promissoras no espaço de busca no pro-

Figura 3.11 – Indivíduos simbióticos vivendo juntos em um ecossistema



Fonte: (CHENG; PRAYOGO, 2014)

cesso de busca da solução global ótima. O SOS começa com uma população inicial chamada ecossistema. No ecossistema inicial, um grupo de organismos é gerado aleatoriamente para o espaço de busca. Cada organismo representa uma solução candidata para o problema de alocação de GD. Cada indivíduo no ecossistema está associado a um determinado valor de aptidão, que reflete o grau de adaptação ao objetivo desejado. Durante o processo de busca, cada organismo da população interage continuamente com outro através das três fases já descritas para criar novos organismos. Em cada fase, o valor da *fitness* é calculada para cada novo organismo. A atualização de um novo organismo é realizada apenas se seu valor de aptidão for avaliado melhor do que sua aptidão pré-interação. Em cada fases, o melhor organismo é selecionado para a próxima geração. O processo de três fases é realizado até que o critério de parada seja atendido.

3.2.3.1 Mutualismo

Um exemplo de mutualismo, que beneficiam ambos os organismos participantes, é a associação entre um fungo e uma alga ou um fungo e uma cianobactéria, formando o que é conhecido como líquen. Nessa associação, as algas ou cianobactérias fornecem matéria orgânica ao fungo, e este, por sua vez, cria as condições favoráveis para o desenvolvimento desses organismos, disponibilizando sais minerais e tornando o ambiente úmido. Esta fase do SOS desempenha tais relações mutualísticas, (LOPES, 2006).

No SOS, X_i é um organismo, ou indivíduo correspondente ao i -ésimo membro do ecossistema. Outro organismo X_j é então selecionado aleatoriamente do ecossistema para interagir com X_i . Ambos os organismos se envolvem em um relacionamento mutualístico com o objetivo de aumentar a vantagem mútua de sobrevivência no ecossistema. Novas soluções candidatas para X_i e X_j são calculadas com base na simbiose mutualística entre os organismos X_i e X_j , que é modelada nas equações 3.21 e 3.22, (CHENG; PRAYOGO, 2014).

$$X_{inovo} = X_i + rand(0, 1) \times (X_{best} - Vetor_Mútuo \times BF_1) \quad (3.21)$$

$$X_{jnovoo} = X_j + rand(0, 1) \times (X_{best} - Vetor_Mútuo \times BF_2) \quad (3.22)$$

$$Vetor_Mútuo = \frac{X_i + X_j}{2} \quad (3.23)$$

O termo $rand(0, 1)$ é um vetor de números aleatórios entre 0 e 1. Na natureza, algumas interações mutualísticas podem dar maiores vantagens adaptativas para um organismo do que para outro. Esse é o motivo para se ter os termos BF_1 e BF_2 , este termo retrata que um organismo A pode ter grande benefício enquanto que o indivíduo B pode ter benefício não muito significativo, assim, esses fatores representam o nível de benefício para cada organismo, ou seja, se um organismo se beneficia parcialmente ou totalmente da interação, (CHENG; PRAYOGO, 2014; NOGUEIRA, 2021), esse termo recebe um número aleatório entre 1 e 2.

A equação 3.23 apresenta um vetor chamado de "Vetor Mútuo", que corresponde a característica de relacionamento entre o organismo X_i e X_j . A parte da equação $(X_{best} - Vetor_Mútuo \times BF_1)$ está retratando o esforço mutualístico para atingir seu objetivo de melhorar sua aptidão para garantir sua sobrevivência. O termo X_{best} é necessário ser utilizado, pois representa o mais alto grau de aptidão, portanto, é utilizado como alvo para o incremento de aptidão dos demais indivíduos, (CHENG; PRAYOGO, 2014).

Por fim, os organismos são atualizados apenas se sua nova aptidão for melhor que sua *fitness* antes da interação dos organismos.

3.2.3.2 Comensalismo

Um exemplo de comensalismo está na interação entre o tubarão e o peixe-piloto, o segundo se beneficia dos restos de alimentos que o primeiro captura, isto é, apenas um organismo se beneficia enquanto o outro não é afetado, (LOPES, 2006).

Semelhante à fase de mutualismo, um indivíduo, X_j , é selecionado aleatoriamente do ecossistema para interagir com X_i . Nesta circunstância, o organismo X_i tenta se beneficiar da interação. No entanto, o próprio organismo X_j não se beneficia nem sofre com o relacionamento. A nova solução candidata de X_i é calculada de acordo com a simbiose comensal entre o organismo X_i e X_j , que é modelada na equação 3.24. Seguindo a regra, o organismo X_i é atualizado somente se sua nova *fitness* for melhor do que sua aptidão antes da interação, (CHENG; PRAYOGO, 2014).

$$X_{inovo} = X_i + rand(-1, 1) \times (X_{best} - X_j) \quad (3.24)$$

A parte da equação $(X_{best} - X_j)$ representa como a relação entre esses organismos é benéfica para melhorar a aptidão no ecossistema de X_i ao maior nível, fornecida por X_j e representada por X_{best} , (CHENG; PRAYOGO, 2014).

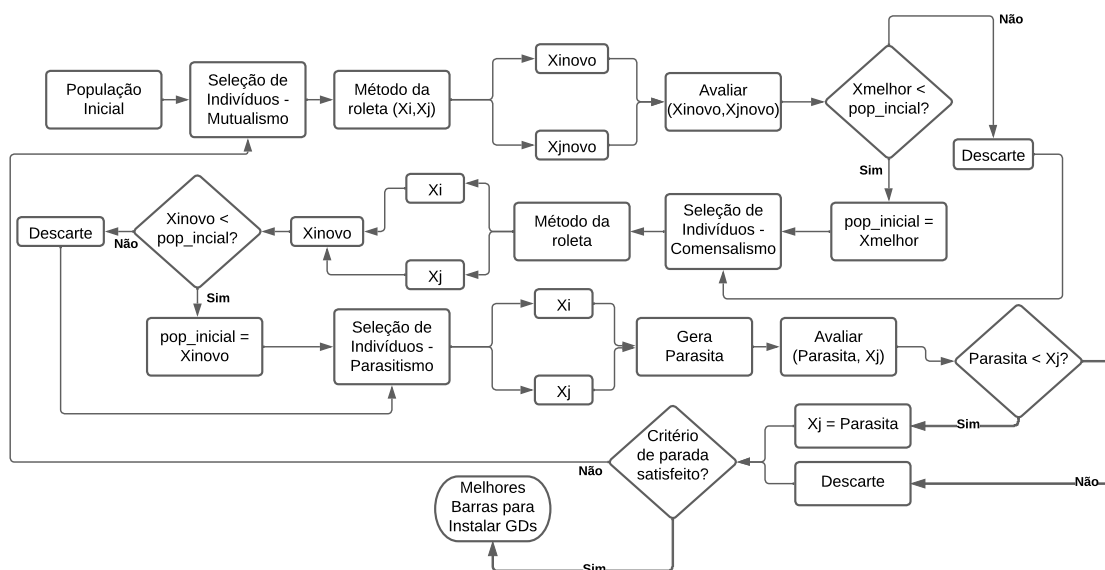
3.2.3.3 Parasitismo

Um exemplo de parasitismo é o parasita plasmódio, que é transmitido pela picada da fêmea infectada do mosquito *anopheles* para o hospedeiro, o homem. Enquanto o parasita prospera e se reproduz dentro do hospedeiro humano, o homem sofre de malária e pode morrer como resultado da relação, (LOPES, 2006; CHENG; PRAYOGO, 2014).

No SOS, o organismo X_i recebe um papel parecido ao do mosquito *anopheles* através da criação de um parasita artificial chamado “Vetor_Parasita”. O Vetor_Parasita é criado no espaço de busca duplicando o organismo X_i e, em seguida, modificando as dimensões selecionadas aleatoriamente usando um número aleatório. O organismo X_j é selecionado aleatoriamente do ecossistema e serve como hospedeiro para o vetor parasita. O Vetor_Parasita tenta substituir X_j no ecossistema. Ambos os organismos são avaliados para medir sua aptidão, caso o Vetor_Parasita tenha um valor de aptidão melhor, ele matará o organismo X_j e ocupará sua posição no ecossistema. Se o valor de aptidão de X_j for melhor, X_j será imune ao parasita e o Vetor_Parasita não poderá mais viver naquele ecossistema.

A ideia geral do SOS está representado no pseudocódigo 2 e seu respectivo fluxograma na Figura 3.12.

Figura 3.12 – Fluxograma do AGCB



Fonte: (CHENG; PRAYOGO, 2014) adaptado

3.2.4 Algoritmo de Otimização de Coronavírus (CVOA)

O surto de SARS-CoV-2 (coronavírus 19 ou COVID-19), teve epicentro na província de Hubei, na China e se espalhou para muitos outros países. A OMS (Organização Mundial da Saúde) declarou emergência de saúde global com base nas crescentes taxas de notificações de casos em locais da China e pelo mundo. O que tudo indica, o SARS-CoV-2 fez a transição de animais para humanos em Wuhan, China, no entanto, não há precisão da rota de transmissão de possível hospedeiros intermediários, (VELAVAN; MEYER, 2020). Em todo o mundo, até o dia 17/01/2023 houve mais de 667 milhões de infectados e mais de 6 milhões de mortos, (OXFORD, 2022). É desconhecido sobre o vírus quantas e quais serão as infecções leves, assintáticas e graves, bem como os casos não reportados e se eles podem transmitir o vírus ou não, (LI et al., 2020). Atualmente espera-se que indivíduos saudáveis tenha infecções leves, e ao contrário, pessoas com comorbidades possa ter complicações da COVID-19, no entanto, esta não é uma regra.

Os vírus podem infectar pessoas e essas pessoas podem morrer, infectar outras pessoas ou se recuperar após o período da doença. As vacinas e o sistema imunológico combatem a doença e ajudam amenizar seus efeitos enquanto o indivíduo ainda está infectado, (MARTÍNEZ-ÁLVAREZ et al., 2020). Esse comportamento pode ser modelado por um modelo SIR, que é traduzido por suscetíveis, infectados e recuperados, (TOLIC; KLEINEBERG; ANTULOV-FANTULIN, 2018).

A rápida disseminação do coronavírus, juntamente com sua capacidade de causar infecção na maioria dos países do mundo de forma rápida e impressionante, inspirou a nova meta-heurística proposta por (MARTÍNEZ-ÁLVAREZ et al., 2020), denominada algoritmo de otimização de coronavírus (CVOA). Este trabalho realizou pequenos ajustes de modo a obter melhores resultados, sobretudo na função de infecção e taxa de disseminação.

Segundo (MARTÍNEZ-ÁLVAREZ et al., 2020), as principais vantagens do CVOA em relação as demais abordagens, podem ser resumidas nos itens abaixo:

1. Atualmente, as estatísticas do coronavírus não são conhecidas com precisão pela comunidade científica e alguns aspectos ainda são controversos, como a taxa de reinfecção (MANSKI; MOLINARI, 2021). Assim sendo, a taxa de infecção, a taxa de mortalidade, a taxa de disseminação ou a probabilidade de reinfecção não podem ser estimadas com precisão, tal fato se deve a alguns problemas, como a falta de testagem para pessoas assintomáticas. Porém, o estado atual da pandemia sugere alguns valores, conforme relatado pela OMS, (ORGANIZATION, 2023). Sendo assim, o CVOA é parametrizado com as taxas e probabilidades condizentes com a realidade, evitando que outros estudiosos demandam tempo e energia em busca da taxa mais adequada.
2. No CVOA, o número de infectados aumenta nas primeiras iterações, após um certo

número de iterações, o número de infectados começa a diminuir, até atingir um conjunto nulo de infectados. Isto imita a disseminação do vírus, em que inicialmente uma pequena quantidade de indivíduos são infectados e devido a transmissibilidade entre organismo, essa taxa aumenta atingindo seu valor de pico, à medida que os indivíduos são infectados e criam anticorpos, em paralelo com as vacinas, estes se tornam imunes ou resistente ao vírus.

3. Taxas elevadas de disseminação do coronavírus é vantajoso para explorar mais profundamente regiões promissoras, processo de intensificação, enquanto o uso de cepas paralelas garante que todas as regiões do espaço de busca sejam exploradas uniformemente, processo de diversificação, (MARTÍNEZ-ÁLVAREZ et al., 2020).

Atualmente, felizmente conseguiu-se desenvolver vacinas que combatem o coronavírus em tempo nunca visto na história da civilização, a vacinação contra a COVID-19 oferece esperança para o fim da pandemia. Em todo o mundo, houve grandes esforços voltados para encontrar vacinas seguras e eficazes. Em julho de 2021, havia 184 vacinas candidatas contra COVID-19 em desenvolvimento pré-clínico, 105 em desenvolvimento clínico e 18 vacinas aprovadas para uso emergencial por pelo menos uma autoridade reguladora, (NDWANDWE; WIYSONGE, 2021). Até o início de 2023, mais de treze bilhões de doses da vacina COVID-19 foram administradas em todo o mundo, mais de cinco bilhões de pessoas haviam tomado pelo menos uma dose e mais de cinco bilhões de pessoas estão completamente vacinadas, (ORGANIZATION, 2023). No CVOA, a vacinação é implementada diminuindo a taxa de disseminação do vírus a medida que o tempo da pandemia é transcorrido, ou seja, conforme o aumento do tempo da duração da pandemia, de tal modo que ao final das iterações a taxa de transmissão seja pequena.

3.2.4.1 Metodologia

A seção que se segue, apresenta a metodologia do CVOA, em que há a descrição das etapas de uma única cepa, posteriormente será sugerido os valores dos parâmetros aqui descritos, logo em seguida será apresentado os pseudocódigos e o fluxograma.

3.2.4.1.1 Etapas

Passo 1: Geração da população inicial. A população inicial é composta por um indivíduo, o chamado paciente zero (**PZ**). Do mesmo modo que na pandemia COVID-19, identifica-se o primeiro indivíduo infectado. Se nenhum mínimo local anterior foi encontrado, uma inicialização aleatória para o PZ é sugerida.

Passo 2: Propagação de doenças. Dependendo do indivíduo, vários casos são avaliados:

1. Cada indivíduo infectado tem uma probabilidade de morrer (**P_DIE**), de acordo com a taxa de mortalidade por coronavírus. Esses indivíduos não podem espalhar a doença para outros indivíduos.
2. Os indivíduos que não morrerem causarão infecção a novos indivíduos (processo chamado de intensificação). Dois tipos de disseminadores são considerados, de acordo com uma determinada probabilidade (**P_SUPERSPREADER**).
 - a) Disseminadores comuns. Indivíduos infectados irão infectar novos indivíduos de acordo com uma taxa de propagação regular (**SPREADING_RATE**).
 - b) Super disseminadores. Indivíduos infectados irão infectar novos indivíduos de acordo com uma taxa de super transmissão (**SUPERSPREADING_RATE**).
3. Há outra consideração que é necessária para garantir a diversificação. Tanto os indivíduos comuns quanto os super disseminadores podem viajar e explorar soluções muito diferentes no espaço de busca. Assim, os indivíduos têm uma probabilidade de viajar (**P_TRAVEL**) para propagar a doença para soluções que podem ser bem diferentes (**TRAVELLER_RATE**). No caso de não ser viajante, novas soluções serão alteradas de acordo com uma **ORDINARY_RATE**.

