

**ALEJANDRO JOSE CALIX AMAYA**

**OTIMIZAÇÃO DA ESTRATÉGIA VOLT-VAR COM ALGORITMO  
GENÉTICO CENTRALIZADO E CONTROLE LOCAL DE  
INVERSORES INTELIGENTES**

Ilha Solteira  
2025



**ALEJANDRO JOSE CALIX AMAYA**

**OTIMIZAÇÃO DA ESTRATÉGIA VOLT-VAR COM ALGORITMO  
GENÉTICO CENTRALIZADO E CONTROLE LOCAL DE  
INVERSORES INTELIGENTES**

Documento apresentado à Faculdade de Engenharia da Universidade Estadual Paulista – UNESP, Câmpus de Ilha Solteira, no Exame geral de Qualificação, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Área de Conhecimento: Automação.

**Prof. Dr. Jonatas Boas Leite**

Orientador

Ilha Solteira

2025

FICHA CATALOGRÁFICA  
Desenvolvida pela Diretoria Técnica de Biblioteca e Documentação

A489o Amaya, Alejandro Jose.  
Otimização da estratégia Volt-VAr com algoritmo genético centralizado e controle local de inversores inteligentes / Alejandro Jose Amaya . -- Ilha Solteira: [s.n.], 2025  
113 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2025

Orientador: Jonatas Boas Leite  
Inclui bibliografia

1. Algoritmo genético centralizado. 2. Controle local. 3. Sistemas de distribuição. 4. Controle de tensão e reativo. 5. Inversor inteligente.

**CERTIFICADO DE APROVAÇÃO**

TÍTULO DA DISSERTAÇÃO: OTIMIZAÇÃO DA ESTRATÉGIA VOLT-VAR COM ALGORITMO GENÉTICO  
CENTRALIZADO E CONTROLE LOCAL DE INVERSORES INTELIGENTES

**AUTOR: ALEJANDRO JOSE CALIX AMAYA**

**ORIENTADOR: JONATAS BOAS LEITE**

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, área:  
Automação pela Comissão Examinadora:



Prof. Dr. JONATAS BOAS LEITE (Participação Virtual)  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP



Dr. MARIO ANDRES MEJIA ALZATE (Participação Virtual)  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. JOEL DAVID MELO TRUJILLO (Participação Virtual)  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / Universidade Federal do ABC - UFABC

Ilha Solteira, 26 de setembro de 2025

## **AGRADECIMIENTOS**

Gostaria de agradecer primeiramente aos meus pais, Orlando Calix e Estela Amaya, por todo o apoio dedicado para que eu pudesse concluir esta etapa da minha vida. Além disso, agradeço ao Prof. Dr. Jonatas Boas Leite pela confiança e pela ajuda prestada no desenvolvimento deste trabalho e, principalmente, por me proporcionar a oportunidade de realizar este curso de mestrado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## RESUMO

As redes de distribuição elétrica enfrentam novos desafios com a integração de tecnologias emergentes, como geradores distribuídos, veículos elétricos e bancos de baterias. Esses dispositivos oferecem benefícios significativos, como maior sustentabilidade energética e uma redução considerável da pegada de carbono. No entanto, as redes elétricas, originalmente projetadas para um fluxo de energia centralizado, tiveram a qualidade do fornecimento elétrico e a estabilidade do sistema comprometidas ao se adaptarem a esse ambiente mais dinâmico. Para mitigar esses efeitos e melhorar a integração de novas tecnologias, diversas propostas foram desenvolvidas, destacando-se os controles de tensão e potência reativa, abreviado como controle Volt-Var, apesar que essas estratégias são amplamente estudadas e utilizadas atualmente, é crucial modernizar de forma constantes essas estratégias para uma correta integração aos sistemas elétricos modernos. Esses métodos evoluíram de um simples controle coordenado de dispositivos convencionais, como bancos de capacitores e transformadores com taps de derivação, para estratégias mais avançadas, incluindo controles locais e inversores inteligentes. Este trabalho propõe um controle híbrido Volt-VAr, para a redução de perdas e desvios de tensão em redes de distribuição ativas através de um fluxo de potência probabilístico horário com um período de tempo de uma semana utilizando duas abordagens de controle: um esquema clássico de gerenciamento centralizado para dispositivos Volt-VAr convencionais, no qual a estratégia inicial é determinada na forma de variáveis discretas. Na segunda abordagem, aplica-se um controle local para um inversor inteligente, que permite realizar ajustes dinâmicos por meio de uma injeção contínua de potência reativa. O controle centralizado é realizado através de um algoritmo genético, enquanto o controle local otimiza a regulação sobre a solução proposta pelo algoritmo (AG). O método proposto é avaliado em um modelo de rede de distribuição inteligente com 135 barras. Os resultados alcançados mostram melhorias consideráveis nos perfis de tensão, permitindo alcançar tensões entre 0,97 e 1,0 mesmo sob condições de carga pesada, além de observar uma redução média de 60% nas perdas globais do sistema estudado.

*Palavras Chaves:* Algoritmo genético centralizado; controle local; sistemas de distribuição; controle de tensão e reativo; inversor inteligente.

## ABSTRACT

Electrical distribution grids face new challenges with the integration of emerging technologies such as distributed generators, electric vehicles, and battery banks. These devices offer significant benefits, such as greater energy sustainability and a significant reduction in the carbon footprint. However, electrical grids, originally designed for a centralized power flow, have seen their power supply quality and system stability compromised as they adapt to this more dynamic environment. To mitigate these effects and improve the integration of new technologies, several proposals have been developed, most notably voltage and reactive power control, abbreviated as Volt-Var control. Although these strategies are widely studied and used today, it is crucial to constantly modernize them for proper integration into modern electrical systems. These methods have evolved from simple coordinated control of conventional devices, such as capacitor banks and transformers with shunt taps, to more advanced strategies, including local controls and smart inverters. This work proposes a hybrid Volt-VAR control system to reduce losses and voltage deviations in active distribution networks through a probabilistic hourly power flow with a one-week time period. It uses two control approaches: a classic centralized management scheme for conventional Volt-VAR devices, in which the initial strategy is determined in the form of discrete variables. The second approach applies local control to a smart inverter, allowing dynamic adjustments through a continuous injection of reactive power. Centralized control is performed through a genetic algorithm, while local control optimizes regulation based on the solution proposed by the algorithm (GA). The proposed method is evaluated on a smart distribution network model with 135 buses. The results show considerable improvements in voltage profiles, allowing voltages between 0.97 and 1.0 even under heavy load conditions, in addition to observing an average 60% reduction in overall losses in the studied system.

*Keywords:* Centralized genetic algorithm; local control; distribution systems; voltage and reactive control; smart inverter

## LISTA DE FIGURAS

<b>Figura 1.</b> Segmento de Rede de Distribuição Radial.....	40
<b>Figura 2.</b> Bancos de Capacitores em Subestação de Distribuição .....	43
<b>Figura 3.</b> Segmento de Rede de com Geração Distribuída.....	45
<b>Figura 4.</b> Faixa de flutuação da magnitude de potência ao longo do tempo.....	52
<b>Figura 5.</b> Diagrama de Fluxo Logica de Processo.....	54
<b>Figura 6.</b> Esquema funcional para AG.....	57
<b>Figura 7.</b> seleção por roleta para uma população de 20 indivíduos.....	63
<b>Figura 8.</b> Processo de cruzamento .....	66
<b>Figura 9.</b> Processo de Mutação .....	67
<b>Figura 10.</b> Fluxograma Funcional para AG .....	71
<b>Figura 11.</b> Esquema de Controle VVC Centralizado.....	72
<b>Figura 12.</b> Curva Volt-Var.....	74
<b>Figura 13.</b> Esquema de Controle da Estratégia Completa .....	75
<b>Figura 14.</b> Esquema de Controle VVC Híbrido.....	76
<b>Figura 15.</b> Fluxograma de Controle VVC Híbrido .....	77
<b>Figura 16.</b> Modelo de Rede de Distribuição 135 Barras .....	79
<b>Figura 17.</b> Gráfico de caixas para dispersão do fitness com $G=500$ .....	82
<b>Figura 18.</b> Gráfico de caixas para dispersão do fitness com $G=1000$ .....	82
<b>Figura 19.</b> Gráfico de Evolução da Resposta de Fitness para $G=500$ .....	83
<b>Figura 20.</b> Gráfico de Evolução da Resposta de Fitness Para $G=1000$ .....	84
<b>Figura 21.</b> Comportamento das Taxas de Cruzamento e Mutação .....	85
<b>Figura 22.</b> Espaço de Busca do AG .....	85
<b>Figura 23.</b> Comparação na Redução de Perdas .....	90
<b>Figura 24.</b> Perfil de Tensão em Baixa Carga. ....	90
<b>Figura 25.</b> Perfil de Tensão em Alta Carga. ....	91
<b>Figura 26.</b> Perfil de Tensão em Média Carga.....	91

<b>Figura 27.</b> Valores de Corrente em Média Carga .....	92
<b>Figura 28.</b> Dispersão de Tensão na Barra 70 em Média Carga.....	93
<b>Figura 29.</b> Dispersão de Tensão na Barra 70 em Alta Carga .....	94
<b>Figura 30.</b> Curvas de Carga Semanal .....	95
<b>Figura 31.</b> Curvas de Carga Primeiros 3 Dias. ....	96
<b>Figura 32.</b> Curvas de Carga 4 Dias Restantes.....	96
<b>Figura 33.</b> Curvas de Tensão na Barra 70 3 Dias.....	97
<b>Figura 34.</b> Curvas de Tensão na Barra 70 4 Dias Restantes .....	98
<b>Figura 35.</b> Valores de Perda Para Cada Hora e Configuração Quinta-Feira.....	99
<b>Figura 36.</b> Valores de Tensão – Híbrido vs. ML em média carga.....	104
<b>Figura 37.</b> Valores de Tensão – Híbrido vs. ML em alta carga.....	104
<b>Figura 38.</b> Valores de Tensão – Híbrido vs. ML em baixa carga.....	104
<b>Figura 39.</b> Valores de Perdas – Híbrido vs. ML .....	105

## LISTA DE TABELAS

<b>Tabela 1.</b> Matriz de deslocamento de fase para vários tipos de conexão.....	48
<b>Tabela 2.</b> Relação de transformação para vários tipos de conexão.....	48
<b>Tabela 3.</b> Estrutura Cromossômica .....	64
<b>Tabela 4.</b> Vector de solução para 5 dispositivos.....	65
<b>Tabela 5.</b> Resultados das configurações para $G=500$ .....	80
<b>Tabela 6.</b> Resultados das configurações para $G=1000$ .....	80
<b>Tabela 7.</b> Resultados das Diferentes Configurações .....	83
<b>Tabela 8.</b> Parâmetros da Rede Para Diferentes Perfis de Carga.....	86
<b>Tabela 9.</b> Resposta do Controle Centralizado Cara Diferentes Condições de Demanda.....	86
<b>Tabela 10.</b> Configurações Obtidas Pelo AG Para Poda Cenário de Carga .....	87
<b>Tabela 11.</b> Resposta do Algoritmo Híbrido Para Diferentes Condições de Demanda.....	88
<b>Tabela 12.</b> Porcentagem de Potência Injetada Pelo Inversor Para Cada Cenário de Carga.....	89
<b>Tabela 13.</b> Resposta do Controle Centralizado Quinta-Feira.....	101
<b>Tabela 14.</b> Resposta do Controle Híbrido Quinta-Feira.....	102

## LISTA DE ABREVIATURAS E SIGLAS

ADMM	<i>Alternating Direction Method of Multipliers</i>
AVR	<i>Automatic Voltage Regulator</i>
BC	Banco de capacitores
BAB	<i>Branch and Bound</i>
VVC	Controle Volt-Var
VVWC	Controle Volt-Var Watt
TRI-VVC	Controle Volt-Var em três etapas
ES	<i>Energy Storage</i>
FAPSO	<i>Fuzzy Adaptive Particle Swarm Optimization</i>
GD	Gerador Distribuído
GRASP	<i>Greedy Randomized Adaptive Search Procedure</i>
IA	Inteligência Artificial
SI	Inversor Inteligente
LSTM	<i>Long Short-Term Memory</i>
OLTC	<i>On-Load Tap Changer</i>
PSO	Otimização por Enxame de Partículas
OR	Otimização Robusta
SPEA2	<i>Strength Pareto Evolutionary Algorithm 2</i>
TRSQP	<i>Trust Region Sequential Quadratic Programming</i>
ULTC	<i>Under Load Tap Changer</i>

## LISTA DE SÍMBOLOS

$A_{i,p}$	Coeficiente intermediário na equação bicuadrática de fluxo de potência
$B_{i,p}$	Coeficiente intermediário na equação bicuadrática do fluxo de potência
$P_{i,p}$	Potência ativa na barra $i$ da fase $p$
$V_{i,p}$	Magnitude da tensão nodal na barra $i$ da fase $p$
$i$	Índice da barra
$p$	Índice das fases $\{a, b, c\}$
$l$	Índice da linha entre as barras $i - 1$ e $i$
$P_{ip}^{EQ}$	Potência ativa equivalente na barra $i$ da fase $p$
$Q_{ip}^{EQ}$	Potência reativa equivalente na barra $i$ da fase $p$
$EQ$	Índice das potências nodais equivalentes
$R_{l,pq}$	Resistência entre as fases $p$ e $q$ na linha $l$
$X_{l,pq}$	Reatância entre as fases $p$ e $q$ na linha $l$
$V_{i-1,p}$	Magnitude da tensão nodal na barra $i - 1$ e a fase $p$
$\delta_{pq}$	Fator de acoplamento magnético entre as fases
$I_l$	Magnitude da corrente na linha $l$
$Z_{l,pq}$	Matriz de impedância entre as fases $p$ e $q$ na linha $l$
$Z_l$	Matriz de impedância na linha $l$
$\bar{S}_{i,p}$	Potência de carga na barra $i$ da fase $p$
$jQ_{i,p}$	Potência reativa na barra $i$ da fase $p$
$R_l$	Resistência na linha $l$
$X_l$	Reatância na linha $l$
$P_{lp}^L$	Perdas da potência ativa na linha $l$ da fase $p$
$Q_{lp}^L$	Perdas da potência reativa na linha $l$ da fase $p$
$Q_{lp}^{CAP}$	Injeção de potência reativa do banco de capacitores
$[M_l]_{6 \times 6}$	Modelo de matriz de arestas correspondente a um conjunto de submatrizes
$[A_l]_{3 \times 3}$	Matriz adimensional do modelo de arestas
$[B_l]_{3 \times 3}$	Matriz de admitância
$[C_l]_{3 \times 3}$	Matriz de impedância
$[D_l]_{3 \times 3}$	Matriz adimensional do modelo de aresta
$K_n^{-1}$	Relação de transformação

$[\emptyset_i]_{3 \times 3}$	Matriz de desvio do ângulo de fase
$[Y_{mi}]_{3 \times 3}$	Matriz de admitância de magnetização
$[Z_{Di}]_{3 \times 3}$	Matriz de impedância de dispersão
$[I]_{3 \times 3}$	Matriz identidade
$t_h$	Instante horário do dia
$S_i^p(t_h)$	Valor da potência complexa para cada instante de tempo
$S_i^p$	Valor da potência constante
$E_i^p(t_h)$	Função percentual de consumo de energia
$r_i^p(t_h)$	Magnitude normalizada da potência consumida
$f_i^p(t_h)$	Fator de potência do consumo
$R(t_h)$	Magnitude normalizada para cada instante horário
$F(t_h)$	Fator de potência para cada instante horário
$X$	Valor sem normalizar
$X^*$	Novo valor normalizado
$\min(X)$	Mínimo valor do intervalo original
$\max(X)$	Máximo valor do intervalo original
$\text{newmin}(X)$	Mínimo valor da nova escala
$\text{newmax}(X)$	Máximo valor da nova escala
$N(y)$	Função de densidade de probabilidade normal
$\sigma_R(t_h)^2$	Variância horária da magnitude normalizada
$\sigma_F(t_h)^2$	Variância horária do fator de potência
$n$	Número total de dias de medição
$k$	Dia da medição
$N_{R,i}^p(t_h)$	Densidade de probabilidade da potência consumida
$N_{F,i}^p(t_h)$	Densidade de probabilidade do fator de potência
$\alpha_{R,i}^p(t_h)$	Variável aleatória entre 0 e 1
$\alpha_{F,i}^p(t_h)$	Variável aleatória entre 0 e 1
$\omega$	Grau de incerteza entre as projeções máxima e mínima
$\beta$	Variável aleatória entre 0 e 1
$V_{PL}$	Tensão de linha do primário
$V_{SL}$	Tensão de linha do secundário
$V_{min}$	Valor mínimo de tensão permitida

$V_{max}$	Valor máximo de tensão permitida
$P_{min}$	Valor mínimo de potência ativa injetada permitida
$P_{max}$	Valor máximo de potência ativa injetada permitida
$P_i$	Potência ativa injetada na barra $i$
$Q_{min}$	Valor mínimo de potência reativa injetada permitida
$Q_{max}$	Valor máximo de potência reativa injetada permitida
$Q_i$	Potência reativa injetada na barra $i$
$K_{nmin}$	Posição mínima para taps
$K_{nmax}$	Posição máxima para taps
$K_{n_{i-1},i}$	Posição atual dos taps
$Q_{min}^{CAP}$	Valor mínimo permitido da potência reativa injetada pelos capacitores
$Q_{i,p}^{CAP}$	Valor da potência reativa injetada pelos capacitores
$Q_{max}^{CAP}$	Valor máximo permitido da potência reativa injetada pelos capacitores
$Q_{i,p}^{BC}$	Valor de potência injetada pelos bancos de capacitores
$Q_{i,p}^{GD}$	Valor de potência injetada pelos geradores distribuídos
$Q_{i,p}^{SI}$	Valor de potência injetada pelo inversor inteligente
$P_{gen,i}$	Potência ativa gerada na barra $i$
$P_{dem,i}$	Potência ativa consumida na barra $i$
$P_{loss,i}$	Perda de potência ativa na barra $i$
$Q_{gen,i}$	Potência reativa gerada na barra $i$
$Q_{dem,i}$	Potência reativa consumida na barra $i$
$Q_{loss,i}$	Perda de potência reativa na barra $i$
$w_1$	Coefficiente de ajuste da importância da penalização por desvio
$w_2$	Coefficiente de ajuste da importância da penalização por perdas
$\Omega_b$	Conjunto de barras da rede
$Pe_{Vo}$	Penalização associada à tensão
$Pe_L$	Penalização associada às perdas
$Pe_{max}$	Perdas totais
$\lambda_1$	Valor do peso para os desvios
$\lambda_2$	Valor do peso para as perdas
$\tau_i$	Probabilidade de <i>fitness</i> inverso

$f_j$	<i>Fitness</i> total
$\tau_{total}$	Soma total das probabilidades do <i>fitness</i> inverso
$r$	Número aleatório no intervalo $[0, \tau_{total}]$
$k_j$	Posição dos taps dos $n$ OLTC
$s_j$	Etapas ativas dos $n$ capacitores
$u_j$	Quantidade de potência injetada pelos $n$ geradores distribuídos
$g_k^{x_j}$	Gene $k$ dos pais selecionados
$x_1$	Pai 1
$x_2$	Pai 2
$g_k^{x_1}$	Gene do pai 1
$g_k^{x_2}$	Gene do pai 2
$Prob_1$	Probabilidade do gene do pai 1
$Prob_2$	Probabilidade do gene do pai 2
$\mathcal{R}$	Número aleatório entre 0 e 1
$\pm\Delta$	Fator de determinação probabilístico
$Prob_j^m$	Probabilidade de mutação
$\rho_c$	Taxa de cruzamento
$\rho_m$	Taxa de mutação
$k_{max}^c$	Taxa máxima de cruzamento
$k_{min}^c$	Taxa mínima de cruzamento
$k_{max}^m$	Taxa máxima de mutação
$k_{min}^m$	Taxa mínima de mutação
$N_s$	Número de soluções semelhantes
$ \mathcal{P} $	Número total de indivíduos
$F_m$	Valor de Parametrização
$\alpha$	Peso do parâmetro associado à variação
$\beta$	Peso do parâmetro associado ao tempo
$\lambda_i$	Variação individual
$\lambda_{max}$	Variação máxima encontrada
$t_i$	Tempo de execução para cada configuração
$t_{max}$	Tempo máximo encontrado

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>20</b>
<b>1.1</b>	<b>OBJETIVOS</b> .....	<b>22</b>
<b>1.1.1</b>	<b>OBJETIVO PRINCIPAL</b> .....	<b>22</b>
<b>1.1.2</b>	<b>OBJETIVOS ESPECÍFICOS</b> .....	<b>22</b>
<b>1.2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>23</b>
<b>1.2.1</b>	<b>CONTROLES CENTRALIZADOS EM REDES DE DISTRIBUIÇÃO</b> .....	<b>24</b>
<b>1.2.2</b>	<b>ALGORITMOS GENÉTICOS APLICADOS EM CONTROLES DE TENSÃO E REATIVO</b> .....	<b>27</b>
<b>1.2.3</b>	<b>CONTROLE LOCAL COM INVERSORES INTELIGENTES</b> .....	<b>30</b>
<b>1.2.4</b>	<b>CONTROLE HÍBRIDO EM REDES DE DISTRIBUIÇÃO</b> .....	<b>32</b>
<b>1.2.5</b>	<b>TÉCNICAS DE APRENDIZAGEM DE MÁQUINA (MACHINE LEARNING)</b> .....	<b>33</b>
<b>1.3</b>	<b>ESTRATÉGIA PROPOSTA E ESTRUTURA DO TEXTO</b> .....	<b>36</b>
<b>2</b>	<b>FLUXO DE POTÊNCIA SEQUENCIAL E PROBABILÍSTICO PARA REDES DE DISTRIBUIÇÃO INTELIGENTES</b> .....	<b>38</b>
<b>2.1</b>	<b>MÉTODO SEQUENCIAL DE VARREDURA E SOMA DE POTÊNCIAS</b> .....	<b>39</b>
<b>2.2</b>	<b>MODELAGEM DE DISPOSITIVOS EM PARALELO</b> .....	<b>42</b>
<b>2.2.1</b>	<b>BANCO DE CAPACITORES</b> .....	<b>43</b>
<b>2.2.2</b>	<b>GERADOR DISTRIBUÍDO</b> .....	<b>44</b>
<b>2.2.3</b>	<b>INVERSOR INTELIGENTE</b> .....	<b>46</b>
<b>2.3</b>	<b>MODELAGEM DE DISPOSITIVOS EM SÉRIE</b> .....	<b>46</b>
<b>2.3.1</b>	<b>OLTC</b> .....	<b>46</b>
<b>2.4</b>	<b>FLUXO DE POTÊNCIA PROBABILÍSTICO PARA SISTEMAS DE DISTRIBUIÇÃO</b> .....	<b>48</b>
<b>2</b>	<b>ESTRATÉGIA DE CONTROLE VOLT/VAR COM AG CENTRALIZADO</b> .....	<b>56</b>
<b>3.1</b>	<b>RESTRIÇÕES</b> .....	<b>57</b>
<b>3.2</b>	<b>FUNÇÃO OBJETIVO</b> .....	<b>59</b>
<b>3.3</b>	<b>PENALIZAÇÃO</b> .....	<b>60</b>
<b>3.4</b>	<b>ELITISMO</b> .....	<b>61</b>
<b>3.5</b>	<b>SELEÇÃO DOS PAIS</b> .....	<b>62</b>
<b>3.6</b>	<b>CRUZAMENTO E MUTAÇÃO</b> .....	<b>64</b>
<b>3.7</b>	<b>FUNÇÃO DE PARAMETRIZAÇÃO</b> .....	<b>69</b>
<b>3.8</b>	<b>VINCULAÇÃO DO ALGORITMO GENÉTICO E O FLUXO DE POTÊNCIA PROBABILÍSTICO</b> .....	<b>70</b>
<b>3</b>	<b>CONTROLE LOCAL PARA INVERSOR INTELIGENTE</b> .....	<b>73</b>
<b>5</b>	<b>CASO DE ESTUDO E ANÁLISE DE RESULTADOS</b> .....	<b>78</b>
<b>5.1</b>	<b>CASO DE ESTUDO 1: AJUSTE DO AG</b> .....	<b>79</b>

<b>5.2</b>	<b>CASO DE ESTUDO 2: VVC CENTRALIZADO .....</b>	<b>86</b>
<b>5.3</b>	<b>CASO DE ESTUDO 3: CONTROLE LOCAL DO SI .....</b>	<b>87</b>
<b>5.4</b>	<b>ANÁLISE DO FLUXO DE POTÊNCIA PROBABILÍSTICO.....</b>	<b>94</b>
<b>5.5</b>	<b>AVALIAÇÃO COMPARATIVA COM TÉCNICAS DE ML APLICADAS AO CONTROLE VOLT-VAR .....</b>	<b>103</b>
<b>6</b>	<b>CONCLUSÕES .....</b>	<b>107</b>
	<b>REFERÊNCIAS .....</b>	<b>109</b>

# 1 INTRODUÇÃO

O aumento exponencial das necessidades energéticas em uma sociedade em constante crescimento tem apresentado grandes desafios para os sistemas elétricos tradicionais. As redes elétricas, originalmente projetadas para atender demandas energéticas modestas e de natureza unidirecional, têm experimentado certas mudanças e um crescimento acelerado, especialmente nas últimas décadas, devido ao aumento contínuo da quantidade de cargas conectadas e à inclusão de dispositivos de geração distribuída. Os sistemas de distribuição modernos enfrentam dificuldades para se adaptar a esse crescimento, o que compromete a qualidade do fornecimento elétrico, afetando negativamente não apenas a rede e seus componentes, mas também os usuários de qualquer tipo, sejam eles industriais, comerciais ou residenciais.

A crescente demanda por energia, em conjunto com a variabilidade devido aos horários rotineiros e de trabalho na população, gera perturbações nos níveis de tensão do sistema provocando que, em certas áreas ou horários de alta demanda, os níveis de tensão estejam fora da faixa ideal. No Brasil, essa faixa ideal de tensão é estabelecida em  $\pm 5\%$  em relação ao valor nominal por unidade de tensão conforme estabelecido pela ANEEL na Seção 8 da Resolução Normativa nº 956 para tensões inferiores aos 230kV no ponto de conexão. Uma tensão fora dessa faixa pode causar diversos problemas, como aumento das perdas elétricas, superaquecimento e redução da vida útil de linhas e equipamentos, desconexões frequentes do sistema, desestabilização de equipamentos de proteção e sistemas eletrônicos, além de um aumento no risco de incêndios.

Ao longo do tempo, diversas estratégias foram implementadas para mitigar esses efeitos e garantir condições seguras e estáveis no fornecimento de energia elétrica. Entre essas estratégias estão o constante reforço das redes de distribuição e transmissão, a construção de novas centrais de geração e a ampliação das existentes, entre outras medidas.

Nesse contexto de estratégias para melhorar a qualidade do fornecimento elétrico nos sistemas de distribuição atuais, destacam-se as técnicas de controle de tensão e reativo (VVC), na sigla em inglês, *Volt-Var Control*, que desempenham um papel fundamental na operação eficiente e estável das redes de distribuição. Essas estratégias são definidas como um conjunto de técnicas projetadas para determinar os ajustes e a gestão ótima de

diversos dispositivos que mantêm os níveis de tensão da rede elétrica dentro de valores operacionais ideais.

Entre esses dispositivos estão os transformadores com taps de derivação sob carga (OLTC), na sigla em inglês, *On-Load Tap Changer* e os reguladores automáticos de tensão (AVR), na sigla em inglês *Automatic Voltage Regulator*, que ajustam diretamente os níveis de tensão na saída dos transformadores, aumentando-os ou reduzindo-os conforme o estado da rede. Também se destacam os dispositivos de injeção de potência, como os bancos de capacitores (BC), os geradores distribuídos (GD) e, mais recentemente, os inversores inteligentes (SI), na sigla em inglês, *Smart Inverter*, utilizados no controle de tensão e potência reativa.

Tanto os BCs quanto os GDs injetam potência diretamente no sistema, o que permite manter a qualidade da tensão mesmo em situações de alta demanda, quando a carga do sistema está saturada (Li *et al.*, 2018) e (Iwata; Fukuyama, 2016). Por sua vez, os inversores inteligentes não apenas permitem a injeção de potência, mas também sua absorção. Além disso, esses dispositivos possuem algumas características, como canais de comunicação bidirecional, funções de proteção avançada e compatibilidade com sistemas modernos de comunicação e controle, que os definem como dispositivos inteligentes, características úteis especialmente em sistemas de distribuição com presença de GD renovável, como solar ou eólica. Nesses casos, ao utilizar fontes renováveis que dependem explicitamente de condições climáticas e sem possuir um controle adequado, pode ocorrer que a energia gerada pelas fontes renováveis não seja totalmente consumida pela carga que está sendo atendida, o que pode resultar em um excedente de energia liberado para o sistema de distribuição, causando alterações no fluxo normal de energia. (Jaramillo-Leon *et al.*, 2022).

As estratégias de VVC geralmente empregam diferentes metodologias, que são classificadas em métodos centralizados, descentralizados e híbridos, conforme definido em Ma *et al.*, (2021). Cada uma dessas metodologias possui sua própria abordagem operacional, projetada para se adaptar a situações específicas. Isso significa que não existe uma metodologia universalmente superior, mas sim que sua eficácia depende das condições particulares da rede, das características da carga ou das restrições econômicas e computacionais.

A determinação das estratégias ideais para o VVC é alcançada por meio de diversos métodos ou algoritmos de controle, que incluem modelos de otimização matemática e metaheurísticos. Esses métodos definem as configurações ótimas dos

dispositivos sob seu controle, seja regulando diretamente a saída de tensão dos transformadores ou injetando potência na rede. O principal objetivo é manter a estabilidade da rede, reduzir o desgaste mecânico dos dispositivos e se adaptar às mudanças nos padrões de carga (Tahir *et al.*, 2016).

