THIAGO SAÚDE MEDEIROS

**Meta-heurísticas bio-inspiradas para otimização multiobjetivo do controle
Volt/VAr no contexto das redes elétricas inteligentes**

São Paulo

2018

THIAGO SAÚDE MEDEIROS

**Meta-heurísticas bio-inspiradas para otimização multiobjetivo do controle
Volt/VAr no contexto das redes elétricas inteligentes**

Dissertação apresentada ao Programa de
Pós-Graduação de Engenharia Elétrica da
Escola Politécnica da Universidade de São
Paulo como parte dos requisitos para
obtenção do Título de Mestre em Ciências

**São Paulo
2018**

THIAGO SAÚDE MEDEIROS

**Meta-heurísticas bio-inspiradas para otimização multiobjetivo do controle
Volt/VAr no contexto das redes elétricas inteligentes**

Dissertação apresentada ao Programa de
Pós-Graduação de Engenharia Elétrica da
Escola Politécnica da Universidade de São
Paulo como parte dos requisitos para
obtenção do Título de Mestre em Ciências

Área de Concentração: Sistemas de
Potência

Orientador: Prof. Dr. Nelson Kagan
Coorientador: Prof. Dr. Carlos Frederico
Meschini de Almeida

**São Paulo
2018**

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, _____ de _____ de _____

Assinatura do autor: _____

Assinatura do orientador: _____

Catálogo-na-publicação

Medeiros, Thiago Saúde

Meta-heurísticas bio-inspiradas para otimização multiobjetivo do controle Volt/VAr no contexto das redes elétricas inteligentes / T. S. Medeiros -- versão corr. -- São Paulo, 2018.

97 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Energia e Automação Elétricas.

1.Energia elétrica (Qualidade e otimização) 2.Distribuição de energia elétrica 3.Algoritmos (Otimização) 4.Meta-Heurísticas-Control de Volt/VAr 5.Control de Volt/VAr-Redes elétricas inteligentes I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Energia e Automação Elétricas II.t.

Aos meus pais,
Paulo e Eliana,
Pelo suporte integral
E companheirismo sem igual

AGRADECIMENTOS

Gostaria de agradecer ao Departamento de Engenharia de Energia e Automação Elétricas da Escola Politécnica da Universidade de São Paulo e a todos os companheiros do Centro de Estudos em Regulação e Qualidade de Energia (Enerq-USP), pela colaboração para que este trabalho pudesse ser realizado.

Agradecimentos especiais ao Professor Nelson Kagan, que desde 2013 me oferece a oportunidade de fazer parte de seu grupo de pesquisa, me proporcionando o meio e o conhecimento responsáveis pelo meu crescimento acadêmico e pessoal. Não há palavras para agradecer o suficiente.

Ao Professor Carlos Frederico Meschini de Almeida e ao Professor Luiz Henrique Leite Rosa pelo suporte e pelos inúmeros conselhos.

Ao amigo de todas as horas e mestrando, Renato de Albuquerque Spalding. Sempre disponível para incontáveis e fundamentais discussões que tivemos ao longo do desenvolvimento deste trabalho.

Também gostaria de agradecer ao CNPq e à CAPES, pelo apoio financeiro que auxiliou no desenvolvimento deste trabalho e na publicação de seus resultados parciais no congresso internacional ICHQP 2016, e à empresa Sinapsis, pela disponibilização da plataforma SINAPGrid, essencial para que as simulações pudessem ser realizadas.

Finalmente, gostaria de agradecer aos meus familiares, em especial ao meu pai, pela educação e experiência, pelo conhecimento e suporte que me dá desde sempre, e à minha mãe e anjo da guarda, pelo amor e carinho incondicionais e pela proteção. Sem eles, nada seria possível.

RESUMO

O presente trabalho tem como objetivo comparar o desempenho de diferentes meta-heurísticas bio-inspiradas aplicadas à resolução de problemas de otimização multiobjetivo do controle de tensão e reativos, ou controle Volt/VAr, em redes elétricas inteligentes.

Entre os algoritmos implementados estão o algoritmo genético, o algoritmo memético, a otimização por colônia de formigas, a otimização por enxame de partículas e o *strength pareto evolutionary algorithm* (SPEA2).

Aplicações dos algoritmos à resolução de problemas de otimização do controle Volt/VAr, em redes de distribuição de energia elétrica com dimensões reais, são utilizadas para comparação de seus indicadores de desempenho. A avaliação é feita tanto em relação à velocidade de busca quanto em relação à qualidade da solução encontrada.