Passo 3: Atualizando populações. Três populações são mantidas e atualizadas para cada geração

1. Mortos (**Deaths**). Se algum indivíduo morrer, ele será adicionado a essa população e nunca mais poderá ser utilizado.
2. População recuperada (**Recovered population**). Após cada iteração, os indivíduos infectados (após a disseminação do coronavírus conforme a etapa anterior) são enviados para a população recuperada. Sabe-se que há probabilidade de reinfecção (**P_REINFECTION**). Assim, um indivíduo pertencente a essa população pode ser reinfecção em qualquer iteração, desde que atenda ao critério de reinfecção. Outra situação deve ser considerada, pois os indivíduos podem estar isolados, como se estivessem seguindo as recomendações de distanciamento social. Para simplificar, considera-se que um indivíduo isolado é enviado para a população recuperada quando a probabilidade de isolamento for atendida (**P_ISOLATION**).
3. Nova população infectada (**New Infected Population**). Essa população reúne todos os indivíduos infectados em cada iteração, de acordo com o procedimento descrito nas etapas anteriores. É possível que novos indivíduos infectados sejam repetidos em cada iteração, conseqüentemente, é recomendável remover esses

indivíduos repetidos dessa população antes que a próxima iteração comece a ser executada.

Passo 4: Critério de parada. Uma das características mais interessantes da abordagem proposta reside na sua capacidade de terminar sem a necessidade de controlar qualquer parâmetro. Essa situação ocorre porque as populações recuperadas e mortas crescem constantemente com o passar do tempo, e a nova população infectada não pode infectar novos indivíduos. Espera-se que o número de indivíduos infectados aumente para um certo número de iterações. No entanto, a partir de uma iteração específica, o tamanho da nova população infectada será menor do que o tamanho atual porque as populações recuperadas e mortas são muito grandes e o tamanho da população infectada diminui com o tempo. Além disso, um número predefinido de iterações (**PANDEMIC_DURATION**) pode ser adicionado ao critério de parada. As medidas de distanciamento social também contribuem para atingir o critério de parada, ([MARTÍNEZ-ÁLVAREZ et al., 2020](#)).

3.2.4.1.2 Configuração de Parâmetros Sugeridos

Como o CVOA simula a propagação do COVID-19, a maioria das taxas (propagação, isolamento ou mortalidade) já são conhecidas. Este fato evita que o pesquisador perca tempo selecionando valores para tais taxas e torna a CVOA uma meta-heurística bastante fácil de executar, ([MARTÍNEZ-ÁLVAREZ et al., 2020](#)). No entanto, deve-se notar que as taxas ainda estão mudando e espera-se que variem ao longo do tempo, à medida que a pandemia evolui. Os valores sugeridos foram recuperados da OMS, ([ORGANIZATION, 2019](#)) e são discutidos a seguir:

1. **P_DIE**: Um indivíduo infectado pode morrer com uma determinada probabilidade. A taxa de letalidade varia em função de alguns fatores, tais como localização, idade da pessoa infectada e a presença de condições de saúde subjacentes, no entanto, essa taxa é definida em aproximadamente 5% pela comunidade científica, ([MIZUMOTO; CHOWELL, june 2020](#)). Logo, $P_DIE = 0,05$.
2. **P_SUPERSPREADER**: É a probabilidade de um indivíduo disseminar a doença para um número maior de indivíduos saudáveis. Acredita-se que esta situação afete até 10% da população infectada, ([WU; LEUNG; LEUNG, feb 2020](#)), portanto, $P_SUPERSPREADER = 0,1$. Após esta condição ser validada, duas situações podem ser encontradas:
 - a) **ORDINARY_RATE**. Se o indivíduo infectado não for um super disseminador, então a taxa de infecção será um número aleatório entre zero e cinco.

- b) SUPERSPREADER_RATE. Se o indivíduo infectado for um super disseminador, até 15 indivíduos saudáveis podem ser infectados. Sugere-se que esta taxa seja controlada por um número aleatório no intervalo entre seis e quinze.
3. P_REINFECTION. Esta é uma questão muito controversa, uma vez que a comunidade científica não concorda se um indivíduo recuperado pode ser novamente testado positivo ou não. Conforme reivindicado pela OMS, nenhum estudo avaliou se a presença de anticorpos para o coronavírus confere imunidade a infecções subsequentes por esse vírus em humanos, (ORGANIZATION, 2020). Alguns testes realizados na Coreia do Sul sugerem uma taxa de 2% de acordo com o *Korea Centers for Disease Control and Prevention*. Portanto, para o momento $P_REINFECTION = 0,02$.
4. P_ISOLATION. Esse valor é incerto porque os países estão tomando medidas diferentes para o isolamento social. Este parâmetro ajuda a reduzir o crescimento exponencial da população infectada após cada iteração. Sugere-se que $P_ISOLATION$ maior ou igual a 0,7, (MARTÍNEZ-ÁLVAREZ et al., 2020).
5. P_TRAVEL. Essa probabilidade simula como um indivíduo infectado pode viajar para qualquer lugar do mundo e infectar indivíduos saudáveis. Sabe-se que quase 10% da população viaja durante uma semana (tempo simulado para cada iteração), então $P_TRAVEL = 0,1$, (MARTÍNEZ-ÁLVAREZ et al., 2020).
6. PANDEMIC_DURATION. Esse parâmetro simula a duração da pandemia, ou seja, o número de iterações. Atualmente, esses dados são desconhecidos, portanto, esse número pode ser ajustado ao tamanho do problema. Sugere-se que $PANDEMIC_DURATION = 30$.

3.2.4.1.3 Pseudocódigos

Esta seção fornece o pseudocódigo das funções do CVOA, é realizado comentários para melhor entendê-las.

Function CVOA. Esta é a função principal e seu pseudocódigo está apresentado no Algoritmo 3. Quatro matrizes devem ser mantidas: *dead* (mortos), *recovered* (recuperados), *infect* (conjunto atual de infectados) e *new infect* (conjunto de novos infectados gerados pela disseminação do coronavírus dos atuais indivíduos infectados). A população inicial é gerada por meio do paciente zero (PZ), que é um indivíduo aleatório.

O número de iterações é controlado pelo laço de repetição principal, avaliando a duração da pandemia ($PANDEMIC_DURATION$) e se ainda existe algum indivíduo infectado. Nesse laço, cada indivíduo pode morrer (é enviado para a matriz *dead*) ou

infectar, aumentando assim o tamanho da nova população infectada. Este mecanismo de infecção é codificado em *Function Infect* (pseudocódigo 4).

Uma vez formada a nova população, todos os indivíduos são avaliados e se algum deles superar o melhor atual, este é atualizado.

Function infect. Essa função recebe um indivíduo infectado e retorna o conjunto de novos infectados. Duas listas adicionais, *recovered* e *dead*, também são recebidas como parâmetros de entrada, pois devem ser atualizadas após a avaliação de todos os indivíduos infectados. O pseudocódigo é mostrado no Algoritmo 4.

Duas condições são avaliadas para determinar o número de novos indivíduos infectados (uso de *SPREADER_RATE* e *SUPERSPREADER_RATE*) ou quão diferentes serão os novos indivíduos (*ORDINARY_RATE* ou *TRAVELER_RATE*). A implementação de como esses novos indivíduos infectados são codificados de acordo com tais taxas é realizada na função *newInfection*.

Function newInfection. Dado um indivíduo infectado, esta função gera novos indivíduos infectados de acordo com as taxas de propagação e disseminação. Esta função também controla se os novos indivíduos infectados ainda não estão na lista *dead* (nesta situação, *newInfect* é ignorada) ou na lista *recovered* (nesse caso, o *P_REINFECTION* é aplicado para determinar se o indivíduo será reinfectado ou se permanece na lista *recovered*). Além disso, considera que o novo indivíduo potencialmente infectado pode ser isolado, o que é controlado por *P_ISOLATION*. Embora o uso de uma lista extra possa ser implementado, decidiu-se tratar esses indivíduos como recuperados. Portanto, se um indivíduo isolado tentar ser infectado, ele será adicionado à lista *recovered*.

A geração efetiva dos novos indivíduos infectados deve ser realizada na função *replicate*. Esta função retorna um conjunto de novos indivíduos infectados, de acordo com as taxas mencionadas.

O pseudocódigo para o procedimento descrito pode ser encontrado no Algoritmo 5.

Function replicate. Esta função tem o objetivo de replicar os indivíduos infectados, nela contém como um indivíduo transmite o vírus para outros novos organismos.

Para realizar a disseminação no COVID-19, utilizou-se o Método de Pesquisa em Vizinhança Variável (do inglês, *Variable Neighborhood Search*, VNS), (SOUZA et al., 2002) e uma mutação que serão descritos a seguir.

Como já descrito anteriormente, cada indivíduo infectado assume a posição de um vetor em uma matriz, em que as linhas são os indivíduos e as colunas são as barras que as GDs são alocadas com seu respectivo módulo de alocação. Assim, seja uma matriz $A = (A_{ij})_{m \times n}$, onde m representa o indivíduo e n as barras candidatas. Em

cada célula a_{ij} é colocado o módulo de GD t alocado ao indivíduo i e barra j . A célula que contém o numeral zero indica que não há módulo de GD alocado. A Figura 3.13 apresenta como o problema é modelado.

Figura 3.13 – Exemplo matriz de alocação de GD

		Barras Candidatas				
		1	2	3	4	5
Indivíduos	1	0	1	0	3	2
	2	1	0	2	0	3
	3	2	0	2	1	1
	4	2	0	0	0	2
	5	0	3	0	3	0

Fonte: (SOUZA et al., 2002) adaptado

Dada uma solução a , para atingir uma solução a' , onde a' é dito vizinho de a , são utilizados três tipos de movimento (Realocação, Troca e Mutação), (SOUZA et al., 2002). Para este problema de alocação de GD utilizando a meta-heurística CVOA e VNS como função, um indivíduo infectado terá a capacidade de infectar novos indivíduos de acordo com o disseminador R_0 . Para ilustrar, será feita a infecção de três novos indivíduos a partir do primeiro organismo da matriz da Figura 3.13.

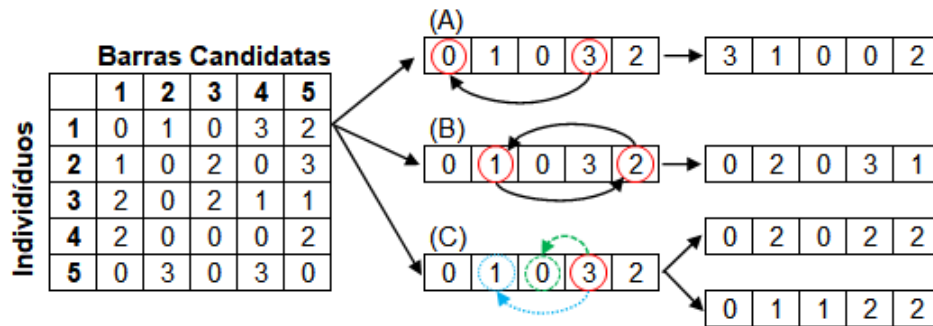
A realocação consiste em realocar as posições dos módulos de GDs, onde uma posição que contenha GD é distribuída para outra, desde que a nova posição esteja vazia, a Figura 3.14 (A) apresenta esse procedimento, observa-se que a GD de módulo 3 da barra 4 é realocada para a barra 1, gerando um novo indivíduo.

A troca, como o próprio nome diz, consiste em trocar de posição duas GDs, contanto que tenham módulos diferentes, a Figura 3.14 (B) exibe esse procedimento, percebe-se que as GDs da barra 2 e 5, de módulos 1 e 2, respectivamente foram permutadas, também infectando outro indivíduo.

A mutação, é o mesmo procedimento empregado no AGCB (subseção 3.2.2), resumidamente, uma unidade de GD é removida de qualquer barra com GD e é redistribuída para qualquer outra barra candidata, garantindo que haja diversidade na população. Na Figura 3.14 (C) esse procedimento é ilustrados em duas situações possíveis, em que acontecerá uma ou outra, como exemplo, a remoção de uma unidade de GD ocorrerá na barra candidata 4, a primeira situação ocorre alocando GD em uma barra candidata que já contém GD, adotaremos a barra 2, exposto em azul com contorno pontilhado, e a segunda é inserindo a GD em barra que não contém GD, ilustrado em verde com contorno tracejado. Ou seja, demonstrou-se os dois tipos de mutações possíveis de ocorrer.


Assim, apresentou-se o modelo de disseminação do vírus, o primeiro indivíduo infectou outras três pessoas, representado parte da nova população infectada, esses indivíduos pode ser verificado na [Figura 3.15](#).

Figura 3.14 – Exemplo de Realocação (A), Troca (B) e Mutação (C)



Fonte: O autor

Figura 3.15 – Exemplo de novas infecções



Fonte: O autor

O procedimento de disseminação do coronavírus ocorre de maneira aleatória, a cada nova iteração o algoritmo pode escolher entre realocar, trocar ou mutação. Em cada iteração, a aptidão dos organismos é avaliada e na próxima população os novos indivíduos podem infectar outros, dependendo das taxas de disseminação. O Pseudocódigo 6 apresenta os procedimentos desta função.

Function die. Esta função é chamada a partir da função principal. Ele avalia todos os indivíduos da população infectada e determina se eles morrem ou não, de acordo com o dado P_DIE. Aqueles que atendem a essa condição são enviados para a lista *dead*. Algoritmo 7 descreve este procedimento.

Function selectBestIndividual. Esta é uma função auxiliar usada para encontrar a melhor *fitness* em uma lista de indivíduos infectados. Seu pseudocódigo é mostrado no Algoritmo 8.

O fluxograma do CVOA é apresentado na [Figura 3.16](#) como se segue.