Além disso, algumas abordagens incorporam técnicas baseadas em inteligência artificial (IA) Com o objetivo de acelerar a convergência dos modelos tradicionais por meio de assistências utilizando IA e flexibilizar os sistemas de controle para ser adaptados a ambientes mais dinâmicos proporcionando características de natureza mais preventiva através da identificação de parâmetros.(Gholami *et al.*, 2022).

## **1.1 Objetivos**

### ***1.1.1 Objetivo Principal***

Este trabalho de pesquisa tem como objetivo o desenvolvimento de uma estratégia de controle de tensão e potência reativa a partir de um algoritmo genético para um controle centralizado de dispositivos convencionais e complementado por um inversor inteligente controlado de forma local para melhorar os perfis de tensão e reduzir perdas ativas em um sistema de distribuição simulado.

### ***1.1.2 Objetivos específicos***

Para atingir o objetivo principal são listados os seguintes objetivos específicos:

- Estudar e compreender as equações de fluxo de potência elétrica, expandindo-as para incluir as restrições associadas aos controles de tensão e reativo;
- Desenvolver um modelo determinista e sequencial de rede de distribuição a partir das equações de fluxo de potência, incorporando a modelagem dos diferentes dispositivos de controle presentes no sistema;
- Complementar a abordagem determinista do fluxo de potência a partir de funções probabilísticas que permitam representar a operação da rede em um modelo horário;

- Desenvolver computacionalmente o sistema de distribuição utilizando as equações dos fluxos de potência sequencial e probabilísticos;
- Definir um modelo para um AG centralizado determinar ajustes em dispositivos de regulação de tensão e injeção de potência em uma rede de distribuição elétrica;
- Estabelecer um modelo de controle local que complemente a abordagem centralizada do AG na estratégia Volt-Var por meio da implementação de um inversor inteligente;
- Desenvolver computacionalmente a estratégia de controle Volt-Var híbrida e vincular corretamente aos modelos computacionais da rede e aos fluxos de potência;
- Realizar uma análise dos resultados obtidos em uma rede de distribuição simulada, destacando os benefícios do algoritmo em termos de redução de perdas, estabilidade da tensão e eficiência operacional.

## 1.2 Revisão Bibliográfica

A implementação de estratégias avançadas de VVC nos sistemas de distribuição apresenta uma série de benefícios significativos, como a melhoria na estabilidade dos perfis de tensão, a redução de perdas e o aumento da capacidade operacional. O desenvolvimento e o sucesso dessas estratégias dependem de vários fatores, que devem ser definidos em etapas anteriores ao desenvolvimento dos algoritmos. Esses fatores incluem a seleção da metodologia empregada, seja centralizada, descentralizada ou híbrida, o tipo de algoritmo de otimização que vai ser utilizado, a definição da função objetivo e as restrições associadas. Essa função pode englobar ou priorizar a estabilidade da tensão, a redução de perdas ou o despacho ótimo de potência, entre outros.

Considerando tanto as características como as limitações da rede elétrica, percebe-se que a escolha, o dimensionamento e a localização dos dispositivos envolvidos, assim como o *design* e o planejamento da estratégia em conjunto com a escolha adequada da metodologia de controle, são cruciais para garantir o funcionamento ótimo do sistema de distribuição elétrica.

Portanto, torna-se necessário revisar diversos trabalhos propostos na literatura, nos quais são aplicados diferentes metodologias, algoritmos, funções objetivo e

dispositivos para o desenvolvimento de estratégias de VVC. Da mesma forma, é conveniente explorar trabalhos que desenvolvam teorias e equações para o modelamento ótimo do fluxo de potência e dos dispositivos previamente mencionados. Esses estudos servem como base para compreender as tendências atuais e as possíveis melhorias no *design* e na implementação de estratégias de controle em redes elétricas.

Em Tahir *et al.*,(2016), é realizada uma análise e revisão bibliográfica sobre VVC para sistemas de distribuição passivos (convencionais) e ativos (com presença de GD). O trabalho aborda tanto metodologias centralizadas quanto descentralizadas, destacando as funções objetivo, como a minimização de perdas, a redução de desvios de tensão e a otimização para o uso de dispositivos de controle. Além disso, são descritos diferentes algoritmos meta-heurísticos popularmente utilizados na literatura, incluindo AGs, otimização por enxame de partículas (PSO) na sigla em inglês *Particle Swarm Optimization* e alguns enfoques baseados em IA, como os que utilizam redes neurais. São considerados tanto cenários com fluxos de potência unidirecional quanto fluxo bidirecional.

### **1.2.1 Controles centralizados em redes de distribuição**

Os algoritmos de VVC desenvolvidos como estratégias centralizadas têm sido amplamente explorados na literatura como técnicas eficientes para o gerenciamento ótimo de redes de distribuição.

Os sistemas de controle centralizados podem ser entendidos como a abordagem clássica, que opera sob a supervisão de um coordenador central, responsável por determinar as estratégias de regulação. Conforme mencionado em Tahir *et al.*, (2016), o coordenador central monitora constantemente o estado da rede, agindo de forma adequada diante de situações de falha ou anomalias. Com o objetivo de preservar os parâmetros operacionais da rede, o coordenador controla a conexão e desconexão dos dispositivos reguladores, como OLTC, AVR e BC, distribuídos ao longo de toda a rede.

Para começar, em Svenda *et al.*, (2022) é apresentada uma proposta baseada no controle Volt-Var-Watt (VWV) em tempo real centralizado para o gerenciamento ótimo de dispositivos OLTC, BC e AVR, ao mesmo tempo que incorpora sistemas de GD e armazenadores de energia (ES), na sigla em inglês *Energy Storage*. O estudo destaca a maximização da capacidade de energias renováveis distribuídas nas redes elétricas.

O problema é formulado como um fluxo de potência ótimo (FPO), em que uma função objetivo é responsável por minimizar as variações de tensão em relação aos valores nominais. Para o controle VVW, é implementado um algoritmo de busca única baseado em técnicas de otimização sequencial de coordenadas descendentes discretas, permitindo o ajuste dos dispositivos controláveis na rede.

Uma abordagem interessante é a exposta em Long; Ochoa, (2016). A proposta busca avaliar o desempenho e os benefícios de três diferentes estratégias para o controle de dispositivos OLTC, com o objetivo de aumentar a capacidade de geração fotovoltaica distribuída em redes de baixa tensão e ao mesmo tempo manter os níveis de tensão do sistema dentro de valores aceitáveis.

As estratégias incluem o controle constante do ponto de ajuste fixo: essa estratégia ajusta os taps do transformador unicamente para manter a tensão nos pontos de referência estabelecidos, sem se adaptar às condições variáveis da rede. Estratégia de controle baseada no tempo: o OLTC atua por meio de um cronograma de tempo predefinido, considerando as flutuações e demandas de tensão para cada momento do dia. Estratégia baseada no monitoramento constante: o OLTC ajusta os taps com base em dados em tempo real coletados por meio de monitoramento remoto. Sensores distribuídos na rede fornecem informações sobre as condições atuais de tensão em diferentes nós.

Outra contribuição é apresentada em Sheng *et al.*, (2016), onde se realiza um VVC modelado como um problema não linear de inteiro misto (MINLP) na sigla em inglês *Mixed-Integer Nonlinear Programming*, e resolvido utilizando um algoritmo baseado em programação quadrática sequencial por regiões de confiança (TRSQP) na sigla em inglês *Trust Region Sequential Quadratic Programming*, em combinação com técnicas de otimização *Branch and Bound* (BAB). O principal objetivo é a redução de perdas, utilizando uma função objetivo que considera fatores de penalização monetária por perdas e pelas atividades de comutação dos dispositivos envolvidos.

Na literatura, o uso de algoritmos meta-heurísticos, como os AGs, PSOs, e os procedimentos de busca aleatória e adaptativa (GRASP), na sigla em inglês *Greedy Randomized Adaptive Search Procedure*, têm sido amplamente explorados para o desenvolvimento de novas estratégias de VVC. Esses algoritmos se destacam por sua capacidade de proporcionar processos mais rápidos, adaptativos e eficientes, permitindo a obtenção de soluções de alta qualidade que garantam uma operação estável e subótima do sistema de distribuição, melhorando tanto a confiabilidade quanto a eficiência no fornecimento de energia elétrica.

Para começar, a proposta apresentada em Mokgonyana *et al.*, (2016) desenvolve um algoritmo PSO para o controle em duas etapas de uma estratégia Volt-Var. Na primeira etapa, é criado um cronograma de despacho ótimo para determinar o estado dos capacitores nos alimentadores, com o objetivo de reduzir o fluxo de potência reativa nos transformadores da subestação. O estado ótimo dos capacitores é estabelecido por meio de técnicas heurísticas simples, descritas pelos autores como regras baseadas na análise de dados operacionais e perfis de carga.

Na segunda etapa, os dados obtidos sobre o estado dos capacitores na etapa anterior são utilizados como entrada para ajustar as posições dos taps do OLTC, juntamente com os estados dos capacitores da subestação. Esses ajustes são realizados com o objetivo de reduzir as perdas de potência e minimizar as variações de tensão no sistema. Para isso, é empregado um algoritmo PSO discreto, onde cada partícula representa uma possível posição do OLTC e ajusta seu comportamento com base no melhor resultado obtido por si mesma (exploração local) e no melhor resultado alcançado pelo conjunto de partículas (exploração global).

Os autores em Niknam *et al.*, (2010) propõem uma abordagem de controle diário Volt-Var para sistemas de distribuição ativos. A proposta utiliza um algoritmo adaptativo baseado na otimização por enxame de partículas difusa (FAPSO) na sigla em inglês *Fuzzy Adaptive Particle Swarm Optimization*, que foi projetado para realizar uma otimização não linear e de inteiros mistos, característica desse tipo de problema.

A função objetivo estabelece a minimização de perdas e os custos associados a elas. O algoritmo FAPSO é entendido como uma versão aprimorada do PSO, que ajusta dinamicamente os parâmetros de inércia e os fatores de aprendizagem por meio de lógica difusa. Isso é alcançado através do controle da injeção de potência ativa e reativa das unidades GD ao longo de toda a rede elétrica, garantindo um fornecimento confiável e eficiente.

Nas etapas iniciais do desenvolvimento deste trabalho, foram explorados diferentes algoritmos de controle para o VVC centralizado. As propostas mencionadas anteriormente refletem as diversas considerações previstas no momento da escolha do sistema de controle, priorizando-se uma convergência rápida e boa qualidade na resposta além de uma implementação computacional prática. Os AG demonstraram satisfazer adequadamente esses requisitos os quais são explorados na subseção seguinte.

### 1.2.2 Algoritmos genéticos aplicados em controles de tensão e reativo

Os AGs têm sido uma ferramenta poderosa na otimização de redes de distribuição elétrica, especialmente no desenvolvimento de novas estratégias de VVC, devido aos benefícios oferecidos pela metodologia evolutiva que eles possuem.

Os AGs permitem buscar configurações ótimas para os diferentes dispositivos que compõem o VVC. Baseados na teoria da evolução das espécies do Charles Darwin, na qual começa com uma determinada população composta por indivíduos que representam, de forma vetorial, diferentes possíveis soluções iniciais. Essas soluções podem ser geradas de maneira aleatória ou com alguma técnica heurística prévia, variando em qualidade, esperando que essa população inicial seja prematura e que as soluções não consigam aos índices desejados. No entanto, por meio de diferentes processos de cruzamento, mutação e adaptabilidade, essa população pode evoluir até alcançar os níveis de qualidade esperados, conforme descrito nas teorias do Darwin, nas quais uma espécie se adapta ao seu ambiente por meio de sua descendência, herdando diferentes genes que permitam sobreviver e prosperar ao longo de várias gerações.

(Mataifa *et al.*, 2022) Devido à naturalização metaheurísticas, os AGs podem resolver problemas não lineares e de grande complexidade computacional, mantendo um equilíbrio entre precisão e tempo de execução, o que os torna muito atrativos para o desenvolvimento de estratégias em tempo real ou em cenários dinâmicos, como os observados nas redes de distribuição ativas (Mataifa *et al.*, 2022).

A redução de perdas e das variações de tensão são alguns dos objetivos mais comuns na otimização Volt-Var para sistemas de distribuição. Quando essas estratégias são integradas aos AGs, obtém-se um desenvolvimento eficiente e flexível. Ao contrário de outros algoritmos evolutivos, os AGs oferecem uma capacidade única de explorar grandes espaços de busca enquanto otimizam múltiplos objetivos de forma simultânea, mantendo tempos de execução rápidos.

No entanto, um dos problemas que os AGs apresentam é a necessidade de calibrar muitos parâmetros que dependem da estrutura do problema, sendo necessário recalibrar esses parâmetros caso o problema aumente de tamanho ou a rede seja modificada.

Com base no descrito, é proposto em Echeverry *et al.*, (2016) um AG para a otimização Volt-Var em sistemas de distribuição ativos, onde cada cromossomo representa um estado para os diferentes dispositivos de controle da rede. A proposta tem como objetivo a minimização de perdas, variações de tensão e a redução da quantidade

de operações de comutação dos dispositivos. Além disso, utiliza uma seleção por roleta, na qual as soluções com melhor *fitness* têm maior probabilidade de serem selecionadas para a próxima geração.

A seleção por roleta é uma ferramenta interessante no desenvolvimento de técnicas de otimização utilizando AGs, pois, nos processos de seleção dos pais, permite considerar todos os indivíduos presentes em uma população, sem descartar aqueles com menor desempenho, conforme explicado em Medeiros; Kagan, (2016)

De forma semelhante, há a contribuição apresentada em Park *et al.*, (2007), na qual se propõe um VVC para a minimização de perdas e a redução das atividades de comutação dos dispositivos gerenciados. Para esse caso, são utilizados BC e transformadores com taps de derivação fora de carga (ULTC), na sigla em inglês *Under Load Tap Changer*. As restrições consideram os limites de tempo de comutação, desgaste mecânico e eficiência operacional, controlados por um AG para determinar, antecipadamente, o cronograma ótimo de operação dos capacitores, enquanto o ULTC é controlado em tempo real para compensar as diferenças entre as cargas reais e as previstas.

Os VVCs, na grande maioria dos casos, baseiam suas estratégias na coordenação dos diferentes dispositivos previamente mencionados. A coordenação ótima garante um sistema de distribuição estável e uma alta qualidade no fornecimento de energia, similar ao apresentado em Mokgonyana *et al.*, (2016), onde se destaca a importância de projetar estratégias que considerem tanto as restrições técnicas quanto as dinâmicas operacionais dos dispositivos.

Em Souza; Almeida, (2010), é apresentado um AG multiobjetivo (SPEA2) na sigla em inglês *Strength Pareto Evolutionary Algorithm 2*, aprimorado por meio de técnicas de lógica difusa para sistemas de distribuição radiais. A proposta foca em determinar a localização e a operação de dispositivos-chave, como AVR e BC, para diferentes cenários de carga.

A estratégia busca otimizar simultaneamente dois objetivos: a redução de perdas e a melhoria no perfil de tensão. Para cumprir esses objetivos, são modelados dois cromossomos, os quais representam, respectivamente, a localização e a operação dos dispositivos controlados. O SPEA2 utiliza duas populações: uma principal e outra usada para arquivar soluções não dominadas. Por outro lado, a lógica difusa é utilizada para reduzir o espaço de busca e lidar com a incerteza inerente ao sistema.

A representação cromossômica, ou codificação, é outro fator crucial no desenvolvimento de um AG, pois contém as informações de cada uma das soluções. Geralmente são utilizados vetores de solução do tipo binário, contínuo ou discreto. Dependendo da natureza do problema, determinadas representações vetoriais podem apresentar vantagens específicas.

A representação binária oferece uma implementação simples, pois cada cromossomo é uma cadeia de bits (0 ou 1), o que permite uma adaptação rápida aos operadores de cruzamento e mutação. No entanto, para determinados problemas, essa abordagem pode ser contraproducente, já que pode ser necessária uma grande quantidade de bits e ocasionar perda de precisão durante a conversão para valores reais. A representação contínua apresenta maior precisão na obtenção das respostas. Seu principal inconveniente é o custo computacional elevado, já que essa representação exige técnicas específicas para o cruzamento e a mutação, como cruzamentos aritméticos ou mutações gaussianas. Finalmente a representação discreta permite a utilização de valores concretos, ou seja, as soluções estão restritas a um determinado espaço, limitando o tipo de soluções possíveis e evitando a ocorrência de soluções indeterminadas ou inconsistentes. No entanto, podem surgir complicações durante o cruzamento e a mutação, pois esses operadores devem ser adaptados ao domínio discreto (Katoch *et al.*, 2021).

No campo do VVC, diversos trabalhos têm abordado diferentes tipos de representação vetorial para as soluções que compõem cada população. Em Qiao; MA, (2020) é utilizada uma codificação binária para representar o estado de comutação dos BCs, em que cada bit corresponde a uma decisão de ligar ou desligar. Neste caso específico, a codificação binária foi considerada como a mais eficiente, já que o vetor de solução contém apenas as informações de comutação (abertura e fechamento) dos dispositivos, o que resulta em uma maior simplicidade na aplicação dos operadores de cruzamento e mutação.

Em Medeiros; Kagan, (2016), é utilizada uma codificação binária de comprimento fixo, a qual representa as posições do TAP de OLTCs e AVRs, além da comutação dos BCs, em que um bit indica o estado de ligado ou desligado dos BCs, e um subconjunto de bits pode codificar uma posição do TAP. Devido a isso, o cruzamento é realizado por meio de um ponto fixo, no qual dois pais trocam segmentos de suas cadeias binárias para gerar descendentes.

Para finalizar, em Najar *et al.*, (2022) é apresentada uma codificação discreta para o controle de BCs, na qual cada cromossomo é uma cadeia de números inteiros que

representa as capacidades dos bancos para injetar potência reativa no sistema, em forma de valores predefinidos que correspondem a um conjunto discreto de níveis.

### ***1.2.3 Controle local com inversores inteligentes***

Os inversores inteligentes possuem um papel fundamental no desenvolvimento de novas estratégias de VVC em redes de distribuição ativas. Sua capacidade de injetar ou absorver potência reativa de forma contínua os torna uma solução eficiente para sistemas de controle dinâmico, permitindo ajustes mais flexíveis, precisos e rápidos nos níveis de tensão do sistema.

Em Mirafzal; Adib, (2020) , é apresentado um estudo em profundidade sobre as funções dos SIs na rede elétrica, onde também são definidos como, inversores com a capacidade de tomar decisões proativas e autônomas com base em medições locais e dados externos. Com base nessa definição, são atribuídas algumas características presentes nesses dispositivos, como, por exemplo, a capacidade de autocontrole e de serem auto adaptabilidade, o que lhes permite operar sob diferentes modos de controle sem a necessidade de um sistema de comunicação e gerenciamento intrusivo. Isso porque esses dispositivos são capazes de tomar decisões por conta própria, dentro de parâmetros previamente estabelecidos, além de adaptar-se de forma flexível a diferentes condições de rede ou de demanda, graças aos ajustes dinâmicos que são capazes de realizar.

No entanto, apesar da flexibilidade que os SIs possuem para realizar suas operações, eles não podem ser integrados à rede sem um estudo ou consentimento prévio, pois podem ocasionar determinados desequilíbrios na rede, dependendo das condições operacionais. Por exemplo, no caso de inversores do tipo PV, que são capazes de injetar tanto potência ativa quanto reativa, estes devem reduzir automaticamente sua potência ativa conforme o limite de corrente de pico, tal e como é mencionado em Mirafzal; Adib, (2020).

Um dos esforços para gerenciar a interconexão dos SIs ao sistema de distribuição foi a criação da norma IEEE 1547, um modelo internacional que incorpora uma série de regulamentos com o objetivo de garantir o sucesso contínuo no estabelecimento de acordos, regras e padrões de interconexão adicionais em nível nacional, regional e estadual.

Nesse documento é estabelecido os requisitos para conexão, testes, manutenção, comissionamento, isolamento, limites, respostas em condições normais e de falha, operações e condições de segurança. Aprovado em 2003, com reafirmação posterior em 2008, o padrão busca estabelecer uma série de regulamentos para a adequada integração na rede de DGs e dos SIs que os controlam, sem comprometer a integridade ou a qualidade do fornecimento elétrico.

Passando para o comportamento dos SIs, este é definido por meio da chamada curva VVC, que estabelece a relação entre a tensão medida e a potência reativa injetada ou absorvida. Essa abordagem demonstrou alta eficácia em redes de distribuição com elevada penetração de GD renovável, pois permite mitigar as flutuações de tensão e melhorar a estabilidade operacional, sem as limitações de comutação ou o desgaste mecânico característico dos dispositivos convencionais (Jaramillo-Leon *et al.*, 2022).

Diversos estudos têm abordado as diferentes vantagens que esses dispositivos oferecem aos VVCs. Por exemplo, em Smith *et al.*, (2011), são exploradas diferentes estratégias de gestão da potência reativa injetada pelos SI. São realizadas análises detalhadas e de diferentes enfoques, como o uso das curvas características Volt-Var e o controle por fator de potência fixo. Este último funciona com um fator de potência unitário constante, com uma injeção limitada ou nula de potência reativa na rede, embora também podem ser considerados com um fator de potência ligeiramente adiantado (absorvente). A proposta também revisa os diferentes modos de operação dos SI, como o modo de conservação de energia normal e o modo de suporte de potência reativa máxima.

Uma abordagem interessante é a descrita em Babu; Khatod, (2024) na qual os inversores são classificados em dois grupos: um focado em mitigar as violações de tensão e o outro na minimização da carga de potência reativa na subestação, melhorando o fator de potência, já que os inversores empregados podem operar em modo indutivo ou capacitivo. Para cumprir esses objetivos, é utilizado um modelo de análise de sensibilidade analítica (VSA).

Em Jaramillo-Leon *et al.*, (2022), são avaliadas estratégias de controle implementadas em inversores inteligentes para regular a saída de tensão de um transformador real. A proposta está focada em manter a tensão do alimentador dentro dos intervalos aceitáveis estabelecidos pelos padrões ANSI C84.1-2016, minimizando os desvios de tensão e maximizando a integração da geração fotovoltaica sem comprometer a qualidade da energia. O inversor é modelado utilizando um fator de potência fixo e desenvolvendo estratégias de controle Volt-Var e Volt-Watt. Entre as restrições

consideradas estão os limites operacionais de tensão, as capacidades dos inversores e as características da rede, evidenciando nos resultados a eficiência e o desempenho dos VVCs na melhoria da estabilidade da rede.

De forma semelhante, em Farivar *et al.*, (2013) é estabelecido um controle local onde as decisões do inversor são regidas unicamente pelo nível de tensão local, utilizando um modelo de rede baseado nas equações de FPO para sistemas de distribuição e uma função de Lyapunov. O modelo tem como objetivo a minimização das variações de tensão e a redução dos custos associados a essas variações.

Em Malekpour *et al.*, (2014), é proposto um algoritmo de controle em tempo real baseado na decomposição por zonas no sistema de distribuição, permitindo que os SIs operem de forma independente, reduzindo os tempos de execução dos dispositivos. Propõe-se uma transformação nas estratégias de controle, evoluindo de abordagens passivas para sistemas de gestão ativos e dinâmicos.

#### **1.2.4 Controle híbrido em redes de distribuição**

O uso de inversores inteligentes nas estratégias de VVC é comumente combinado com dispositivos convencionais, como OLTC, ULTC, AVR e BC. As estratégias de controle coordenado têm sido amplamente exploradas devido à versatilidade e robustez dos algoritmos e técnicas utilizadas. Essas estratégias permitem integrar o ajuste discreto proporcionado pelos sistemas convencionais com um ajuste mais contínuo e flexível, graças à capacidade de resposta dinâmica oferecida pelos SIs.

Diferentes estudos propuseram diversas estratégias para o controle coordenado dos SIs e dispositivos convencionais. Por exemplo, em Xu *et al.*, (2017), é apresentado um VVC coordenado em múltiplas escalas de tempo, baseado em um modelo de programação estocástica. Esse modelo opera em duas escalas temporais, seguindo uma abordagem semelhante à decomposição apresentada em Mokgonyana *et al.*, (2016).

Na primeira etapa, é definida a configuração ótima dos dispositivos OLTC e BC, considerando seu tempo de resposta relativamente lento e o desgaste mecânico associado à sua operação. Devido a essas características, essa etapa opera em uma escala de tempo mais longa, com atualizações a cada hora.

Por outro lado, a segunda etapa se concentra na coordenação dos SI disponíveis na rede, ajustando a injeção de potência reativa em resposta às rápidas flutuações de tensão causadas pela incerteza na produção renovável e pela variabilidade da demanda. Como os SIs possuem uma capacidade de resposta muito mais rápida, essa etapa opera em uma escala de tempo mais curta, com ajustes a cada 15 minutos.

Seguindo essa mesma linha, em Pamshetti; Singh, (2019) é proposta uma estratégia robusta de controle de tensão em três etapas (TRI-VVC) para redes de distribuição com geração fotovoltaica. A primeira etapa otimiza os dispositivos lentos, como BC e OLTC, em um horizonte de tempo longo, minimizando as perdas de energia e ao mesmo tempo mantendo uma tensão estável. A segunda etapa atua em janelas de 15 minutos, ajustando os SIs para compensar as variações rápidas na geração fotovoltaica e na demanda. A terceira etapa emprega um controle de queda local para responder em tempo real a flutuações súbitas de tensão. Esse esquema utiliza um modelo de otimização robusta (OR) para garantir decisões ótimas mesmo diante de incertezas.

Uma abordagem interessante é apresentada em Zhang *et al.*, (2019), onde se propõe um algoritmo de controle multiobjetivo para a gestão coordenada de BC, OLTC e SI. A proposta combina o método de restrições ( $\epsilon$ -Constraint Method) para gerar soluções não dominadas e um método de tomada de decisão difusa para selecionar a configuração ótima. Este último avalia cada solução com base em objetivos como a redução dos custos operacionais e a manutenção da tensão dentro dos limites, alcançando um equilíbrio eficiente entre estabilidade e desempenho energético.

### **1.2.5 Técnicas de Aprendizagem de Máquina (Machine Learning)**

Com o crescente interesse no desenvolvimento de sistemas de controle que utilizem técnicas baseadas em inteligência artificial, abrem-se novos caminhos e oportunidades para a operação ótima em redes de distribuição por meio das estratégias de controle de tensão e potência reativa.

Não é surpresa que os sistemas de distribuição estejam em constante crescimento e transformação devido à integração de novas tecnologias, como dispositivos de geração de energia renovável ou sistemas de armazenamento de energia. Esse processo decorre tanto da demanda cada vez maior quanto das necessidades ambientais atuais.

As técnicas baseadas em inteligência artificial propõem um sistema de controle voltado para a identificação de padrões e a previsibilidade da demanda, possibilitando a execução de ações que se antecipem a situações específicas de consumo. Isso é alcançado por meio de processos de treinamento fundamentados em sistemas de aprendizagem de máquina (ML), realizados de forma automática a partir de dados fornecidos que também são conhecidos como dados brutos ou conjuntos de dados para um sistema computacional ou máquina. Esse processo é baseado em duas etapas principais: um modelo de treinamento e um modelo de teste para a tomada de decisões (Pandey *et al.*, 2019).

Durante o modelo de treinamento são introduzidas grandes quantidades de dados, nesse processo são relacionadas diferentes entradas com determinadas saídas preparando o sistema para a identificação de padrões e tomada de decisões, realizando ajustes nos parâmetros do sistema em função da resposta diante dos diferentes cenários ou situações. Para esse processo são utilizados dados de treinamento, os quais são previamente processados extraindo características fundamentais evitando saturar ao sistema com dados irrelevantes. Uma vez concluída esta etapa os dados de treinamento são substituídos pelos dados de teste, os quais são desconhecidos para o sistema, é avaliado o rendimento do modelo e verificada a capacidade de oferecer previsões confiáveis em situações novas (Pandey *et al.*, 2019).

Para realizar os modelos de ML são utilizadas as redes neurais, essas redes permitem modelar, relacionar e identificar as características dos dados de entrada em relação aos dados de saída. Esse comportamento é semelhante ao funcionamento do cérebro humano, no qual as informações de entrada são identificadas por meio dos sentidos e processadas no cérebro para a posterior execução de uma resposta, que pode ser instintiva ou cognitiva.

As redes neurais são constituídas por diversas camadas, as quais, são formadas por um grande número de neurônios interconectados, tanto dentro da própria camada como na camada seguinte. Essas camadas podem ser divididas em três tipos: a camada de entrada, que é responsável de receber os dados iniciais e passá-los à camada seguinte aqui não são realizados cálculos complexos, pois sua função se limita a receber e transmitir os parâmetros de entrada. A camada de saída está localizada no final da rede e contém a resposta do modelo em relação aos dados de entrada (Quiñones Huatangari *et al.*, 2020).

As camadas ocultas, ou de processamento, localizadas entre as camadas de entrada e saída, são responsáveis por processar e transformar as informações recebidas nas camadas de entrada. Isso é realizado por meio dos pesos, que são valores numéricos que

determinam a força e a importância da conexão entre um neurônio de uma camada e um neurônio da camada seguinte. O processamento dos dados é feito multiplicando uma entrada pelo seu peso, somando o produto e processando a soma com o uso de uma função de transferência não linear para gerar um resultado, ou seja, uma saída (Quiñones Huatangari *et al.*, 2020).

Uma vez definidos os conceitos de redes neurais e os processos de treinamento, cabe fazer a seguinte pergunta: como são relacionados com os controles de tensão e reativo? Na literatura, essas técnicas costumam ser encontradas como mecanismos para otimizar e acelerar algoritmos convencionais. Por exemplo, muitas das propostas utilizam técnicas de otimização matemática para treinar um modelo de rede neural. Uma vez concluída a etapa de treinamento, a rede substitui o algoritmo de otimização na gestão da estratégia de VVC. Essas técnicas também são úteis para realizar previsões sobre o comportamento da demanda, identificar padrões e tomar ações preventivas. A seguir, são revisados alguns trabalhos que empregam esses modelos em aplicações de VVC.