Os algoritmos mostraram resultados promissores para aplicação a redes de distribuição com dimensões reais, encontrando soluções de qualidade em tempos de busca aceitáveis. Parte deste desempenho se dá pelos métodos meta-heurísticos, parte por conta da modelagem adotada no processo de otimização.

Palavras-chave: Distribuição de energia elétrica. Qualidade do produto. Controle Volt/VAr. Meta-heurísticas.

ABSTRACT

The present work aims at comparing the performance of different bio-inspired metaheuristics applied to the Volt/VAr control multiobjective optimization problem in smart grids.

Among the algorithms implemented are the genetic algorithm, the memetic algorithm, ant colony optimization, particle swarm optimization and the *strength pareto evolutionary algorithm* (SPEA2).

Applications of the algorithms to solve Volt/VAr control optimization problems in distribution networks with real dimensions are used to compare their performance indicators. The evaluation is done both in relation to the search speed and in relation to the quality of the solution found.

The promising results show that the algorithms are applicable to distribution networks with real dimensions, finding quality solutions in acceptable search times. This performance is obtained due to both the metaheuristic methods, and the modeling adopted in the optimization process.

Keywords: Energy distribution. Power quality. Volt/VAr control. Metaheuristics.

LISTA DE ILUSTRAÇÕES

Figura 1 - Compensações pagas pelas distribuidoras brasileiras	19
Figura 2 - Influência do OLTC no perfil de tensão do alimentador	23
Figura 3 - Influência dos RTs no perfil de tensão do alimentador	24
Figura 4 - Influência dos BCs no perfil de tensão do alimentador	25
Figura 5 - CVV baseado em um modelo do sistema de distribuição	28
Figura 6 - Função trapezoidal μJ para as perdas técnicas da rede	43
Figura 7 - Função trapezoidal μV para o nível de tensão das barras com carga da rede	43
Figura 8 - Função trapezoidal μCh para os chaveamentos executados pelos equipamentos do CVV	44
Figura 9 - Fluxograma de um algoritmo genético	47
Figura 10 - Exemplo de codificação de um indivíduo do AG	48
Figura 11 - Fluxograma da etapa de avaliação dos indivíduos	49
Figura 12 - Seleção pelo método da roleta	50
Figura 13 - Seleção pelo método do torneio binário	51
Figura 14 - Cruzamento em um ponto	52
Figura 15 - Cruzamento uniforme	52
Figura 16 - Mutação (bits destacados sofreram mutação)	53
Figura 17 - Fluxograma de um algoritmo memético	54
Figura 18 - Busca local pelo método Hill Climbing	55
Figura 19 - Fluxograma da otimização por colônia de formigas	57
Figura 20 - Exemplo de codificação de um caminho feito por uma formiga	58
Figura 21 - Deslocamento de uma formiga no diagrama de rotas	59
Figura 22 - Fluxograma da otimização por enxame de partículas	62
Figura 23 - Exemplo de codificação da localização de uma partícula	63
Figura 24 - Atualização da localização de uma partícula	66
Figura 25 - Fluxograma do SPEA2	68
Figura 26 - SPEA2: funções de ajuste brutas, maximização de f_1 e f_2	70
Figura 27 - Diagrama unifilar da rede do primeiro caso de aplicação	74
Figura 28 - Evolução média da função objetivo	75
Figura 29 - Diagrama unifilar da rede do segundo caso de aplicação	78
Figura 30 - Perdas técnicas na rede por patamar horário	79

Figura 31 - Tensão nas barras com carga da rede no patamar de maior demanda	80
Figura 32 - Perdas técnicas na rede por patamar horário	84
Figura 33 - Tensão nas barras com carga da rede no patamar de maior demanda	86
Figura 34 - Distribuição das soluções no espaço de busca	88
Figura 35 - Diagrama unifilar da rede do quarto caso de aplicação	90
Figura 36 - Distribuição das soluções não-dominadas no espaço de busca	90

LISTA DE TABELAS

Tabela 1 - Limites entre os níveis de tensão em regime permanente	17
Tabela 2 - DRP_E por consumidor por região e total nacional	18
Tabela 3 - DRC_E por consumidor por região e total nacional	18
Tabela 4 - Característica das referências estudadas	39
Tabela 5 - Comportamento da velocidade de uma partícula	65
Tabela 6 - Comparação dos indicadores de desempenho dos algoritmos	76
Tabela 7 - Redução nas perdas técnicas	79
Tabela 8 - Notas referentes ao nível de tensão nas barras com carga	81
Tabela 9 - Número médio de chaveamentos por equipamento	82
Tabela 10 - Posição de tap dos OLTCs e estado de seis BCs durante um dia de operação - AG Básico	82
Tabela 11 - Posição de tap dos OLTCs e estado de seis BCs durante um dia de operação - OEP	83
Tabela 12 - Funções objetivo a minimizar para análise de sensibilidade	84
Tabela 13 - Redução nas perdas técnicas	85
Tabela 14 - Notas referentes ao nível de tensão nas barras com carga	86
Tabela 15 - Número médio de chaveamentos por equipamento	87