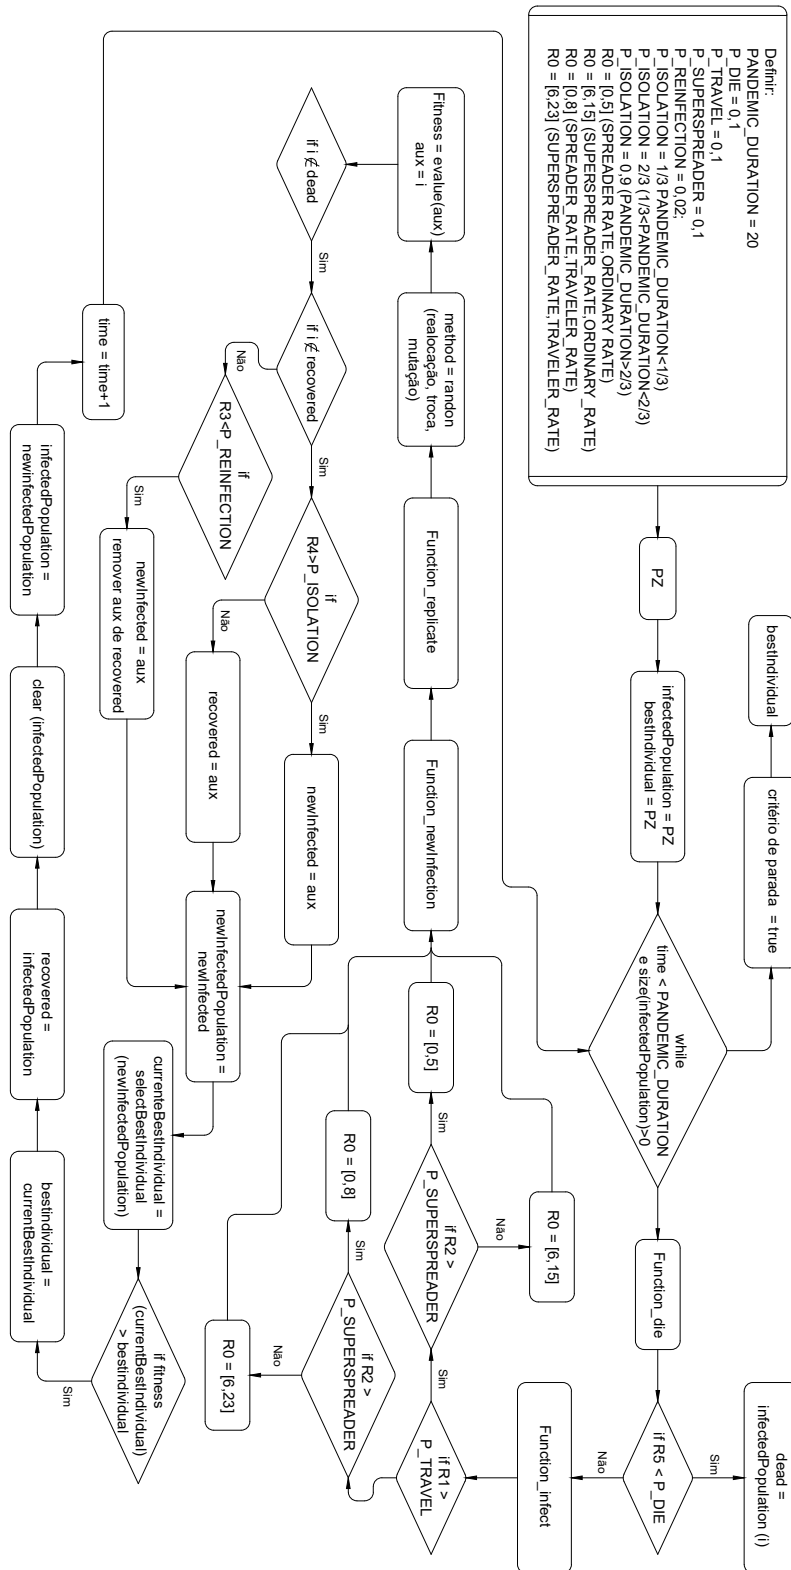
Algorithm 2 Pseudocódigo *Symbiotic Organism Search*

```

1: População Inicial
2: for  $i = 1 \rightarrow size(Barras\_Candidatas)$  do
3:    $pop\_inicial \leftarrow individuo(i)$ 
4: end for
5:  $avaliar(pop\_inicial)$ 
6:  $X_{best} \leftarrow melhor(pop\_inicial)$ 
7:
8: Seleção de indivíduo
9:  $X_i \leftarrow método\_roleta(pop\_inicial)$ 
10:  $X_j \leftarrow método\_roleta(pop\_inicial)$ 
11:
12: Mutualismo
13:  $BF_1 \leftarrow randon(1, 2)$ 
14:  $BF_2 \leftarrow randon(1, 2)$ 
15:  $Vetor\_Mútuo = \frac{X_i + X_j}{2}$ 
16:  $X_{inovo} = X_i + rand(0, 1) \times (X_{best} - Vetor\_Mútuo \times BF_1)$ 
17:  $X_{jnovos} = X_j + rand(0, 1) \times (X_{best} - Vetor\_Mútuo \times BF_2)$ 
18:  $avaliar(X_{inovo}, X_{jnovos})$ 
19:  $X_{melhor} \leftarrow melhor(X_{inovo}, X_{jnovos})$ 
20: if  $X_{melhor} < pop\_inicial(end, end)$  then
21:    $pop\_inicial(end, :) \leftarrow X_{melhor}$ 
22: end if
23:
24: Comensalismo
25:  $X_{best} \leftarrow melhor(pop\_inicial)$ 
26:  $X_i \leftarrow método\_roleta(pop\_inicial)$ 
27:  $X_j \leftarrow método\_roleta(pop\_inicial)$ 
28:  $X_{inovo} = X_i + rand(-1, 1) \times (X_{best} - X_j)$ 
29:  $avaliar(X_{inovo})$ 
30: if  $X_{inovo} < pop\_inicial(end, end)$  then
31:    $pop\_inicial(end, :) \leftarrow X_{inovo}$ 
32: end if
33:
34: Parasitismo
35:  $X_i \leftarrow método\_roleta(pop\_inicial)$ 
36:  $X_j \leftarrow método\_roleta(pop\_inicial)$ 
37:  $Vetor\_Parasita \leftarrow 2 * dim(X_i(m, n))$  ▷ duplicar aleatoriamente m ou n
38:  $avaliar(X_j, Vetor\_Parasita)$ 
39: if  $Vetor\_Parasita < X_j$  then
40:    $X_j \leftarrow Vetor\_Parasita$ 
41: end if
42:
43: Verificar condição de parada
44: if  $melhor\_solução = true$  then
45:   return  $solução$ 
46: else
47:   volte para Seleção de indivíduos
48: end if

```

Figura 3.16 – Fluxograma do CVOA



Fonte: O autor

Algorithm 3 Function CVOA

```

1: define infectedPopulation, newInfectedPopulation as set of Individual
2: define dead, recovered as list of Individual
3: define PZ, bestIndividual, currentBestIndividual, aux as Individual
4: define time as integer
5: define bestSolutionFitness, currentbestFitness as real
6: time  $\leftarrow$  0
7: PZ  $\leftarrow$  InfectPatientZero()
8: infectedPopulation  $\leftarrow$  PZ
9: bestIndividual  $\leftarrow$  PZ
10: while time < PANDEMIC_DURATION AND sizeof (infectedPopulation) > 0 do
11:   dead  $\leftarrow$  die(infectedPopulation)
12:   for all  $i \in$  infectedPopulation do
13:     aux  $\leftarrow$  infect(i,recovered,dead)
14:     if notnull(aux) then
15:       newInfectedPopulation  $\leftarrow$  aux
16:     end if
17:   end for
18:   currentBestIndividual  $\leftarrow$  selectBestIndividual(newInfectedPopulation)
19:   if fitness(currentBestIndividual) > bestIndividual then
20:     bestIndividual  $\leftarrow$  currentBestIndividual
21:   end if
22:   recovered  $\leftarrow$  infectedPopulation
23:   clear(infectedPopulation)
24:   infectedPopulation  $\leftarrow$  newInfectedPopulation
25:   time  $\leftarrow$  time +1
26: end while
27: return bestIndividual

```

Algorithm 4 *Function infect*

Require: infected **as of** *Individual*; recovered, dead **as list of** *Individual*

```

1: define R1, R2 as real
2: define newInfected as list of Individual
3: R1  $\leftarrow$  RandomNumber()
4: R2  $\leftarrow$  RandomNumber()
5: if R1 >  $P\_TRAVEL$  then
6:   if R2 >  $P\_SUPERSPREADER$  then
7:     newInfected  $\leftarrow$  newInfection (infected, recovered, dead, SPREADER_RATE,
      ORDINARY_RATE)
8:   else
9:     newInfected  $\leftarrow$  newInfection (infected, recovered, dead, SUPERSPREA-
      DER_RATE, ORDINARY_RATE)
10:  end if
11: else
12:   if R2 >  $P\_SUPERSPREADER$  then
13:     newInfected  $\leftarrow$  newInfection (infected, recovered, dead, SPREADER_RATE,
      TRAVELER_RATE)
14:   else
15:     newInfected  $\leftarrow$  newInfection (infected, recovered, dead, SUPERSPREA-
      DER_RATE, TRAVELER_RATE)
16:   end if
17: end if
18: return newInfected

```

Algorithm 5 *Function newInfection*

Require: infected **as of** *Individual*; recovered, dead **as list of** *Individual*

```

1: define R3, R4 as real
2: define newInfected as list of Individual
3: R3  $\leftarrow$  RandomNumber()
4: R4  $\leftarrow$  RandomNumber()
5: aux  $\leftarrow$  replicate(infected, SPREAD_RATE, TRAVELER_RATE)
6: for all  $i \in aux$  do
7:   if  $i \notin$  dead then
8:     if  $i \notin$  recovered then
9:       if R4 >  $P\_ISOLATION$  then
10:        newInfected  $\leftarrow$   $i$ 
11:       else
12:        recovered  $\leftarrow$   $i$ 
13:       end if
14:       else if R3 <  $P\_REINFECTION$  then
15:        newInfected  $\leftarrow$ 
16:        remove  $i$  from recovered
17:       end if
18:     end if
19:   end for
20: return newInfected

```

Algorithm 6 *Function replicate*

Require: infected as *list of Individual*; infectedPopulation as *list of Individual***Require:** R0 as *integer*

```

1: define newInfected as list of Individual
2: for all i ∈ R0 do
3:   method ← Randon (Realocação, Troca, Mutação)
4:   if method = Realocação then
5:     newInfected ← newInfection(Realocação)
6:   else if method = Troca then
7:     newInfected ← newInfection(Troca)
8:   else if method = Mutação then
9:     newInfected ← newInfection(Mutação)
10:  end if
11:  Fitness ← evaluate(newInfection)
12:  newInfected ← i
13: end for
14: return newInfected

```

Algorithm 7 *Function die*

Require: infectedPopulation as *list of Individual*

```

1: define dead as list of Individual
2: define R5 as real
3: for all i ∈ infectedPopulation do
4:   R5 ← RandonNumber
5:   if R5 < P_DIE then
6:     dead ← i
7:   end if
8: end for
9: return dead

```

Algorithm 8 *Function selectBestIndividual*

Require: infectedPopulation as *list of Individual*

```

1: define bestIndividual as Individual
2: define bestFitness as real
3: bestFitness ← MINVALUE
4: for all i ∈ infectedPopulation do
5:   if fitness(i) > bestFitness then
6:     bestFitness ← fitness(i)
7:     bestIndividual ← i
8:   end if
9: end for
10: return bestIndividual

```

4 Testes e Resultados

4.1 Introdução

Empregando o MSP descrito na seção 3.1 com os algoritmos de otimização apresentados na seção 3.2, alocou-se módulos de GD (QntGD) em barras candidatas para cada sistema teste de distribuição, sendo estes 10, 34, 70 e 126 barras, cuja a função objetivo é a diminuição da perda de potência ativa nas linhas de distribuição, conforme apresentado na equação 3.20.

Como metodologia, executou-se cada sistema utilizando cada meta-heurística aplicada um total de 20 vezes, com o objetivo de coletar o número de iterações que os sistemas convergem, a quantidade de fluxo de potência necessário, o tempo de execução como fator comparativo das heurísticas e as barras candidatas que receber(em) a(s) GD(s).

Não há na literatura um problema modelado exatamente como este, com os mesmos módulos de GD e barras candidatas, sendo assim, realizou-se uma busca exaustiva para determinar o mínimo global do sistema teste de 10 barras, em seguida, executou-se o AGCB 1000 vezes e constatou-se que este alcança o resultado de maneira satisfatória. Não foi possível aplicar a busca exaustiva no sistema de 34 barras em diante, assim, como o AGCB converge de maneira rápida e satisfatória, este é utilizado como uma busca exaustiva, visto que não podemos afirmar que todas as possibilidades foram testadas. Assim, o sistema de 34 barras foi executado 30.000 vezes, o de 70 barras 70.000 vezes e o de 126 barras 200.000 vezes. Em determinado momento, verificou-se que a solução que apresentava a melhor solução não se alterou, e assim utilizou-se esta como referência. O algoritmo é dito convergente quando chega nessa solução, sendo esse o critério de parada do AGCB, SOS e CVOA, no CVOA, o PANDEMIC_DURATION é acrescido. O número de execuções é outro critério de parada para o AGCB e SOS, no primeiro executou-se os valores citados anteriormente e para o segundo os sistemas de 10, 34, 70 e 126 barras executou até 1.000, 50.000, 100.000 e 10.000.000 de vezes.


Os parâmetros de cada algoritmo foram definidos previamente em 3.2, vale frisar que no AGCB em cada iteração há o processo de seleção, cruzamento, mutação e melhoria local, ou seja, a taxa de mutação é de 100%. No SOS, em cada iteração há o mutualismo, comensalismo e parasitismo.

As simulações foram realizadas no Matlab 2021a em um notebook i7 10^a geração, ssd 240 Gb, 16Gb de memória ram e placa de vídeo dedicada de 2 Gb.

4.1.1 Sistema de 10 Barras

O sistema de 10 barras apresenta uma tensão nominal de 23 kV, potência total de carga instalada de 12,37 MW e 4,19 Mvar. Os dados deste sistema estão apresentados no Anexo A e a topologia do sistema na Figura 4.1, seu caso base representa uma perda ativa total de 0,7838MW.

Figura 4.1 – Sistema de 10 barras



Fonte: O autor

Em todas as meta-heurísticas implementadas, a solução que minimiza as perdas na rede foram as mesmas, conforme é possível observar na Tabela 4.1 e Figura 4.2. Antes da inserção de GD na rede, a tensão mínima registrada foi 0,8375 pu na barra 10, após a inserção das GDs, a tensão mínima registrada foi de 0,9384 pu, na mesma barra. A Figura 4.3 apresenta o perfil de tensão da rede sem e com alocação de GD. É possível constatar a melhoria que houve no perfil de tensão, uma vez que quanto mais próximo de 1 pu, melhor é para as cargas. Essa melhoria no perfil de tensão se repete para todos os sistemas, sendo esse um resultado já esperado, conforme discutido na seção 2.1.2. Ressalta-se ainda o mínimo global alcançado de 0,1785 MW, promovendo uma redução de 77,22% das perdas totais da rede.

Tabela 4.1 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 10 barras.


Barras	8	9	10	Pot. GD	Perda Ativa (MW)
Pot. [kW]	1000	1000	1500	3500	0,1785

4.1.2 Sistema de 34 Barras

O sistema de 34 barras possui tensão nominal de 11 kV, potência total de carga instalada de 4,63 MW e 2,88 Mvar. Os dados deste sistema estão apresentados no Anexo B e a topologia do sistema na Figura 4.4, seu caso base representa uma perda ativa total de 0,2223MW.


Exceto para a meta-heurística CVOA, em que 5% das iterações não convergiram, os demais algoritmos implementados convergiram para a solução que minimiza as perdas

Figura 4.2 – Sistema de 10 barras com alocação de GD



Fonte: O autor

Figura 4.3 – Perfil de tensão do sistema teste de 10 barras sem e com GD




Fonte: O autor

da rede, disponível na [Tabela 4.2](#) e [Figura 4.5](#). Antes da inserção de GD na rede, a tensão mínima registrada foi 0,9417 pu na barra 27, após a inserção das GDs, a tensão mínima registrada foi de 0,9708 pu na barra 23. A [Figura 4.6](#) apresenta o perfil de tensão da rede sem e com alocação de GD. Destaca-se ainda o mínimo global alcançado de 0,1085 MW, o que confere uma redução de 51,18% das perdas totais da rede.

4.1.3 Sistema de 70 Barras

O sistema de 70 barras apresenta tensão nominal de 12,66 kV, potência total de carga instalada de 3,80 MW e 2,69 Mvar. Os dados deste sistema estão apresentados no Anexo C e a topologia do sistema na [Figura 4.7](#), seu caso base representa uma perda ativa total entre os ramos de 0,2250MW.