Para começar, apresenta-se em Tomin *et al.*, (2019) um algoritmo VVC híbrido baseado em técnicas de ML. A proposta tem a particularidade de utilizar uma estratégia de aprendizagem profundo centralizado (DeepCS) para realizar o modelo de treinamento aplicando um controle de segurança preventivo, enquanto o modelo de teste é executado de forma distribuída para o controle de múltiplos agentes (MACS). O processo de treinamento foi realizado utilizando duas redes neurais por meio de técnicas de aprendizagem de longo prazo. O treinamento está focado na gestão da injeção de potência reativa e na coordenação de recursos energéticos distribuídos, tomando como entradas os níveis de tensão globais no sistema de distribuição e, como saídas, a injeção de potência. Finalmente, a execução do modelo é realizada com agentes autônomos distribuídos que coordenam a comutação dos dispositivos, alcançando assim um controle cooperativo orientado à convergência global do sistema.

Seguindo nessa linha, é proposto em Gao *et al.*, (2021) um algoritmo de gestão para múltiplos agentes focados no controle de BC, OLTC e reguladores de tensão. Os agentes são treinados utilizando dados históricos sob dois objetivos principais: a otimização global do sistema e a otimização local por parte de cada agente. Esses objetivos são alcançados por meio de sistemas de aprendizagem por reforço, nos quais são recompensadas atividades como a redução da diferença de parâmetros entre as funções de valor de seus vizinhos e as próprias.

As propostas mencionadas (Tomin *et al.*, 2019) e (Gao *et al.*, 2021), realizam o treinamento utilizando técnicas de Big Data, já que estas oferecem um maior número de dados e cenários reais, o que permite aprender padrões mais gerais e aderentes ao caso de estudo, além de atualizar constantemente os modelos com novas entradas. No entanto, as técnicas de Big Data apresentam a limitação de que é necessário obter essa base de dados e que ela forneça as características necessárias para o treinamento ótimo do sistema o que pode ser um problema para os diferentes pesquisadores que desejam desenvolver novas técnicas baseadas em ML, já que obter esses dados e garantir que sejam atuais representa um obstáculo considerável (Yindong; Zhongqin, 2014).

Ao carecer de uma base de dados sólida, muitos autores optam por utilizar algoritmos já existentes para realizar o treinamento da rede neural, como é apresentado em (LI; XU, 2024), onde foi empregado um algoritmo de direção alternada de multiplicadores (ADMM) distribuído, que permite o intercâmbio de informações entre áreas adjacentes. Os autores mencionam que uma das limitações do ADMM reside na quantidade de iterações necessárias para a convergência e em como isso afeta os tempos de execução e a qualidade da rede de comunicação entre dispositivos. No entanto, em vez de reduzir o número de iterações, o que poderia comprometer a qualidade das soluções, os autores optaram por empregar um sistema de aprendizagem de memória de longo prazo (LSTM) para aprender e acelerar o processo de convergência dinâmica por meio da melhoria dos parâmetros, sem substituir o ADMM nas tarefas de gestão da rede elétrica.

### **1.3 Estratégia Proposta e Estrutura do Texto**

A estratégia proposta baseia-se no desenvolvimento de um sistema de controle de tensão e potência híbrido, implementando duas abordagens de controle: a primeira sendo um algoritmo genético centralizado para realizar ajustes em dispositivos mecânicos OLTC, BC e GD. A segunda abordagem é baseada em um controle local para um inversor inteligente, a fim de determinar a quantidade de potência injetada na rede.

A estratégia é apresentada em três etapas: a primeira focada na determinação de parâmetros para o AG, que incluem o tamanho da população e o número de gerações a partir de vários testes. A segunda etapa implementa o AG já com os parâmetros estabelecidos para determinar os ajustes dos dispositivos e executar a estratégia Volt-Var

centralizada, com foco na redução de perdas e na minimização dos desvios de tensão. A terceira etapa complementa a abordagem centralizada por meio do inversor, realizando ajustes na forma de injeção de potência reativa.

As três etapas são executadas em um modelo de rede de distribuição utilizando um fluxo de potência sequencial e três condições de carga (baixa, média e alta), comparando ambas as abordagens. Finalmente, o fluxo sequencial é complementado utilizando um modelo probabilístico de potência constante, para simular condições horárias em um intervalo de uma semana, além de comparar a estratégia com uma abordagem de controle baseada em técnicas de machine learning.

Com relação ao texto, a primeira seção foca em realizar uma breve introdução, apresentar os objetivos do trabalho e realizar uma revisão bibliográfica, mostrando as diferentes estratégias que foram consideradas para o desenvolvimento deste trabalho.

A segunda seção mostra as equações e a lógica de controle utilizada para o desenvolvimento do fluxo de potência sequencial e do probabilístico implementados em um modelo de distribuição elétrica.

A terceira seção apresenta as equações e operadores implementados no desenvolvimento do AG, além de mostrar a metodologia utilizada nos processos iterativos, incluindo função objetivo e restrições.

A quarta seção apresenta o sistema de controle local, o inversor, e como estes opera em conjunto com o controle centralizado. A quinta seção mostra os resultados alcançados nas diferentes simulações realizadas, avaliando o desempenho do algoritmo sob diferentes condições de demanda. A sexta seção apresenta as conclusões e considerações finais.

## 2 FLUXO DE POTÊNCIA SEQUENCIAL E PROBABILÍSTICO PARA REDES DE DISTRIBUIÇÃO INTELIGENTES

As redes de distribuição elétrica são compostas por um conjunto de barras e linhas interconectadas, além dos diversos dispositivos de proteção, medição e regulação integrados à rede elétrica. O principal objetivo desses sistemas é distribuir o fornecimento elétrico proveniente de um ou vários alimentadores principais para os diferentes usuários conectados a esse sistema.

Devido à natureza interconectada das redes de distribuição, na qual o estado de uma barra influencia diretamente o estado das barras adjacentes, é necessário aplicar técnicas e metodologias específicas para traduzir esse comportamento em uma linguagem computacional. Essas redes são comumente modeladas como um grafo, onde os nós representam as barras elétricas e as arestas simbolizam as linhas de transmissão ou transformadores que conectam essas barras (Souza *et al.*, 2024).

A análise do fluxo de potência em um sistema de distribuição desbalanceado requer a consideração de que cada barra possui tensões e correntes específicas para cada fase  $p \in \Omega_p = \{a, b, c\}$ , além da injeção ou consumo de potência ativa e reativa. Essas variáveis devem cumprir com as restrições de equilíbrio de potência em cada barra, garantindo que as demandas de energia sejam corretamente atendidas e que as tensões se mantenham dentro dos limites operacionais estabelecidos.

Existem diversas formas de abordar os problemas de fluxo de potência em sistemas de distribuição. Em Souza *et al.*, (2024), são analisados métodos como o de varredura direta e reversa, os métodos baseados em matrizes de impedância e os métodos recursivos, cada um com características específicas de funcionamento e operação. O desempenho desses métodos depende tanto das dimensões e da topologia da rede quanto dos requisitos computacionais que cada abordagem exige.

Na literatura, os métodos matriciais, como Gauss-Seidel e Newton-Raphson, têm sido amplamente estudados e aplicados devido à sua alta confiabilidade em sistemas desbalanceados. No entanto, apresentam a desvantagem de possuir tempos de processamento consideravelmente lentos, especialmente em sistemas radiais de grande escala, pois requerem cálculos intensivos relacionados à matriz de impedância no caso de Gauss-Seidel e à matriz Jacobiana no método de Newton-Raphson.

Por outro lado, os métodos recursivos oferecem uma alternativa eficiente, alcançando tempos de processamento mais curtos graças ao uso da busca em profundidade, que percorre toda a rede atualizando tensões e correntes de forma recursiva. Esses métodos permitem a paralelização de tarefas, reduzindo ainda mais o tempo de convergência. No entanto, apresentam desvantagens, como maior complexidade de implementação, carga computacional elevada e o risco de saturação nos processos paralelos.

No entanto, também se destacam os métodos de varredura reversa e direta, amplamente utilizados na literatura devido à sua rápida convergência e à baixa complexidade computacional que requerem. Neste trabalho, esses métodos são implementados como base fundamental para o desenvolvimento e teste dos AGs e do controle local dos SIs no gerenciamento do VVC.

## 2.1 Método sequencial de varredura e soma de potências


Os métodos sequenciais baseiam seu funcionamento na resolução iterativa do fluxo de potência por meio de varreduras que percorrem a rede para trás e para frente. Essas varreduras são executadas de forma sequencial utilizando a lista de adjacência, a qual depende explicitamente da topologia da rede e define a ordem em que são calculadas as magnitudes de tensão e corrente do sistema (Souza *et al.*, 2024).

O funcionamento das varreduras consiste em duas fases: a varredura para trás e a varredura para frente. Na varredura para trás, a rede é percorrida desde o último nó até a subestação, ou o nó raiz, e ao longo do caminho são calculadas as correntes em cada ramo com base nas potências ativa e reativa consumidas pelas cargas conectadas a cada nó. Por outro lado, a varredura para frente começa a partir da subestação e avança até os últimos nós da rede, atualizando as tensões nodais considerando as quedas de tensão nas linhas. As tensões nos nós começam com um valor unitário em pu, mas são atualizadas durante a varredura para frente.

Para começar a análise e entender como funciona o método de varredura para frente, considera-se a Figura 1. Se tomada a barra  $i - 1$ , que está a montante da barra  $i$ , então a magnitude da tensão  $V_{i-1}$  pode ser expressa em termos de  $V_i$  considerando a queda de tensão ao longo da linha com impedância  $\bar{Z}_l$ , a qual é dada por (1).

$$V_{i-1} = V_i + \bar{Z}_l \cdot I_l, \quad \forall i \in \Omega_b \text{ e } \forall l \in \Omega_l \quad (1)$$

**Figura 1.** Segmento de Rede de Distribuição Radial



Fonte: Adaptado de (Souza *et al.*, 2024)

Os métodos sequenciais baseiam seu funcionamento na resolução iterativa do fluxo de potência por meio de varreduras que percorrem a rede para trás e para frente. Essas varreduras são executadas de forma sequencial utilizando a lista de adjacência, a qual depende explicitamente da topologia da rede e define a ordem em que são calculadas as magnitudes de tensão e corrente do sistema (Souza *et al.*, 2024). Onde  $I_l$  é a corrente que flui pela linha entre as barras  $i - 1$  e  $i$ .

A partir dessa configuração, a análise se desenvolve por meio da formulação de equações de balanço de potência, (2) – (5), que consideram as potências ativa e reativa em cada nó, a injeção ou consumo de potência  $\bar{S}_{i,p}$  e as perdas nas linhas.

$$\bar{S}_{i,p} = P_{i,p} + jQ_{i,p} \quad (2)$$

$$\bar{Z}_l = \{R_{l,pq} + j X_{l,pq} | p = 0, 1 \text{ e } 2 \wedge q = 0, 1 \text{ e } 2\} \quad (3)$$

$$\bar{S}_{l+1,p}^{EQ} = P_{l,p}^{EQ} + jQ_{l,p}^{EQ} \quad (4)$$

$$\bar{S}_{l+1,p}^L = P_{l,p}^L + jQ_{l,p}^L \quad (5)$$

$$Z_l^2 = R_l^2 + X_l^2 \quad (6)$$

Em que (2) representa a potência de carga na  $i$ -ésima barra e fase  $p$ . A equação (3) é a matriz de impedância do  $i$ -ésimo segmento, ou linha entre as barras  $i - 1$  e  $i$ . A equação (4) é a potência equivalente que flui entre as barras  $i - 1$  e  $i$ . Por sua vez, (5)

representa as perdas na linha entre as barras  $i - 1$  e  $i$ . Finalmente, (6) expressa o módulo, ou a magnitude ao quadrado da impedância da linha.

Para o desenvolvimento ótimo de problemas de fluxo de potência que utilizam métodos de varredura, é possível aplicar o método de soma de potência. Nesse método, para cada seção do circuito, resolve-se uma equação bi-quadrática em termos da magnitude da tensão nodal, conforme detalhado em Blanco *et al.*, (2024).

$$V_{i,p}^4 + A_{i,p}V_{i,p}^2 + B_{i,p} = 0, p = 0, 1 \text{ e } 2 \quad (7)$$

Esta equação (7), representa a formulação bi-quadrática que determina a magnitude da tensão no nó  $i$  e na fase  $p$ . Sendo esta a base para o cálculo das tensões nodais durante a varredura para frente. Os termos  $A_{i,p}$  e  $B_{i,p}$  são:

$$A_{i,p} = 2 \left( \sum_{q=0}^2 (P_{lp}^{EQ} R_{l,pq} + Q_{lp}^{EQ} X_{l,pq}) \delta_{pq} \right) - V_{i-1,p}^2 \quad (8)$$

$$B_{i,p} = \sum_{q=0}^2 \left( (P_{lp}^{EQ})^2 + (Q_{lp}^{EQ})^2 \right) Z_{l,pq} \quad (9)$$

A equação (8) representam a relação entre a potência equivalente (tanto ativa quanto reativa) que flui através da linha e os valores de sua impedância. Também considera a tensão ao quadrado na barra à jusante  $V_{i-1,p}^2$ . Por sua vez, (9) representa a combinação das potências equivalentes ao quadrado ponderadas pelos elementos da matriz de impedância.

O termo  $Z_{l,pq}$ , em (8), representa a expansão das linhas de distribuição por meio dos elementos da matriz de impedância, calculados considerando tanto a autoimpedância quanto a impedância mútua entre fases. Isso é refletido em (10) e sua consistência com (6).

$$Z_{l,pq} = \sum_{t=0}^2 (R_{l,pt}R_{l,tp} + X_{l,pt}X_{l,tq}) \quad (10)$$

As equações (11) e (12) representam as potências ativas e reativas que fluem através  $l$ -ésima linha, respectivamente, enquanto as equações (13) e (14) representam as perdas de potência ativa e reativa  $l$ -ésima linha da rede.

$$P_{l,p}^{EQ} = P_{i,p} + \sum_{j=1}^{ni} (P_{l,p}^{EQ} + P_{l,p}^L) \quad (11)$$

$$Q_{l,p}^{EQ} = Q_{i,p} + \sum_{j=1}^{ni} (Q_{l,p}^{EQ} + Q_{l,p}^L) \quad (12)$$

$$P_{l,p}^L = \sum_{q=0}^2 \frac{R_{l,pq} \left( (P_{l,p}^{EQ})^2 + (Q_{l,p}^{EQ})^2 \right) \delta_{pq}}{V_{i,p}^2} \quad (13)$$

$$Q_{l,p}^L = \sum_{q=0}^2 \frac{X_{l,pq} \left( (P_{l,p}^{EQ})^2 + (Q_{l,p}^{EQ})^2 \right) \delta_{pq}}{V_{i,p}^2} \quad (14)$$

$$\delta_{pq} = \cos\left(\frac{(p-q)2\pi}{3}\right) \quad (15)$$

A equação (15) é o termo utilizado para projetar o fluxo de potência entre diferentes fases, considerando o acoplamento magnético entre elas.

## 2.2 Modelagem de dispositivos em paralelo

Como é mencionado na seção 2.1, uma rede de distribuição, de forma geral, é um sistema de barras interconectadas por meio de linhas. Esses sistemas incorporam uma grande variedade de dispositivos, que são integrados ao sistema de duas formas: em derivação (paralelo) e em série.

Geralmente, os dispositivos em derivação estão associados às barras, devido à relação direta que existe entre as variáveis elétricas das barras, como a tensão ( $V$ ) e a potência aparente ( $S$ ), e o efeito que esses dispositivos exercem sobre essas variáveis ao injetar potência, no caso dos capacitores e geradores, ou ao consumi-la, como ocorre com as cargas conectadas.

A seguir, é realizada uma análise de como esses dispositivos são modelados e integrados ao sistema de distribuição.

### 2.2.1 Banco de capacitores

Um capacitor, de forma simples, pode ser descrito como um dispositivo de armazenamento de energia dentro de um campo elétrico, constituído por dois condutores elétricos carregados de forma oposta e separados por materiais dielétricos.

Geralmente, esses dispositivos são interconectados entre si em função do kVar requerido, formando o que é conhecido como banco de capacitores. Essa configuração permite ajustar de forma flexível a injeção de potência reativa no sistema e é utilizada em redes de baixa, média e alta tensão para melhorar o fator de potência, estabilizar a tensão e reduzir as perdas elétricas.

Os bancos de capacitores nos sistemas de distribuição têm a função de fornecer potência reativa para compensar o efeito das cargas indutivas geradas por dispositivos como motores, fornos a arco e sistemas de iluminação. Além disso, os capacitores são fundamentais no desenvolvimento de estratégias de controle de tensão e reativo, devido à sua capacidade de injetar potência no sistema e elevar os níveis de tensão quando conectados à rede.

**Figura 2.** Bancos de Capacitores em Subestação de Distribuição



Fonte: Tomado de (EATON POWERING BUSINESS WORLDWIDE, [s. d.]

Para modelar matematicamente o comportamento do banco de capacitores e seu impacto no fluxo de potência, em Blanco *et al.*, (2024) é estabelecida a seguinte formulação.

$$Q_{l,p}^{EQ} = (Q_{i,p} - Q_{i,p}^{CAP}) + \sum_{j=1}^{n_i} (Q_{j,p}^{EQ} + Q_{j,p}^L) \quad (16)$$

em que  $Q_{lp}^{CAP}$  representa a injeção de potência reativa no sistema, modificando o valor da potência  $Q_{l,p}^{EQ}$  na  $l$ -ésima linha. Essa abordagem permite realizar o controle sobre a injeção de reativo dos capacitores ao gerenciar de forma discreta a comutação das etapas dos capacitores.k

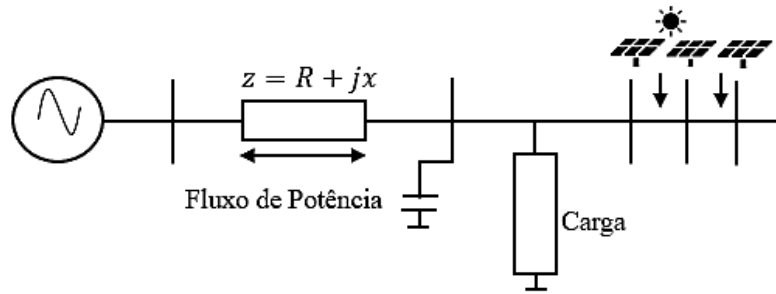
### 2.2.2 Gerador distribuído

Não existe um consenso geral e amplamente aceito sobre a definição de GD, pois diferentes autores apresentam perspectivas variadas sobre o que esses dispositivos representam. Por exemplo, em muitos casos, considera-se como geração em pequena escala, próxima aos pontos de consumo e associada exclusivamente a fontes renováveis. No entanto, outras definições incluem tanto sistemas renováveis quanto não renováveis, e até mesmo geração em grande escala, desde que estejam localizados próximos à carga (Mehigan *et al.*, 2018).

A integração de GD nas redes de distribuição tem experimentado um crescimento considerável, destacando-se a energia fotovoltaica como a opção com maior aceitação pelo público. Apenas entre 2022 e 2023, foi registrado um aumento de 80% na potência fotovoltaica distribuída em nível global, alcançando uma capacidade instalada de 1,6 TW. Os países que lideraram essa expansão foram a China, os Estados Unidos e a União Europeia (IEA, 2023).

Esse crescimento acelerado é resultado de diversos fatores, como uma maior conscientização ambiental por parte da população, a redução dos custos da energia solar e uma crescente demanda por energia. Isso tornou a incorporação desses sistemas uma alternativa viável frente à dependência total da geração convencional centralizada.

**Figura 3.** Segmento de Rede de com Geração Distribuída



Fonte: Adaptado de (Souza *et al.*, 2024)

A integração desses dispositivos ao modelo de rede pode ser feita de duas formas: a primeira é modelando o gerador como uma barra do tipo *PV*; e a segunda, como uma barra do tipo *PQ*. Para a presente análise, é utilizada a modelagem do tipo *PQ* Blanco *et al.*, 2024).

$$P_{l,p}^{EQ} = (P_{i,p} - P_{i,p}^{DG}) + \sum_{j=1}^{n_i} (P_{j,p}^{EQ} + P_{j,p}^L) \quad (17)$$

$$Q_{l,p}^{EQ} = (Q_{i,p} - Q_{i,p}^{DG}) + \sum_{j=1}^{n_i} (Q_{j,p}^{EQ} + Q_{j,p}^L) \quad (18)$$

A diferença chave entre a modelagem do tipo *PQ* e *PV* está nas variáveis elétricas que são controladas ou fixadas, e nas variáveis que são calculadas durante a análise de fluxo de potência.

Na modelagem do tipo *PQ*, considera-se uma capacidade fixa de injeção de potência ativa e reativa, ou seja, seu comportamento é semelhante ao de uma carga inversa, onde injeta energia em vez de consumi-la. Por outro lado, a modelagem do tipo *PV* requer uma compensação técnica de controle de tensão, ajustando a injeção de potência reativa de forma dinâmica com base em uma magnitude fixa de tensão. Esse tipo de controle é comum em motores síncronos (Moghaddas-Tafreshi; Mashhour, 2009).

### 2.2.3 *Inversor inteligente*

Originalmente, os inversores limitavam suas funções apenas à conversão de corrente contínua (CC) para corrente alternada (CA). No entanto, com os avanços no desenvolvimento de novas tecnologias, suas capacidades aumentaram, dotando-os de funções avançadas de compensação de energia e permitindo sua participação na regulação da tensão no ponto de acoplamento comum. Isso foi possível graças à atualização do padrão IEEE 1547-2018, que estabelece diretrizes específicas para a injeção e absorção de potência reativa por meio do VVC (Jaramillo-Leon *et al.*, 2023).

A incorporação do inversor no modelo matemático pode ser realizada de maneira semelhante à proposta em (18), controlando a quantidade de potência reativa que ele pode injetar. A equação (17) não é considerada, uma vez que o inversor analisado neste caso está projetado apenas para a injeção de potência reativa, sem participação na potência ativa. Para o controle de injeção ou absorção de reativo, é utilizada a curva Volt-Var como em Jaramillo-Leon *et al.*, (2023).

## 2.3 **Modelagem de Dispositivos em Série**

Da mesma forma que os elementos em derivação estão associados às barras, os dispositivos em série estão vinculados às linhas de distribuição, pois afetam diretamente a corrente elétrica  $I_l$  que circula por elas, modificando sua magnitude conforme sua função específica. Um exemplo claro disso são os transformadores, cuja função principal é ajustar os níveis de tensão e corrente para assegurar a transferência de energia. A corrente que entra pelo enrolamento primário não é igual, em magnitude, à que sai pelo enrolamento secundário, devido à relação de transformação existente entre ambos e às correntes de magnetização presentes no núcleo dos transformadores.

Assim como na seção 2.2, é realizada uma análise de como esses dispositivos são modelados e integrados ao sistema de rede.

### 2.3.1 *OLTC*

Os transformadores são máquinas elétricas estáticas, cuja principal função é transformar um nível de tensão em outro, dependendo da relação de espiras entre seus

enrolamentos primário e secundário. Esses dispositivos incorporam um elemento chamado *tap*, que permite ajustar a tensão de saída do enrolamento secundário. Para os transformadores de distribuição padrão, essa alteração geralmente é feita fora de linha e em incrementos de  $\pm 2,5\%$  por cada *tap*, com um intervalo máximo típico de  $\pm 5\%$  para pequenos ajustes de tensão.

Para aplicações mais avançadas, os transformadores de potência incorporam um componente denominado OLTC, um mecanismo de comutação que permite ajustar o *tap* do transformador enquanto este está em operação, sem a necessidade de desconectá-lo da rede ou desconectar a carga. O maior intervalo de ajuste proporciona, assim, maior precisão na regulação da tensão e, devido à sua capacidade de operar em linha, é um dispositivo fundamental nas tarefas de regulação de tensão.

A incorporação matemática dos OLTC no modelo de rede é realizada por meio de uma forma matricial  $[M_l]_{6 \times 6}$ . Essa matriz contém informações sobre a relação de transformação e a impedância da linha.

$$[M_l]_{6 \times 6} = \begin{bmatrix} [\mathcal{A}_l]_{3 \times 3} & [\mathcal{B}_l]_{3 \times 3} \\ [\mathcal{C}_l]_{3 \times 3} & [\mathcal{D}_l]_{3 \times 3} \end{bmatrix} = \begin{bmatrix} K_n^{-1}[\phi_l]_{3 \times 3} & [Y_{m_l}]_{3 \times 3} \\ -[Z_{D_l}]_{3 \times 3} & K_n^{-1}[\phi_l]_{3 \times 3} \end{bmatrix} \quad (19)$$

A equação (19) representa como o transformador afeta as tensões e correntes entre seus terminais. Onde  $K_n$  representa a relação de transformação entre os enrolamentos,  $[\phi_l]$  o desfasamento do ângulo, enquanto  $[Y_{m_l}]$  e  $[Z_{D_l}]$  são as matrizes de admitância de magnetização e de impedância, respectivamente (Leite; Mantovani, 2015).

A equação (19) pode ser simplificada se considerarmos um transformador ideal com relação de transformação estrela-estrela (Y-Y). Nesse caso, as matrizes de impedância e admitância interna são consideradas nulas, e o desfasamento entre os enrolamentos é representado pela matriz identidade  $[I]_{3 \times 3}$ . Isso implica que não há perdas internas nem mudanças no ângulo de fase entre as fases do transformador, permitindo uma representação simplificada do mesmo.

$$[M_l]_{6 \times 6} = \begin{bmatrix} [\mathcal{A}_l]_{3 \times 3} & [\mathcal{B}_l]_{3 \times 3} \\ [\mathcal{C}_l]_{3 \times 3} & [\mathcal{D}_l]_{3 \times 3} \end{bmatrix} = \begin{bmatrix} K_n^{-1}[I]_{3 \times 3} & [0]_{3 \times 3} \\ -[0]_{3 \times 3} & K_n^{-1}[I]_{3 \times 3} \end{bmatrix} \quad (20)$$

Nas Tabelas 1 e 2, são apresentadas as diferentes configurações de admitância, impedância e desfasamento em função do tipo de relação de transformação.

**Tabela 1.** Matriz de deslocamento de fase para vários tipos de conexão

Conxão	$\varphi_{11}$	$\varphi_{12}$	$\varphi_{13}$	$\varphi_{21}$	$\varphi_{22}$	$\varphi_{23}$	$\varphi_{31}$	$\varphi_{32}$	$\varphi_{33}$
<b>Yg-Yg</b>	1	0	0	0	1	0	0	0	1
<b>Yg-<math>\Delta</math></b>	1	0	-1	-1	1	0	0	-1	1
<b><math>\Delta</math>-Yg</b>	1	-1	0	0	1	-1	-1	0	1
<b><math>\Delta</math>-<math>\Delta</math></b>	1	0	0	0	1	0	0	0	1

Fonte: Adaptado de Buck, (2023)

**Tabela 2.** Relação de transformação para vários tipos de conexão

Conxão	$K_n$
<b>Yg-Yg</b>	$V_{PL}/V_{SL}$
<b>Yg-<math>\Delta</math></b>	$V_{PL}/\sqrt{3}V_{SL}$
<b><math>\Delta</math>-Yg</b>	$\sqrt{3}V_{PL}/V_{SL}$
<b><math>\Delta</math>-<math>\Delta</math></b>	$V_{PL}/V_{SL}$

Fonte: Adaptado de Buck, (2023)

## 2.4 Fluxo de Potência Probabilístico para Sistemas de Distribuição

As equações do fluxo de carga apresentado na seção anterior representam de forma confiável o comportamento instantâneo da rede elétrica, em que o estado de uma determinada barra afeta as barras adjacentes e, conseqüentemente, os parâmetros de tensão e corrente associados a essas barras e linhas. No entanto, essa abordagem está limitada a uma única condição operativa, fixada em um instante específico do sistema,

sem considerar as variações que a demanda energética pode apresentar ao longo das horas ou dos dias. Em sistemas de distribuição reais, a carga não é estática e varia de acordo com o perfil de consumo dos usuários, apresentando picos de demanda geralmente nas primeiras horas da manhã e ao meio-dia, bem como períodos de baixo consumo durante a noite ou madrugada.

Com base no exposto, esta seção tem como objetivo o desenvolvimento de um modelo de fluxo de potência probabilístico, capaz de simular perfis de carga ao longo do tempo em sistemas de distribuição e que será complementado pelas equações de fluxo de potência apresentadas na seção anterior.

Para simular a variabilidade temporal no comportamento da demanda, é utilizado o subscrito  $t_h$ , o qual representa um instante horário do dia, expresso em horas inteiras dentro do intervalo de 0 a 23. Isso significa que, por exemplo, quando  $t_h = 0$ , o sistema se encontra no horário das 00:00 horas e, à medida que o valor de  $t_h$  aumenta, o período também avança. Assim, para um  $t_h = 1$  corresponde às 01:00 horas, e assim sucessivamente, até completar um ciclo diário de 24 horas, resultando que a carga oscile de forma contínua ao longo do tempo e que, para cada valor de  $t_h$ , seja realizado um novo cálculo do fluxo de potência (Kheirkhah *et al.*, 2023).

Os diferentes cálculos de fluxo de potência realizados em cada instante  $t_h$  são executados utilizando um modelo de potência constante  $S_i^p(t_h)$ , no qual os valores de potência ativa e reativa são escalonados para cada hora por meio da multiplicação da potência base  $S_i^p$  associada à carga por uma função de escalonamento complexa  $E_i^p(t_h)$ , aplicada tal como é mostrado na equação (21) e detalhado em Leite; Mantovani, (2015b).

$$S_i^p(t_h) = S_i^p \cdot E_i^p(t_h) \quad (21)$$

Essa função permite modificar simultaneamente a magnitude e o fator de potência da carga de forma horária. A função  $E_i^p(t_h)$  é chamada de função percentual de consumo de energia e possui natureza não determinística, ao contrário do modelo apresentado na seção anterior, no qual um mesmo conjunto de entradas gera sempre os mesmos resultados, sem qualquer tipo de variação, o que é útil em determinadas situações, como na avaliação do desempenho de uma técnica específica ou na análise sob condições pontuais do sistema. No entanto, quando o objetivo é simular um cenário mais realistas ou estendido no tempo, as abordagens não determinísticas oferecem uma representação mais adequada.

$$E_i^p(t_h) = r_i^p(t_h) \cdot e^{j \cos^{-1}(f_i^p(t_h))} \quad (22)$$

A equação (22) descreve o cálculo da função  $E_i^p(t_h)$  para cada instante de tempo  $(t_h)$ , onde  $r_i^p(t_h)$  representa a magnitude normalizada da potência consumida, ou seja, um coeficiente que permite modificar a potência ativa nominal de cada barra de acordo com a variância do consumo ao longo do dia. Por outro lado,  $f_i^p(t_h)$  é o fator de potência do consumo associado a cada barra.