LISTA DE SIGLAS E ABREVIATURAS

ACO	<i>Ant Colony Optimization</i>
AG	Algoritmo Genético
AIS	<i>Artificial Immune System</i>
AM	Algoritmo Memético
ANEEL	Agência Nacional de Energia Elétrica
BC	Banco de Capacitores
CE	Compensador Estático
CVV	Controle Volt/VAr
DMS	<i>Distribution Management System</i>
DRC	Duração Relativa da Transgressão para Tensão Crítica
DRC_E	Duração Relativa da Transgressão para Tensão Crítica Equivalente
DRC_M	Duração Relativa da Transgressão Máxima de Tensão Crítica
DRP	Duração Relativa da Transgressão para Tensão Precária
DRP_E	Duração Relativa da Transgressão para Tensão Precária Equivalente
DRP_M	Duração Relativa da Transgressão Máxima de Tensão Precária
GD	Geração Distribuída
GIS	<i>Geographic Information System</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
MDM	<i>Meter Data Management</i>
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm II</i>
OCF	Otimização por Colônia de Formigas
OEP	Otimização por Enxame de Partículas
OLTC	<i>On Load Tap Changer</i>
PLIM	Programação Linear Inteira Mista
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional
PSO	<i>Particle Swarm Optimization</i>
RED	Recurso Energético Distribuído
RT	Regulador de Tensão
SCADA	<i>Supervisory Control and Data Acquisition</i>
SPEA2	<i>Strength Pareto Evolutionary Algorithm 2</i>

SUMÁRIO

1 Introdução.....	15
1.1 Motivação do trabalho	15
1.2 Contextualização.....	16
1.3 Objetivos	19
1.4 Organização do documento	20
2 Estado da arte.....	22
2.1 Controle Volt/VAr	22
2.1.1 Equipamentos necessários para a realização do controle Volt/VAr.....	23
2.1.2 Abordagens de implantação nos sistemas de distribuição	25
2.2 Métodos de otimização do controle Volt/VAr	29
2.3 Organização das referências.....	38
3 Desenvolvimento do modelo.....	41
3.1 O problema de otimização do controle Volt/VAr	41
3.2 Algoritmos genéticos.....	46
3.3 Algoritmo memético.....	53
3.4 Colônia de formigas	56
3.5 Enxame de partículas.....	61
3.6 O problema de otimização multiobjetivo do controle Volt/Var.....	66
3.7 <i>Strength Pareto Evolutionary Algorithm 2</i>	67
4 Aplicação	73
4.1 Caso I - Análise de desempenho dos algoritmos	73
4.2 Caso II - Análise de qualidade em relação aos objetivos do CVV.....	77
4.2.1 Análise de sensibilidade	83
4.3 Caso III - Análise da resolução multiobjetivo do problema (A)	88

4.4 Caso IV- Análise da resolução multiobjetivo do problema (B).....	89
5 Conclusões	91
5.1 Tópicos para ulterior desenvolvimento.....	93
REFERÊNCIAS BIBLIOGRÁFICAS	94

1 Introdução

1.1 Motivação do trabalho

Uma das preocupações das concessionárias de distribuição de energia elétrica é garantir a qualidade do seu produto, mantendo o nível de tensão em regime permanente em conformidade com os indicadores definidos pela agência reguladora. A Agência Nacional de Energia Elétrica (ANEEL), órgão responsável por regular e fiscalizar este segmento, estabelece limites para caracterizar os níveis de tensão e limites para os indicadores de tensão em regime permanente através do Módulo 8 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) [1].

Uma das principais ferramentas utilizadas na adequação da qualidade da energia elétrica aos limites de tensão estabelecidos pela ANEEL é o controle Volt/VAr (CVV), ou controle de tensão e reativos. Trata-se do controle de equipamentos instalados na subestação de distribuição, como *On Load Tap Changers* (OLTCs), assim como equipamentos instalados ao longo da rede primária de distribuição, como reguladores de tensão (RTs) e bancos de capacitores (BCs), visando manter a tensão dentro dos limites aceitáveis em todos os pontos da rede para qualquer condição de carga e gerenciar a potência reativa na rede, que tem impacto tanto nos níveis de tensão quanto na amplitude da corrente no alimentador e, por consequência, nas perdas técnicas.