Figura 4.4 – Sistema de 34 barras



Fonte: O autor

Tabela 4.2 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 34 barras.


Barras	12	22	24	26	27	33	Pot. GD	Perda Ativa (MW)
Pot. [kW]	200	200	400	400	200	200	1600	0.1085

Em todas as meta-heurísticas implementadas, a solução que minimiza as perdas na rede foram as mesmas, conforme é possível observar na Tabela 4.3 e Figura 4.8. Antes da inserção de GD na rede, a tensão mínima registrada foi 0,9092 pu na barra 66, após a inserção das GDs, a tensão mínima registrada foi de 0,9532 pu, na mesma barra. A Figura 4.9 apresenta o perfil de tensão da rede sem e com alocação de GD. Salienta-se ainda o mínimo global alcançado de 0,1063 MW, promovendo uma redução de 52,76% das perdas totais da rede.

Tabela 4.3 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 70 barras

Barras	67	Pot. GD	Perda Ativa [MW]
Pot. [kW]	1100	1100	0,1063

Figura 4.5 – Sistema de 34 barras com alocação de GD



Fonte: O autor

4.1.4 Sistema de 126 Barras


O sistema de 126 barras possui tensão nominal de 1 kV, potência total de carga instalada de 4,23 MW e 2,87 Mvar. Os dados deste sistema estão apresentados no Anexo D e a topologia do sistema na Figura 4.10, seu caso base representa uma perda ativa total de 0,1939MW.

Esse sistema teste apresentou alguns problemas, sobretudo no CVOA, devido as grandes populações, o algoritmo despense muito tempo para realizar as varreduras na *recovered* (matrizes com pouco mais de 1 milhão de linhas) e *dead* (com pouco mais de 12 mil linhas), algo em médias de 4,5 dias, sem falar nos constantes problemas de queda de energia, interrupção inesperada do MATLAB, entre outros. Sendo assim, realizou-se 8 das 20 execuções pretendidas.

A única meta-heurística que convergiu em 100% das execuções foi o AGCB, atingindo o mínimo global das perdas totais do sistema em 99,17 kW. O SOS teve 85% de eficiência, em 3 ocasiões o mínimo local encontrado foi de 99,1821 kW, 99,1830 kW e 99,1832 kW. O CVOA, das 8 execuções que foram interrompidas pelo critério de parada, 5 convergiram, tendo 62,5% de eficácia, as aptidões atingidas foram: 99,1810 kW, 99,1834 kW e 99,1803 kW.


A solução que confere as perdas mínimas do sistema teste está apresentado na Tabela 4.4, a Figura 4.11 apresenta a localização da GD de modo diferente, onde, cada nó colorido de vermelho corresponde a uma unidade do módulo de GD. A tensão mínima

Figura 4.6 – Perfil de tensão do sistema teste de 34 barras sem e com GD



Fonte: O autor


Figura 4.7 – Sistema de 70 barras



Fonte: O autor


registrada antes da alocação de GD, ocorreu na barra 119 com 0,9666 pu, após a inserção de GD, a tensão mínima constatada foi de 0,9942 pu na barra 117. O perfil de tensão deste sistema pode ser verificado na [Figura 4.12](#). Aponta-se ainda que, a redução das perdas de energia foi de aproximadamente 49%.

Figura 4.8 – Sistema de 70 barras com alocação de GD



Fonte: O autor

Figura 4.9 – Perfil de tensão do sistema teste de 70 barras sem e com GD

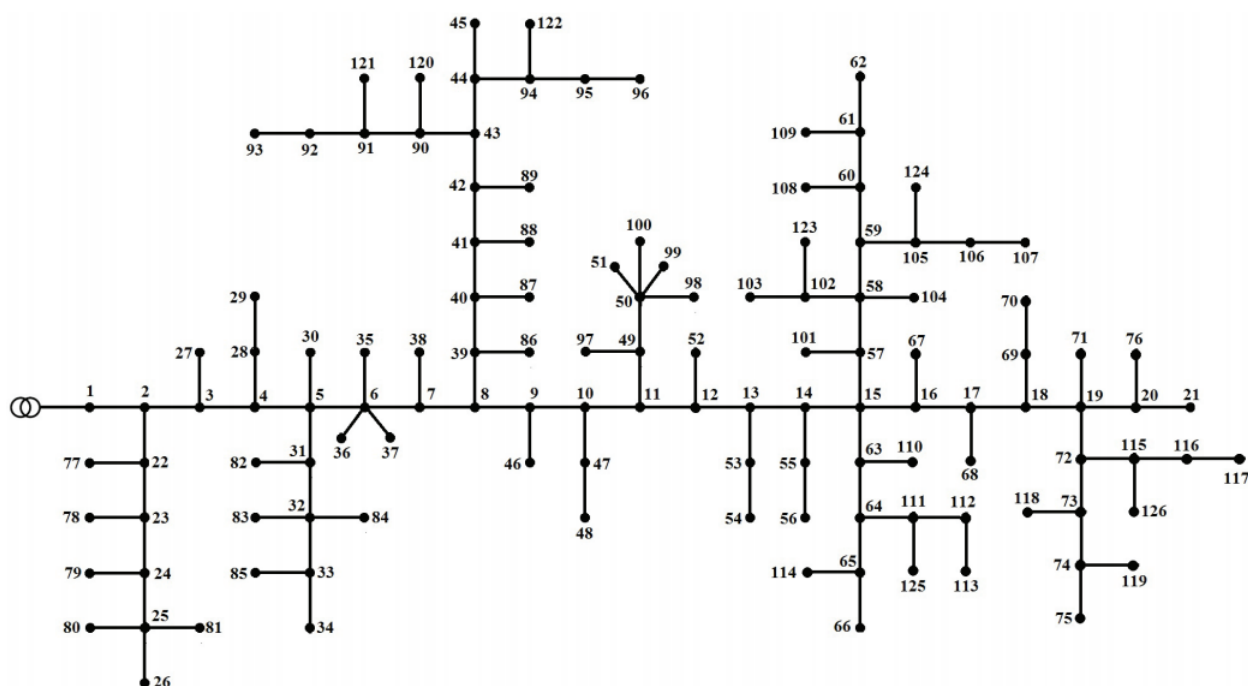


Fonte: O autor

4.1.5 Resultados

Apresentando o comportamento de cada sistema com e sem GD, expondo as mínimas perdas atingidas e a notável melhoria dos perfis de tensão, a seguir serão analisados os desempenhos de cada algoritmo (AGCB, SOS e CVOA). As Tabelas 4.5, 4.6, 4.7 e 4.8 expõem os resultados após as 20 execuções, mensurando o desempenho principalmente em

Figura 4.10 – Sistema de 126 barras



Fonte: (PRADO; GARCES, 2013) adaptado

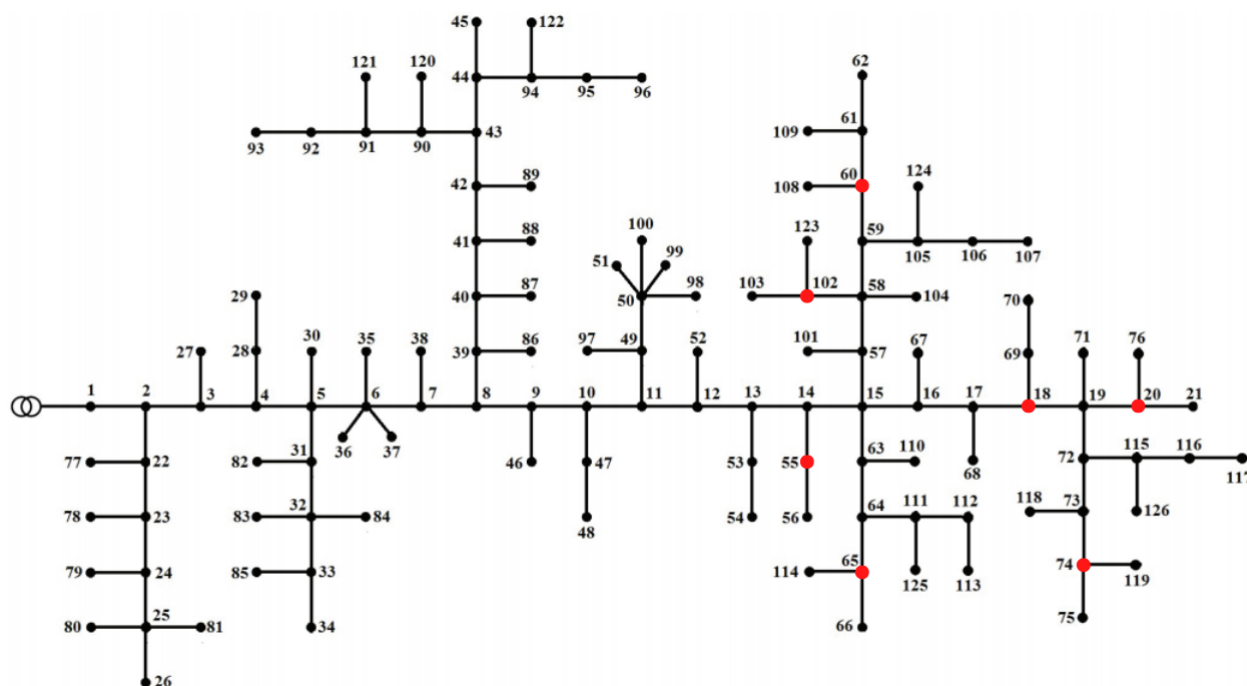
Tabela 4.4 – Alocação de módulos de GD que minimiza as perdas da rede para o sistema de 126 barras

Barras	18	20	55	60	65	74	102	Pot. GD [MW]	Perda Ativa [MW]
Pot. [kW]	200	200	200	200	200	200	200	1400	0,0992

termos de tempo de convergência (t) e a quantidade de vezes que foi necessário executar a sub-rotina de fluxo de carga (MSP). A coluna Iter (iterações) indica quantas vezes o referido algoritmo foi executado até atingir a convergência. Este parâmetro não é uma boa medida, uma vez que esse valor é influenciado pela lógica e arquitetura da meta-heurística. Os dados estatísticos utilizados para mensurar cada algoritmo foram: média, desvio padrão, mínimo, máximo e gráficos de *boxplot*.

Diante do apresentado, conforme é possível analisar nas Tabelas 4.5, 4.6, 4.7 e 4.8, para os sistemas de 10, 34 e 126 barras, o AGCB apresentou melhores resultados e o SOS teve desempenho superior no sistema de 70 barras. Cabe apontar que em quase todas as situações analisadas o CVOA teve desempenho pior (exceto para o sistema de 126 barras, que o SOS executou o MSP mais vezes para atingir a convergência), tanto quanto à convergência, que apresentou pior eficiência, quanto aos parâmetros apresentados.

Figura 4.11 – Sistema de 126 barras com alocação de GD



Fonte: O autor

Tabela 4.5 – Resultado das meta-heurísticas implementadas para o sistema teste de 10 barras


10 Barras	AGCB			SOS			CVOA		
	t (s)	Iter	MSP	t (s)	Iter	MSP	t (s)	Iter	MSP
Média	0,0294	33,75	155,00	0,0511	93,45	487,25	0,1198	8,30	906,15
Desvio Padrão	0,0337	17,24	68,98	0,0370	60,03	300,14	0,0685	2,23	457,43
Mínimo	0,0083	13,00	72,00	0,0015	1,00	25,00	0,0165	4,00	64,00
Máximo	0,1625	84,00	356,00	0,1532	248,00	1.260,00	0,2992	13,00	1.833,00

Os gráficos de *boxplot* são apresentados nas Figuras 4.13 e 4.14. A análise gráfica simplifica os valores apresentados nas tabelas, uma vez que graficamente é possível ter mais sensibilidade com os dados.

Na Figura 4.13 (A), apresenta-se a convergência do sistema de 10 barras em conjunto com os algoritmos aplicados. No AGCB, nota-se que a amplitude dos dados é menor e simétrica, sendo a única meta-heurística que apresenta *outliers*. Os algoritmos SOS e CVOA apresentam maiores variações nos dados e são positivamente assimétricos. O mesmo se repete para o sistema de 34 barras exibido na Figura 4.13 (B), no entanto, a meta-heurística que apresenta *outlier* é a CVOA.

A Figura 4.14 (A) exhibe o gráfico de *boxplot* para o sistema de 70 barras, porém,

Figura 4.12 – Perfil de tensão do sistema teste de 126 barras sem e com GD



Fonte: O autor

Tabela 4.6 – Resultado das meta-heurísticas implementadas para o sistema teste de 34 barras

34 Barras	AGCB			SOS			CVOA		
	t (s)	Iter	MSP	t (s)	Iter	MSP	t (s)	Iter	MSP
Média	5,50	394,40	1.645,60	8,82	19.495,15	97.543,75	2.033,90	14,05	176.337,25
Desvio Padrão	4,36	173,74	694,98	7,24	16.180,22	80.901,09	2.426,87	2,46	115.223,16
Mínimo	0,67	154,00	684,00	0,41	890,00	4.518,00	155,01	9,00	46.713,00
Máximo	15,44	756,00	3.092,00	22,75	49.710,00	248.618,00	9.593,65	20,00	482.255,00

Tabela 4.7 – Resultado das meta-heurísticas implementadas para o sistema teste de 70 barras

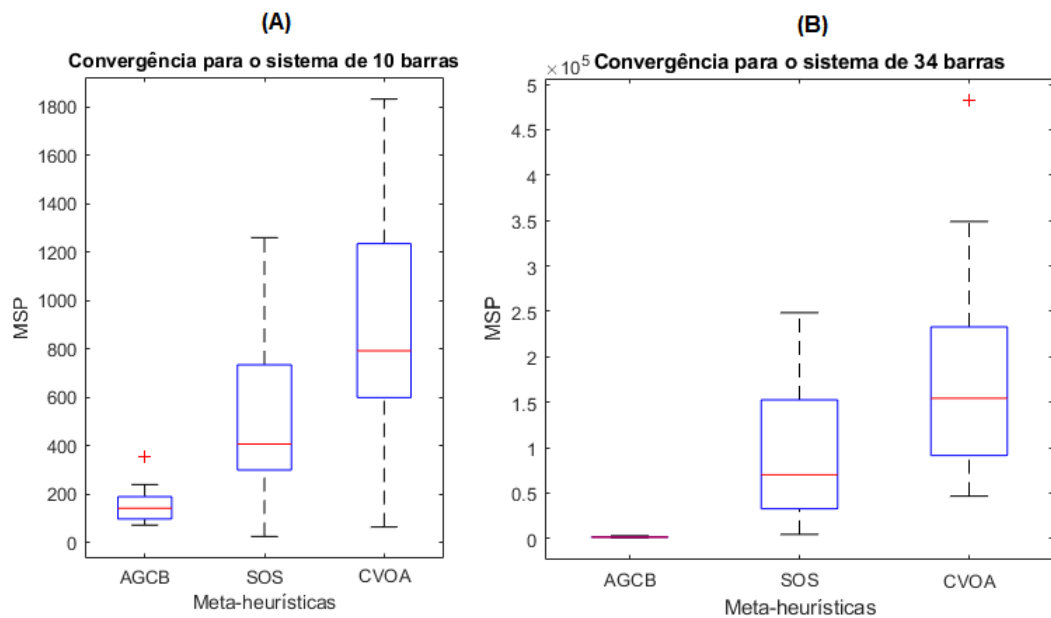
70 Barras	AGCB			SOS			CVOA		
	t (s)	Iter	MSP	t (s)	Iter	MSP	t (s)	Iter	MSP
Média	0,3804	305,45	1.361,80	0,1384	114,20	711,00	135,4884	3,55	13.001,30
Desvio Padrão	0,3841	368,31	1.473,23	0,1308	127,05	635,25	508,6346	2,82	34.541,79
Mínimo	0,0207	1,00	144,00	0,0208	1,00	145,00	0,0334	1,00	203,00
Máximo	1,2302	1.368,00	5.612,00	0,3519	349,00	1.885,00	2.269,7016	12,00	144.959,00

devido aos valores discrepantes do CVOA, não foi possível obter graficamente outras informações, tais como: centro dos dados, amplitude das informações, simetria ou assimetria do conjunto de dados. O mesmo se repete na [Figura 4.14 \(B\)](#) para o sistema de 126 barras, só que dessa vez a amplitude dos dados do SOS impossibilitou obter mais informações.