Os cálculos de  $r_i^p(t_h)$  e  $f_i^p(t_h)$  são realizados a partir de uma função de densidade (24) e da obtenção de dados horários correspondentes à magnitude normalizada  $R(t_h)$  e ao fator de potência  $F(t_h)$  do alimentador principal do sistema. Os dados para  $R(t_h)$  e  $F(t_h)$  foram extraídos de (Kheirkhah *et al.*, 2023), porém adaptados às necessidades específicas deste trabalho, no qual se requerem condições de carga ligeiramente mais exigentes do que as do estudo original.

Essa adaptação foi realizada por meio de técnicas de normalização min-max, as quais constituem um processo de ajuste dos valores medidos em diferentes escalas para uma mesma escala, de modo que todos os atributos sejam paralelos entre si (Pandey; Jain, 2017)

$$X^* = \left( \frac{X - \min(X)}{\max(X) - \min(X)} \right) (newmax - newmin) + newmin \quad (23)$$

A equação (23) apresenta a técnica de normalização utilizada, conforme apresentada em Sinsomboonthong, (2022), a qual descreve uma extensão do método clássico de min-max, onde os termos  $\min(X)$  e  $\max(X)$  representam o intervalo de valores original, enquanto  $newmin(X)$  e  $newmax(X)$  correspondem à nova escala de valores para a qual se deseja transformar os diferentes dados de  $X$ , que, neste trabalho, são alterados os valores de  $R(t_h)$ , com o objetivo de obter condições de carga mais pesadas, enquanto os valores de  $F(t_h)$  permanecerão inalterados.

$$N(y) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(y-\mu)^2}{2\sigma^2}} \quad (24)$$

A equação (24) representa a função de densidade de probabilidade normal,  $N(y)$ , onde  $y$  é a distribuição da variável aleatória,  $\mu$  o valor médio da variável  $y$  quanto ao  $\sigma$  representa o desvio padrão de  $y$ .

É possível estabelecer uma relação entre a equação (24) e as variáveis utilizadas no modelo probabilístico, onde  $y$  pode assumir os valores de  $R(t_h)$  ou  $F(t_h)$ . Isso implica que  $y$  pode ser interpretada como uma função horária  $y(t_h)$ , que varia seu valor a cada período de tempo  $t_h$ . Dado que  $\sigma$ , é o desvio padrão associado a  $y$ , também pode ser expressa como uma função horária para  $R(t_h)$  e  $F(t_h)$ . Esse desvio é calculado nas equações (25) e (26), onde  $\sigma_R(t_h)^2$  e  $\sigma_F(t_h)^2$  representam, a variância horária da magnitude normalizada e do fator de potência respectivamente.

$$\sigma_R(t_h)^2 = \frac{(\sum_{k=1}^n R_k(t_h))^2 - \frac{(\sum_{k=1}^n R_k(t_h))^2}{n}}{n-1} \quad (25)$$

$$\sigma_F(t_h)^2 = \frac{(\sum_{k=1}^n F_k(t_h))^2 - \frac{(\sum_{k=1}^n F_k(t_h))^2}{n}}{n-1} \quad (26)$$

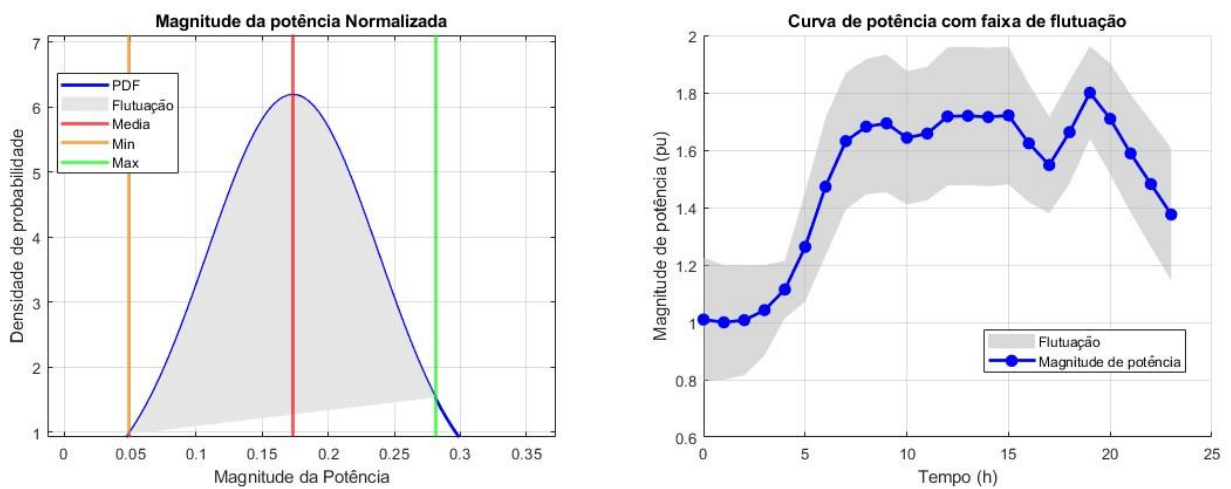
A variância é calculada utilizando o número total de dias de medição,  $n$ , além do dia da medição  $k$ , além que tem um grande impacto na função de densidade, afetando diretamente a forma da curva normal, já que determina o quão “larga” ou “estreita” é a distribuição de probabilidades, é possível escolher um ponto específico dentro da curva normal, determinadas pelas equações (27) e (28).

$$N_{R,i}^p(t_h) = \frac{\omega + \alpha_{R,i}^p(t_h)(1 - \omega)}{\sigma_R(t_h)\sqrt{2\pi}} \quad (27)$$

$$N_{F,i}^p(t_h) = \frac{\omega + \alpha_{F,i}^p(t_h)(1 - \omega)}{\sigma_F(t_h)\sqrt{2\pi}} \quad (28)$$

Onde  $\alpha_{R,i}^p(t_h)$  e  $\alpha_{F,i}^p(t_h)$  são variáveis aleatórias entre 0 e 1, a variável  $\omega$  limita o grau de incerteza entre as projeções máxima e mínima, enquanto  $N_{R,i}^p(t_h)$  e  $N_{F,i}^p(t_h)$  são os pontos projetados das curvas probabilísticas. Conforme mencionado anteriormente, foram utilizados como base os dados de  $R(t_h)$  e  $F(t_h)$  fornecidos por (Kheirkhah *et al.*, 2023) para o cálculo das funções de densidade e da função percentual de energia, porém adaptados às necessidades deste trabalho.

**Figura 4.** Faixa de flutuação da magnitude de potência ao longo do tempo



Fonte: Próprio autor

Essa adaptação é refletida na Figura 4 as quais representam a magnitude da potência normalizada (a) e a curva de potência com faixa de dispersão (b). Observa-se que a curva obtida a partir dos dados das densidades de carga  $r_i^p(t_h)$  apresenta uma maior dispersão em comparação com a curva apresentada em Kheirkhah *et al.*, (2023) além de possuir maiores magnitudes de carga (b). Isso se deve ao fato de que, para o desenvolvimento deste trabalho, busca-se simular diferentes condições de carga, as quais diferem consideravelmente entre os períodos de baixa e alta demanda energética, o que gera uma maior dispersão dos dados em relação à média. No entanto, isso não implica que os resultados careçam de sentido, pois apresentam um comportamento esperado e compatível com os objetivos do trabalho, além de que o intervalo de tempo utilizado em Kheirkhah *et al.*, (2023) foi reduzido de um mês para apenas uma semana, que era o necessário para estudar o comportamento da estratégia proposta.

Onde  $\alpha_{R,i}^p(t_h)$  e  $\alpha_{F,i}^p(t_h)$  são variáveis aleatórias entre 0 e 1, a variável  $\omega$  limita o grau de incerteza entre as projeções máxima e mínima, enquanto  $N_{R,i}^p(t_h)$  e  $N_{F,i}^p(t_h)$  são os pontos projetados das curvas probabilísticas. Conforme mencionado anteriormente, foram utilizados como base os dados de  $R(t_h)$  e  $F(t_h)$  fornecidos por (Kheirkhah *et al.*, 2023) para o cálculo das funções de densidade e da função percentual de energia, porém adaptados às necessidades deste trabalho.

Essa adaptação é refletida na Figura 4 as quais representam a magnitude da potência normalizada (a) e a curva de potência com faixa de dispersão (b). Observa-se que a curva obtida a partir dos dados das densidades de carga  $r_i^p(t_h)$  apresenta uma maior dispersão em comparação com a curva apresentada em Kheirkhah *et al.*, (2023) além de possuir maiores magnitudes de carga (b). Isso se deve ao fato de que, para o desenvolvimento deste trabalho, busca-se simular diferentes condições de carga, as quais diferem consideravelmente entre os períodos de baixa e alta demanda energética, o que gera uma maior dispersão dos dados em relação à média. No entanto, isso não implica que os resultados careçam de sentido, pois apresentam um comportamento esperado e compatível com os objetivos do trabalho, além de que o intervalo de tempo utilizado em Kheirkhah *et al.*, (2023) foi reduzido de um mês para apenas uma semana, que era o necessário para estudar o comportamento da estratégia proposta.

$$r_i^p(t_h) = \text{sgn}(\beta - 0.5) \cdot \sqrt{2\sigma_R^2(t_h) \ln\left(\frac{1}{N_{R,i}^p(t_h)\sigma_R(t_h)\sqrt{2\pi}}\right)} + R_k(t_h) \quad (29)$$

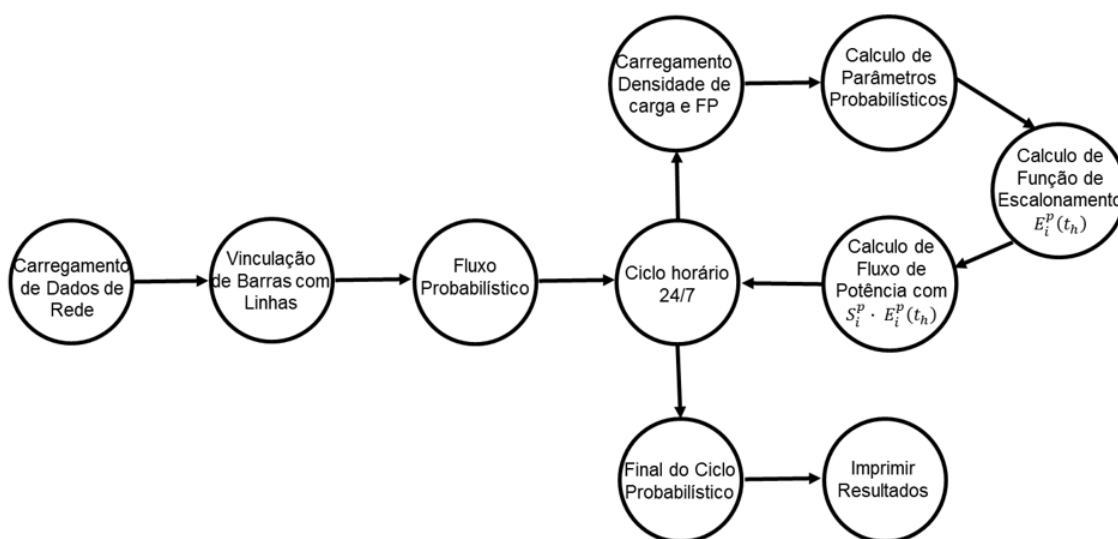
$$f_i^p(t_h) = \text{sgn}(\beta - 0.5) \cdot \sqrt{2\sigma_F^2(t_h) \ln\left(\frac{1}{N_{F,i}^p(t_h)\sigma_F(t_h)\sqrt{2\pi}}\right)} + F_k(t_h) \quad (30)$$

A equação (24) representa a função de densidade de probabilidade normal,  $N(y)$ , onde  $y$  é a distribuição da variável aleatória,  $\mu$  o valor médio da variável  $y$  e  $\sigma$  representa o desvio padrão de  $y$ .

Finalmente as equações (29) e (30) calculam os valores  $r_i^p(t_h)$  e  $f_i^p(t_h)$  que compõem os termos da equação (22) a partir dos resultados obtidos de (27) e (28). Nessas expressões, é utilizada a função inversa da distribuição normal, de forma que é possível gerar um valor específico da variável a partir de um parâmetro de entrada aleatório  $\beta$  de

0 a 1. O operador  $sgn(\beta - 0.5)$  pode resultar negativo ( $-1$ ) para um  $\beta < 0,5$  ou positivo ( $+1$ ) para  $\beta > 0,5$ , orientando a direção do desvio em relação à média. Assim, o valor médio da curva normal é ajustado em função do nível de dispersão  $\sigma$  e do parâmetro aleatório  $\beta$ , gerando um valor final que respeita a forma da distribuição.

**Figura 5.** Diagrama de Fluxo Logica de Processo



Fonte: Próprio autor

Para explicar a lógica de controle utilizada para a aplicação conjunta dos fluxos de potência sequencial e probabilístico, apresenta-se o fluxograma da Figura 5, no qual é mostrada passo a passo a sequência executada nesses processos.

Primeiramente, realiza-se o carregamento dos dados da rede, ou seja, os IDs das barras e linhas, incluindo os dados das variáveis associadas a esses elementos, como a impedância complexa e as cargas, além das informações dos dispositivos controlados. Em seguida, é feita a vinculação entre as barras e as linhas para, posteriormente, iniciar a função do fluxo probabilístico.

Uma vez executada essa função, inicia-se o ciclo horário, no qual são carregados os dados históricos de densidades de carga e fator de potência. Em seguida, são calculados os parâmetros do modelo probabilístico e, utilizando esses parâmetros, é calculada a função de escalonamento  $E_i^p(t_h)$ .

Quando se consegue o valor de escalonamento, é executado o fluxo probabilístico e enviada a função  $E$  para realizar o produto mostrado em (21). Como a função de escalonamento é calculada a cada hora durante os 7 dias, isso significa que o fluxo sequencial será executado a mesma quantidade de vezes. Cada iteração do fluxo representa uma hora de um dia, sendo esse o chamado ciclo horário.

Durante o ciclo horário, as informações dos resultados são armazenadas em cada iteração, e, ao final do ciclo completo, ou seja, finalizando os 7 dias, esses resultados são impressos para a respectiva análise.

Cabe mencionar que a análise realizada considera apenas os processos de ambos os fluxos de forma conjunta, para observar a lógica utilizada no mecanismo completo e mostrar de forma clara quais são as etapas e as chamadas de funções quando é realizada uma iteração. Fluxo de Potência Probabilístico para Sistemas de Distribuição.

### 3 ESTRATÉGIA DE CONTROLE VOLT/VAR COM AG CENTRALIZADO

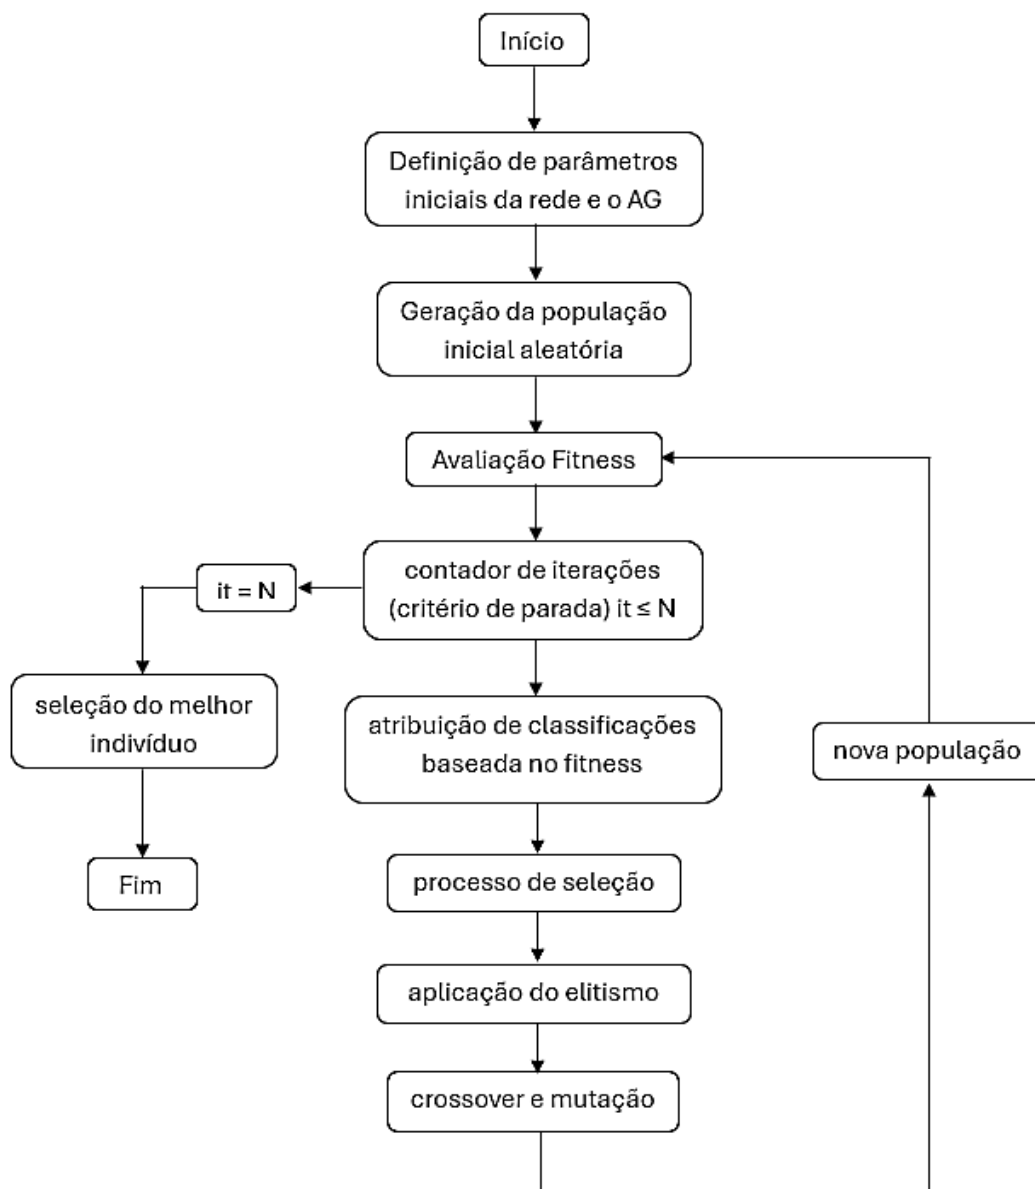
A estrutura utilizada neste trabalho para o desenvolvimento do AG empregado no VVC centralizado é explicado nesta seção, pretende-se mostrar a lógica do processo iterativo, além dos diferentes operadores que o compõem.

O AG desenvolvido segue uma abordagem convencional iniciando o processo com a definição dos parâmetros de população, número de gerações, limites das taxas de mutações e cruzamento, posteriormente é gerada a população inicial de forma aleatória, na qual os indivíduos são avaliados por meio da função objetivo, que, neste caso, é baseada no índice de sensibilidade do sistema. A partir dessa avaliação, inicia-se o processo iterativo com o número de gerações como critério de parada, os indivíduos que constituem a população corrente são ordenados de acordo com sua função do *fitness*, onde os melhores indivíduos tomam as primeiras posições. Com os indivíduos organizados é iniciado o processo de seleção dos pais são escolhidos utilizando o método da roleta a partir do fitness inverso.

Para formar a próxima geração, são aplicados operadores genéticos, como o cruzamento, a mutação e o elitismo, sendo este último responsável por garantir que os indivíduos de melhor qualidade da geração corrente passem diretamente para a nova. Uma vez criada a nova população, são executados processos de mutação controlada para preservar a diversidade genética. Esse ciclo iterativo é repetido até alcançar um número predeterminado de iterações, é selecionado o melhor indivíduo da última população e aplicada a estratégia Volt-Var centralizada otimizando os ajustes dos dispositivos controlados.

O esquema da Figura 6 exemplifica melhor o que foi descrito, proporcionando uma perspectiva gráfica do processo iterativo do AG. Esse esquema mostra apenas o desenvolvimento do AG sem a aplicação do controle local do SI.

**Figura 6.** Esquema funcional para AG



Fonte: Próprio autor

### 3.1 Restrições

Esta seção inicia com a apresentação e descrição das restrições do VVC centralizado, que se concentram em limitar as operações dos dispositivos de injeção de

potência e regulação direta de tensão dentro de intervalos específicos que garantem sua operação segura e eficiente. Trata-se de uma estrutura básica utilizada em muitos algoritmos, como em Jaramillo-Leon *et al.*, (2023).

$$V_{min} \leq V_{i,p} \leq V_{max} \quad (31)$$

$$P_{min} \leq P_{i,p}^{DG} \leq P_{max} \quad (32)$$

$$Q_{min} \leq Q_{i,p}^{DG} \leq Q_{max} \quad (33)$$

$$K_{nmin} \leq K_{n_{i-1},i} \leq K_{nmax} \quad (34)$$

$$Q_{min}^{CAP} \leq Q_{i,p}^{CAP} \leq Q_{max}^{CAP} \quad (35)$$

A restrição (31) assegura que os valores de tensão em cada barramento sejam mantidos dentro de uma faixa aceitável, garantindo a estabilidade e a operação segura do sistema. Onde  $V_{i,p}$  é a magnitude da tensão na fase  $p$  da barra  $i$ . Os termos  $V_{min}$  e  $V_{max}$  são os valores limite de tensão permitidos. Para este caso de estudo, a faixa de operação está definida entre  $0.95 \leq V_{p,i} \leq 1.05$  em valores por unidade (pu), o que permite prevenir problemas de subtensão ou sobretensão que possam afetar a qualidade do fornecimento elétrico ou danificar os equipamentos conectados à rede.

As restrições (32) e (33) limitam a injeção de potência ativa ( $P_{i,p}^{DG}$ ) e reativa ( $Q_{i,p}^{DG}$ ) do GD por fase  $p$  instalado na barra  $i$ , para evitar que os dispositivos excedam suas capacidades nominais de injeção de potência.

De maneira semelhante, as restrições (34) e (35) regulam as posições dos taps dos OLTC ( $K_{n_{i-1},i}$ ) e a injeção de potência reativa dos bancos de capacitores ( $Q_{i,p}^{CAP}$ ), respectivamente. Essas restrições são essenciais para manter a funcionalidade dentro dos limites físicos e técnicos dos dispositivos.

$$\sum_{i=1}^{N_b} \sum_{p=1}^{N_f} (P_{i,p}^{GD} - P_{i,p}) = \sum_{l=1}^{N_r} \sum_{p=1}^{N_f} P_{l,p}^L \quad (36)$$

$$\sum_{i=1}^{\Omega_b} \sum_{p=1}^{\Omega_f} (Q_{i,p}^{GD} + Q_{i,p}^{BC} - Q_{i,p}) = \sum_{l=1}^{\Omega_l} \sum_{p=1}^{\Omega_f} Q_{l,p}^L \quad (37)$$

Finalmente, as restrições (36) e (37) representam o balanço de potência ativa e reativa em cada barra do sistema. O balanço de potência é assegurado com a solução do fluxo de potência convencional com modelo apresentado de (7) a (18).

Esse conjunto de restrições permite a coordenação efetiva entre os diferentes dispositivos envolvidos no algoritmo de controle, garantindo que cada um opere dentro de seus limites técnicos e físicos. Tanto a regulação da tensão quanto a injeção de potência ativa e reativa são executadas de forma controlada, evitando qualquer tipo de sobrecarga ou conflitos no sistema.

### 3.2 Função Objetivo

Por sua vez, a função objetivo é projetada para otimizar o desempenho da rede, focando em dois aspectos fundamentais: a minimização das variações de tensão e a redução das perdas de potência ativa. Além disso, são aplicados custos de penalização para as soluções que excedem determinados limites associados às perdas e variações, garantindo a confiabilidade e a qualidade das diferentes estratégias geradas.

$$\min f(x) = w_1 \sum_{i=1}^{|\Omega_b|} \sum_{p=1}^{|\Omega_p|} |1 - V_{p,i}| + w_2 \sum_{l=1}^{|\Omega_l|} \sum_{p=1}^{|\Omega_p|} P_{l,p}^L \quad (38)$$

O primeiro termo da equação (38) é responsável por minimizar as variações de tensão em relação ao valor nominal, em que  $V_{p,i}$  é a magnitude da tensão na fase  $p$  da barra  $i$  sendo  $|\Omega_b|$  o número total de barras na rede, semelhante ao proposto em Jaramillo-Leon *et al.*, (2022).

A expressão  $|1 - V_{p,i}|$  é responsável por medir a variação absoluta de cada magnitude de tensão em relação ao valor ideal de 1 pu. Esse valor é utilizado como uma referência para guiar o algoritmo em direção a uma melhor solução. Os AG, assim como qualquer técnica heurística, não garantem um ótimo global; no entanto, o algoritmo pode ser guiado para se aproximar desse valor. Por exemplo, tanto 0,96 quanto 0,98 pu. são boas soluções, mas, se for considerado um aumento repentino de demanda devido à comutação de uma carga pesada, é mais conveniente manter uma tensão próxima desse valor ideal.

A função objetivo penaliza diretamente as variações de tensão em cada barra, o que é alcançado por meio de uma constante de ponderação  $w_1$  que ajusta a importância relativa da penalização pela variação.

O segundo termo descreve a parte da redução de perdas na função objetivo. A variável  $P_{l,p}^L$  representa a perda de potência ativa na fase  $p$  da linha  $l$  sendo  $|\Omega_l|$  o número total de linhas na rede.

Por outro lado, a variável de ponderação  $w_2$  é responsável por controlar a relevância desse termo dentro da função objetivo. Um valor maior de  $w_2$  em relação a  $w_1$  indicaria que a equação (38) dá um peso maior à redução de perdas, em comparação com a minimização das variações de tensão do primeiro termo. Isso permite realizar ajustes na função objetivo de acordo com as necessidades da rede.

### 3.3 Penalização

Caso as perdas ativas ou desvios de tensão excedam determinados limites estabelecidos, aplica-se uma penalização que aumenta o valor da função objetivo, tornando essas soluções menos atrativas dentro do processo de seleção do algoritmo genético. Esse mecanismo garante que as soluções que não satisfazem com as restrições sejam avaliadas negativamente, reduzindo sua probabilidade de serem selecionadas para avançar para a próxima geração, ou participar dos processos de cruzamento e mutação.

A penalização associada à tensão, representada por  $Pe_{V_o}$  é calculada como a soma das variações absolutas acima ou abaixo dos limites permitidos de 0,95 e 1,05 pu para cada barra  $i$  e fase  $p$  conforme mostrado na equação (39):

$$Pe_{V_o} = \sum_{i=1}^{|\Omega_b|} \sum_{p=1}^{|\Omega_p|} \max(0, V_{p,i} - 1.05) + \max(0, 0.95 - V_{p,i}) \quad (39)$$

De maneira semelhante, a penalização associada às perdas de potência ativa, representada por  $Pe_L$  avalia se as perdas ativas totais excedem um valor máximo permitido denominado  $P_{max}^L$  conforme representado em (40).

$$Pe_L = \max \left( 0, \left( \sum_{l=1}^{|\Omega_l|} \sum_{p=1}^{|\Omega_p|} P_{l,p}^L \right) - P_{max}^L \right) \quad (40)$$

Essas penalizações são incorporadas na função objetivo por meio de um termo adicional que as pondera com os valores de penalização  $\lambda_1$  e  $\lambda_2$  que representam a importância relativa das penalizações de tensão e perdas, respectivamente:

$$f_{pen}(\mathbf{x}) = f(\mathbf{x}) + \lambda_1 Pe_{V_o} + \lambda_2 Pe_L \quad (41)$$

O mecanismo de penalização é incorporado ao AG por meio de (41). Seu principal objetivo é penalizar as soluções geradas que não atendam aos valores permitidos tanto para a variação de tensão quanto para as perdas nas redes. As soluções penalizadas apresentam um *fitness* menos atrativo, o que reduz a probabilidade de que essas soluções avancem para a próxima geração, seja de forma direta utilizando o mecanismo de elitismo, ou de forma indireta por meio da descendência no processo de cruzamento.

### 3.4 Elitismo

O elitismo em um AG é uma técnica que garante a conservação dos melhores indivíduos de cada geração ao longo do processo iterativo. Durante a avaliação de uma população, os indivíduos são ordenados em função de seu *fitness*, do melhor ao pior, e é selecionado um grupo dos indivíduos mais destacados, conhecido como população de elite, para ser transferido diretamente para a próxima geração. Se, durante o processo evolutivo, surgir um novo indivíduo com um desempenho superior ao de algum dos membros dessa população de elite, ele o substitui, deslocando o indivíduo menos apto do grupo.

Neste estudo, a população de elite representa 5% do total de indivíduos de cada geração. Esse percentual foi escolhido para manter um equilíbrio entre a qualidade e a diversidade da população, garantindo que possíveis soluções ótimas não sejam perdidas. Além disso, embora os indivíduos de elite sejam transferidos diretamente, eles também podem participar nos processos de cruzamento e mutação, mas para este último, com

uma baixa probabilidade de ser selecionados, o que protege sua estrutura genética e evita possíveis degradações no desempenho.