Existem diferentes abordagens possíveis para a realização do controle Volt/VAr [2]. No contexto das redes elétricas inteligentes, sistemas de distribuição com elevado grau de automação e alta penetração de comunicação bidirecional entre os elementos do sistema, o controle Volt/VAr passa a ser uma funcionalidade com possibilidade e necessidade de execução automática e dinâmica, com a utilização em tempo real das informações provenientes dos diversos equipamentos e sistemas de maneira centralizada. Um dos desafios para a adoção dessa abordagem é o tempo computacional necessário para a realização da otimização do controle Volt/VAr, devido à extensão do espaço de busca do problema [3].

Nos últimos anos, meta-heurísticas bio-inspiradas vêm sendo aplicadas com êxito em uma ampla gama de problemas de otimização, inclusive na área de sistemas de distribuição de energia elétrica. Sendo assim, deseja-se comparar a eficiência desses métodos de busca aplicados à resolução de problemas de otimização multiobjetivo do controle Volt/VAr, visando sua possível aplicação em redes de distribuição reais.

1.2 Contextualização

O controle Volt/VAr é uma ferramenta fundamental para que as concessionárias de distribuição atendam aos critérios de qualidade da energia elétrica definidos pela Agência Nacional de Energia Elétrica, ANEEL.

Esses critérios são definidos no Módulo 8 do PRODIST, onde são estabelecidos limites para caracterizar os níveis de tensão em regime permanente, os quais são divididos em três faixas: adequada, precária e crítica.

Para valores de tensão nominal (V_{nom}) entre 1kV e 69kV (redes de média tensão), a faixa adequada de tensão é definida entre 0,93p.u. e 1,05p.u. em relação à tensão de referência, que deve ser entre 95% e 105% da tensão nominal de operação do sistema. Valores de tensão de leitura (V_L) são classificados na faixa precária caso a medição se encontre entre 0,90p.u. e 0,93p.u. em relação à tensão de referência, e na faixa crítica caso a medição se encontre abaixo de 0,90p.u. ou acima de 1,05p.u..

Para valores de tensão nominal abaixo de 1kV (redes de baixa tensão), esses limites são ligeiramente diferentes, como pode ser visto na Tabela 1. Além disso, nesse caso os valores de tensão de leitura são sempre comparados com a tensão nominal de operação.

Tabela 1 - Limites entre os níveis de tensão em regime permanente

Faixa de tensão	Tensão nominal	
	$1\text{kV} < V_{\text{nom}} < 69\text{kV}$	$V_{\text{nom}} < 1\text{kV}$
Adequada	$0,93V_{\text{ref}} \leq V_L \leq 1,05V_{\text{ref}}$	$0,92V_{\text{nom}} \leq V_L \leq 1,05V_{\text{nom}}$
Precária	$0,90V_{\text{ref}} \leq V_L < 0,93V_{\text{ref}}$	$0,87V_{\text{nom}} \leq V_L < 0,92V_{\text{nom}} \parallel 1,05V_{\text{nom}} < V_L \leq 1,06V_{\text{nom}}$
Crítica	$V_L < 0,90V_{\text{ref}} \parallel V_L > 1,05V_{\text{ref}}$	$V_L < 0,87V_{\text{nom}} \parallel V_L > 1,06V_{\text{nom}}$

Fonte: [1]

Além dos limites para caracterizar os níveis de tensão em regime permanente, o PRODIST define indicadores de conformidade de tensão elétrica. Entre os indicadores individuais estão o índice de duração relativa da transgressão para tensão precária (DRP) e o para tensão crítica (DRC).

Para gerar os indicadores de um determinado consumidor, é realizada uma medição de 618 horas (uma semana), que compreende o registro de 1008 leituras obtidas em períodos consecutivos de 10 minutos cada. São necessárias 1008 leituras válidas para o cálculo dos indicadores, portanto, no caso de haver leituras expurgadas por conta de variações de tensão de curta duração ou interrupções de longa duração é necessário agregar períodos adicionais e consecutivos de medição.

A partir do conjunto de leituras válidas são verificadas a porcentagem do número de leituras realizadas em que a tensão verificada no ponto de conexão se encontra na faixa precária e crítica de tensão, para o cálculo do DRP e do DRC, respectivamente.

Essas medições devem ser feitas de forma amostral, sendo a dimensão da amostra definido em [1] de acordo com o número total de unidades consumidoras da distribuidora, ou em consumidores que tenham efetuado reclamações que se mostraram procedentes após a realização de uma inspeção técnica inicial.