Tabela 4.8 – Resultado das meta-heurísticas implementadas para o sistema teste de 126 barras

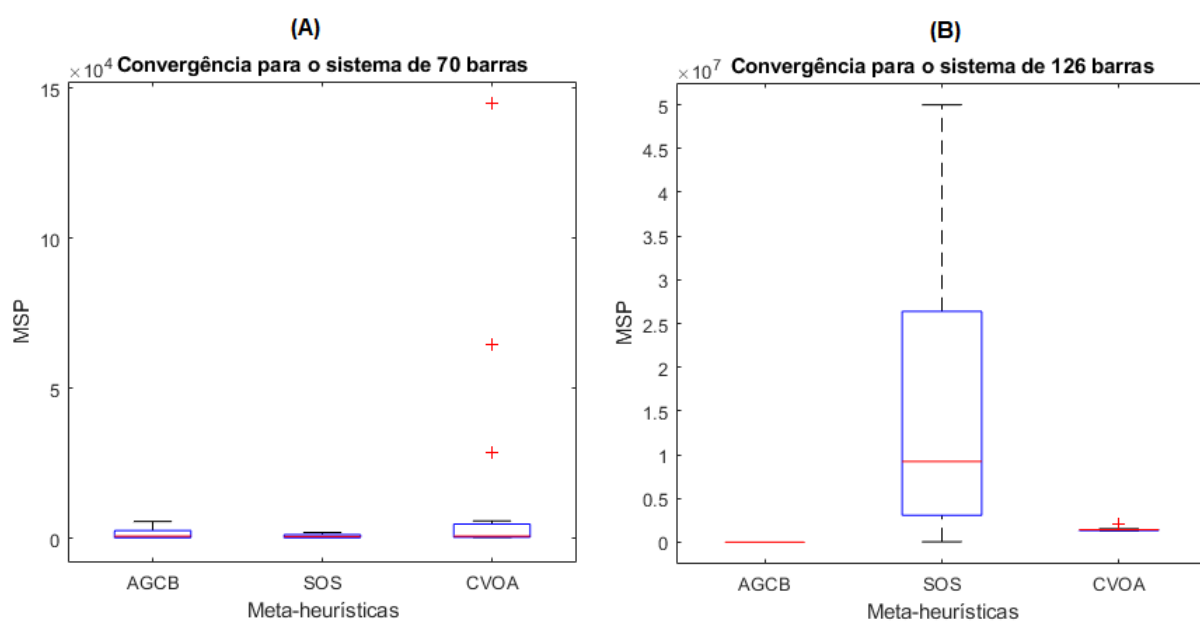
	AGCB			SOS			CVOA		
126 Barras	t (s)	Iter	MSP	t (s)	Iter	MSP	t (s)	Iter	MSP
Média	1.657,53	2.434,90	9.991,60	3.151,05	3.453.986,30	17.270.183,50	390.690,83	18,88	1.442.951,88
Desvio Padrão	755,35	788,89	3.155,56	3.241,16	3.572.992,49	17.864.962,44	252.113,75	1,13	284.533,93
Mínimo	572,62	1.286,00	5.396,00	11,12	11.992,00	60.212,00	122.378,91	17,00	1.302.858,00
Máximo	3.333,18	4.078,00	16.564,00	9.304,96	10.000.000,00	50.000.252,00	845.750,00	20,00	2.122.541,00

Figura 4.13 – Gráfico de *Boxplot* dos sistemas de 10 e 34 barras



Fonte: O autor

Figura 4.14 – Gráfico de *Boxplot* dos sistemas de 70 e 126 barras



Fonte: O autor

5 Conclusão

Neste trabalho, foram apresentados resultados para o problema de alocação de geração distribuída utilizando algoritmos bio-inspirados baseados nos Algoritmo Genético de Chu-Bealey, *Symbiotic Organism Search* e Algoritmo de Otimização do Coronavírus.

No processo da análise de eficiência dos algoritmos foram empregados os seguintes sistemas de teste amplamente conhecidos na literatura: 10, 34, 70 e 126 barras, todos eles apresentando características radiais. Os sistemas foram considerados em regime permanente e sem variação horária de carga, a natureza da geração também não foi levada em consideração. Caso fosse considerada a sazonalidade, a natureza da geração (solar, eólica, hídrica ou térmica) teria grande relevância na modelagem do problema.

Dos resultados obtidos, pôde-se verificar parte dos benefícios proporcionados pela GD, como a redução das perdas ativas de potência e, conseqüentemente, as perdas de energia ativa, melhoria nos níveis de tensão da rede, quando evitada a instalação indiscriminada de GD (motivo para a limitação do fator de penetração em aproximadamente 30%).

Em relação aos algoritmos bioinspirados implementados neste trabalho, o AGCB e o SOS mostraram-se de fácil implementação quando comparados com o CVOA, pois este último precisa da implementação computacional de muitas funções e verificações, o que o torna mais complexo. Por outro lado, a função *replicate* no CVOA permite um alto grau de liberdade para o desenvolvedor no sentido de tentar representar a disseminação, propagação e intensificação do vírus de forma particular para cada problema. Apesar de todos os algoritmos bioinspirados serem populacionais, o CVOA é o que exige um maior espaço de memória, uma vez que é necessário armazenar a lista de indivíduos recuperados e mortos durante a convergência do algoritmo, que em alguns casos, provoca a manipulação de matrizes com dimensão superior a um milhão de linhas.

O SOS pode ser melhor aplicado a problemas de natureza contínua, e não discreta. O fato de calcular a média entre dois números e depois o arredondamento, pode fazer com que o algoritmo tenha dificuldades de convergência.

O AGCB foi aquele que apresentou melhores resultados, teve 100% de eficiência nas 20 execuções programadas, convergiu de forma mais rápida e com uma capacidade de processamento menor que os outros algoritmos. O SOS teve desempenho intermediário aos algoritmos bioinspirados implementados, já o CVOA foi o que teve pior eficiência, uma vez que necessita de longo tempo de execução devido a própria natureza do algoritmo, e ao fato de gerar matrizes de grandes dimensões e ainda possuir os processos de varredura que tornam a verificação demorada.

Como esperado, todos os algoritmos diminuíram a sua convergência com o aumento do espaço de busca, uma vez que quanto mais combinações na proposta, maior a necessidade de verificação da qualidade da solução. De modo geral, o estudo realizado com os algoritmos bio-inspirados implementados cumpriu com o propósito principal desta dissertação, e permitiu a obtenção de resultados adequados para a alocação de unidades de GD que pudessem maximizar os diferentes benefícios técnicos envolvidos.

Como trabalho futuro, com o intuito de melhorar o desempenho do CVOA, sugere-se aplicar novas cepas de forma a melhorar o processo de convergência, uma vez que serão consideradas novas e diferentes taxas de disseminação, propagação e intensificação.

Outra proposta de trabalho futuro consiste em utilizar o algoritmo que obteve os melhores resultados neste trabalho, no caso o AGCB, para considerar na modelagem a natureza da geração, a sazonalidade da carga e os custos relacionados a diferentes fontes de geração, para assim, determinar aquela que trará mais vantagens ao sistema de distribuição de energia elétrica e conseqüentemente, ao serviço prestado à população.

Referências

ABREU, Y. V. d.; OLIVEIRA, M. A. G. d.; GUERRA, S. M.-G. *ENERGIA, ECONOMIA, ROTAS TECNOLÓGICAS. TEXTOS SELECIONADOS*. Palmas, TO - Brasil: eumed.net, 2010. ISBN 978-84-693-6489-5. Citado 2 vezes nas páginas 60 e 61.

ABSOLAR, A. B. de energia S. F. *Energia solar deve trazer mais de R\$ 50,8 bilhões de investimentos no País este ano, projeta ABSOLAR*. [S.l.], 2022. Disponível em: <<https://www.absolar.org.br/noticia/energia-solar-deve-trazer-mais-de-r-508-bilhoes-d-e-investimentos-no-pais-este-ano-projeta-absolar/>>. Acesso em: 07 nov. 2022. Citado na página 28.

ABU-MOUTI, F. S.; EL-HAWARY, M. E. Optimal distributed generation allocation and sizing in distribution systems via artificial bee colony algorithm. In: *IEEE TRANSACTIONS ON POWER DELIVERY*. [S.l.: s.n.], 2011. v. 26, n. 4. Citado na página 35.

ACHARYA, N.; MAHAT, P.; MITHULANANTHAN, N. An analytical approach for dg allocation in primary distribution network. *International Journal of Electrical Power & Energy Systems*, v. 28, n. 10, p. 669–678, 2006. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061506000652>>. Citado na página 21.

AGRAWAL, P. et al. Metaheuristic algorithms on feature selection: A survey of one decade of research (2009-2019). *IEEE Access*, v. 9, p. 26766–26791, 2021. Citado 2 vezes nas páginas 58 e 59.

ANDRÉ, L. Modelagem de relações simbióticas em um ecossistema computacional para otimização. In: . [S.l.: s.n.], 2015. Citado na página 64.

ANEEL. *Conexão em Geração Distribuída - Brasil*. [S.l.], 2022. Disponível em: <<https://app.powerbi.com/view?r=eyJrIjoiY2VmMmUwN2QtYWFiOS00ZDE3LWI3NDMtZDk0NGI4MGU2NTkxIiwidCI6IjQwZDZmOWI4LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOiR9>>. Acesso em: 06 nov. 2022. Citado 3 vezes nas páginas 20, 30 e 32.

ANEEL. *Geração Distribuída*. [S.l.], 2022. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/geracao-distribuida>>. Acesso em: 08 nov. 2022. Citado na página 30.

ANEEL. *Perdas de Energia*. [S.l.], 2022. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/distribuicao/perdas-de-energia/perdas-de-energia>>. Acesso em: 05 nov. 2022. Citado na página 23.

ANEEL, A. N. de E. E. *SOLUÇÃO NORMATIVA ANEEL Nº 1.000, DE 7 DE DEZEMBRO DE 2021*. [S.l.], 2023. Disponível em: <https://www2.aneel.gov.br/cedoc/re_n20211000.html>. Acesso em: 20 fev. 2023. Citado na página 21.

BARBOSA, G. T. G. et al. Alocação Ótima de geração distribuída usando um algoritmo de polinização de flores. In: *LI Simpósio Brasileiro de Pesquisa Operacional*. [S.l.: s.n.], 2019. Citado na página 35.

- BOCANEGRA, S. Y.; MONTOYA, O. D. Heuristic approach for optimal location and sizing of distributed generators in ac distribution networks. *WSEAS Transactions on Power Systems*, v. 14, n. 3, p. 113–121, 2019. Citado na página 20.
- BORGES, C.; FALCAO, D. Impact of distributed generation allocation and sizing on reliability, losses and voltage profile. In: *2003 IEEE Bologna Power Tech Conference Proceedings*, [S.l.: s.n.], 2003. v. 2, p. 5 pp. Vol.2-. Citado na página 20.
- BRASIL. Decreto-lei nº 5.163 de 30 de julho de 2004. *Diário Oficial [da] República Federativa do Brasil*, Brasília, DF, 2004. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2004/decreto/d5163.HTM>. Citado na página 25.
- BRASIL. Resolução normativa nº 482, de 17 de abril de 2012. *Agência Nacional [de] Energia Elétrica - ANEEL*, Brasília, DF, 2012. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2012482.pdf>>. Citado na página 25.
- BRASIL. Parâmetros de custos – geração e transmissão. *Empresa [de] Pesquisas Energéticas - EPE*, Brasília, DF, 2021. Citado 2 vezes nas páginas 30 e 31.
- BRASIL. Plano decenal de expansão de energia 2030. *Empresa [de] Pesquisas Energéticas - EPE*, Brasília, DF, 2021. Citado na página 31.
- BRASIL. Relatório síntese 2022. *Empresa [de] Pesquisas Energéticas - EPE*, Brasília, DF, 2021. Citado 2 vezes nas páginas 30 e 31.
- BRIGATTO, G. A. A. *TEORIA DO PROBLEMA DO FLUXO DE CARGA*. Goiânia, GO - Brasil: Programa de Pós Graduação em Engenharia Elétrica e Computação - PPGEEC, 2021. Citado 7 vezes nas páginas 43, 44, 45, 46, 49, 52 e 55.
- BROWNLEE, J. *Clever Algorithms: Nature-Inspired Programming Recipes*. second. [S.l.: s.n.], 2012. ISBN 978-3-030-31019-6. Citado 2 vezes nas páginas 58 e 59.
- CARVALHO, R. d. L.; ALMEIDA, T. d. S.; ROCHA, M. L. *Introdução à Metaheurísticas*. Palmas, TO - Brasil: Universidade Federal do Tocantins - EDUFT, 2020. Citado na página 58.
- CHENG, M.-Y.; PRAYOGO, D. Symbiotic organisms search: A new metaheuristic optimization algorithm. *Computers Structures*, v. 139, p. 98–112, 2014. ISSN 0045-7949. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0045794914000881>>. Citado 4 vezes nas páginas 66, 67, 68 e 69.
- CHU, P.; BEASLEY, J. A genetic algorithm for the generalised assignment problem. *Computers & Operations Research*, v. 24, n. 1, p. 17–23, 1997. ISSN 0305-0548. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0305054896000329>>. Citado 2 vezes nas páginas 62 e 63.
- EPBR. *Geração distribuída demanda uniformidade de regras tributárias*. [S.l.], 2022. Disponível em: <<https://epbr.com.br/geracao-distribuida-demanda-uniformidade-de-regras-tributarias/>>. Acesso em: 07 nov. 2022. Citado na página 29.
- EPE. *Painel de Dados de Micro e Minigeração Distribuída*. [S.l.], 2022. Disponível em: <<http://shinyepe.brazilsouth.cloudapp.azure.com:3838/pdgd/>>. Acesso em: 08 nov. 2022. Citado 3 vezes nas páginas 30, 31 e 33.

FILHO, W. P. B.; AZEVEDO, A. C. S. de. Geração distribuída Vantagens e desvantagens. *II Simpósio de Estudo e Pesquisas em Ciências do Ambiente na Amazônia*. Citado na página 28.