### 3.5 Seleção dos Pais

Os conceitos e operadores do AG são fortemente inspirados nas teorias de seleção natural de Charles Darwin, onde os indivíduos mais adaptados ao seu ambiente têm uma maior probabilidade de sobrevivência e de transmitir seus genes à descendência.

Em sua obra “A Origem das Espécies”, Darwin explica o conceito de seleção sexual, um princípio que pode ser observado em diversas espécies, especialmente naquelas com dimorfismo sexual, onde existem diferenças visíveis na fisionomia entre machos e fêmeas. Nesses casos, as fêmeas tendem a escolher os machos com as melhores características genéticas para a procriação, garantindo a transmissão de traços vantajosos.

No entanto, isso não implica que os indivíduos com menores características de adaptação não possam possuir genes favoráveis que beneficiem as futuras gerações. Por essa razão, para o desenvolvimento deste trabalho, decidiu-se aplicar a seleção por roleta, um método amplamente estudado na literatura, que concede uma maior probabilidade de seleção aos indivíduos de melhor qualidade, mas sem excluir completamente aqueles com desempenho inferior, garantindo diversidade genética durante o processo evolutivo.

Para iniciar o processo, define-se a probabilidade de cada indivíduo invertendo o *fitness* de cada um, já que este é um problema de minimização. Como mostrado em (40), os indivíduos com *fitness* mais baixos conseguem uma aptidão inversa mais alta. Isso é ilustrado em (42).

$$\tau_j = \frac{1}{f_j} = \frac{1}{f_{pen}(\mathbf{x}_j)}, \quad \forall \mathbf{x}_j \in \mathcal{P} \quad (42)$$

Em que  $\tau_j$  representa a probabilidade inversa associada a cada indivíduo  $\mathbf{x}_j$  de uma população  $\mathcal{P}$ .

Uma vez calculada a aptidão inversa de todos os indivíduos da população, realiza-se um processo de normalização das probabilidades de seleção. Esse ajuste é necessário


para garantir que os valores de fitness estejam dentro de um intervalo adequado, evitando problemas que poderiam afetar o desempenho do algoritmo, como a dominação de um pequeno grupo de indivíduos sobre as próximas gerações. A normalização é realizada por meio da soma total das aptidões, garantindo que cada indivíduo receba uma probabilidade proporcional ao seu desempenho relativo.

$$\tau_{total} = \sum_{j=1}^{|\mathcal{P}|} \tau_j \quad (43)$$

Posteriormente, é gerado um número aleatório  $r \in [0, \tau_{total}]$  e percorre-se a população  $\mathcal{P}$  acumulando as aptidões invertidas até que a condição (44) seja satisfeita. O primeiro indivíduo  $k$  que cumprir essa condição é selecionado como pai.

$$\sum_{j=1}^k \tau_j \geq r, \quad j = 1, 2, \dots, |\mathcal{P}| \quad (44)$$

**Figura 7.** seleção por roleta para uma população de 20 indivíduos



Fonte: Próprio autor

Nota-se que os pais selecionados são inseridos em uma lista denominada "pais", para evitar que um mesmo indivíduo possa procriar mais de uma vez por geração. No entanto, é permitido que mais de um indivíduo seja gerado a partir de um mesmo par.

A Figura 7 apresenta, de forma ilustrativa, um exemplo de como o método de seleção por roleta é aplicado neste trabalho. Após a aplicação da normalização descrita em (42), são atribuídas as probabilidades que cada indivíduo possui para ser selecionado como pai. Para este exemplo, optou-se por uma população pequena, com apenas 20 indivíduos, pois isso permite uma visualização mais em comparação com um maior número de membros. Observa-se que, apesar de favorecer aos indivíduos de melhor qualidade, atribuindo uma probabilidade maior de procriar, o modelo não descarta o restante da população, nem são atribuídas probabilidades excessivamente baixas, o que permite um bom nível de diversidade ao longo das gerações, evitando o domínio genético de um pequeno grupo da população. Uma vez atribuídas todas as probabilidades, é gerado um número aleatório que seleciona um indivíduo, o qual é inserido na lista de pais até que seja atingido o número total desejado.

### 3.6 Cruzamento e Mutação

Para compreender o funcionamento das funções de cruzamento e mutação em um algoritmo genético, é fundamental entender a estrutura cromossômica. Nesse contexto, os cromossomos contêm a informação codificada das possíveis soluções geradas e evoluídas pelo algoritmo. Esses cromossomos são representados de forma vetorial e, dependendo do tipo de problema, podem adotar uma representação discreta ou binária, permitindo a manipulação de seus genes por meio dos operadores genéticos para melhorar a qualidade das soluções em cada geração.

Para o desenvolvimento deste trabalho, optou-se por uma aplicação cromossômica vetorial discreta. Esse vetor contém as informações sobre as posições do OLTC ( $k_j$ ), os passos dos BC ( $s_j$ ) e o percentual de potência injetada pelos geradores ( $u_j$ ) para uma quantidade  $n$  de dispositivos de cada tipo. O descrito está refletido na Tabela 3.

**Tabela 3.** Estrutura Cromossômica

CROMOSSOMO ( $x_j$ )		
OLTC	BC	GD
$k_j$	$s_j$	$u_j$

Fonte: Próprio Autor

Se é considerado um vetor composto por 5 dispositivos que incluem um OLTC, dois BC e também dois GD, o vetor assume a forma apresentada na Tabela 4.

**Tabela 4.** Vector de solução para 5 dispositivos

CROMOSOMA ( $x_1$ )				
OLTC	BC		GD	
$k_1$	$s_1$	$s_2$	$u_1$	$u_2$

Fonte: Próprio Autor

O processo de cruzamento deste AG é realizado por meio da combinação probabilística dos genes  $g_k^{x_j}$  dos pais selecionados para a procriação. Cada pai começa com uma probabilidade de 0,5, que é atualizada aumentando ou diminuindo em função de um fator  $\pm\Delta$  dependendo de qual pai transmitiu o último gene. Essa abordagem permite gerar uma nova descendência que herda as características de ambos os pais.

Considere-se dois pais,  $x_1$  e  $x_2$ , para uma configuração básica, com um único elemento por dispositivo, de modo que cada pai tenha a forma  $x_1 = \{k_1, s_1, u_1\}$  e  $x_2 = \{k_2, s_2, u_2\}$ .

$$g_k^{x_3} = \begin{cases} g_k^{x_1} & \text{if } \mathcal{R} < Prob_1 \\ g_k^{x_2} & \text{if } \mathcal{R} \geq Prob_1 \end{cases}, \quad k = 1, 2, \dots, |x_j| \quad (45)$$

Em que  $\mathcal{R}$  é um número entre 0 e 1 gerado de forma aleatória.  $Prob_1$  e  $Prob_2$ , são as probabilidades dos pais 1 e 2. Inicialmente  $Prob_1 = Prob_2 = 0.5$ .

A atualização das probabilidades é ajustada após a seleção do gene.

- Se  $g_k^{x_3} = g_k^{x_1}$ 

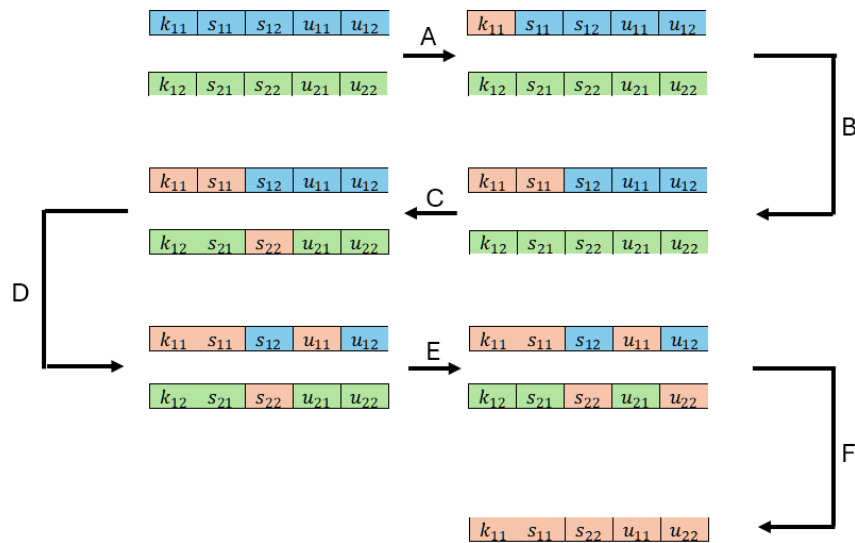
$$Prob_1 = \max(0, Prob_1 - \Delta), \quad Prob_2 = \min(1, Prob_2 + \Delta) \quad (46)$$

- Se  $g_k^{x_3} = g_k^{x_2}$ 

$$Prob_1 = \min(1, Prob_1 + \Delta), \quad Prob_2 = \max(0, Prob_2 - \Delta) \quad (47)$$

As funções  $\min(\cdot)$  e  $\max(\cdot)$  são utilizadas para a atualização das probabilidades  $Prob_1$  e  $Prob_2$  para garantir que estas se mantenham sempre dentro de um intervalo permitido entre 0 e 1. Isso é especialmente relevante para configurações com uma maior quantidade de dispositivos. O fator de crescimento  $\pm\Delta$  pode ser ajustado em função das dimensões do problema.

**Figura 8.** Processo de cruzamento



Fonte: Próprio autor

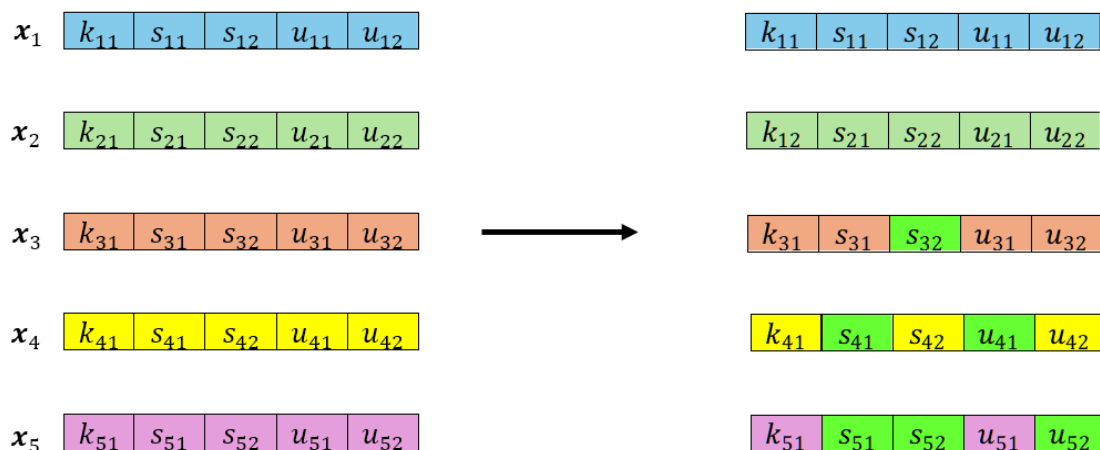
Na Figura 8, é exemplificado as diferentes etapas do processo de cruzamento. A partir de um vetor com 5 dispositivos controlados. No início do processo, o pai 1 ( $x_1$ ) representado pelo vetor azul e o pai 2 ( $x_2$ ) representado pelo vetor verde, têm, inicialmente, a mesma probabilidade,  $Prob_1$  e  $Prob_2$ , de transmitir o primeiro gene, e é selecionado aleatoriamente qual deles transmite, na figura cada gene herdado é representado pelo elemento de cor bege. Na etapa A, o primeiro gene já é transmitido por  $x_1$  mas agora  $x_2$  tem uma maior probabilidade de transmitir seu segundo gene. Durante a etapa B, o segundo gene é transmitido novamente por  $x_1$ , apesar de já ter transmitido o gene anterior e reduzida a probabilidade de transmitir o próximo gene em um fator  $-\Delta$ . No entanto, essa probabilidade não é zero e, portanto, embora menor, existe a possibilidade de que um pai transmita dois genes de forma consecutiva. A partir da etapa C,  $x_2$  consegue transmitir seu primeiro gene, que está situado na terceira posição do vetor, enquanto na etapa D  $x_2$  transmite novamente o gene seguinte e, finalmente, na

etapa E,  $x_2$  transmite o gene final, concluindo na etapa D, onde é apresentado o vetor solução resultante do cruzamento entre  $x_1$  e  $x_2$ . Para concluir, na etapa F, é mostrado o vetor resultante, que combina os genes herdados de  $x_1$  e  $x_2$ , formando a nova descendência  $x_3$  representado pelo vetor bege.

Esse processo pode ser extrapolado para um vetor de  $n$  posições, seguindo a mesma mecânica probabilística. No caso exemplificado, observa-se que as probabilidades favoreceram  $x_1$ ; no entanto, isso não implica que  $x_1$  seja um vetor de melhor qualidade que  $x_2$ , apenas que as possibilidades estiveram a seu favor. Em outros processos, talvez  $x_2$  tivesse maior presença ou ambos os vetores poderiam ter transmitido uma quantidade semelhante de genes.

Para a função de mutação, optou-se por seguir uma estratégia probabilística, na qual, em cada geração, uma determinada percentagem da população experimenta mudanças nos genes que a compõem. Essas mudanças são executadas de forma dinâmica e estão relacionadas ao *fitness* do indivíduo, de modo que aqueles com pior desempenho têm uma maior probabilidade de serem selecionados para mutação.

**Figura 9.** Processo de Mutação



Fonte: Próprio autor

Na Figura 9 é exemplificado o processo de mutação que cada população segue em cada uma das gerações, no qual se têm 5 vetores  $x_1$ ,  $x_2$ ,  $x_3$ ,  $x_4$  e  $x_5$  que, neste exemplo específico, estão ordenados em função de seus valores de *fitness*. Diferentemente do exemplo da Figura 8, onde não é considerada a diferença no *fitness* dos dois vetores, neste

caso observa-se que os vetores inferiores sofrem uma maior quantidade de alterações nas informações de certos genes que contêm, ao contrário dos primeiros, cujos vetores permanecem inalterados, cada gene alterado é representado utilizando verde neon. Isso ocorre porque o sistema está projetado para mutar os indivíduos de pior desempenho, ao mesmo tempo em que preserva os melhores de cada população.

O tipo de mutação implementado é de natureza aleatória, o que significa que não existe um sistema de parametrização que indique quais genes específicos devem ser modificados com base no desempenho do indivíduo. Em vez disso, cada gene é avaliado de forma independente, e sua modificação depende exclusivamente da probabilidade de mutação atribuída.

A probabilidade de mutação  $Prob_j^m$  de cada indivíduo pode ser calculada a partir da soma total dos valores de *fitness* de todos os indivíduos dessa determinada geração.

$$Prob_j^m = \frac{\sum_{f_k \in \mathcal{P}} f_k - f_j}{\sum_{f_k \in \mathcal{P}} f_k}, \quad j = 1, 2, \dots, |\mathcal{P}| \quad (48)$$

No entanto, tanto as funções de cruzamento quanto as de mutação são processos dinâmicos, devido à integração de dois parâmetros denominados  $\rho_c$  e  $\rho_m$ , que ajustam as taxas de cruzamento e mutação, respectivamente. Esse ajuste depende da variabilidade existente na população, permitindo modificar esses parâmetros conforme seja detectada a quantidade de indivíduos semelhantes dentro da população.

Nas primeiras gerações, onde a população inicial é aleatória e apresenta alta variabilidade, a taxa de cruzamento  $\rho_c$  é mantida elevada para facilitar a combinação de diferentes características genéticas. Por outro lado, a taxa de mutação  $\rho_m$  começa baixa para não perturbar a diversidade inicial, mas aumenta gradualmente à medida que o processo evolutivo avança e é detectada convergência na população. De forma inversa, a taxa de cruzamento diminui nas gerações posteriores para estabilizar a busca em torno das melhores soluções. Esse equilíbrio entre exploração (mutação) e intensificação (cruzamento) é fundamental para alcançar a otimização do sistema. Essas funções são definidas em Reiz; Leite, (2022) e são as seguintes:

$$\rho_c = k_{max}^c - \frac{N_s}{|\mathcal{P}|} (k_{max}^c - k_{min}^c) \quad (49)$$

$$\rho_m = k_{max}^m - \frac{N_s}{|\mathcal{P}|} (k_{max}^m - k_{min}^m) \quad (50)$$

Onde o número  $N_s$  representa o número de soluções semelhantes em uma geração,  $|\mathcal{P}|$  é o número total de indivíduos. Os termos,  $k_{max}^c$  e  $k_{min}^c$  são as taxas máximas e mínimas de cruzamento. De forma análoga  $k_{max}^m$  e  $k_{min}^m$  representam as taxas máximas e mínimas de mutação.

### 3.7 Função de parametrização

Como mencionado no início da seção 3, a proposta está dividida em 3 etapas, que são executadas de forma sequencial, onde a etapa seguinte utiliza os resultados da anterior para o desenvolvimento dos processos dessa mesma etapa.

A configuração ideal para os parâmetros do AG, como o tamanho da população  $|\mathcal{P}|$  e o número de gerações  $|\mathcal{G}|$ , é determinada na primeira etapa, e os resultados de cada uma dessas provas são tabelados na seção 5 e parametrizados a partir de uma função.

São considerados os valores de variação e o tempo de processamento como critérios fundamentais para avaliar cada configuração. A função utilizada para determinar a métrica é a seguinte:

$$F_m = \alpha \frac{\lambda_k}{\lambda_{max}} + \beta \frac{t_k}{t_{max}} \quad (51)$$

Em que  $\lambda_k$  é a variação individual para cada configuração, enquanto  $\lambda_{max}$  é a variação máxima encontrada. Da mesma forma, a segunda parte da soma representa os tempos de execução para cada configuração  $t_k$  e o tempo máximo encontrado  $t_{max}$ . Em relação às variáveis  $\alpha$  e  $\beta$  estas representam os pesos para cada parâmetro. Neste caso,  $\alpha = \beta = 0.5$ , de modo que cada parâmetro tenha a mesma relevância na determinação da métrica.

### 3.8 Vinculação do algoritmo genético e o fluxo de potência probabilístico

O objetivo desta subseção é explicar o processo de vinculação entre o modelo de fluxo de potência probabilístico, o qual foi explicado na seção anterior, e o AG, descrito na presente seção. Cabe destacar que as equações próprias de cada modelo não são alteradas, já que a integração é realizada do ponto de vista informático, sem vincular formalmente ambas as estruturas matemáticas. A ideia principal é detalhar a lógica empregada para a coordenação de ambos os modelos e como o AG é aplicado dentro de um sistema de simulação horária, tal como foi proposto neste trabalho.

Para alcançar esse objetivo, são apresentadas as Figuras 9, que descreve ambos os processos aplicados de forma simultânea. Observa-se que o processo se inicia com a leitura dos dados da rede, os quais incluem as variáveis associadas às barras, como a identificação (ID) de cada barra, a potência complexa, além da localização e das capacidades dos dispositivos de regulação. Neste caso, são lidos os dados dos BCs, GDs e OLTC; este último, apesar de estar vinculado às linhas, requer informações sobre o par de barras em que se encontra. Também são lidos e armazenados os dados associados às linhas, como a impedância complexa  $Z$ , a matriz  $[M_l]_{6 \times 6}$  e as barras de origem (bDe) e destino (bPara) correspondentes a cada linha.

Uma vez extraídos esses dados, procede-se à vinculação de cada barra ID com as linhas, utilizando os identificadores de início e fim de cada uma, para posteriormente serem armazenadas na lista de adjacência. Após a criação da lista, continua-se com o fluxo probabilístico, que começa por meio de dois ciclos de repetição: o primeiro percorre os 7 dias que compõem a semana de leitura e o segundo percorre as 24 horas de cada dia. Por exemplo, a primeira iteração do primeiro ciclo inicia na segunda-feira e, a partir desse dia, começa o segundo ciclo que percorre as 24 horas associadas ao primeiro dia. Esse processo se repete 7 vezes até completar a semana toda, totalizando 168 iterações.

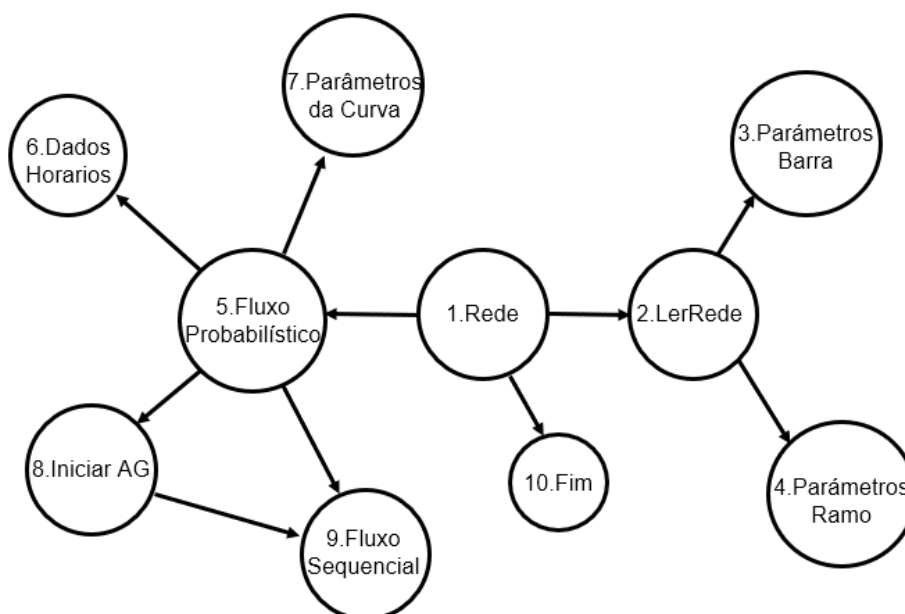
Durante ambos os ciclos, são lidos os dados horários de  $R(t_h)$  e  $F(t_h)$  para, posteriormente, calcular os parâmetros do fluxo probabilístico, ou seja, as variáveis  $\sigma_R(t_h)^2$ ,  $\sigma_F(t_h)^2$ ,  $N_{R,i}^p(t_h)$ ,  $N_{F,i}^p(t_h)$ ,  $r_i^p(t_h)$ , e  $f_i^p(t_h)$ , conforme mostram as equações de (24) a (30) e que são utilizadas para o cálculo de  $E_i^p(t_h)$  em cada uma das iterações. Uma vez calculado o primeiro valor de  $E_i^p(t_h)$ , é executada uma função condicional que verifica se a hora corrente é par; nesse caso, o AG deve ser executado para determinar as variáveis do vetor de solução, conforme descrito na Figura 6. A contagem das horas

começa a partir da hora 0:00, então o primeiro valor de  $h$  é 0, o que garante que o AG sempre será executado no início de ambos os ciclos.

Quando um ciclo completo do AG é executado, o vetor de solução é armazenado. Esse vetor contém as informações da configuração final para os dispositivos BC, GD e OLTC, conforme mostrado na Tabela 4. O vetor que foi salvo ao final da execução do AG durante uma hora par é utilizado diretamente na hora seguinte, que é ímpar, sem a necessidade de realizar outro ciclo do AG. Por exemplo, a configuração final encontrada para a hora 0:00 é reutilizada na hora 1:00. Essa estratégia foi adotada porque a variação da carga entre uma hora e a seguinte geralmente não é drástica, o que melhora a eficiência do algoritmo, pois reduz a quantidade de execuções necessárias. Isso implica em uma menor atividade de comutação, o que, por sua vez, reduz o desgaste mecânico dos dispositivos envolvidos.

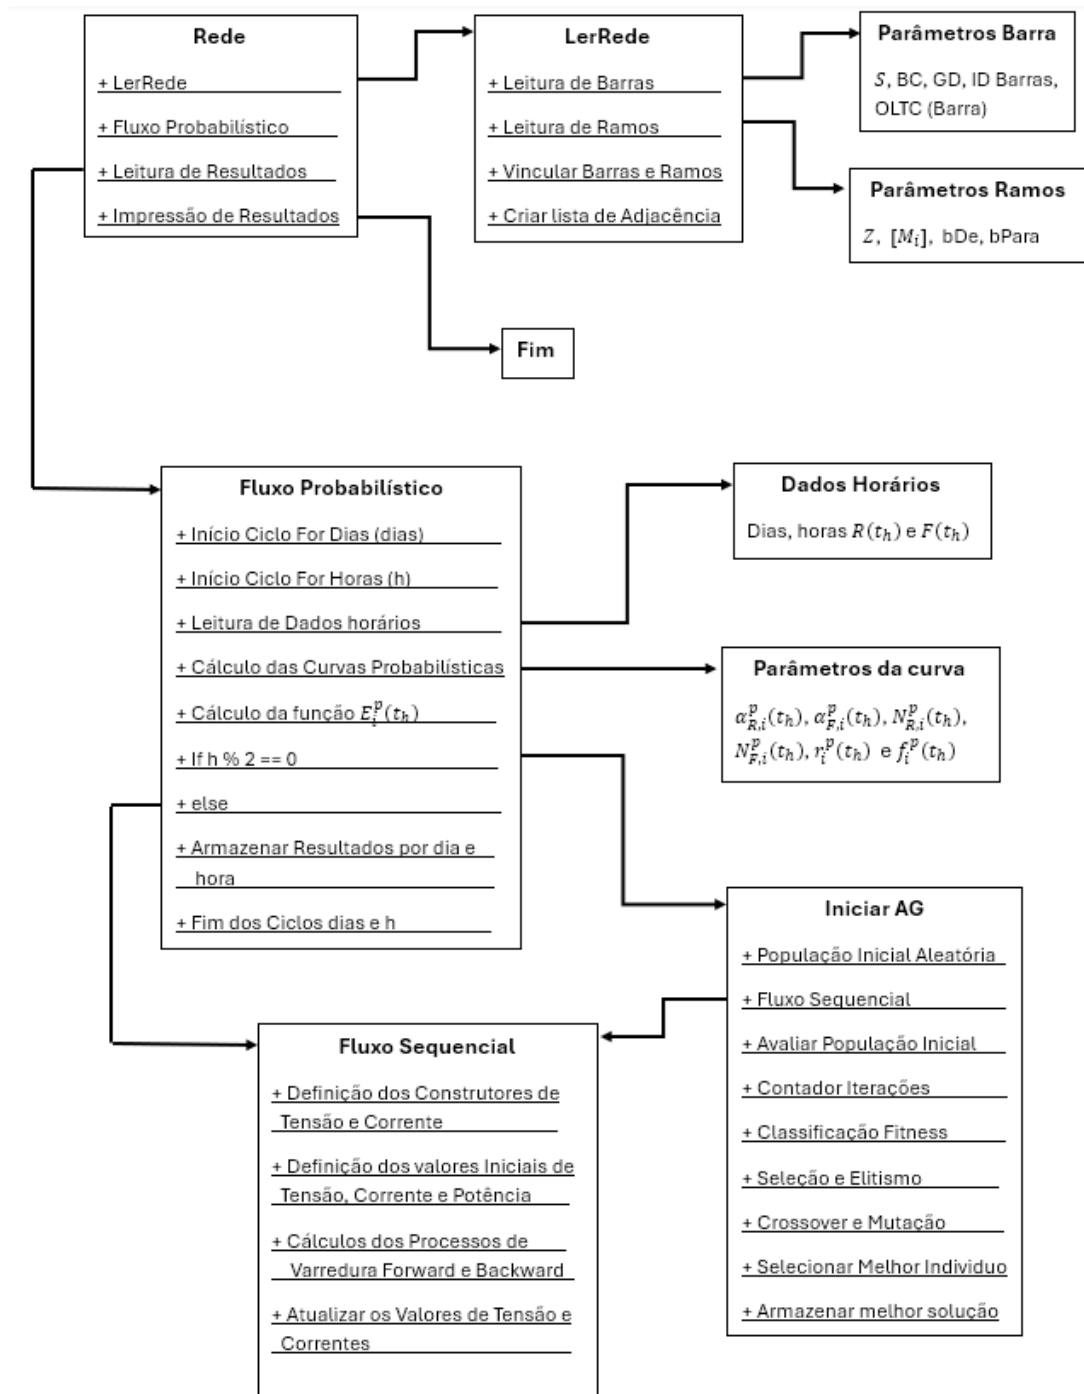
Ao final de ambos os ciclos, são armazenadas as diferentes soluções encontradas para cada dia e cada hora; essas são salvas em listas de dados. Tais listas são utilizadas para imprimir os resultados ao final do algoritmo, pois, se não forem armazenadas dessa forma, o algoritmo guardaria apenas a última configuração, ou seja, aquela encontrada na hora 22:00 do domingo, uma vez que o último ciclo do AG é executado na última hora par, finalizando completamente o algoritmo.

**Figura 10.** Fluxograma Funcional para AG



Fonte: Próprio autor

**Figura 11.** Esquema de Controle VVC Centralizado



Fonte: Próprio autor

## 4 CONTROLE LOCAL PARA INVERSOR INTELIGENTE

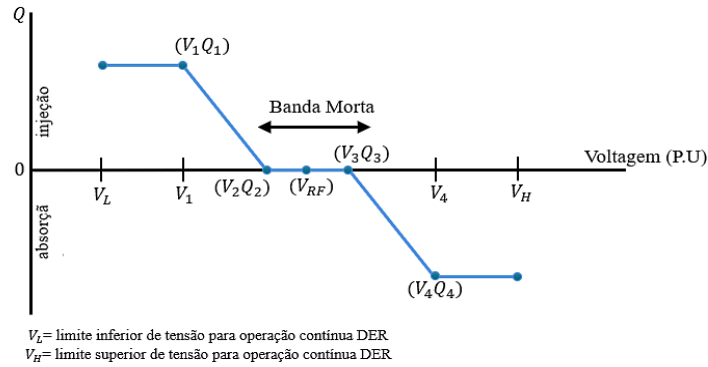
O controle local de um inversor inteligente é implementado por meio do uso da curva Volt-VAr, que estabelece a relação entre a tensão medida no ponto de conexão e a potência reativa injetada ou absorvida.