O valor da duração relativa da transgressão máxima de tensão precária (DRP_M) é estabelecido pela ANEEL em 3%, para todos os níveis de tensão de atendimento. Caso as medições de tensão de um consumidor indiquem um valor de DRP superior ao DRP_M , a distribuidora tem o prazo de 90 dias para regularizar a tensão de atendimento. A Tabela 2 mostra os valores do índice de duração relativa da

transgressão para tensão precária equivalente (DRP_E) por consumidor para cada uma das regiões brasileiras e o DRP_E por consumidor brasileiro.

Tabela 2 - DRP_E por consumidor por região e total nacional

DRP _E						
Ano	Região					Brasil
	Centro-Oeste	Nordeste	Norte	Sudeste	Sul	
2010	2,09	2,53	9,02	0,97	2,79	2,21
2011	2,08	2,43	6,77	1,00	2,47	2,01
2012	1,77	2,03	6,38	0,94	1,96	1,76
2013	2,26	1,85	6,55	0,76	1,38	1,60
2014	1,83	1,62	5,66	0,79	1,28	1,46
2015	0,80	2,22	6,47	1,09	1,59	1,78
2016	0,94	1,98	4,24	1,09	1,71	1,61

Fonte: [4]

O valor da duração relativa da transgressão máxima de tensão crítica (DRC_M) é estabelecido em 0,5%, para todos os níveis de tensão de atendimento. Caso as medições de tensão de um consumidor indiquem um valor de DRC superior ao DRC_M , o prazo máximo para a distribuidora regularizar a tensão de atendimento é de 15 dias. A Tabela 3 mostra os valores do índice de duração relativa da transgressão para tensão crítica equivalente (DRC_E) por consumidor para cada uma das regiões brasileiras e o DRC_E por consumidor brasileiro.

Tabela 3 - DRC_E por consumidor por região e total nacional

DRC _E						
Ano	Região					Brasil
	Centro-Oeste	Nordeste	Norte	Sudeste	Sul	
2010	0,43	1,63	1,14	0,17	1,37	0,81
2011	0,14	1,32	0,78	0,13	1,18	0,64
2012	0,05	0,90	0,89	0,11	1,55	0,58
2013	0,13	0,75	0,63	0,07	0,67	0,38
2014	0,12	0,92	1,02	0,17	1,00	0,55
2015	0,29	1,75	2,94	0,43	1,31	1,06
2016	0,51	1,48	2,74	0,40	1,60	1,03

Fonte: [4]

Caso não ocorra a regularização da tensão de atendimento dentro do prazo especificado, a distribuidora deve compensar financeiramente todas as unidades

consumidoras submetidas à tensão de atendimento com transgressão dos indicadores até que a situação da tensão fornecida seja regularizada.

O gráfico da Figura 1 mostra o número total de compensações pagas (curva azul) e o valor total pago (barras verdes) pelas distribuidoras de energia elétrica brasileiras a partir de 2011. Em 2016 foram gastos R\$24,6 milhões em pouco mais de 358 mil compensações pagas por estas companhias, seguindo a tendência (iniciada em 2014) desses valores subirem.

Figura 1 - Compensações pagas pelas distribuidoras brasileiras

Fonte: [4]

1.3 Objetivos

Este trabalho tem como objetivo principal comparar a eficiência de diferentes meta-heurísticas bio-inspiradas aplicadas à resolução de problemas de otimização do controle Volt/VAr em redes elétricas inteligentes de distribuição, considerando múltiplos objetivos, como a minimização de perdas técnicas e do número de chaveamentos dos equipamentos de controle de tensão e potência reativa. Sendo assim, objetivos intermediários se fazem necessários, sendo estes:

- Descrição do controle Volt/VAr e de sua importância nos sistemas de distribuição de energia elétrica.
- Descrição do funcionamento das meta-heurísticas bio-inspiradas a serem implementadas.
- Aplicação dos algoritmos estudados, formulação dos problemas de otimização do controle Volt/VAr e sua aplicação em sistemas de distribuição reais.

1.4 Organização do documento

Este trabalho está organizado de modo que os capítulos que o compõe sigam de forma ordenada os objetivos almejados.

O capítulo 2 apresenta a pesquisa bibliográfica sobre o controle Volt/VAr em sistemas de distribuição de energia elétrica, a descrição dos equipamentos necessários para sua realização e as abordagens possíveis de implantação. Além disso, apresenta a revisão da literatura sobre os métodos meta-heurísticos de busca aplicados a diferentes tipos de problema de otimização, com destaque para a otimização do controle Volt/VAr.