GONZALEZ-LONGATT, F.; FORTOUL, C. Review of distributed generation concept: Attempt of unification. *Renewable Energy and Power Quality Journal*, v. 1, 03 2005. Citado 2 vezes nas páginas 25 e 26.

GRIFFIN, T. et al. Placement of dispersed generation systems for reduced losses. In: *Proceedings of the 33rd Annual Hawaii International Conference on System Sciences*. [S.l.: s.n.], 2000. p. 9 pp.–. Citado na página 20.

GRISALES, L. F. et al. Optimal planning and operation of distribution systems considering distributed energy resources and automatic reclosers. *IEEE Latin America Transactions*, v. 16, n. 1, p. 126–134, 2018. Citado na página 39.

GRISALES-NOREÑA, L. F. et al. Hybrid metaheuristic optimization methods for optimal location and sizing dgs in dc networks. In: *Springer Nature Switzerland AG 2019*. [S.l.: s.n.], 2019. p. 221–225. Citado na página 39.

GRISALES-NOREÑA, L. F.; MONTOYA, D. G.; RAMOS-PAJA, C. A. Optimal sizing and location of distributed generators based on pbil and pso techniques. *Energies*, v. 11, n. 4, 2018. ISSN 1996-1073. Disponível em: <<https://www.mdpi.com/1996-1073/11/4/1018>>. Citado na página 20.

HASSAN, A. S.; SUN, Y.; WANG, Z. Optimization techniques applied for optimal planning and integration of renewable energy sources based on distributed generation: Recent trends. *Cogent Engineering*, Cogent OA, v. 7, n. 1, p. 1766394, 2020. Disponível em: <<https://doi.org/10.1080/23311916.2020.1766394>>. Citado na página 37.

HOSSEINI, S.-D. et al. Optimal placement of distributed generators with regard to reliability assessment using virus colony search algorithm. *International Journal of Renewable Energy Research*, v. 8, p. 714–723, 01 2018. Citado na página 36.

HUY, T. H. B. Enhancing distribution system performance via distributed generation placement and reconfiguration based on improved symbiotic organisms search. *Journal of Control Science and Engineering*, Hindawi, v. 2023, p. 6081991, Mar 2023. ISSN 1687-5249. Disponível em: <<https://doi.org/10.1155/2023/6081991>>. Citado na página 40.

HUY, T. H. B. et al. An improved metaheuristic method for simultaneous network reconfiguration and distributed generation allocation. *Alexandria Engineering Journal*, v. 61, n. 10, p. 8069–8088, 2022. ISSN 1110-0168. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1110016822000692>>. Citado na página 37.

INEE, I. N. [de] E. E. *O que é Geração Distribuída*. [S.l.], 2022. Disponível em: <http://www.inee.org.br/forum_ger_distrib.asp?Cat=gd>. Acesso em: 07 nov. 2022. Citado na página 26.

IVANOV, O. et al. Metaheuristic approaches for distributed generation placement optimization in electrical grids : A comparison between pso, tiki-taka and archimedes optimization algorithms. In: *2022 International Conference and Exposition on Electrical And Power Engineering (EPE)*. [S.l.: s.n.], 2022. p. 208–212. Citado na página 41.

- JAMATIA, P.; BHATTACHARJEE, S.; SHARMA, S. Allocation of electric vehicle charging station in distribution network along with distributed generation sources. In: *2022 IEEE 6th International Conference on Condition Assessment Techniques in Electrical Systems (CATCON)*. [S.l.: s.n.], 2022. p. 196–201. Citado na página 40.
- JÚNIOR, P. S. Z. *Modelo Multiobjetivo de Alocação e Dimensionamento de Geração Distribuída para Redes de Distribuição*. 194 p. Dissertação (Mestrado em Engenharia Elétrica e Computação) — Universidade Federal Goiás, Goiânia, 2018. Citado na página 61.
- JÚNIOR, B.; FERREIRA, M. Impacto da geração distribuída na proteção de sistema de distribuição. In: *Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Itajubá*. [S.l.: s.n.], 2017. Citado na página 29.
- JÚNIOR, L. C. Z. *Fundamentos de Sistemas Elétricos de Potência*. 1. ed. São Paulo: Editora Livraria da Física, 2005. Citado na página 22.
- KAGAN, N.; OLIVEIRA, C. C. B. de; ROBBA, E. J. *Introdução aos Sistemas de Distribuição de Energia Elétrica*. 1. ed. São Paulo: Editora Edgard Blücher, 2005. Citado na página 22.
- KAWAMBWA, S. et al. A cloud model based symbiotic organism search algorithm for dg allocation in radial distribution network. *Evolutionary Intelligence*, v. 15, n. 1, p. 545–562, Mar 2022. ISSN 1864-5917. Disponível em: <<https://doi.org/10.1007/s12065-020-00529-y>>. Citado na página 40.
- LEZAMA, J. M. L.; GALEANO, N. M.; DUQUE, F. V. Optimal allocation of distributed generation in power systems considering multiple operative scenarios. In: *International Journal of Engineering Research and Technology - IJERT*. [S.l.: s.n.], 2020. v. 13, n. 10, p. 2788–2791. Citado na página 34.
- LI, R. et al. Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (sars-cov-2). *Science*, v. 368, n. 6490, p. 489–493, 2020. Disponível em: <<https://www.science.org/doi/abs/10.1126/science.abb3221>>. Citado na página 70.
- LOPES, S. *Bio*. 4. ed. São Paulo, SP - Brasil: Ed. Saraiva, 2006. Único. ISBN 85-02-04796-5. Citado 4 vezes nas páginas 66, 67, 68 e 69.
- LOPEZ, L. et al. Distributed generation allocation and sizing: A comparison of metaheuristics techniques. In: *2019 IEEE International Conference on Environment and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / ICPS Europe)*. [S.l.: s.n.], 2019. p. 1–6. Citado na página 36.
- LUKE, S. *Essentials of Metaheuristics*. 2nd. ed. Goiânia, GO - Brasil: Programa de Pós Graduação em Engenharia Elétrica e Computação - PPGEEC, 2016. Online Version 2.3. Citado na página 58.
- LÓPEZ-LEZAMA, J. M.; CONTRERAS, J.; PADILHA-FELTRIN, A. Location and contract pricing of distributed generation using a genetic algorithm. *International Journal of Electrical Power Energy Systems*, v. 36, n. 1, p. 117–126, 2012. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S014206151100281X>>. Citado na página 39.

- MACHAVA, A. S.; KABERERE, K. K.; VILANCULO, G. A. A method for optimal distributed generation allocation considering load demand uncertainties. In: *International Journal of Electrical and Electronic Engineering & Telecommunications - IJEETC 2022*. [S.l.: s.n.], 2022. v. 11, n. 3. Citado na página 34.
- MANSKI, C. F.; MOLINARI, F. Estimating the covid-19 infection rate: Anatomy of an inference problem. *Journal of Econometrics*, v. 220, n. 1, p. 181–192, 2021. ISSN 0304-4076. Pandemic Econometrics. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304407620301676>>. Citado na página 70.
- MARTÍNEZ-ÁLVAREZ, F. et al. Coronavirus optimization algorithm: A bioinspired metaheuristic based on the covid-19 propagation model. *Big Data*, v. 8, n. 4, p. 308–322, 2020. PMID: 32716641. Disponível em: <<https://doi.org/10.1089/big.2020.0051>>. Citado 4 vezes nas páginas 70, 71, 73 e 74.
- MITHULANANTHAN, N.; OO, T.; PHU, L. V. Distributed generator placement in power distribution system using genetic algorithm to reduce losses. *Science & Technology Asia*, v. 9, n. 3, p. 55–62, Nov. 2015. Disponível em: <<https://ph02.tci-thaijo.org/index.php/SciTechAsia/article/view/41639>>. Citado na página 20.
- MIZUMOTO, K.; CHOWELL, G. Estimating risk for death from coronavirus disease, china, january–february 2020. *Emerging Infectious Diseases*, v. 26, n. 6, p. 1251–1256, june 2020. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7258458/>>. Citado na página 73.
- MONTICELLI, A. J. *Fluxo de Carga em Redes de Energia Elétrica*. São Paulo, SP - Brasil: Editora Edgard Blucher LTDA, 1983. Citado na página 43.
- MONTOYA, O. D. et al. Distribution systems operation considering energy storage devices and distributed generation. *IEEE Latin America Transactions*, v. 15, n. 5, p. 890–900, 2017. Citado na página 20.
- MONTOYA, O. D. et al. Vortex search algorithm for optimal sizing of distributed generators in ac distribution networks with radial topology. In: FIGUEROA-GARCÍA, J. C. et al. (Ed.). *Applied Computer Sciences in Engineering*. Cham: Springer International Publishing, 2019. p. 235–249. ISBN 978-3-030-31019-6. Citado na página 20.
- NDWANDWE, D.; WIYSONGE, C. S. Covid-19 vaccines. *Current Opinion in Immunology*, v. 71, p. 111–116, 2021. ISSN 0952-7915. Vaccines * SS on Widening perspectives on the BAFF family Ligands receptors. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S095279152100090X>>. Citado na página 71.
- NOGUEIRA, W. C. *Alocação e Dimensionamento Ótimo de Geração Distribuída Utilizando o Fluxo de Potência Intervalar*. 118 p. Dissertação (Mestrado em Engenharia Elétrica e Computação) — Universidade Federal Goiás, Goiânia, 2021. Citado na página 35.
- NOGUEIRA, W. C. *Alocação e Dimensionamento Ótimo de Geração Distribuída Utilizando o Fluxo de Potência Intervalar*. 118 p. Dissertação (Mestrado em Engenharia Elétrica e Computação) — Universidade Federal Goiás, Goiânia, 2021. Citado na página 68.

- OMAR, B.; SAIDA, I. B.; NOUREDDINE, B. Energy management optimization for micro-grids, using a chaotic symbiotic organism search algorithm. *Acta Polytechnica Hungarica*, v. 19, n. 7, 2022. Citado na página 41.
- ONS, O. N. do S. E. *CURVA DE CARGA HORÁRIA*. [S.l.], 2023. Disponível em: <https://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/curva_carga_horaria.aspx>. Acesso em: 20 fev. 2023. Citado na página 21.
- ORGANIZATION, W. H. *Coronavirus disease 2019 (COVID-19)*. [S.l.], 2019. Disponível em: <<https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200403-sitrep-74-covid-19-mp.pdf>>. Acesso em: 23 jan. 2023. Citado na página 73.
- ORGANIZATION, W. H. *"Immunity passports" in the context of COVID-19*. [S.l.], 2020. Disponível em: <<https://www.who.int/news-room/commentaries/detail/immunity-passports-in-the-context-of-covid-19>>. Acesso em: 23 jan. 2023. Citado na página 74.
- ORGANIZATION, W. H. *WHO Coronavirus (COVID-19)*. [S.l.], 2023. Disponível em: <<https://covid19.who.int/>>. Acesso em: 20 jan. 2023. Citado 2 vezes nas páginas 70 e 71.
- OXFORD, U. of. *Coronavirus Pandemic (COVID-19)*. [S.l.], 2022. Disponível em: <<https://ourworldindata.org/coronavirus>>. Acesso em: 19 jan. 2023. Citado na página 70.
- PHAM, T. D.; NGUYEN, T. T.; DINH, B. H. Find optimal capacity and location of distributed generation units in radial distribution networks by using enhanced coyote optimization algorithm. *Neural Computing and Applications*, v. 33, n. 9, p. 4343–4371, May 2021. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-020-05239-1>>. Citado na página 37.
- PRADO, I. F.; GARCES, L. P. Chu-beasley genetic algorithm applied to the allocation of distributed generation. In: *2013 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America)*. [S.l.: s.n.], 2013. p. 1–7. Citado 4 vezes nas páginas 34, 63, 64 e 90.
- PRODIST. *Módulo 7 - Cálculo de Perdas na Distribuição*. [S.l.], 2022. Disponível em: <https://www2.aneel.gov.br/cedoc/aren2021956_2_6.pdf>. Acesso em: 05 nov. 2022. Citado na página 23.
- QUIRIOGA, G. A. Impacto da geração distribuída sobre o sistema de proteção: considerações para o planejamento de redes de distribuição. In: *Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo*. [S.l.: s.n.], 2019. Citado na página 29.
- RASTGOU, A.; MOSHTAGH, J.; BAHRAMARA, S. Improved harmony search algorithm for electrical distribution network expansion planning in the presence of distributed generators. *Energy*, v. 151, p. 178–202, 2018. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544218304286>>. Citado na página 41.
- RUPOLO, D.; MANTOVANI, J. R. S.; JUNIOR, B. R. P. Medium-and low-voltage planning of electric power distribution systems with distributed generation, energy storage sources, and electric vehicles. In: *2019 IEEE Milan PowerTech*. [S.l.: s.n.], 2019. p. 1–5. Citado na página 38.

- SALKUTI, S. R.; LHO, Y. H. Optimum location of voltage regulators in the radial distribution systems. *International Journal of Emerging Electric Power Systems*, v. 17, n. 3, p. 351–361, 2016. Disponível em: <<https://doi.org/10.1515/ijeeps-2015-0197>>. Citado na página 20.
- SANTOS, J. D.; NEGRETE, L. P. G.; BRITO, L. D. C. Allocation of distributed generation in distribution networks using specialized genetic algorithms. In: *2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*. [S.l.: s.n.], 2021. p. 1–5. Citado na página 29.
- SOLAR, C. *O que é geração distribuída de energia elétrica?* [S.l.], 2022. Disponível em: <<https://canalsolar.com.br/o-que-e-geracao-distribuida-de-energia-eletrica/>>. Acesso em: 07 nov. 2022. Citado na página 28.
- SOLAR, P. *Geração distribuída de energia (GD)*. [S.l.], 2022. Disponível em: <<https://www.portalsolar.com.br/geracao-distribuida-de-energia.html>>. Acesso em: 07 nov. 2022. Citado na página 28.
- SOUZA, M. J. F. et al. Método de pesquisa em vizinhança variável aplicado ao problema de alocação de salas. *XXII Encontro Nacional de Engenharia de Produção*, Curitiba, Santa Bárbara D'Oeste, p. 8p, 2002. Citado 2 vezes nas páginas 75 e 76.
- SYST, I. et al. Optimization solution of congestion problem with facts devices using symbiotic organism search algorithm. *International Journal of Systems Assurance Engineering and Management*, p. 3, 11 2022. Citado na página 66.
- THE, T. T.; QUOC, S. N.; NGOC, D. V. Symbiotic organism search algorithm for power loss minimization in radial distribution systems by network reconfiguration and distributed generation placement. In: *Mathematical Problems in Engineering*. [S.l.: s.n.], 2020. v. 2020. Citado na página 35.
- TOLIC, D.; KLEINEBERG, K.-K.; ANTULOV-FANTULIN, N. Simulating sir processes on networks using weighted shortest paths. *Scientific Reports*, n. 6562 (2018), 2018. Citado na página 70.
- TRUONG, K. H. et al. An improved meta-heuristic method to maximize the penetration of distributed generation in radial distribution networks. *Neural Computing and Applications*, v. 32, n. 14, p. 10159–10181, Jul 2020. ISSN 1433-3058. Disponível em: <<https://doi.org/10.1007/s00521-019-04548-4>>. Citado na página 36.
- VELAVAN, T. P.; MEYER, C. G. The covid-19 epidemic. *Tropical Medicine and International Health*, v. 25, n. 3, p. 278–280, 2020. Citado na página 70.
- WU, J. T.; LEUNG, K.; LEUNG, G. M. Nowcasting and forecasting the potential domestic and international spread of the 2019-ncov outbreak originating in wuhan, china: a modelling study. *Lancet*, v. 395, n. 10225, p. 689–697, feb 2020. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7159271/>>. Citado na página 73.