Em Jaramillo-Leon *et al.*, (2023), é definida a curva Volt-VAr, uma função linear por segmentos, definida por quatro pares de pontos ordenados  $(V_1, Q_1)$ ,  $(V_2, Q_2)$ ,  $(V_3, Q_3)$ ,  $(V_4, Q_4)$ . A função é responsável por relacionar a magnitude da tensão no ponto de conexão (eixo x) com a potência reativa disponível (eixo y) que o inversor pode injetar ou absorver. O controle é definido por (52).

$$Q^{inv} = \begin{cases} Q_1 & \text{if } v \leq V_1 \\ (v - V_2) \left( \frac{Q_2 - Q_1}{V_2 - V_1} \right) + Q_2 & \text{if } V_1 < v \leq V_2 \\ 0 & \text{if } V_2 < v \leq V_3 \\ (v - V_2) \left( \frac{Q_2 - Q_1}{V_2 - V_1} \right) + Q_2 & \text{if } V_3 < v \leq V_4 \\ Q_1 & \text{if } v > V_4 \end{cases} \quad (52)$$

Para tensões inferiores a  $V_1$  o inversor fornece 100% de sua capacidade de potência reativa. Entre  $V_1$  e  $V_2$  a injeção de reativo varia de 0% a 100%, enquanto entre  $V_2$  e  $V_3$  o inversor não injeta nem absorve reativo, o que é conhecido como zona de inatividade ou "deadband". Quando a tensão ultrapassa  $V_3$  o inversor começa a absorver reativo, e para tensões superiores a  $V_4$  ele absorve 100% de sua capacidade isto é observado na figura 12 .

A definição dos parâmetros de tensão do SI,  $V_1, V_2, V_3$  e  $V_4$  foi estabelecida com base nos valores recomendados pela norma IEEE 1547-2018, que regula a integração e operação de recursos energéticos distribuídos e micro redes em sistemas de potência. Seguindo esta norma foram estabelecidos os seguintes valores de referência para os pontos da curva volt-var: 0,95 pu para  $V_1$ , 0,98 pu para  $V_2$ , 1,02 pu para  $V_3$  e 1,05 pu para  $V_4$ .

**Figura 12.** Curva Volt-Var.

Fonte: Próprio autor

Adicionalmente, são inseridas as equações de balanço de potência ativa e reativa, assim como as restrições de tensão e de operação dos inversores inteligentes. Isso é feito para controlar as injeções do inversor e evitar que ele provoque uma sobre compensação e gere desequilíbrios nos perfis de tensão do sistema.

$$\sum_{i=1}^{N_b} \sum_{p=1}^{N_f} Q_{i,p}^{GD} + Q_{i,p}^{BC} + Q_{i,p}^{SI} - Q_{i,p} = \sum_{i=1}^{N_b} \sum_{p=1}^{N_f} \text{Im}\{V_{i,p} I_{i,p}^*\} \quad (53)$$

$$|Q_{p,i}^{SI}| \leq Q_{max,p,i}^{SI} \quad (54)$$

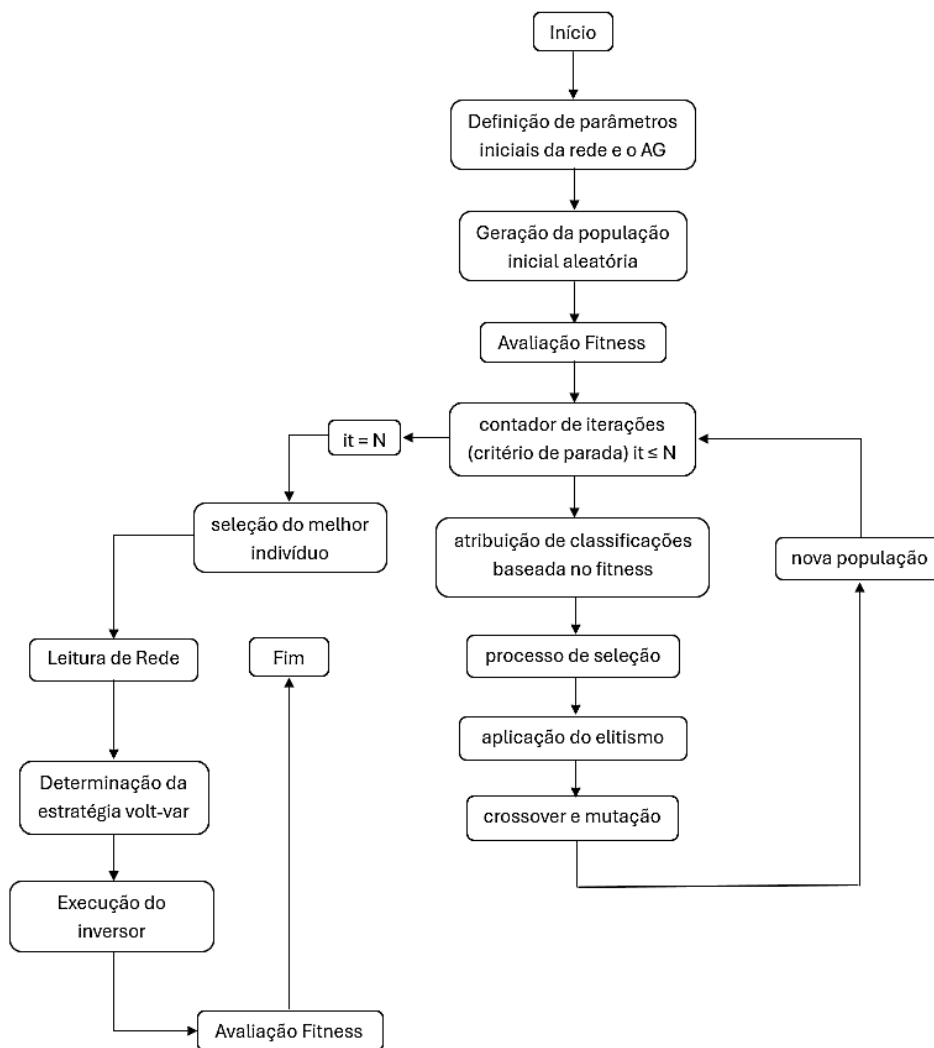
$$V_{min,p,i} \leq |V_{p,i}| \leq V_{max,p,i} \quad (55)$$

$$|I_{p,i}^{SI}| \leq I_{max,p,i}^{SI} \quad (56)$$

A equação (53) estabelece o balanço de potência reativa em cada barra, onde a soma da potência injetada pelos BCs, os GDs e pelo SI, menos a demanda, é igual à potência que flui para as barras adjacentes. A equação (54) limita a magnitude da potência injetada em função da capacidade máxima do dispositivo, (55) define o intervalo operacional da tensão, e (56) estabelece a restrição de corrente do SI. As equações (53) e (54) controlam a injeção do SI, evitando gerar uma sobre compensação e, por consequência, um desequilíbrio no sistema.

Na Figura 13 apresenta-se o esquema da estratégia de controle híbrido. Observa-se que, uma vez selecionada a configuração final do AG, é realizada uma leitura do estado local da rede, a partir da qual é executado o controle do SI. O objetivo principal do inversor é melhorar o perfil de tensão, garantindo a estabilidade e a eficiência do sistema.

**Figura 13.** Esquema de Controle da Estratégia Completa

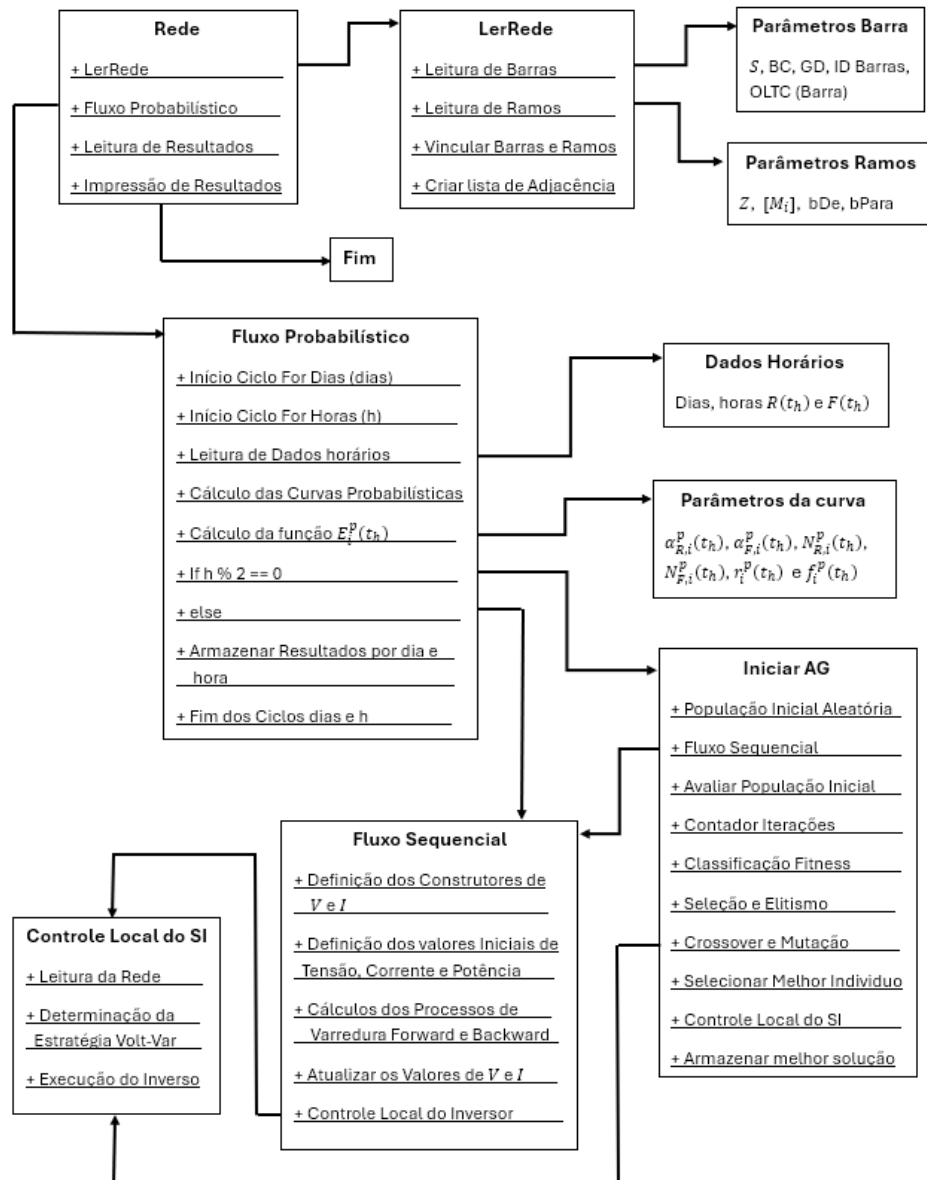


Fonte: Próprio autor

A vinculação do controle local para o inversor é realizada utilizando os mesmos princípios descritos na Seção 4.8. O processo se mantém igual até a parte da função condicional. Sabe-se que, se a hora corrente for par, então é iniciado o processo referente ao AG; no entanto, este é executado conforme descrito na Figura 13, quando o processo iterativo termina, é realizada uma última leitura do estado da rede e determina-se a

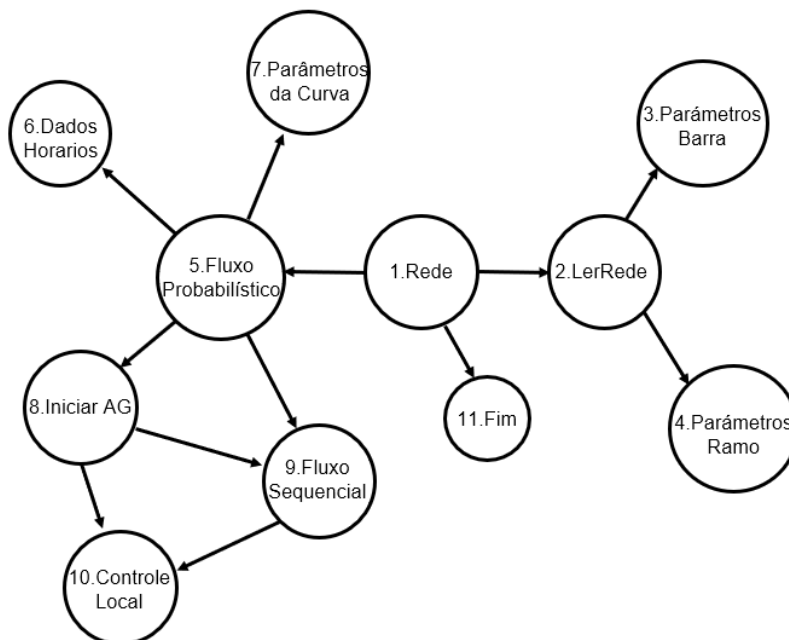
quantidade de reativo a ser injetada, utilizando como referência a curva volt-var e as equações de (52) a (56).

**Figura 14.** Esquema de Controle VVC Híbrido



Fonte: Próprio autor

**Figura 15.** Fluxograma de Controle VVC Híbrido



Fonte: Próprio autor

Originalmente, quando a hora era ímpar, mantinha-se a configuração corrente dos dispositivos de regulação determinada pelo AG basicamente, a estratégia era definida a cada duas horas. No entanto, o inversor não possui limitações de comutação mecânica e pode operar de forma mais intermitente. Com base nesse princípio, o controle local pode ser efetuado em um espectro temporal mais amplo, o que permite controlar o inversor a cada hora.

Quando se chega a condição de hora ímpar, aplica-se diretamente o fluxo sequencial, mas agora com a particularidade de que, uma vez realizado, é feita uma nova leitura da rede e determina-se a estratégia volt-var do inversor. Explicado de forma mais simples: o AG é executado cada duas horas (hora par), determina-se a configuração dos dispositivos e, em seguida, aplica-se o SI. Já na hora seguinte (hora ímpar), o fluxo é aplicado diretamente utilizando a solução do AG, e calcula-se a injeção de reativo para determinar a atuação do inversor. Esse processo está ilustrado nas Figuras 14 e 15.

## 5 CASO DE ESTUDO E ANÁLISE DE RESULTADOS

Esta seção tem como objetivo apresentar os resultados obtidos pelo AG centralizado na coordenação dos dispositivos OLTC, CB e GD, focados na regulação da tensão e na redução de perdas no sistema de distribuição. Além disso, integra-se um controle local baseado em inversores inteligentes, utilizando curvas Volt-VAr para realizar ajustes dinâmicos e complementares à solução centralizada.

Como mencionado anteriormente, a proposta está implementada em três etapas principais. A primeira etapa consiste em determinar a configuração ótima dos parâmetros do AG, avaliando o processo iterativo com diferentes tamanhos de população e quantidades de gerações. Cabe mencionar que a escolha dessa configuração foi realizada com base na rede de distribuição utilizada neste trabalho; os parâmetros podem variar em diferentes tamanhos de rede devido ao tempo de convergência do fluxo em outros sistemas.

Os dispositivos envolvidos são tratados como variáveis discretas, seguindo o esquema cromossômico descrito na seção 3.6, utilizando uma configuração básica, ou seja, um elemento para cada tipo de dispositivo.

Na segunda etapa, uma vez definidos os parâmetros ótimos do AG, seu desempenho é avaliado em diferentes cenários de carga: baixa, média e alta. O objetivo é analisar como o algoritmo responde a diversas condições de demanda e verificar sua estabilidade e capacidade de adaptação.

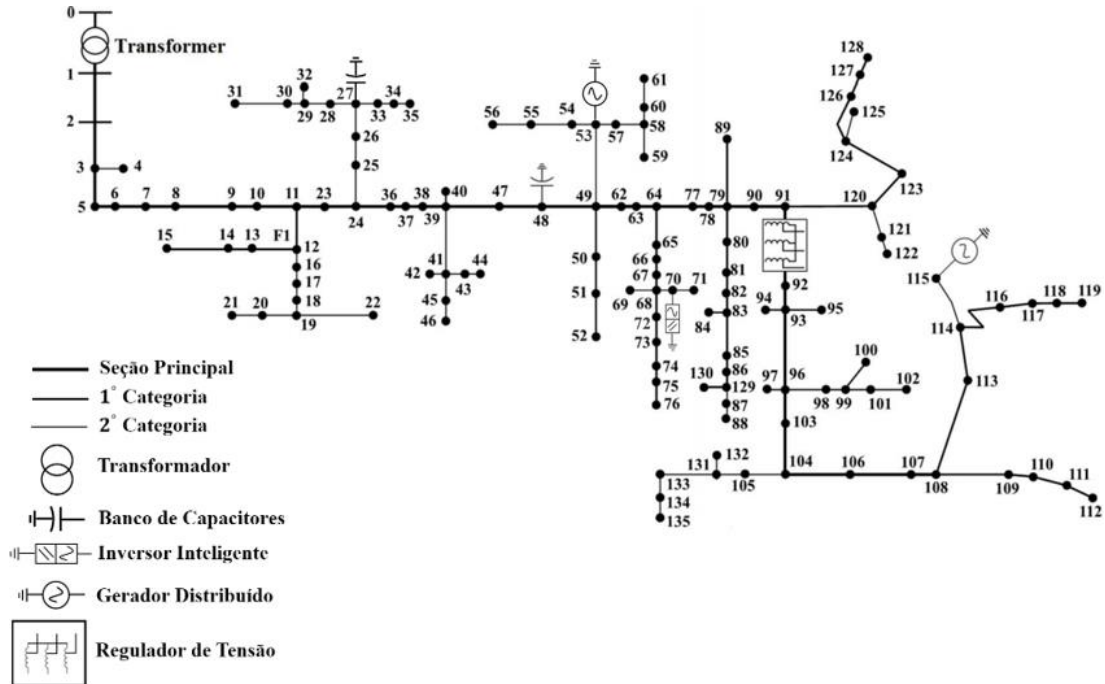
Por fim, a terceira etapa se concentra na integração do controle local. Nessa fase, a configuração ótima obtida na etapa 1 é aplicada e novamente avaliada nos três cenários de carga, mas desta vez em conjunto com o controle local Volt-VAr por meio do SI. Esse controle permite realizar ajustes contínuos e dinâmicos nos processos de compensação de tensão e potência reativa, maximizando a eficiência e a estabilidade do sistema.

A proposta foi implementada e testada em um sistema de testes para uma rede inteligente de 135 barras, apresentado e descrito em Blanco *et al.*, (2024), o qual é mostrado na Figura 16.

Os dispositivos controlados são distribuídos na rede elétrica da seguinte forma: os bancos de capacitores  $s_1$  e  $s_2$ , com capacidades de 0,9 MVAR e 0,5 MVAR, respectivamente;  $s_1$  está instalado na barra 48, enquanto  $s_2$  está localizado na barra 27. O

gerador distribuído  $u_1$  encontra-se na barra 115 e possui capacidade de 0,6 MVA despachável, enquanto o segundo gerador,  $u_2$ , está na barra 55 com capacidade de 0,3 MVA. Para este estudo, foi incluído apenas um OLTC  $k_1$ , visto que os testes iniciais

**Figura 16.** Modelo de Rede de Distribuição 135 Barras



Fonte: Adaptado de Blanco *et al.*, (2024)

indicaram que apenas um era necessário. Este está localizado na linha entre as barras 91 e 92, sendo modelado como um dispositivo com 32 posições. O inversor foi instalado na barra 70 com capacidade de 0,8 MVAR, embora a análise deste dispositivo e seu impacto no sistema sejam realizadas posteriormente.

A seguir, são listadas as diferentes etapas para observar o desenvolvimento gradual da estratégia proposta.

## 5.1 Caso de estudo 1: ajuste do AG

Essa etapa se concentra em determinar a configuração ótima para os parâmetros do algoritmo genético. As avaliações são feitas por meio das taxas de mutação e cruzamento variáveis, definidas em (49) e (50), com limites mínimos e máximos de  $0.25 \leq \rho_m \leq 0.9$  para a mutação e  $0.1 \leq \rho_c \leq 0.9$  para o cruzamento, aplicadas a

populações de 20, 40, 60 e 80 indivíduos, com testes realizados ao longo de 500 e 1000 gerações. Utiliza-se a função de parametrização definida em (51), que considera tanto o desempenho do algoritmo (*fitness*) quanto o tempo de processamento. Os valores de peso utilizados para a função objetivo foram  $w_1 = 0,8$  e  $w_2 = 0,2$  isso permite que os valores de tensão, por serem muito menores que os valores das perdas, tenham uma maior relevância na função objetivo. Para os valores de penalização, ambos os valores de  $\lambda$  utilizam um valor de 1,8. No entanto, no caso de  $\lambda_1$ , a sua aplicação ocorre de forma global sobre a penalização total de tensão. A dependência em relação à quantidade de barras com tensões fora do intervalo viável está implícita na magnitude de ( $Pe_{Vo}$ ) que aumenta proporcionalmente conforme mais barras violam os limites de tensão

Nas Tabela 5 e 6 apresentam os resultados do algoritmo genético após 500 e 1000 iterações respectivamente com os tamanhos de população previamente mencionados. Cada população foi avaliada por meio de uma amostragem de 100 testes individuais, para obter as médias de *fitness* (Fit Prom.), desvio padrão (Desvio Prom.), perdas do sistema (Perdas Prom.) e os valores mínimos alcançados nessas métricas. Também está incluída a redução de perdas (Redux Perdas) em relação ao caso base. As tabelas refletem como o tamanho da população influencia a estabilidade e a qualidade das soluções.

**Tabela 5.** Resultados das configurações para  $|\mathcal{G}|=500$

$ \mathcal{G} $	$ \mathcal{P} $	Fit prom.	Desv prom.	Perd prom	Fit Min	Desv Min	Perd Min	Redux Perd (%)
500	20	0,02890	0,0107347	129191	0,02837	0,00953	131921	89,6
500	40	0,02879	0,0106710	128837	0,02833	0,01005	129053	89,9
500	60	0,02859	0,0106340	127737	0,02829	0,01048	126589	90,0
500	80	0,02856	0,0104334	128538	0,02832	0,01004	129002	89,8

Fonte: Próprio Autor

**Tabela 6.** Resultados das configurações para  $|\mathcal{G}|=1000$

$ \mathcal{G} $	$ \mathcal{P} $	Fit prom	Desv prom	Perd prom	Fit Min	Desv Min	Perd Min	Redux Perd
1000	20	0,02883	0,0108558	128154	0,02835	0,01027	128060	89,9
1000	40	0,02864	0,0102631	129905	0,02832	0,01046	126886	90,02
1000	60	0,02852	0,0102559	129219	0,02834	0,01049	126817	90,02
1000	80	0,02847	0,0102763	128819	0,02830	0,01051	126525	90,05

Fonte: Próprio Autor

Observa-se nas Tabelas 5 e 6 que o AG consegue reduzir de forma eficaz tanto as variações de tensão, com variações médias de 0,010 pu, quanto as perdas do sistema,

alcançando reduções máximas de 90%, o que contribui para melhorar a qualidade do fornecimento de energia elétrica.

Em ambas as tabelas, evidenciam-se valores mínimos de *fitness* semelhantes; no entanto, a diferença está na consistência com que esses valores são alcançados. A configuração final, com  $|\mathcal{P}| = 80$  e  $|\mathcal{G}| = 1000$ , apresenta o menor desbalanceamento entre a média das respostas e o valor mínimo obtido, o que indica uma maior estabilidade. No entanto, isso não significa que a eficiência seja superior, pois essa configuração requer uma maior quantidade de recursos computacionais para desenvolver o processo de compensação Volt-VAr.

Isso é ilustrado por meio dos gráficos de caixa nas Figuras 17 e 18, que representam a distribuição dos valores de *fitness* obtidos sob diferentes configurações de tamanho de população e número de iterações. Esses gráficos complementam os dados tabulados ao destacar, de forma visual, a variabilidade, os valores centrais (mediana) e os possíveis valores atípicos (*outliers*) para cada configuração.

Na Figura 17, ilustra-se a consistência na geração de soluções utilizando  $|\mathcal{G}| = 500$  para cada configuração de população, enquanto, na Figura 18, avalia-se o desempenho com  $|\mathcal{G}| = 1000$ . Observa-se que a menor variabilidade está associada à configuração com  $|\mathcal{P}| = 80$  e  $|\mathcal{G}| = 1000$ , apresentando, além disso, um número reduzido de valores atípicos.

Por outro lado, ao analisar configurações com menor tamanho de população, evidencia-se uma maior variabilidade nos resultados, sendo mais pronunciada em  $|\mathcal{P}| = 20$ . Esse comportamento pode estar relacionado à rápida convergência do algoritmo. Para populações de maior tamanho, ele, na maioria dos casos, alcança um ótimo local antes de chegar à  $|\mathcal{G}| = 400$ .

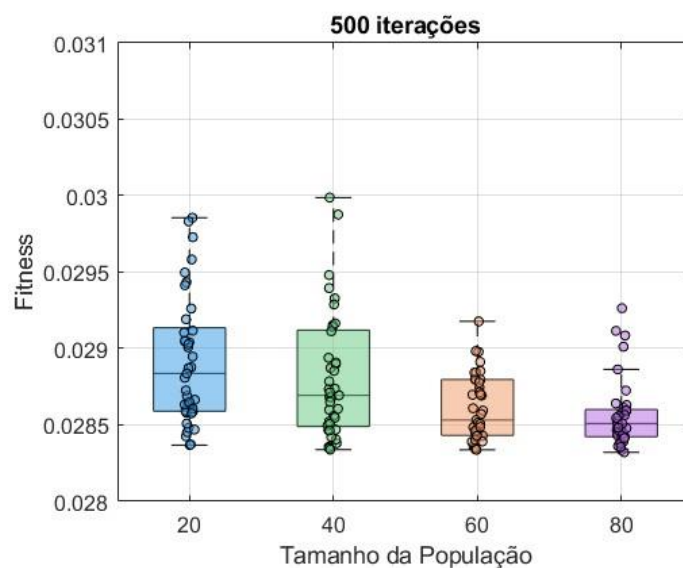
Como era de esperar, à medida que aumenta o número de gerações e o tamanho da população, a variabilidade se reduz, resultando em respostas cada vez mais consistentes.

Esse comportamento é novamente evidenciado nos gráficos das Figuras 17 e 18. Ao observar os resultados obtidos para populações de 60 e 80 indivíduos, tanto com  $|\mathcal{G}| = 500$  quanto com  $|\mathcal{G}| = 1000$  gerações, nota-se que a variabilidade nas respostas não apresenta diferenças substanciais. As médias resultantes são bastante semelhantes, o que está de acordo com o mencionado anteriormente sobre a rápida convergência do algoritmo. A menor média é observada nas configurações que consideram um total de

$|\mathcal{G}| = 1000$  gerações. No entanto, isso não se traduz em um melhor desempenho, pois essas configurações requerem um tempo de convergência significativamente maior.


Para avaliar o desempenho de cada configuração, é aplicada (51), considerando o tempo de convergência e a variabilidade do conjunto de respostas obtido por cada configuração. Os resultados estão nas Tabelas 6.

**Figura 17.** Gráfico de caixas para dispersão do fitness com  $|\mathcal{G}|=500$



Fonte: Próprio Autor

**Figura 18.** Gráfico de caixas para dispersão do fitness com  $|\mathcal{G}|=1000$



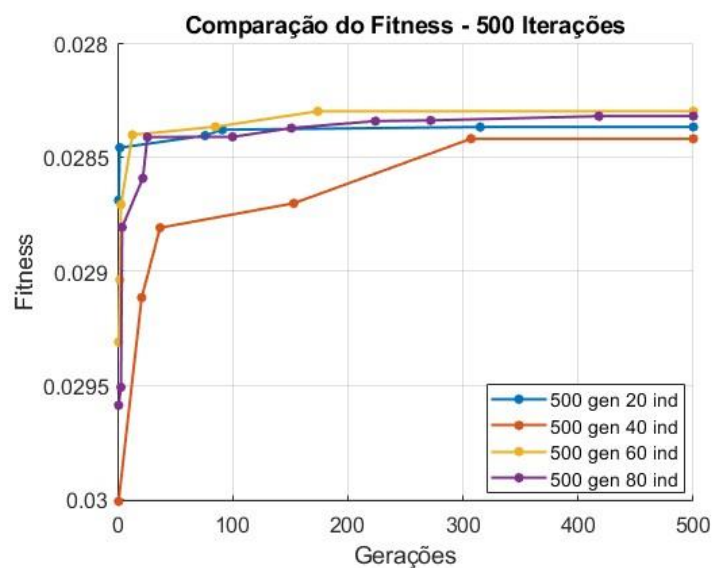
Fonte: Próprio Autor

**Tabela 7.** Resultados das Diferentes Configurações

$ \mathcal{G} $	$ \mathcal{P} $	Tempo(s)	Variância	Métrica
20	500	69,31	4,07E-07	0,58
40	500	123,711	4,06E-08	0,35
60	500	179,35	1,89E-08	0,31
80	500	238,31	1,28E-08	0,35
20	1000	123,82	6,29E-08	0,46
40	1000	235,17	2,02E-08	0,38
60	1000	343,84	6,35E-09	0,46
80	1000	450,05	1,84E-10	0,50

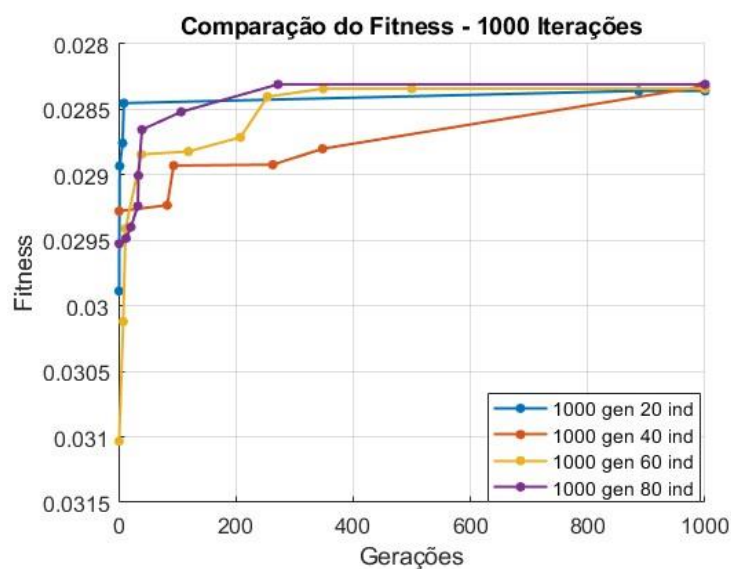
Fonte: Próprio Autor

Na Tabela 7, evidencia-se que a configuração com melhor desempenho é aquela que integra  $|\mathcal{P}| = 60$  e  $|\mathcal{G}| = 500$ . Os parâmetros avaliados, como mencionado anteriormente, incluem o tempo de convergência e a menor variabilidade nos resultados. Por isso, o melhor desempenho é definido como o menor valor obtido usando (51).