O capítulo 3 apresenta a formulação geral do problema e a descrição do funcionamento e da terminologia dos métodos meta-heurísticos de busca a serem aplicados à resolução de problemas de otimização do controle Volt/VAr. Entre esses métodos estão os algoritmos evolutivos: algoritmo genético (AG) básico, ou canônico, uma de suas variantes, o algoritmo memético (AM) e a versão melhorada do *strength pareto evolutionary algorithm* (SPEA2); e outros algoritmos biologicamente inspirados: otimização por colônia de formigas (OCF), em inglês *ant colony optimization* (ACO), e otimização por enxame de partículas (OEP), em inglês *particle swarm optimization* (PSO).

O capítulo 4 apresenta a aplicação dos algoritmos estudados à resolução de problemas de otimização do controle Volt/VAr para três casos. No primeiro, os algoritmos são aplicados a uma rede de menor porte, visando comparar seus indicadores de desempenho. No segundo caso, é utilizada uma rede real de distribuição, de maior porte, de forma a analisar o comportamento dos algoritmos em

relação aos objetivos do CVV. Finalmente, é realizado um estudo de caso no qual é aplicado o algoritmo de otimização multiobjetivo SPEA2.

O capítulo 5 apresenta as conclusões gerais deste trabalho e tópicos para desenvolvimento futuro.

2 Estado da arte

Neste capítulo é apresentada a pesquisa bibliográfica referente ao controle Volt/VAr, a descrição dos equipamentos necessários para sua realização e a descrição das abordagens possíveis de implantação nos sistemas de distribuição de energia elétrica. Em seguida, é apresentada uma série de aplicações dos métodos meta-heurísticos de otimização.

2.1 Controle Volt/VAr

O controle Volt/VAr é uma das ferramentas fundamentais de operação para qualquer sistema de distribuição de energia elétrica [5]. Refere-se ao controle de equipamentos instalados na subestação de distribuição, como *On Load Tap Changers*, e na rede primária de distribuição, como reguladores de tensão, bancos de capacitores e compensadores estáticos (CEs).

Seu principal objetivo é manter a tensão ao longo de toda a rede elétrica dentro dos limites aceitáveis, qualquer que seja a condição de carga do sistema [5]. Portanto, está diretamente relacionado à qualidade da energia distribuída, especialmente em relação a variações de tensão de longa duração. Além disso, visa gerenciar a potência reativa da rede, reduzindo a magnitude da corrente no alimentador, influenciando na redução das perdas técnicas e na diminuição da queda de tensão ao longo da rede.

No contexto das redes elétricas inteligentes, cujo foco é o aumento da eficiência e da confiabilidade do sistema, os objetivos do controle Volt/VAr podem ser expandidos. Além dos já citados, três objetivos adicionais são desejáveis, sendo esses: a redução da demanda elétrica (e consequentemente da energia elétrica consumida) através do controle dos níveis de tensão no sistema (assumindo que as cargas são dependentes da tensão), execução do CVV em casos de reconfiguração de rede em condição normal ou de emergência (*self-healing*) e execução do CVV na presença de recursos energéticos distribuídos, como geração distribuída (GD) e elementos de armazenamento de energia [5]. Com isso, é necessário que o controle Volt/VAr seja flexível e dinâmico.

2.1.1 Equipamentos necessários para a realização do controle Volt/VAr

Nesta seção serão apresentados os equipamentos mais utilizados na realização do controle Volt/VAr e suas principais características [6].

- Transformadores com *On Load Tap Changer*

Os transformadores equipados com comutador de derivação sob carga, em inglês *On Load Tap Changer* (OLTC), são equipamentos localizados nas subestações de distribuição.

São responsáveis por controlar a tensão nos barramentos de carga das subestações. Tipicamente, as derivações encontram-se no enrolamento de alta tensão (primário), e através da variação da relação de transformação, a tensão no enrolamento secundário é controlada. O gráfico da Figura 2 mostra a influência de um transformador com OLTC no perfil de tensão de um alimentador.

Figura 2 - Influência do OLTC no perfil de tensão do alimentador

Fonte: Autor

- Reguladores de tensão

Os reguladores são equipamentos, em geral compostos por uma ou mais unidades monofásicas de autotransformadores, utilizados no controle de tensão ao longo do alimentador de distribuição. Possuem o funcionamento similar ao dos transformadores com OLTC, controlando a tensão à jusante através da comutação da derivação do

enrolamento do transformador. O gráfico da Figura 3 mostra a influência dos reguladores de tensão no perfil de tensão de um alimentador.

Figura 3 - Influência dos RTs no perfil de tensão do alimentador

Fonte: Autor

- Bancos de capacitores

Os bancos de capacitores são equipamentos utilizados no gerenciamento de potência reativa da rede de distribuição. Usualmente estão localizados nos barramentos das subestações e ao longo do alimentador, próximos às cargas com maior demanda de reativos.