Apêndices

APÊNDICE A – Resultado 10 Barras

Tabela A.1 – Resultados da alocação de GD para o sistema de 10 barras

Barra	Tensão sem GD	Tensão com GD	Ângulo sem GD	Ângulo com GD
1	1,0000	1,0000	0,0000	0,0000
2	0,9929	0,9944	-0,5218	-0,3458
3	0,9874	0,9896	-1,2678	-0,8180
4	0,9634	0,9726	-2,3306	-1,3588
5	0,9480	0,9632	-2,6519	-1,4210
6	0,9172	0,9488	-3,7212	-1,7073
7	0,9072	0,9461	-4,1367	-1,7527
8	0,8890	0,9441	-4,6184	-1,6936
9	0,8587	0,9411	-5,4036	-1,5404
10	0,8375	0,9384	-5,9901	-1,4613

APÊNDICE B – Resultado 34 Barras

Tabela B.1 – Resultados da alocação de GD para o sistema de 34 barras

Barra	Tensão sem GD	Tensão com GD	Ângulo sem GD	Ângulo com GD
1	1,0000	1,0000	0,0000	0,0000
2	0,9941	0,9958	0,0534	0,0906
3	0,9890	0,9922	0,1003	0,1718
4	0,9820	0,9876	0,2155	0,3215
5	0,9760	0,9837	0,3159	0,4530
6	0,9704	0,9802	0,4115	0,5797
7	0,9666	0,9775	0,5045	0,6814
8	0,9644	0,9761	0,5556	0,7385
9	0,9620	0,9747	0,6161	0,8083
10	0,9608	0,9743	0,6456	0,8441
11	0,9603	0,9741	0,6566	0,8571
12	0,9602	0,9741	0,6598	0,8620
13	0,9887	0,9919	0,1082	0,1796
14	0,9884	0,9916	0,1153	0,1867
15	0,9883	0,9915	0,1172	0,1886
16	0,9883	0,9915	0,1174	0,1887
17	0,9659	0,9777	0,4868	0,6831
18	0,9622	0,9757	0,5498	0,7718
19	0,9581	0,9738	0,6325	0,8804
20	0,9548	0,9726	0,6995	0,9709
21	0,9520	0,9717	0,7580	1,0531
22	0,9487	0,9712	0,8372	1,1560
23	0,9460	0,9708	0,9026	1,2409
24	0,9435	0,9710	0,9644	1,3265
25	0,9423	0,9709	0,9943	1,3655
26	0,9418	0,9711	1,0058	1,3831
27	0,9417	0,9712	1,0092	1,3881
28	0,9662	0,9772	0,5129	0,6896
29	0,9660	0,9769	0,5185	0,6951
30	0,9659	0,9768	0,5213	0,6978
31	0,9604	0,9742	0,6545	0,8555
32	0,9601	0,9742	0,6635	0,8678
33	0,9599	0,9743	0,6680	0,8748
34	0,9599	0,9743	0,6695	0,8763

APÊNDICE C – Resultado 70 Barras

Tabela C.1 – Resultados da alocação de GD para o sistema de 70 barras

Barra	Tensão sem GD	Tensão com GD	Ângulo sem GD	Ângulo com GD
1	1,0000	1,0000	0,0000	0,0000
2	1,0000	1,0000	-0,0012	-0,0007
3	0,9999	0,9999	-0,0025	-0,0014
4	0,9999	0,9999	-0,0025	-0,0014
5	0,9998	0,9999	-0,0059	-0,0033
6	0,9990	0,9992	-0,0185	-0,0036
7	0,9901	0,9931	0,0493	0,1393
8	0,9808	0,9868	0,1211	0,2898
9	0,9786	0,9853	0,1384	0,3262
10	0,9774	0,9846	0,1472	0,3452
11	0,9724	0,9796	0,2321	0,4289
12	0,9713	0,9785	0,2509	0,4474
13	0,9682	0,9754	0,3038	0,4996
14	0,9652	0,9725	0,3503	0,5454
15	0,9623	0,9696	0,3966	0,5910
16	0,9595	0,9667	0,4427	0,6364
17	0,9589	0,9662	0,4512	0,6448
18	0,9581	0,9653	0,4654	0,6588
19	0,9581	0,9653	0,4656	0,6589
20	0,9576	0,9649	0,4741	0,6674
21	0,9573	0,9646	0,4796	0,6728
22	0,9568	0,9641	0,4885	0,6815
23	0,9568	0,9641	0,4887	0,6817
24	0,9567	0,9640	0,4900	0,6830
25	0,9566	0,9639	0,4929	0,6859
26	0,9564	0,9637	0,4961	0,6890
27	0,9563	0,9636	0,4974	0,6903
28	0,9563	0,9636	0,4978	0,6907
29	0,9999	0,9999	-0,0027	-0,0017
30	0,9999	0,9999	-0,0053	-0,0043
31	0,9997	0,9997	-0,0032	-0,0022

32	0,9997	0,9997	-0,0028	-0,0018
33	0,9996	0,9996	-0,0009	-0,0001
34	0,9993	0,9994	0,0035	0,0045
35	0,9990	0,9990	0,0094	0,0104
36	0,9989	0,9990	0,0104	0,0114
37	0,9999	0,9999	-0,0030	-0,0019
38	0,9997	0,9998	-0,0094	-0,0084
39	0,9996	0,9996	-0,0118	-0,0108
40	0,9995	0,9996	-0,0123	-0,0112
41	0,9995	0,9995	-0,0123	-0,0113
42	0,9988	0,9989	-0,0233	-0,0223
43	0,9985	0,9986	-0,0280	-0,0269
44	0,9985	0,9985	-0,0286	-0,0275
45	0,9985	0,9985	-0,0287	-0,0277
46	0,9984	0,9984	-0,0305	-0,0295
47	0,9984	0,9984	-0,0305	-0,0295
48	0,9998	0,9998	-0,0077	-0,0051
49	0,9985	0,9986	-0,0526	-0,0500
50	0,9947	0,9947	-0,1917	-0,1891
51	0,9941	0,9942	-0,2115	-0,2089
52	0,9785	0,9853	0,1387	0,3265
53	0,9785	0,9853	0,1388	0,3267
54	0,9747	0,9831	0,1691	0,4035
55	0,9714	0,9815	0,1947	0,4715
56	0,9669	0,9792	0,2303	0,5666
57	0,9626	0,9770	0,2653	0,6607
58	0,9401	0,9668	0,6618	1,2620
59	0,9290	0,9618	0,8644	1,5632
60	0,9248	0,9599	0,9454	1,6812
61	0,9197	0,9579	1,0499	1,8277
62	0,9123	0,9545	1,1189	2,0023
63	0,9120	0,9549	1,1217	2,0262
64	0,9117	0,9556	1,1253	2,0613
65	0,9098	0,9537	1,1432	2,0775
66	0,9092	0,9532	1,1485	2,0824
67	0,9713	0,9785	0,2520	0,4486
68	0,9713	0,9785	0,2520	0,4486

69	0,9678	0,9751	0,3098	0,5055
70	0,9678	0,9750	0,3099	0,5055

APÊNDICE D – Resultado 126 Barras

Tabela D.1 – Resultados da alocação de GD para o sistema de 126 barras

Barra	Tensão sem GD	Tensão com GD	Ângulo sem GD	Ângulo com GD
1	1,0500	1,0500	0,0000	0,0000
2	1,0394	1,0414	-0,2143	-0,0799
3	1,0369	1,0393	-0,2742	-0,1018
4	1,0200	1,0267	-0,3997	-0,0316
5	1,0120	1,0209	-0,4614	0,0062
6	1,0076	1,0177	-0,5292	0,0108
7	1,0042	1,0153	-0,5816	0,0169
8	0,9986	1,0114	-0,6604	0,0469
9	0,9949	1,0091	-0,7155	0,0757
10	0,9899	1,0059	-0,7909	0,1172
11	0,9868	1,0041	-0,8372	0,1542
12	0,9832	1,0021	-0,8915	0,2071
13	0,9802	1,0005	-0,9364	0,2520
14	0,9786	0,9998	-0,9622	0,2897
15	0,9765	0,9989	-0,9944	0,3291
16	0,9733	0,9973	-1,0456	0,3824
17	0,9693	0,9954	-1,1106	0,4609
18	0,9686	0,9952	-1,1213	0,4786
19	0,9679	0,9948	-1,1331	0,4900
20	0,9675	0,9947	-1,1391	0,5008
21	0,9674	0,9946	-1,1414	0,4987
22	1,0380	1,0399	-0,2379	-0,1034
23	1,0373	1,0393	-0,2483	-0,1137
24	1,0367	1,0387	-0,2587	-0,1241
25	1,0363	1,0382	-0,2653	-0,1307
26	1,0362	1,0382	-0,2656	-0,1310
27	1,0365	1,0390	-0,2777	-0,1052
28	1,0191	1,0259	-0,4073	-0,0391
29	1,0180	1,0248	-0,4091	-0,0408
30	1,0110	1,0199	-0,4681	-0,0004
31	1,0115	1,0204	-0,4708	-0,0030

32	1,0111	1,0200	-0,4777	-0,0098
33	1,0109	1,0198	-0,4814	-0,0134
34	1,0109	1,0198	-0,4817	-0,0137
35	1,0076	1,0176	-0,5298	0,0101
36	1,0076	1,0176	-0,5299	0,0101
37	1,0076	1,0177	-0,5293	0,0106
38	1,0042	1,0152	-0,5819	0,0165
39	0,9980	1,0108	-0,6700	0,0375
40	0,9974	1,0103	-0,6792	0,0285
41	0,9969	1,0098	-0,6869	0,0210
42	0,9966	1,0094	-0,6928	0,0153
43	0,9961	1,0089	-0,7009	0,0073
44	0,9958	1,0087	-0,7046	0,0038
45	0,9957	1,0086	-0,7065	0,0019
46	0,9946	1,0088	-0,7179	0,0734
47	0,9898	1,0058	-0,7937	0,1145
48	0,9897	1,0057	-0,7940	0,1142
49	0,9864	1,0037	-0,8424	0,1491
50	0,9862	1,0035	-0,8455	0,1462
51	0,9861	1,0035	-0,8460	0,1457
52	0,9831	1,0020	-0,8920	0,2066
53	0,9801	1,0005	-0,9368	0,2516
54	0,9801	1,0004	-0,9371	0,2513
55	0,9784	1,0000	-0,9627	0,3018
56	0,9784	0,9999	-0,9630	0,3016
57	0,9759	0,9986	-1,0039	0,3438
58	0,9754	0,9984	-1,0122	0,3592
59	0,9750	0,9982	-1,0183	0,3655
60	0,9747	0,9982	-1,0217	0,3728
61	0,9745	0,9980	-1,0248	0,3699
62	0,9744	0,9979	-1,0255	0,3692
63	0,9759	0,9986	-1,0026	0,3395
64	0,9756	0,9984	-1,0073	0,3467
65	0,9753	0,9984	-1,0119	0,3631
66	0,9752	0,9983	-1,0124	0,3626
67	0,9733	0,9972	-1,0466	0,3814
68	0,9692	0,9954	-1,1111	0,4604

69	0,9685	0,9951	-1,1223	0,4776
70	0,9685	0,9950	-1,1228	0,4771
71	0,9677	0,9946	-1,1344	0,4888
72	0,9675	0,9946	-1,1396	0,4959
73	0,9671	0,9945	-1,1453	0,5090
74	0,9667	0,9945	-1,1519	0,5331
75	0,9666	0,9945	-1,1523	0,5327
76	0,9675	0,9947	-1,1395	0,5005
77	1,0378	1,0398	-0,2390	-0,1045
78	1,0373	1,0393	-0,2486	-0,1140
79	1,0366	1,0386	-0,2597	-0,1251
80	1,0363	1,0382	-0,2657	-0,1311
81	1,0362	1,0382	-0,2656	-0,1310
82	1,0115	1,0204	-0,4709	-0,0031
83	1,0111	1,0200	-0,4780	-0,0101
84	1,0111	1,0200	-0,4782	-0,0102
85	1,0108	1,0197	-0,4824	-0,0144
86	0,9979	1,0108	-0,6705	0,0370
87	0,9973	1,0102	-0,6796	0,0281
88	0,9969	1,0098	-0,6870	0,0209
89	0,9965	1,0094	-0,6930	0,0151
90	0,9958	1,0087	-0,7032	0,0051
91	0,9958	1,0086	-0,7040	0,0044
92	0,9957	1,0086	-0,7043	0,0041
93	0,9957	1,0086	-0,7045	0,0039
94	0,9958	1,0087	-0,7052	0,0032
95	0,9957	1,0086	-0,7056	0,0028
96	0,9957	1,0086	-0,7058	0,0026
97	0,9864	1,0037	-0,8426	0,1490
98	0,9861	1,0034	-0,8460	0,1457
99	0,9861	1,0034	-0,8459	0,1458
100	0,9862	1,0035	-0,8457	0,1460
101	0,9758	0,9986	-1,0047	0,3429
102	0,9753	0,9985	-1,0130	0,3666
103	0,9752	0,9985	-1,0134	0,3662
104	0,9753	0,9984	-1,0127	0,3588
105	0,9749	0,9981	-1,0190	0,3649

106	0,9748	0,9981	-1,0196	0,3642
107	0,9748	0,9981	-1,0200	0,3639
108	0,9746	0,9981	-1,0225	0,3721
109	0,9745	0,9979	-1,0250	0,3697
110	0,9759	0,9986	-1,0028	0,3393
111	0,9755	0,9983	-1,0081	0,3459
112	0,9753	0,9982	-1,0088	0,3453
113	0,9752	0,9981	-1,0092	0,3448
114	0,9752	0,9984	-1,0123	0,3627
115	0,9672	0,9943	-1,1423	0,4933
116	0,9671	0,9943	-1,1431	0,4925
117	0,9671	0,9942	-1,1436	0,4920
118	0,9670	0,9944	-1,1459	0,5084
119	0,9666	0,9944	-1,1526	0,5324
120	0,9958	1,0087	-0,7033	0,0050
121	0,9957	1,0086	-0,7044	0,0039
122	0,9958	1,0086	-0,7053	0,0031
123	0,9753	0,9985	-1,0131	0,3664
124	0,9748	0,9981	-1,0191	0,3648
125	0,9754	0,9983	-1,0084	0,3456
126	0,9671	0,9943	-1,1432	0,4924

Anexos

ANEXO A – Sistema de 10 Barras

Tensão de base = 23 kV

Potência de base = 1000 kVA

Tabela A.1 – Dados de Potência do Sistema de 10 Barras

Barra	Potência Ativa (kW)	Potência Reativa (kvar)
1	0	0
2	1840	460
3	980	340
4	1790	446
5	1598	1840
6	1610	600
7	780	110
8	1150	60
9	980	130
10	1640	200

Tabela A.2 – Dados de Ramos do Sistema de 10 Barras

Barra inicial	Barra final	R(Ω)	X(Ω)
1	2	0,1233	0,4127
2	3	0,0140	0,6051
3	4	0,7463	1,2050
4	5	0,6984	0,6084
5	6	1,9831	1,7276
6	7	0,9053	0,7886
7	8	2,0552	1,1640
8	9	4,7953	2,7160
9	10	5,3434	3,0264