**Figura 19.** Gráfico de Evolução da Resposta de Fitness para  $|\mathcal{G}|=500$ 

Fonte: Próprio Autor

**Figura 20.** Gráfico de Evolução da Resposta de Fitness Para  $|\mathcal{G}|=1000$

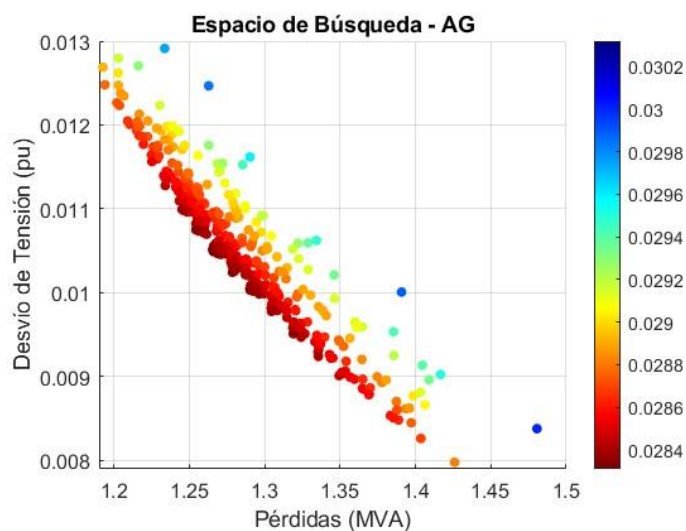


Fonte: Próprio Autor

Nas Figuras 19 e 20, mostra-se o comportamento padrão da evolução da resposta, para cada tipo de configuração, é observada a convergência rápida do algoritmo. Além disso, é possível notar que as melhores respostas são alcançadas nas configurações que utilizam um número elevado de indivíduos na população, corroborando a afirmação anterior de que, para este trabalho em específico, o fator determinante para explorar de forma otimizada o espaço de busca é o tamanho da população, e não a quantidade de gerações. Cabe mencionar que, apesar que as curvas apresentarem um comportamento ascendente, o problema continua sendo de minimização. No entanto, para fins de análise, a orientação do eixo y foi invertida a fim de mostrar de forma mais clara a evolução do fitness ao longo do processo iterativo.

Além disso, observa-se também nos gráficos das Figuras 19 e 20 que as respostas tendem a se aproximar de um ponto comum, o que pode ser interpretado como uma indicação de que a solução ótima pode estar localizada dentro desse mesmo espaço de busca. Para ilustrar essa afirmação, apresenta-se o gráfico da Figura 21, que mostra o espaço de busca explorado pelo AG. As perdas, expressas em MVA, são representadas no eixo x, enquanto os desvios, expressos em pu, estão situados no eixo y. Por meio do valor de fitness, são exibidos os valores físicos reais alcançados por cada solução. O gráfico considera todo o espectro de soluções, independentemente da configuração utilizada, sendo representadas todas as melhores soluções encontradas ao final de cada processo iterativo.

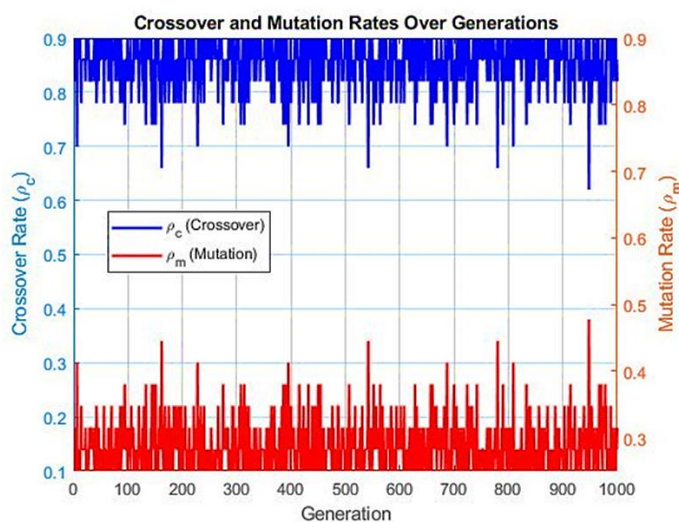
**Figura 22.** Espaço de Busca do AG



Fonte: Próprio Autor

Para concluir esta primeira etapa, é mostrado na Figura 22 o comportamento das taxas de cruzamento e mutação representadas pelas variáveis  $\rho_c$  e  $\rho_m$  durante um processo iterativo convencional com  $|G| = 500$ . Na figura é apresentado um comportamento complementar, onde o valor de cada uma varia em função da variabilidade da população. Se, em uma geração, a maior parte dos indivíduos for diferente, então a taxa de mutação é baixa, mas a de cruzamento é alta. Por outro lado, se a maioria dos indivíduos de uma população for igual ou muito semelhante, a taxa de mutação aumenta e, gradualmente, a de cruzamento é reduzida.

**Figura 21.** Comportamento das Taxas de Cruzamento e Mutação



Fonte: Próprio Autor

## 5.2 Caso de estudo 2: VVC centralizado

Uma vez determinada a configuração ideal para o AG, que apresenta um melhor equilíbrio entre tempo de convergência e dispersão das soluções, procede-se à avaliação e observação do comportamento do algoritmo nos cenários de baixa, média e alta carga.

Na Tabela 8, apresentam-se os parâmetros da rede nos três cenários de carga sem a intervenção do AG nem dos dispositivos de controle, ou seja, no caso base. Nesta tabela estão incluídos os valores de *fitness*, as variações de tensão, perdas ativas e potência aparente da rede elétrica.

**Tabela 8.** Parâmetros da Rede Para Diferentes Perfis de Carga

Carga	Fitness	Desvios	Perdas MW	Potência MVA
Baixa	0,098	0,0481	0,38	7,18
Média	0,249	0,0745	0,91	10,77
Alta	0,372	0,088	1,72	14,35

Fonte: Próprio Autor

Para observar a intervenção do AG na rede de distribuição, apresentam-se, na Tabela 9, os resultados obtidos para cada cenário de carga. Foram realizados 100 testes com a configuração previamente definida no caso de estudo 1.

**Tabela 9.** Resposta do Controle Centralizado Para Diferentes Condições de Demanda

Carga	Fit prom.	Desv prom.	Perd prom. (MW)	Fit Min	Desv Min	Perd Min (MW)	Redux Perd (%)
Baixa	0,02860	0,010515	128392	0,02833	0,01004	0,1291	89,8
Média	0,06735	0,022920	311699	0,06638	0,02220	0,3092	76
Alta	0,09304	0,029452	441845	0,09069	0,02706	0,4391	65

Fonte: Próprio Autor

Ao comparar os valores entre as Tabelas 8 e 9 de variações de tensão e perdas, observa-se que o AG consegue manter os parâmetros da rede dentro de valores estáveis e que a redução de perdas se mantém entre um 65% nos cenários de maior demanda e um 90% para demandas baixas. Além disso, há uma considerável redução das variações e uma melhora notável no *fitness*. Além disso, para o caso com maior demanda, observa-se que o valor de *fitness* associado é ainda melhor do que aquele obtido no caso base com baixa demanda, o que evidencia a eficiência do algoritmo mesmo em cenários de alta

saturação energética. Na Tabela 10, apresentam-se as melhores configurações encontradas, associadas aos valores de *fitness* mostrados na Tabela 9.

**Tabela 10.** Configurações Obtidas Pelo AG Para Cada Cenário de Carga

Demanda	Carga				
	$k_1$	$s_1$	$s_2$	$u_1$	$u_2$
Baixa	1,02	0,8	0,55	1,0	0,4
Média	1,04	0,95	0,7	1,0	0,45
Alta	1,04	1,0	0,9	1,0	0,65

Fonte: Próprio Autor

Observa-se que, em todos os cenários de carga, o primeiro GD opera a 100% de sua capacidade. Por outro lado, o segundo gerador aumenta sua injeção de potência reativa de forma gradual, em função do aumento da carga. Esse é um comportamento natural, já que o segundo gerador possui aproximadamente a metade da capacidade do primeiro, sendo sua injeção total suficiente para manter um nível de tensão ótimo. No entanto, entre o grande número de soluções de boa qualidade, existem configurações em que a injeção pode ser dividida entre ambos os bancos, o que abre margem para a inclusão de futuras restrições que priorizem uma distribuição mais uniforme da injeção entre os dispositivos controlados. No caso dos BCs, a injeção de cada um é gradual, aumentando à medida que a carga também aumenta, sendo que o primeiro banco apresenta o maior percentual de injeção, já que possui o dobro da capacidade do segundo. Consequentemente, observa-se o mesmo comportamento identificado no caso dos GDs. O OLTC aumenta a tensão em um fator de 1,02 para baixa demanda, 1,04 para cargas média e altas, evidenciando seu papel na regulação da tensão conforme as condições de carga do sistema.

### 5.3 Caso de estudo 3: controle local do SI

Para este terceiro caso de estudo, pretende-se incorporar um controle local para um SI localizado na barra 70, em conjunto com o AG e seu esquema de controle centralizado.

O gerenciamento das tarefas de regulação do inversor é executado conforme descrito na seção 4. Após o AG determinar a configuração dos dispositivos discretos de

controle, aplica-se o controle local do SI para realizar pequenos ajustes na forma de injeção ou absorção de reativo, visando melhorar o perfil de tensão.

Na Tabela 11, apresentam-se os resultados após a aplicação dessa abordagem de controle híbrido, que combina estratégias centralizadas e locais.

**Tabela 11.** Resposta do Algoritmo Híbrido Para Diferentes Condições de Demanda

<b>Carga</b>	<b>Fit prom.</b>	<b>Desv prom.</b>	<b>Perd prom. (MW)</b>	<b>Fit Min</b>	<b>Desv Min</b>	<b>Perd Min (MW)</b>	<b>Redux Perd (%)</b>
Média	0,06147	0,01912	293622	0,05983	0,018322	0,28726	77,5
Alta	0,08472	0,02264	423531	0,08248	0,021834	0,41341	67,5

Fonte: Próprio Autor

Comparando os resultados entre as Tabelas 9 e 11, evidencia-se uma melhora significativa no perfil de tensão devido à incorporação do SI já que o dispositivo é capaz de realizar injeções de potência reativa mais contínuas e flexíveis, o que permite realizar pequenos ajustes de tensão nas barras, além de alcançar uma leve redução nas perdas.

No entanto, pode-se perceber que não há presença do inversor nos cenários de baixa demanda. Isso é devido que a regulação fornecida pelos dispositivos mecânicos, somada à gestão do AG, oferece sustentação suficiente à rede, sem a necessidade de intervenção do inversor. Isso ocorre porque a tensão da rede já se encontra em valores ótimos ou semi-ótimos de operação e, conforme ilustrado na Figura 24, a faixa operacional do inversor estaria situada dentro da chamada banda morta ou deadband.

Em contrapartida, nos cenários de média e alta demanda o SI pode desempenhar um papel ativo na regulação da rede, gerando uma diferença notável no valor do *fitness* antes e depois de aplicar a gestão local do inversor.

Considerando novamente as tabelas 9 e 11, para os cenários de demanda média, tem-se uma melhoria do 9,36% no fitness em relação aos casos em que são aplicados apenas os dispositivos mecânicos. Isso acarreta uma redução notável dos desvios de tensão em 26%, e no que diz respeito à redução de perdas, obtém-se uma leve melhoria do 2%.

Isso fica mais evidente na Tabela 12, que apresenta a quantidade de potência injetada pelo SI em cada cenário de carga, em condições de carga média seu aporte é do 45%, e esse porcentagem aumenta paulatinamente nos cenários de alta demanda, onde o SI atinge até 84% de sua capacidade total. E, finalmente, em demanda baixa, a injeção do SI é zero, como foi descrito anteriormente.

**Tabela 12.** Porcentagem de Potência Injetada Pelo Inversor Para Cada Cenário de Carga

Carga		
Baixa	Meia	Alta
0,0	0,45	0,84


Fonte: Próprio Autor

Por outro lado, embora a redução de perdas não seja tão significativa em comparação com a melhora na compensação de tensão, observa-se uma notável otimização no valor de *fitness* do processo iterativo. Isso ocorre porque os fatores de ponderação  $w_1$  e  $w_2$  associados à variação de tensão e às perdas, estão definidos para atribuir uma maior importância à estabilidade da tensão, como foi descrito ao princípio do sacão. O gráfico da Figura 23, mostra que apesar da redução de perdas entre os casos base e os casos que envolvem sistemas de regulação é significativa, quando se compara entre ambas as estratégias de regulação, a diferença é mais sutil.

Por outro lado, os gráficos das figuras 24, 25 e 26 mostram os perfis de tensão e corrente em cada uma das condições de carregamento da rede.


Na Figura 24, observa-se de forma gráfica os níveis de tensão na rede. A linha vermelha reflete as tensões em cada barra do sistema, em seu estado base, ou seja, sem aplicar nenhum tipo de regulação. A linha verde mostra as melhorias graças à aplicação de dispositivos de regulação mecânica controlados pelo AG. As melhorias são bastante evidentes, graças ao AG é possível alcançar perfis de tensão que estão dentro dos parâmetros de operação ótima em cada ponto da rede. Deve-se considerar que esse gráfico é para cenários de baixa demanda, onde a regulação é de menor intensidade em comparação com cenários de maior carga.

**Figura 23.** Comparação na Redução de Perdas



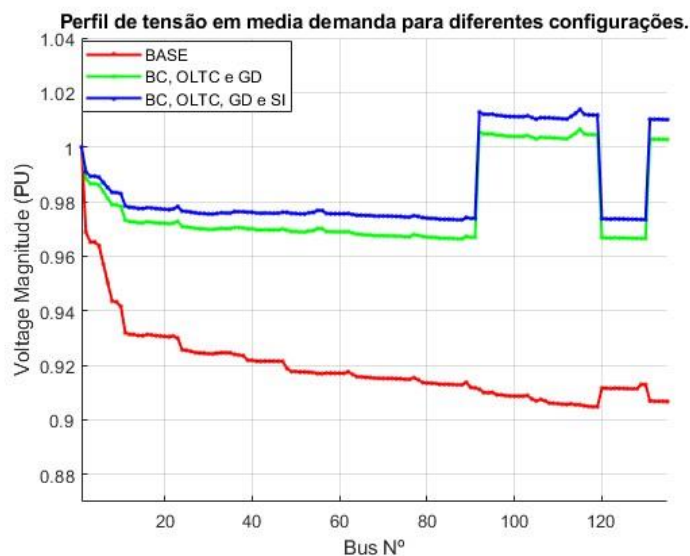
Fonte: Próprio Autor

**Figura 24.** Perfil de Tensão em Baixa Carga.




Fonte: Próprio Autor

**Figura 26.** Perfil de Tensão em Média Carga



Fonte: Próprio Autor

**Figura 25.** Perfil de Tensão em Alta Carga.



Fonte: Próprio Autor

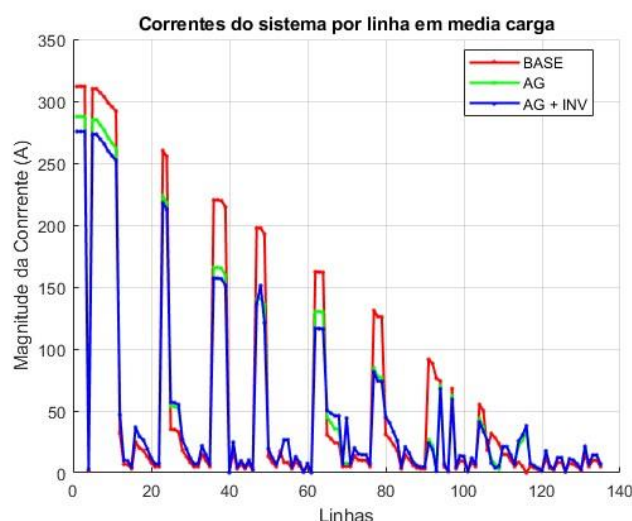
O impacto do SI nos perfis de tensão fica evidente nos gráficos das Figuras 25 e 23, nesses gráficos são mostradas as mesmas linhas vermelha e verde, associadas aos casos base e ao AG, respectivamente. Tanto para os cenários de demanda média quanto para os de alta demanda, apenas com o AG são alcançados bons valores de tensão, entre 0,97 e 1,0 pu para uma demanda média e entre 0,95 e 0,9 pu para alta demanda, sendo

possível a operação da rede com esses níveis de tensão. No entanto, se forem consideradas maiores variações na carga ou operações constantes em alta demanda energética, é evidente que a configuração atual pode não ser suficiente, sendo necessário o apoio do SI.

A linha azul presente nos gráficos 16 e 17 mostra o impacto do SI sobre os perfis de tensão. De forma geral, observam-se valores de tensão mais próximos de 1 pu em comparação aos proporcionados pelo AG. Isso se torna ainda mais evidente nos casos de demanda alta, onde as tensões se mantêm dentro da faixa de 0,97 a 1,01 pu. Considerando que, nesse cenário, o inversor injeta 85% da sua capacidade total de potência reativa, percebe-se que ele fornece a possibilidade de sustentar o sistema diante de variações maiores de carga ou aumentos futuros, evidenciando a relevância que esses controles híbridos possuem nos sistemas de distribuição modernos.

Na Figura 27, mostra-se o comportamento gráfico da corrente que flui nas diferentes linhas do sistema de distribuição em condições de carga média. Observa-se que o valor máximo de corrente corresponde ao caso base, o que é esperado, já que não possui nenhum tipo de regulação ou controle. Por outro lado, as configurações que envolvem apenas o AG e o SI apresentam um comportamento semelhante. No entanto, em algumas linhas, a magnitude da corrente é maior na configuração com o SI em comparação com a do AG.

**Figura 27.** Valores de Corrente em Média Carga



Fonte: Próprio Autor

Essa diferença pode ser atribuída à ação do SI ao injetar ou absorver potência reativa conforme a estratégia Volt-Var, o que pode gerar fluxos de correntes adicionais em


certas ramificações do sistema. Além disso, o inversor pode estar compensando flutuações locais de tensão que não são gerenciadas diretamente pelo AG, resultando em um leve aumento das correntes em algumas linhas específicas.

Para observar de forma mais direta o impacto do inversor sobre o perfil de tensão, são apresentados os gráficos das Figuras 28 e 29, os quais mostram diagramas de dispersão que ilustram o potencial de complementar uma otimização clássica baseada em dispositivos mecânicos com abordagens distribuídas de natureza mais flexível. Nos gráficos, observa-se um conjunto de valores de tensão associados à barra onde o inversor está instalado, a de número 70.

Percebe-se que ambas as abordagens conseguem alcançar uma compensação aceitável. No entanto, ao complementar a estratégia centralizada com o controle distribuído, obtém-se uma maior consistência na qualidade do fornecimento de energia. Essa combinação permite uma injeção precisa de potência, o que contribui para uma maior homogeneidade nas diferentes avaliações, reduzindo a ocorrência de valores fora da faixa desejada. Em contraste, a abordagem puramente clássica apresenta uma dispersão mais acentuada, com alguns pontos situados abaixo da média.

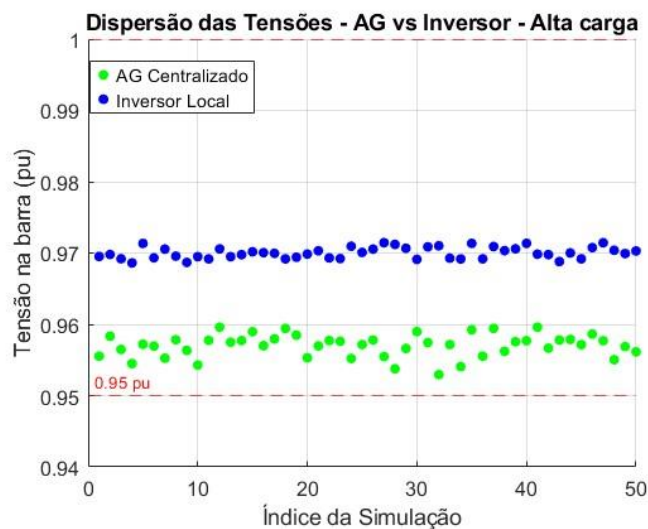
O descrito anteriormente representa uma das maiores vantagens desse controle híbrido, pois garante um fornecimento de energia mais confiável e constante diante de possíveis variações de carga. Graças a essa dualidade, as abordagens clássicas não são descartadas, mas sim complementadas por tecnologias mais modernas, resultando em um sistema de suporte de alta qualidade.

**Figura 28.** Dispersão de Tensão na Barra 70 em Média Carga



Fonte: Próprio Autor

**Figura 29.** Dispersão de Tensão na Barra 70 em Alta Carga




Fonte: Próprio Autor

#### 5.4 Análise do Fluxo de Potência Probabilístico

Esta subseção tem como objetivo apresentar os resultados obtidos pelo AG e o controle local em um ambiente dinâmico sob condições de carga horárias, ao contrário dos resultados anteriores, nos quais a análise estava limitada a condições estáticas da rede e a três cenários de carga: baixa, média e alta. Agora, será testada a eficiência e o comportamento do algoritmo sob um esquema de controle contínuo ao longo de um horizonte de 24 horas. A lógica utilizada é a descrita nas Figuras 10, 11, 14 e 15, onde o AG é executado para cada 2 horas, nas quais são realizadas as comutações dos dispositivos mecânicos, enquanto o inversor é ajustado em um intervalo menor de tempo, sendo esse ajuste realizado a cada hora durante os 7 dias da semana, exceto quando as condições de demanda forem suficientemente baixas, de modo que o inversor não precise injetar potência.

Para iniciar, é necessário primeiro analisar o comportamento do fluxo de potência probabilístico e verificar se as potências para cada hora e dia apresentam um comportamento lógico. O gráfico da Figura 30 apresenta as curvas de carga do sistema para cada hora dos diferentes dias. Observa-se que o gráfico é do tipo áreas empilhadas, pois permite uma boa visualização do comportamento da rede ao evitar a sobreposição entre as áreas, resultando em um gráfico mais limpo e fácil de analisar.

**Figura 30. Curvas de Carga Semanal**

Fonte: Próprio Autor

Cada área do gráfico representa a demanda de energia de um dia específico da semana ao longo das 24 horas. O eixo das abscissas vai de 0 a 23, pois representa as 24 horas do dia a partir da hora 0:00, enquanto o eixo das ordenadas indica a potência acumulada até um determinado ponto, não representa a demanda individual, mas sim como cada dia contribui para a soma acumulada por hora.


Por exemplo, se for considerada a hora 5:00, os pontos de fronteira entre cada área indicam a contribuição relativa de cada dia naquela hora. Isso não significa que a potência do domingo seja maior do que a soma das potências dos demais dias, mas que sua área representa uma fração do total acumulado naquela hora.

Apesar que o gráfico permite visualizar o comportamento da demanda, é útil para as análises seguintes ter uma representação mais próxima dos valores reais. As figuras 31 e 32 cumprem essa função. Para melhorar a visualização da demanda, as potências da semana foram separadas em dois gráficos: o primeiro representa as curvas de carga dos 3 primeiros dias (segunda, terça e quarta-feira), enquanto o segundo representa os dias restantes (quinta, sexta, sábado e domingo).

Observa-se que, nos gráficos, a potência oscila entre os limites para os cenários de baixa e alta demanda estabelecidos na Tabela 9, embora em determinadas horas de alguns dias a carga consiga ultrapassar alguns desses limites. Esse é um comportamento


normal, pois a estratégia emprega tanto valores probabilísticos como aleatórios, o que pode gerar valores fora do intervalo estabelecido, mas que não entorpece a análise.

**Figura 31.** Curvas de Carga Primeiros 3 Dias.



Fonte: Próprio Autor

**Figura 32.** Curvas de Carga 4 Dias Restantes



Fonte: Próprio Autor

Pode-se perceber que o dia que apresenta maiores variações de carga é a quinta-feira, exibindo valores fora dos limites mencionados, e este dia será utilizado como referência para as análises seguintes.

Além disso, os gráficos mostram que os dias com menor carga são aqueles pertencentes ao fim de semana. Isso é lógico, pois geralmente, são dias em que a atividade industrial e laboral tende a ser nula ou a operar com capacidade reduzida. Os picos de carga estão associados à mudança de escala realizada por meio da equação (23).

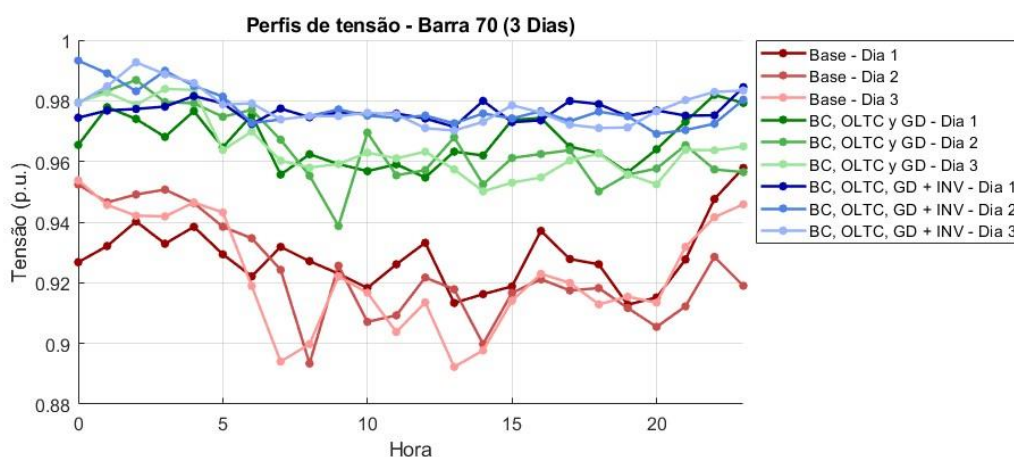
Originalmente, esses valores variavam em um intervalo de 0,5, medidos entre o valor mais alto e o mais baixo; agora, para este trabalho, o intervalo aumentou, apresentando uma diferença de até 1,1, medida entre o maior e o menor valor. Essa alteração foi necessária, porque, ao comparar os gráficos 28 e 29 com os dados da Tabela 8, percebe-se que estes atingem os limites mínimos e máximos associados às condições de carga baixa e alta, respectivamente.

A estratégia proposta se concentra na redução dos desvios de tensão e perdas, conforme é indicado na equação (38). Ao contrário da análise em condições estáticas, onde são considerados apenas instantes da rede nos quais é fácil comparar graficamente as tensões em cada barra para os casos base, VVC centralizado e controle local, nos 3 cenários de carga, tal como mostram os gráficos das Figuras 24 a 26. No entanto, na análise com fluxos horários probabilísticos não há um único perfil de tensão; há um para cada hora do dia, durante os 7 dias da semana, totalizando 168 perfis de tensão.

Para observar a eficácia da proposta, é escolhida uma barra de referência e, por meio dos gráficos das Figuras 33 e 34 são representadas as tensões dessa barra para as 24 horas e os 7 dias da semana. A barra selecionada para esta análise foi a barra 70, pois é onde está instalado o inversor e onde se espera uma maior diferença.


A Figuras 33 representam as tensões na barra 70 para os 3 primeiros dias da semana e a Figura 34 para os 4 dias restantes.

**Figura 33.** Curvas de Tensão na Barra 70 3 Dias



Fonte: Próprio Autor

**Figura 34.** Curvas de Tensão na Barra 70 4 Dias Restantes



Fonte: Próprio Autor

É importante destacar que o gráfico é constituído por 3 cores de linhas que estão associadas às estratégias empregadas na rede: a linha vermelha representa o estado base, a verde representa o VVC centralizado e a azul representa o controle local, é o mesmo código de cores utilizado em análises anteriores. Cabe mencionar que o controle local inclui tanto o inversor quanto os dispositivos mecânicos controlados pelo AG.


O tom das linhas diminui à medida que os dias passam: para o primeiro dia, o tom é intenso, enquanto para o último dia desse gráfico a cor da linha torna-se mais clara. Essa decisão foi tomada para manter a coerência no gráfico e para que o leitor associe essa cor específica a um determinado estado da rede.

Analisando as tensões, observa-se que, para os casos base, as tensões variam entre 0,95 pu para a condição de carga mais leve e descem até 0,89 pu nos picos de demanda. Quando o controle centralizado é ativado, essas tensões oscilam dentro de um intervalo aceitável de tensão, com 0,95 pu para cargas pesadas e 0,99 pu em carga leve, sendo este valor de potência incluso inferior ao mostrado na Tabela 10. Quando o controle local é combinado com o controle centralizado, as tensões não apenas atingem intervalos mais favoráveis, mas também conseguem manter um nível de estabilidade mais do que aceitável durante todos os períodos de todos os dias da semana. Isso está em linha com o observado nos casos estáticos onde o controle local, em conjunto com o controle centralizado, fornece uma maior estabilidade ao sistema, e essa estabilidade é constante, garantindo assim uma boa qualidade no fornecimento de energia elétrica.

Outra coisa a destacar é que, durante o fim de semana, as tensões obtidas tanto com a abordagem centralizada como com a híbrida apresentam níveis semelhantes, dado que se trata dos dias de menor carga. No entanto, nos períodos de maior demanda, as diferenças entre as duas abordagens tornam-se mais evidentes, evidenciando a melhoria que se consegue ao utilizar ambos os métodos em conjunto.