Através da injeção de potência reativa capacitiva na rede, corrigem o fator de potência, tipicamente indutivo, normalmente deixando-o próximo da unidade. Com isso, a magnitude da corrente do alimentador é reduzida, provocando redução das perdas técnicas na rede e da queda de tensão ao longo dos condutores. O gráfico da Figura 4 mostra a influência dos bancos de capacitores no perfil de tensão de um alimentador.

Figura 4 - Influência dos BCs no perfil de tensão do alimentador

Fonte: Autor

2.1.2 Abordagens de implantação nos sistemas de distribuição

Para a realização do controle Volt/VAr nos sistemas de distribuição de energia elétrica, são necessárias quatro etapas, sendo essas: (i) medições das grandezas elétricas, (ii) verificar se as medições indicam condições esperadas de operação, (iii) determinar ações de controle para estabelecer melhores condições de operação (caso necessário) e (iv) enviar comandos para os equipamentos de controle de tensão e reativos para que estas ações de controle sejam executadas [2].

Existem diversas abordagens possíveis para que o controle Volt/VAr seja realizado, sendo as mais comumente utilizadas [3]:

- Controle local

Consiste na utilização de medições locais, como tensão, corrente, fator de potência e horário, para a determinação das ações de controle que devem ser executadas pelos equipamentos de controle de tensão e potência reativa de forma autônoma e independente, com o objetivo de melhorar as condições de operação da rede.

Essa abordagem, apesar de ser economicamente atrativa, possui diversas limitações, uma vez que não leva em consideração a operação do sistema de forma global e otimizada. Isso pode provocar a realização desnecessária de ações de controle durante o processo de melhoria dos níveis de tensão e potência reativa, podendo levar o CVV a operações inadequadas em casos de reconfiguração de rede e na presença de recursos energéticos distribuídos.

Atualmente, essa forma de controle de tensão e reativos nas redes de média tensão é a mais utilizada pelas concessionárias de distribuição de energia elétrica brasileiras, devido ao seu custo reduzido, facilidade de implantação e escalabilidade.

- Controle baseado em regras pré-definidas

Esse tipo de controle necessita que todos os equipamentos de controle de tensão e potência reativa sejam monitorados e controlados pelo Sistema de Supervisão e Aquisição de Dados, em inglês *Supervisory Control and Data Acquisition* (SCADA). O sistema é responsável por adquirir as medições realizadas pelos equipamentos em campo, determinar (baseado em um conjunto de regras pré-definidas) as ações do CVV necessárias para que a rede seja operada de maneira mais eficiente e enviar os comandos necessários para os equipamentos de controle de tensão e potência reativa.

Apesar do custo elevado por conta da necessidade de infraestrutura de telecomunicação, essa abordagem possui diversas vantagens em relação à anterior, como a medição de grandezas elétricas em pontos estratégicos da rede e função de auto monitoramento. Essas características permitem que a tomada de decisão sobre as ações de controle a serem executadas seja mais eficiente e que o operador do sistema seja notificado em caso de falha no controle. Porém, como o sistema se baseia em um conjunto de regras pré-definidas para a tomada de decisões, esse tipo de controle não se adapta bem em situações de reconfiguração de rede ou em condições de operação variáveis.

- Controle otimizado com base em um modelo do sistema de distribuição

Essa abordagem contempla todos os objetivos almejados para o CVV no contexto das redes elétricas inteligentes. Nesse contexto, a comunicação bidirecional para troca de

informações entre os elementos do sistema é fundamental. Sendo assim, para a aplicação desta abordagem é necessário que os sistemas utilizados pelas distribuidoras de energia sejam integrados, permitindo que haja troca de informação entre eles.

No controle Volt/VAr baseado em um modelo do sistema de distribuição, a ferramenta de otimização de controle Volt/VAr se encontra no nível do *Distribution Management System* (DMS), sistema com inúmeras aplicações que visam o monitoramento e controle do sistema de distribuição. Além disso, são necessárias informações provenientes de outros sistemas técnicos de TI para que a otimização do problema seja feita com uma visão global do sistema de distribuição. Entre estes sistemas estão o de informações geográficas, em inglês *Geographic Information System* (GIS) e o sistema de dados de medições para faturamento, em inglês *Meter Data Management* (MDM), além do SCADA, já mencionado na abordagem anterior.

A integração desses sistemas técnicos de TI é feita com base nas normas IEC 61968, com foco nos sistemas utilizados na distribuição de energia, e IEC 61970, com foco em sistemas de gerenciamento de energia. Juntas elas definem o *Common Information Model* (CIM), padrão que, por modelar os elementos da rede elétrica e os dados referentes a eles, permite a troca de informação entre diferentes aplicações.