ANEXO B – Sistema de 34 Barras

Tensão de base = 11 kV

Potência de base = 1000 kVA

Tabela B.1 – Dados de Potência do Sistema de 34 Barras

Barra	Potência Ativa (kW)	Potência Reativa (kvar)	Barra	Potência Ativa (kW)	Potência Reativa (kvar)
1	0	0	18	230	142,5
2	230	142,5	19	230	142,5
3	0	0	20	230	142,5
4	230	142,5	21	230	142,5
5	230	142,5	22	230	142,5
6	0	0	23	230	142,5
7	0	0	24	230	142,5
8	230	142,5	25	230	142,5
9	230	142,5	26	230	142,5
10	0	0	27	137	85
11	230	142,5	28	75	48
12	137	84	29	75	48
13	72	45	30	75	48
14	72	45	31	57	37,5
15	72	45	32	57	37,5
16	13,5	7,5	33	57	37,5
17	230	142,5	34	57	37,5

Tabela B.2 – Dados de Ramos do Sistema de 34 Barras

Barra inicial	Barra final	R(Ω)	X(Ω)	Barra inicial	Barra final	R(Ω)	X(Ω)
1	2	0,1170	0,048	18	19	0,2079	0,0473
2	3	0,1073	0,044	19	20	0,1890	0,0430
3	4	0,1645	0,0457	20	21	0,1890	0,0430
4	5	0,1495	0,0415	21	22	0,2620	0,0450
5	6	0,1495	0,0415	22	23	0,2620	0,0450
6	7	0,3144	0,054	23	24	0,3144	0,0540
7	8	0,2096	0,036	24	25	0,2096	0,0360
8	9	0,3144	0,054	25	26	0,1310	0,0225
9	10	0,2096	0,036	26	27	0,1048	0,0180
10	11	0,1310	0,0225	7	28	0,1572	0,0270
11	12	0,1048	0,018	28	29	0,1572	0,0270
3	13	0,1572	0,027	29	30	0,1572	0,0270
13	14	0,2096	0,036	10	31	0,1572	0,0270
14	15	0,1048	0,018	31	32	0,2096	0,0360
15	16	0,0524	0,009	32	33	0,1572	0,0270
6	17	0,1794	0,0498	33	34	0,1048	0,0180
17	18	0,1645	0,0457	-	-	-	-

ANEXO C – Sistema de 70 Barras

Tensão de base = 12,66 kV

Potência de base = 1000 kVA

Tabela C.1 – Dados de Potência do Sistema de 70 Barras

Barra	Potência Ativa (kW)	Potência Reativa (kvar)	Barra	Potência Ativa (kW)	Potência Reativa (kvar)
1	0,00	0,00	36	6,00	4,00
2	0,00	0,00	37	26,00	18,55
3	0,00	0,00	38	26,00	18,55
4	0,00	0,00	39	0,00	0,00
5	0,00	0,00	40	24,00	17,00
6	0,00	0,00	41	24,00	17,00
7	2,60	2,20	42	1,20	1,00
8	40,40	30,00	43	0,00	0,00
9	75,00	54,00	44	6,00	4,30
10	30,00	22,00	45	0,00	0,00
11	28,00	19,00	46	39,22	26,30
12	145,00	104,00	47	39,22	26,30
13	145,00	104,00	48	0,00	0,00
14	8,00	5,50	49	79,00	56,40
15	8,00	5,50	50	384,70	274,50
16	0,00	0,00	51	384,70	274,50
17	45,50	30,00	52	40,50	28,30
18	60,00	35,00	53	3,60	2,70
19	60,00	35,00	54	4,35	3,50
20	0,00	0,00	55	26,40	19,00
21	1,00	0,60	56	24,00	17,20
22	114,00	81,00	57	0,00	0,00
23	5,30	3,50	58	0,00	0,00
24	0,00	0,00	59	0,00	0,00
25	28,00	20,00	60	100,00	72,00
26	0,00	0,20	61	0,00	0,00
27	14,00	10,00	62	1244,00	888,00
28	14,00	10,00	63	32,00	23,00
29	26,00	18,60	64	0,00	0,00
30	26,00	18,60	65	227,00	162,00
31	0,00	0,00	66	59,00	42,00
32	0,00	0,00	67	18,00	13,00
33	0,00	0,00	68	18,00	13,00
34	14,00	10,00	69	28,00	20,00
35	19,50	14,00	70	28,00	20,00

Tabela C.2 – Dados de Ramos do Sistema de 70 Barras

Barra inicial	Barra final	R(Ω)	X(Ω)	Barra inicial	Barra final	R(Ω)	X(Ω)
1	2	0,0005	0,0012	4	37	0,0044	0,0108
2	3	0,0005	0,0012	37	38	0,0640	0,1565
3	4	0,0001	0,0001	38	39	0,1053	0,1230
4	5	0,0015	0,0036	39	40	0,0304	0,0305
5	6	0,0251	0,0294	40	41	0,0018	0,0021
6	7	0,3660	0,1864	41	42	0,7283	0,8509
7	8	0,3811	0,1941	42	43	0,3100	0,3623
8	9	0,0922	0,0470	43	44	0,0410	0,0478
9	10	0,0493	0,0251	44	45	0,0092	0,0116
10	11	0,8190	0,2707	45	46	0,1089	0,1373
11	12	0,1872	0,0619	46	47	0,0009	0,0012
12	13	0,7114	0,2351	5	48	0,0034	0,0084
13	14	1,0300	0,3400	48	49	0,0851	0,2083
14	15	1,0440	0,3450	49	50	0,2898	0,7091
15	16	1,0580	0,3496	50	51	0,0822	0,2011
16	17	0,1966	0,0650	9	52	0,0928	0,0473
17	18	0,3744	0,1238	52	53	0,3319	0,1114
18	19	0,0047	0,0016	10	54	0,1740	0,0886
19	20	0,3276	0,1083	54	55	0,2030	0,1034
20	21	0,2106	0,0696	55	56	0,2842	0,1447
21	22	0,3416	0,1129	56	57	0,2813	0,1433
22	23	0,0140	0,0046	57	58	1,5900	0,5337
23	24	0,1591	0,0526	58	59	0,7837	0,2630
24	25	0,3463	0,1145	59	60	0,3042	0,1006
25	26	0,7488	0,2475	60	61	0,3861	0,1172
26	27	0,3089	0,1021	61	62	0,5075	0,2585
27	28	0,1732	0,0572	62	63	0,0974	0,0496
3	29	0,0044	0,0108	63	64	0,1450	0,0738
29	30	0,0640	0,1565	64	65	0,7105	0,3619
30	31	0,3978	0,1315	65	66	1,0410	0,5302
31	32	0,0702	0,0232	12	67	0,2012	0,0611
32	33	0,3510	0,1160	67	68	0,0047	0,0014
33	34	0,8390	0,2816	13	69	0,7394	0,2444
34	35	1,7080	0,5646	69	70	0,0047	0,0016
35	36	1,4740	0,4873	-	-	-	-

ANEXO D – Sistema de 126 Barras

Tensão de base = 1,0 kV

Potência de base = 1,0 MVA

Tabela D.1 – Dados de Potência do Sistema de 126 Barras

Barra	Potência Ativa (MW)	Potência Reativa (Mvar)	Barra	Potência Ativa (MW)	Potência Reativa (Mvar)
1	0,000	0,000	64	0,000	0,000
2	0,000	0,000	65	0,000	0,000
3	0,120	0,085	66	0,078	0,059
4	0,000	0,000	67	0,043	0,024
5	0,000	0,000	68	0,013	0,008
6	0,000	0,000	69	0,000	0,000
7	0,350	0,190	70	0,047	0,030
8	0,000	0,000	71	0,076	0,056
9	0,000	0,000	72	0,000	0,000
10	0,250	0,160	73	0,000	0,000
11	0,000	0,000	74	0,000	0,000
12	0,000	0,000	75	0,035	0,024
13	0,326	0,233	76	0,042	0,029
14	0,000	0,000	77	0,112	0,078
15	0,000	0,000	78	0,030	0,018
16	0,000	0,000	79	0,078	0,045
17	0,103	0,078	80	0,023	0,012
18	0,000	0,000	81	0,056	0,042
19	0,000	0,000	82	0,012	0,008
20	0,067	0,045	83	0,045	0,031
21	0,045	0,027	84	0,030	0,018
22	0,000	0,000	85	0,085	0,053
23	0,000	0,000	86	0,036	0,022
24	0,000	0,000	87	0,045	0,034
25	0,042	0,025	88	0,009	0,006
26	0,063	0,047	89	0,034	0,026
27	0,105	0,068	90	0,000	0,000
28	0,000	0,000	91	0,000	0,000

Tabela D.1 continuação da página anterior

Barra	Potência Ativa (MW)	Potência Reativa (Mvar)	Barra	Potência Ativa (MW)	Potência Reativa (Mvar)
29	0,204	0,176	92	0,000	0,000
30	0,135	0,098	93	0,024	0,015
31	0,000	0,000	94	0,000	0,000
32	0,000	0,000	95	0,000	0,000
33	0,000	0,000	96	0,013	0,008
34	0,026	0,015	97	0,024	0,017
35	0,033	0,021	98	0,049	0,042
36	0,052	0,034	99	0,045	0,032
37	0,036	0,025	100	0,025	0,017
38	0,024	0,016	101	0,034	0,021
39	0,000	0,000	102	0,000	0,000
40	0,000	0,000	103	0,034	0,021
41	0,000	0,000	104	0,042	0,031
42	0,000	0,000	105	0,000	0,000
43	0,000	0,000	106	0,000	0,000
44	0,000	0,000	107	0,036	0,022
45	0,078	0,054	108	0,065	0,047
46	0,035	0,023	109	0,023	0,015
47	0,000	0,000	110	0,025	0,017
48	0,035	0,021	111	0,000	0,000
49	0,000	0,000	112	0,000	0,000
50	0,000	0,000	113	0,055	0,042
51	0,032	0,020	114	0,032	0,021
52	0,035	0,026	115	0,000	0,000
53	0,000	0,000	116	0,000	0,000
54	0,034	0,024	117	0,056	0,037
55	0,000	0,000	118	0,043	0,031
56	0,056	0,044	119	0,068	0,049
57	0,000	0,000	120	0,053	0,038
58	0,000	0,000	121	0,035	0,020
59	0,000	0,000	122	0,023	0,015
60	0,000	0,000	123	0,022	0,015
61	0,000	0,000	124	0,044	0,035
62	0,071	0,052	125	0,035	0,025
63	0,000	0,000	126	0,039	0,024

Tabela D.2 – Dados de Ramos do Sistema de 126 Barras

Barra inicial	Barra final	R(Ω)	X(Ω)	Barra inicial	Barra final	R(Ω)	X(Ω)
1	2	0,00125	0,00180	64	65	0,00153	0,00181
2	3	0,00031	0,00050	65	66	0,00069	0,00063
3	4	0,00285	0,00261	16	67	0,00109	0,00100
4	5	0,00143	0,00130	17	68	0,00210	0,00192
5	6	0,00078	0,00092	18	69	0,00130	0,00119
6	7	0,00063	0,00074	69	70	0,00056	0,00052
7	8	0,00120	0,00137	19	71	0,00148	0,00136
8	9	0,00089	0,00105	19	72	0,00087	0,00103
9	10	0,00123	0,00145	72	73	0,00135	0,00160
10	11	0,00087	0,00103	73	74	0,00221	0,00262
11	12	0,00112	0,00132	74	75	0,00067	0,00062
12	13	0,00093	0,00110	20	76	0,00056	0,00052
13	14	0,00065	0,00078	22	77	0,00086	0,00078
14	15	0,00086	0,00102	23	78	0,00056	0,00051
15	16	0,00250	0,00296	24	79	0,00071	0,00065
16	17	0,00342	0,00405	25	80	0,00078	0,00072
17	18	0,00068	0,00080	25	81	0,00065	0,00059
18	19	0,00083	0,00098	31	82	0,00076	0,00070
19	20	0,00120	0,00142	32	83	0,00056	0,00051
20	21	0,00140	0,00166	32	84	0,00086	0,00079
2	22	0,00210	0,00249	33	85	0,00075	0,00068
22	23	0,00124	0,00147	39	86	0,00075	0,00069
23	24	0,00140	0,00166	40	87	0,00087	0,00080
24	25	0,00135	0,00160	41	88	0,00113	0,00103
25	26	0,00053	0,00048	42	89	0,00065	0,00060
3	27	0,00230	0,00210	43	90	0,00132	0,00121
4	28	0,00210	0,00249	90	91	0,00069	0,00063
28	29	0,00304	0,00278	91	92	0,00079	0,00072
5	30	0,00470	0,00430	92	93	0,00057	0,00052
5	31	0,00153	0,00181	44	94	0,00096	0,00088
31	32	0,00120	0,00142	94	95	0,00211	0,00193
32	33	0,00105	0,00124	95	96	0,00056	0,00052
33	34	0,00063	0,00058	49	97	0,00056	0,00052
6	35	0,00124	0,00114	50	98	0,00089	0,00092
6	36	0,00089	0,00082	50	99	0,00065	0,00060

Tabela D.2 continuação da página anterior

Barra inicial	Barra final	R(Ω)	X(Ω)	Barra inicial	Barra final	R(Ω)	X(Ω)
6	37	0,00034	0,00031	50	100	0,00056	0,00052
7	38	0,00106	0,00097	57	101	0,00142	0,00130
8	39	0,00096	0,00113	58	102	0,00076	0,00070
39	40	0,00103	0,00122	102	103	0,00069	0,00063
40	41	0,00097	0,00115	58	104	0,00105	0,00096
41	42	0,00078	0,00092	59	105	0,00065	0,00060
42	43	0,00121	0,00143	105	106	0,00105	0,00096
43	44	0,00110	0,00130	106	107	0,00057	0,00052
44	45	0,00087	0,00103	60	108	0,00093	0,00086
9	46	0,00462	0,00423	61	109	0,00067	0,00061
10	47	0,00234	0,00277	63	110	0,00053	0,00049
47	48	0,00035	0,00034	64	111	0,00094	0,00086
11	49	0,00113	0,00133	111	112	0,00130	0,00119
49	50	0,00078	0,00092	112	113	0,00088	0,00081
50	51	0,00089	0,00082	65	114	0,00075	0,00069
12	52	0,00135	0,00124	72	115	0,00171	0,00157
13	53	0,00096	0,00088	115	116	0,00092	0,00084
53	54	0,00068	0,00062	116	117	0,00062	0,00057
14	55	0,00120	0,00110	73	118	0,00120	0,00110
55	56	0,00056	0,00052	74	119	0,00083	0,00076
15	57	0,00087	0,00103	90	120	0,00023	0,00021
57	58	0,00086	0,00102	91	121	0,00065	0,00061
58	59	0,00088	0,00105	94	122	0,00043	0,00041
59	60	0,00078	0,00092	102	123	0,00045	0,00042
60	61	0,00113	0,00134	105	124	0,00037	0,00034
61	62	0,00088	0,00081	111	125	0,00059	0,00054
15	63	0,00134	0,00158	115	126	0,00121	0,00111
63	64	0,00086	0,00102	-	-	-	-