Um bom indicativo é o fato de que os gráficos de 30 e 31 têm tendências semelhantes aos gráficos 22 e 23, este é um ponto muito importante a considerar, uma vez que esses gráficos foram obtidos sob as mesmas condições de carga, que a demanda era exatamente a mesma quando as duas abordagens do algoritmo foram implementadas. O fato de que nos gráficos 30 e 31 se observa um comportamento similar, apesar de utilizar densidades de carga diferentes para cada dia e incorporar variáveis aleatórias, demonstra a consistência do algoritmo mesmo em condições dinâmicas.

**Figura 35.** Valores de Perda Para Cada Hora e Configuração Quinta-Feira



Fonte: Próprio Autor

Como foi mencionado anteriormente, para realizar uma análise de um dia específico foi selecionada a quinta-feira, pois ela apresenta os maiores picos de carga ao longo das suas 24 horas. O gráfico da Figura 35 mostra a análise de perdas realizada nesse dia em particular onde observa-se que as perdas são maiores nos estados base da rede e são reduzidas de forma significativa quando se implementa uma das duas estratégias, de forma semelhante ao que é mostrado na Figura 23. No entanto, ao contrário do sistema estático, aqui são observados períodos em que as

perdas são maiores nos casos que implementam o controle híbrido em comparação com os que utilizam apenas a abordagem centralizada. Isso ocorre novamente devido à aleatoriedade do sistema, pois nessas horas específicas pode ter sido gerado um valor maior de carga. Por exemplo, às 11:00, exatamente ao meio-dia, o perfil de carga obtido para a abordagem centralizada foi de 11,27 MVA, enquanto o controle híbrido apresentou uma carga de 14,7 MVA, resultando em menores perdas para a abordagem centralizada.

Para concluir os resultados, são apresentadas as Tabelas 13 e 14, as quais contêm os parâmetros da rede para a quinta-feira ao longo das 24 horas do dia. Ao contrário das Tabelas 9 e 11, não foram incluídos valores médios, já que foi avaliada uma única folha de resultados para reduzir a quantidade de dados da tabela. Observa-se que o fitness é consistente com os resultados obtidos nos casos estáticos, além de permitir relacionar o fitness alcançado com a demanda da rede em cada período, visualizando de forma mais clara o que foi afirmado anteriormente quando foram analisadas as perdas da hora 11:00, complementando assim os gráficos apresentados para esta análise.

**Tabela 13.** Resposta do Controle Centralizado Quinta-Feira

Período	Fitness	Desvio	Perdas (MW)	Potência (MVA)
0	0.0217049	0.0115373	79325.4	7.72777
1	0.0310574	0.0154434	118925	8.00424
2	0.0154118	0.00795711	57521.7	6.87224
3	0.0222403	0.0106986	86995.9	6.85348
4	0.0210048	0.0114885	75121.7	7.74831
5	0.0224445	0.0116677	83364.9	7.50127
6	0.0503601	0.024819	193971	10.9765
7	0.0799503	0.0359285	325613	13.3859
8	0.0790372	0.0357027	320955	13.5768
9	0.0972776	0.0408487	410763	14.096
10	0.0572443	0.0274473	224376	11.6036
11	0.0518064	0.0250654	201915	10.9889
12	0.0528671	0.0266651	200522	11.2716
13	0.110265	0.0455554	469404	14.3074
14	0.0942114	0.0412826	389059	14.3034
15	0.0947299	0.0412367	392589	14.1963
16	0.0478667	0.0241314	181614	10.919
17	0.0604041	0.0268633	247439	11.4379
18	0.0394818	0.0205518	146506	9.90358
19	0.0889751	0.0396499	364068	13.1425
20	0.0479337	0.023879	183324	10.3609
21	0.056973	0.0260373	229824	10.971
22	0.0250132	0.0141548	87046.8	7.96579
23	0.0435785	0.0228483	160874	9.30465

Fonte: Próprio Autor

**Tabela 14.** Resposta do Controle Híbrido Quinta-Feira

Período	Fitness	Desvio	Perdas (MW)	Potência (MVA)
0	0.0103921	0.00471658	0.042087	5.94325
1	0.0125604	0.00645612	0.047026	6.42071
2	0.0126131	0.00504386	0.0545448	6.45119
3	0.0165992	0.00784683	0.0656327	7.28572
4	0.018815	0.00834654	0.0771803	7.72786
5	0.0179675	0.00854865	0.0707634	7.79543
6	0.0402108	0.0201061	0.15341	11.3744
7	0.0637924	0.0257365	0.274716	14.3778
8	0.034238	0.0191274	0.120409	10.9117
9	0.0648488	0.0253504	0.283398	14.6031
10	0.0560854	0.0265637	0.221502	12.8762
11	0.058571	0.0265916	0.237165	12.8863
12	0.0715774	0.0301977	0.301525	14.6955
13	0.0571372	0.0273539	0.22417	13.3746
14	0.07019	0.0298286	0.29458	14.4662
15	0.0728602	0.0300056	0.310659	14.5223
16	0.0401087	0.0199509	0.15355	11.2937
17	0.0489476	0.020458	0.207174	11.7301
18	0.0369623	0.0183812	0.141527	10.2249
19	0.0455143	0.0200068	0.187638	11.6195
20	0.0493124	0.0208948	0.207272	11.7518
21	0.0417442	0.0195039	0.166223	10.5632
22	0.0252864	0.0114542	0.102522	8.49266
23	0.017006	0.00718823	0.0715701	7.18952

Fonte: Próprio Autor

## 5.5 Avaliação comparativa com técnicas de ML aplicadas ao controle Volt-Var

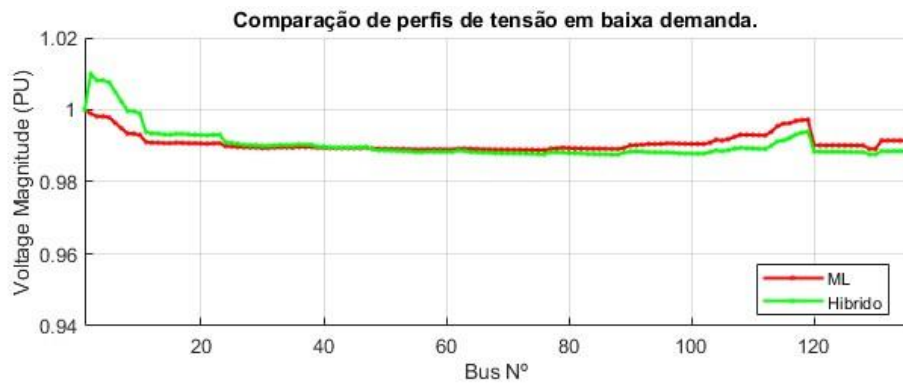
Até este ponto, foi avaliado o desempenho do algoritmo proposto tanto em cenários de rede com fluxo sequencial e probabilístico, assim como em três casos específicos de demanda. Em todos os resultados, a estratégia mostra um comportamento eficiente, mantendo níveis de tensão adequados na rede. No entanto, esses resultados foram obtidos sob seu próprio marco de referência, para validar a confiabilidade, é recomendável realizar comparações com alguma outra estratégia de controle, na qual os resultados possam ser replicados ou, pelo menos, aproximar-se dos obtidos.

Com base no exposto, trabalhou-se em conjunto com pessoal da Universidade Estadual de Ohio, na qual foi desenvolvido um sistema de controle de tensão e potência reativa utilizando a mesma rede de 135 barras como referência, sob as mesmas três condições de carga. A ideia principal é observar se os resultados são consistentes, o que implicaria que a proposta apresentada neste trabalho possui coerência e confiabilidade para a aplicação de uma estratégia VVC.

Um fator a ser considerado é que, para esses testes, a distribuição dos dispositivos foi alterada. Agora, o OLTC foi colocado entre as barras 1 e 2, aumentou-se a quantidade de BC para 6, localizados nas barras 115, 116, 117, 118, 119 e 133, com capacidades de 0,45 MVAR para o BC da barra 115 e 0,15 MVAR para cada um dos cinco restantes. O inversor foi instalado na última barra, a 135, com capacidade de 0,3 MVAR, e o uso de GD foi eliminado.

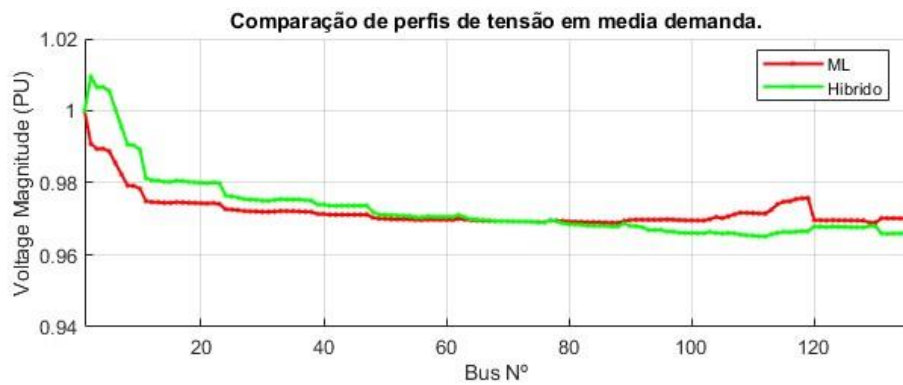
Os gráficos das Figuras 36 a 38 mostram a comparação entre os perfis de tensão alcançados por meio do AG e do controle local ou híbrido, identificados pela linha verde, e as tensões obtidas utilizando métodos de ML, representadas pela linha vermelha, para cada cenário de demanda.

**Figura 38.** Valores de Tensão – Híbrido vs. ML em baixa carga



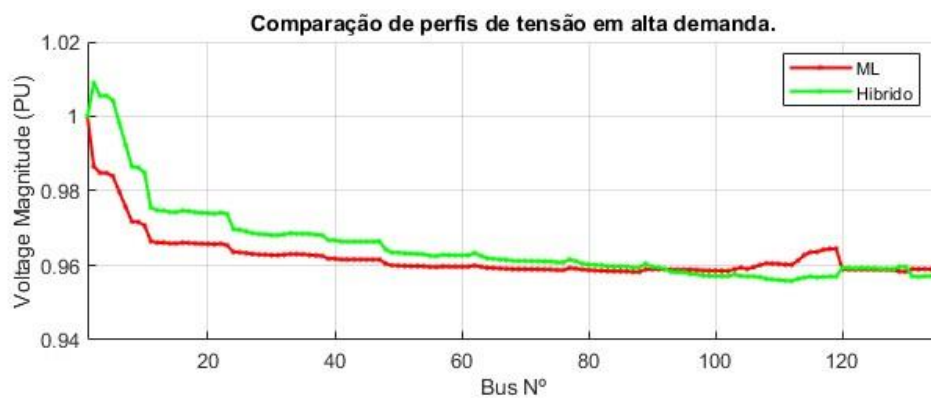
Fonte: Próprio Autor

**Figura 36.** Valores de Tensão – Híbrido vs. ML em média carga



Fonte: Próprio Autor

**Figura 37.** Valores de Tensão – Híbrido vs. ML em alta carga




Fonte: Próprio Autor

Apesar que são observadas diferenças nas tensões entre o modelo baseado no controle híbrido em comparação com o modelo baseado em ML, especialmente nas barras finais, essas diferenças residem na própria natureza do AG, já que, tratando-se de uma técnica metaheurísticas, esta não garante um ótimo global de todo o espaço de busca e por conseguinte, a resposta encontrada pelo AG não injeta a capacidade total dos BCs. No entanto, essas diferenças, embora existentes, são leves.

Também é observada uma diferença nas barras iniciais, isso se deve ao fato de que, para a abordagem de ML, o OLTC localizado na subestação fica na primeira posição do tap, enquanto a abordagem híbrida testa diferentes posições ao longo do processo iterativo do AG, por isso está sujeito a alterações o que explicaria o porquê desse aumento das tensões nas barras iniciais entre as duas abordagens. .

Ambas as abordagens alcançam níveis de tensão muito bons para o sistema. É evidente que o melhor perfil é o proporcionado pelo método híbrido. Essa melhoria pode ser resultado do efeito do AG, no qual se permite explorar diferentes configurações, mais especificamente posições do OLTC, o que também afetaria a potência injetada pelo inversor. No entanto, os resultados baseados em ML apresentam tensões bastante boas e uma estabilidade mais do que aceitável no sistema.

**Figura 39.** Valores de Perdas – Híbrido vs. ML



Fonte: Próprio Autor

O gráfico da Figura 39 mostra a comparação dos valores de perdas tanto para o modelo híbrido quanto para o baseado em técnicas de ML. Observa-se que as perdas apresentam valores bastante semelhantes, conseguindo reduzir, em ambos os casos, um

valor significativo de perdas no sistema nas três condições de demanda. No entanto, é observada uma clara melhoria associada ao algoritmo híbrido, o que pode ser devido aos efeitos do OLTC e do inversor, já que o efeito dos mesmos é maior no sistema híbrido, pois a injeção dos BC está limitada devido ao processo iterativo do AG.

Apesar das diferenças, estas resultam pequenas e de acordo com o observado nas comparações de tensão, o que favorece a confiabilidade do modelo híbrido desenvolvido para tarefas de otimização da rede.

## 6 CONCLUSÕES

O Trabalho demonstrou as diferentes vantagens existentes ao implementar um controle de tensão e reativo em um sistema de distribuição trifásico, foi observado através dos diferentes gráficos as melhorias nos níveis de tensão do sistema além da redução de perdas.

Foi observada a comparativa entre utilizar um sistema de controle clássico de caráter centralizado utilizando apenas dispositivos mecânicos e aplicar uma estratégia de controle híbrida na qual se utiliza tanto o controle centralizado em companhia de um inversor inteligente gerido por meio de um controle local. Os diferentes resultados mostram como a combinação de ambas as abordagens proporciona maior estabilidade ao sistema, mantendo níveis de tensão dentro de faixas aceitáveis e ao mesmo tempo permitindo que a rede se adapte às condições dinâmicas do sistema.

Essas condições dinâmicas foram simuladas através do fluxo de potência probabilístico apresentado neste trabalho, isso permitiu observar como a estratégia híbrida consegue realizar ajustes de injeção de potência de forma constante, evitando que, por exemplo, um passo do banco de capacitores deve ser comutado, já que o inversor complementa a potência faltante, isto traz consigo algumas vantagens, como a redução do desgaste mecânico ao minimizar as atividades de comutação.

Fazendo uma revisão sobre os três estados de rede analisados baixa, média e alta, observa-se que nas condições de baixa demanda não é necessária a intervenção do inversor ao contrário do observado quando a carga aumenta, isto permite concluir que apesar dos melhores resultados alcançados pelo controle híbrido este não deixa de ser um complemento do controle de tensão e reativo convencional, porque existem condições de rede onde a demanda é um pouco mais constante ou tem comportamento mais previsível e que a gestão pode ser feita apenas usando um controle convencional, sem ser necessário o investimento de complementar com um inversor inteligente, porque a rede não apresenta mudanças inesperadas e podem ser desenvolvidas estratégias adaptadas a esse sistema.

No entanto, se se projetam tendências de crescimento acelerado seria vantajoso considerar implementar um controle local em conjunto com a estratégia existente para fazer frente às mudanças futuras.

Além disso, as comparações realizadas entre a estratégia proposta neste trabalho e um modelo baseado em ML mostram a confiabilidade do algoritmo, já que os resultados são replicados sob as mesmas condições de demanda, mas com diferentes abordagens de controle.

Ambas as abordagens apresentam resultados de otimização favoráveis, alcançando um alto grau de estabilidade no sistema. Uma abordagem não precisa substituir a outra, pois tanto as técnicas baseadas em algoritmos de otimização quanto aquelas que utilizam técnicas de IA apresentam vantagens claras, dependendo das circunstâncias da rede ou do objetivo buscado. Se o interesse está no caráter determinístico do modelo, ou seja, que as mesmas entradas forneçam as mesmas saídas, então as abordagens baseadas em otimização são a melhor opção. Caso contrário, se o objetivo está orientado para um sistema que se antecipe a situações de risco por meio da avaliação de parâmetros ou padrões, as técnicas baseadas em IA fornecem as ferramentas necessárias para alcançar tais objetivos.

Algumas das limitações presentes na proposta seria que está restrito a operar em um sistema por hora, onde uma mudança deve ser feita após uma hora e essa mudança só pode envolver o investidor dependendo da hora. Este é um dos pontos a considerar já que o inversor sendo um dispositivo eletrônico ele está adaptado para realizar uma resposta à demanda, pois não possui limitações mecânicas, o que é um dos aspectos para melhorar na proposta.

No entanto, os resultados mostrados são satisfatórios dentro do esquema completo, pois demonstram a correta aplicação das restrições do modelo e a correta ligação entre os modelos de fluxo de potência e as estratégias de controle centralizado e local, cumprindo os objetivos estabelecidos no início do trabalho.

## 7 REFERÊNCIAS

- BABU, K. R.; KHATOD, D. K. Smart Inverter-Based Distributed Volt/Var Control for Voltage Violation Mitigation of Unbalanced Distribution Networks. **IEEE Transactions on Power Delivery**, [s. l.], v. 39, n. 3, p. 1481–1490, 2024.
- BLANCO, G. O.; LEITE, J. B.; PERALTA, R. A. V. **Power Flow Solution for Unbalanced Distribution Networks with Distributed Generator Using Sweep Method and Improved Compensation Technique**. [S. l.: s. n.], 2024.
- BRIAN JARAMILLO-LEON; ERIK JARAMILLO-LEON; W E. CHUMBI; SERGIO ZAMBRANO-ASANZA; JOHN F. FRANCO; JONATAS B. LEITE. Desempenho das funções de controle de inversores inteligentes de sistemas fotovoltaicos na regulação de tensão do sistema de distribuição. *Em: 2022*, [s. l.], . **Anais [...]**. [S. l.: s. n.], 2022.
- BUCK, R. V. **análise da técnica de solução para o problema de alocação ótima de dispositivos tradicionais de controle de tensão e reativos em redes de distribuição de energia elétrica**. Ilha Solteira: [s. n.], 2023.
- DE SOUZA, B. A.; DE ALMEIDA, A. M. F. Multiobjective Optimization and Fuzzy Logic Applied to Planning of the Volt/Var Problem in Distributions Systems. **IEEE Transactions on Power Systems**, [s. l.], v. 25, n. 3, p. 1274–1281, 2010.
- DE SOUZA, M.; LEITE, J. B.; REIZ, C. Efficient Power Flow Algorithm for Unbalanced Three-Phase Distribution Networks using Recursion and Parallel Programming. *Em: 2024 IEEE 22ND MEDITERRANEAN ELECTROTECHNICAL CONFERENCE (MELECON)*, 2024, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2024. p. 650–655.
- EATON POWERING BUSINESS WORLDWIDE. **Open air capacitor banks**. [S. l.: s. n.], [s. d.].
- ECHEVERRY R, J. Diego.; ROSA, L. H. L.; GARCIA A, J. C.; ALMEIDA, C. F.; MEDEIROS, T. S.; KAGAN, N. Algorithm for decentralized Volt/VAr control in distribution networks. *Em: 2016 17TH INTERNATIONAL CONFERENCE ON HARMONICS AND QUALITY OF POWER (ICHQP)*, 2016, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2016. p. 306–311.
- FARIVAR, M.; LIJUN CHEN; LOW, S. Equilibrium and dynamics of local voltage control in distribution systems. *Em: 52ND IEEE CONFERENCE ON DECISION AND CONTROL*, 2013, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2013. p. 4329–4334.
- GAO, Y.; WANG, W.; YU, N. Consensus Multi-Agent Reinforcement Learning for Volt-Var Control in Power Distribution Networks. **IEEE Transactions on Smart Grid**, [s. l.], v. 12, n. 4, p. 3594–3604, 2021.
- GHOLAMI, K.; ISLAM, Md. R.; RAHMAN, Md. M.; AZIZIVAHED, A.; FEKIH, A. State-of-the-art technologies for volt-var control to support the penetration of renewable

energy into the smart distribution grids. **Energy Reports**, [s. l.], v. 8, p. 8630–8651, 2022.

INTERNATIONAL ENERGY AGENCY. **Snapshot of Global PV Markets 2023 Task 1 Strategic PV Analysis and Outreach PVPS**. [S. l.: s. n.], 2023.

IWATA, S.; FUKUYAMA, Y. Dependability verification of parallel differential evolutionary particle swarm optimization based voltage and reactive power control. *Em: 2016 IEEE INTERNATIONAL CONFERENCE ON POWER SYSTEM TECHNOLOGY (POWERCON)*, 2016, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2016. p. 1–6.

JARAMILLO-LEON, B.; ZAMBRANO-ASANZA, S.; FRANCO, J. F.; LEITE, J. B. Simulation-based optimization framework to increase distribution system photovoltaic hosting capacity through optimal settings of smart inverter Volt-VAR control function. **Electric Power Systems Research**, [s. l.], v. 215, p. 108971, 2023.

KATOCH, S.; CHAUHAN, S. S.; KUMAR, V. A review on genetic algorithm: past, present, and future. **Multimedia Tools and Applications**, [s. l.], v. 80, n. 5, p. 8091–8126, 2021.

KHEIRKHAH, A. R.; NETO, J. C. das N.; JOHARI, F.; MESCHINI, C. F.; KAGAN, N.; LEITE, J. B. Quantificação da Resiliência em Redes de Distribuição por meio de Avaliação de Risco. *Em: 2023 XV BRAZILIAN CONFERENCE ON QUALITY OF POWER (CBQEE)*, 2023, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2023. p. 1–7.

LEITE, J. B.; MANTOVANI, J. R. S. Development of a Smart Grid Simulation Environment, Part I: Project of the Electrical Devices Simulator. **Journal of Control, Automation and Electrical Systems**, [s. l.], v. 26, n. 1, p. 80–95, 2015a.

LEITE, J. B.; MANTOVANI, J. R. S. Development of a Smart Grid Simulation Environment, Part I: Project of the Electrical Devices Simulator. **Journal of Control, Automation and Electrical Systems**, [s. l.], v. 26, n. 1, p. 80–95, 2015b.

LI, B.; XU, Q. A Machine Learning-Assisted Distributed Optimization Method for Inverter-Based Volt-VAR Control in Active Distribution Networks. **IEEE Transactions on Power Systems**, [s. l.], v. 39, n. 2, p. 2668–2681, 2024.

LI, Q.; ZHANG, Y.; JI, T.; LIN, X.; CAI, Z. **Volt/Var Control for Power Grids with Connections of Large-Scale Wind Farms: A Review**. [S. l.]: Institute of Electrical and Electronics Engineers Inc., 2018.

LONG, C.; OCHOA, L. F. Voltage Control of PV-Rich LV Networks: OLTC-Fitted Transformer and Capacitor Banks. **IEEE Transactions on Power Systems**, [s. l.], v. 31, n. 5, p. 4016–4025, 2016.

MA, W.; WANG, W.; CHEN, Z.; HU, R. A centralized voltage regulation method for distribution networks containing high penetrations of photovoltaic power. **International Journal of Electrical Power & Energy Systems**, [s. l.], v. 129, p. 106852, 2021.

- MALEKPOUR, A. R.; PAHWA, A.; NATARAJAN, B. Distributed volt/var control in unbalanced distribution systems with distributed generation. *Em: 2014 IEEE SYMPOSIUM ON COMPUTATIONAL INTELLIGENCE APPLICATIONS IN SMART GRID (CIASG)*, 2014, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2014. p. 1–6.
- MATAIFA, H.; KRISHNAMURTHY, S.; KRIGER, C. Volt/VAR Optimization: A Survey of Classical and Heuristic Optimization Methods. **IEEE Access**, [s. l.], v. 10, p. 13379–13399, 2022.
- MEDEIROS, T. S.; KAGAN, N. Bio-inspired metaheuristics applied to Volt/VAR Control optimization problem in smart grid context. *Em: 2016 17TH INTERNATIONAL CONFERENCE ON HARMONICS AND QUALITY OF POWER (ICHQP)*, 2016, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2016. p. 295–300.
- MEHIGAN, L.; DEANE, J. P.; GALLACHÓIR, B. P. Ó.; BERTSCH, V. A review of the role of distributed generation (DG) in future electricity systems. **Energy**, [s. l.], v. 163, p. 822–836, 2018.
- MIRAFZAL, B.; ADIB, A. On Grid-Interactive Smart Inverters: Features and Advancements. **IEEE Access**, [s. l.], v. 8, p. 160526–160536, 2020.
- MOGHADDAS-TAFRESHI, S. M.; MASHHOUR, E. Distributed generation modeling for power flow studies and a three-phase unbalanced power flow solution for radial distribution systems considering distributed generation. **Electric Power Systems Research**, [s. l.], v. 79, n. 4, p. 680–686, 2009.
- MOKGONYANA, L.; ZHANG, J.; ZHANG, L.; XIA, X. Coordinated two-stage volt/var management in distribution networks. **Electric Power Systems Research**, [s. l.], v. 141, p. 157–164, 2016.
- NAJAR, W. F.; MUFTI, M. D.; OWAIS, R.; REHMAN, N. Optimised Volt/Var Control in Distribution System with Capacitor Banks Using Genetic Algorithm. *Em: 2022 1ST INTERNATIONAL CONFERENCE ON SUSTAINABLE TECHNOLOGY FOR POWER AND ENERGY SYSTEMS (STPES)*, 2022, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2022. p. 1–6.
- NIKNAM, T.; FIROUZI, B. B.; OSTADI, A. A new fuzzy adaptive particle swarm optimization for daily Volt/Var control in distribution networks considering distributed generators. **Applied Energy**, [s. l.], v. 87, n. 6, p. 1919–1928, 2010.
- PAMSHETTI, V. B.; SINGH, S. P. Optimal coordination of PV smart inverter and traditional volt-VAR control devices for energy cost savings and voltage regulation. **International Transactions on Electrical Energy Systems**, [s. l.], v. 29, n. 7, 2019.
- PANDEY, A.; JAIN, A. Comparative Analysis of KNN Algorithm using Various Normalization Techniques. **International Journal of Computer Network and Information Security**, [s. l.], v. 9, n. 11, p. 36–42, 2017.

PANDEY, D.; NIWARIA, K.; CHOURASIA, B. Machine Learning Algorithms: A Review. **International Research Journal of Engineering and Technology**, [s. l.], 2019. Disponível em: www.irjet.net.

PARK, Jong-young; NAM, S.; PARK, Jong-keun. Control of a ULTC Considering the Dispatch Schedule of Capacitors in a Distribution System. **IEEE Transactions on Power Systems**, [s. l.], v. 22, n. 2, p. 755–761, 2007.

QIAO, F.; MA, J. Voltage/Var Control for Hybrid Distribution Networks Using Decomposition-Based Multiobjective Evolutionary Algorithm. **IEEE Access**, [s. l.], v. 8, p. 12015–12025, 2020.

QUIÑONES HUATANGARI, L.; OCHOA TOLEDO, L.; KEMPER VALVERDE, N.; GAMARRA TORRES, O.; BAZÁN CORREA, J.; DELGADO SOTO, J. Red neuronal artificial para estimar un índice de calidad de agua. **Enfoque UTE**, [s. l.], v. 11, n. 2, p. 109–120, 2020.

REIZ, C.; LEITE, J. B. Optimal Coordination of Protection Devices in Distribution Networks With Distributed Energy Resources and Microgrids. **IEEE Access**, [s. l.], v. 10, p. 99584–99594, 2022.

SHENG, W.; LIU, K.; CHENG, S.; MENG, X.; DAI, W. A Trust Region SQP Method for Coordinated Voltage Control in Smart Distribution Grid. **IEEE Transactions on Smart Grid**, [s. l.], v. 7, n. 1, p. 381–391, 2016.

SINSOMBOONTHONG, S. Performance Comparison of New Adjusted Min-Max with Decimal Scaling and Statistical Column Normalization Methods for Artificial Neural Network Classification. **International Journal of Mathematics and Mathematical Sciences**, [s. l.], v. 2022, p. 1–9, 2022.

SMITH, J. W.; SUNDERMAN, W.; DUGAN, R.; SEAL, B. Smart inverter volt/var control functions for high penetration of PV on distribution systems. *Em: 2011 IEEE/PES POWER SYSTEMS CONFERENCE AND EXPOSITION*, 2011, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2011. p. 1–6.

SVENDA, G.; KRSTIC, I.; KANJUH, S.; JAJCANIN, M.; VULETIC, D. Volt Var Watt Optimization in Distribution Network with High Penetration of Renewable Energy Sources and Electric Vehicles. *Em: 2022 IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES CONFERENCE EUROPE (ISGT-EUROPE)*, 2022, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2022. p. 1–5.

TAHIR, M.; NASSAR, M. E.; EL-SHATSHAT, R.; SALAMA, M. M. A. A review of Volt/Var control techniques in passive and active power distribution networks. *Em: 2016 IEEE SMART ENERGY GRID ENGINEERING (SEGE)*, 2016, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2016. p. 57–63.

TOMIN, N. V.; KURBATSKY, V. G.; REUTSKY, I. S. Hybrid intelligent technique for voltage/VAR control in power systems. **IET Generation, Transmission & Distribution**, [s. l.], v. 13, n. 20, p. 4724–4732, 2019.

XU, Y.; DONG, Z. Y.; ZHANG, R.; HILL, D. J. Multi-Timescale Coordinated Voltage/Var Control of High Renewable-Penetrated Distribution Systems. **IEEE Transactions on Power Systems**, [s. l.], v. 32, n. 6, p. 4398–4408, 2017.

YINDONG, Y.; ZHONGQIN, B. Advances and Future Challenges in Electric Power Big Data. *Em: 2014 SECOND INTERNATIONAL CONFERENCE ON ADVANCED CLOUD AND BIG DATA*, 2014, [s. l.], . **Anais [...]**. [S. l.]: IEEE, 2014. p. 213–219.

ZHANG, C.; XU, Y.; DONG, Z.; RAVISHANKAR, J. Three-Stage Robust Inverter-Based Voltage/Var Control for Distribution Networks With High-Level PV. **IEEE Transactions on Smart Grid**, [s. l.], v. 10, n. 1, p. 782–793, 2019.