O diagrama da Figura 5 mostra o fluxo de informações, medições de campo e comandos para equipamentos no controle Volt/VAr com base em um modelo do sistema de distribuição.

Medições provenientes dos equipamentos e medidores em campo são adquiridas pelos sistemas SCADA e MDM. Essas medições, em conjunto com os dados do sistema GIS, são utilizados no cálculo de estimação de estados, resultando em um modelo detalhado do sistema de distribuição. Com o auxílio desse modelo e de cálculos de fluxo de potência, a ferramenta de otimização do controle Volt/VAr define um plano de ações de controle ótimo. Esse plano é enviado para o SCADA que, por sua vez, envia os comandos necessários para os equipamentos em campo.

Figura 5 - CVV baseado em um modelo do sistema de distribuição

Fonte: Autor

Esse tipo de controle apresenta inúmeras vantagens em relação às abordagens anteriores. Além de permitir uma total coordenação entre os equipamentos de controle de tensão e de potência reativa, permite a otimização global do sistema com objetivos operacionais flexíveis. Somado a isso, por conta da modelagem precisa e dinâmica da rede, o CVV pode se adaptar a situações de reconfiguração de rede e a alta penetração de geração distribuída no sistema, característica não existente nas abordagens descritas anteriormente. Sendo assim, esse tipo de controle é capaz de contemplar todos os objetivos almejados para o CVV no contexto das redes elétricas inteligentes.

No Brasil, existem alguns casos de aplicação piloto do CVV centralizado, localizados nas cidades de Aquiraz, no Ceará (Coelce), Sete Lagoas, em Minas Gerais (Cemig) Armação dos Búzios, no Rio de Janeiro (Ampla), Aparecida, em São Paulo (EDP) e Barueri, em São Paulo (Eletropaulo) [7].

2.2 Métodos de otimização do controle Volt/VAr

Diversos métodos de otimização podem ser utilizados para realizar a otimização do controle Volt/VAr, como a programação quadrática [8], programação dinâmica [9] e programação linear inteira mista [10]. Com o passar do tempo, técnicas analíticas baseadas na simplificação e divisão do problema em partes menores foram substituídas por técnicas baseadas em regras pré-definidas. Nos últimos 15 anos, devido ao aumento do espaço de busca do problema, as meta-heurísticas começaram a ser utilizadas. A seguir serão apresentados alguns exemplos de técnicas utilizadas na otimização do controle Volt/VAr encontradas na literatura, com destaque para as meta-heurísticas bio-inspiradas.

- Programação dinâmica

Em [9], uma rede neural artificial é utilizada para obtenção de um cronograma preliminar de estados do OLTC e de um BC instalado na subestação para o próximo dia de operação. Esse cronograma é refinado através de uma programação dinâmica com lógica difusa.

Os objetivos desejados são manter a tensão de saída da subestação em um valor especificado, manter o fator de potência do transformador principal o mais alto possível e minimizar a quantidade de mudanças de tap no transformador e de chaveamentos do BC. Todos os objetivos são incluídos na função objetivo do problema através de funções de pertinência.

Nas restrições do problema são considerados limites diários de chaveamentos realizados pelos equipamentos, limites de tensão na barra de saída da subestação e um limite inferior para o fator de potência no transformador.

A metodologia é aplicada para um dia de operação de uma subestação em Taiwan e os resultados simulados são comparados com as medições feitas em campo.

O cronograma de estados do BC obtido pela programação dinâmica foi muito similar ao executado pelo operador do sistema, diferindo apenas em um patamar de carga. Com isso, os resultados da simulação foram muito próximos das medições de campo.

em relação ao fator de potência. No patamar em que diferem, a solução proposta pelo artigo apresentou um fator de potência mais próximo da unidade.

Quanto ao nível da tensão na saída da subestação, os resultados simulados (taps do OLTC definidos pelo método proposto) foram melhores do que os medidos em campo (taps definidos de maneira não otimizada). Com o cronograma de posições de tap definido pela metodologia, a tensão se manteve mais estável e próxima de 1,0p.u., apesar de ser necessário um maior número de chaveamentos executados pelo OLTC.

- Programação linear inteira mista

Em [10], o problema de controle Volt/VAr é tratado através da otimização do despacho de recursos energéticos distribuídos (REDs) para o próximo dia de operação. O problema é dividido em duas partes, ambas resolvidas através de programação linear inteira mista (PLIM).

Na primeira parte, a metodologia visa encontrar um cronograma de despacho dos REDs, em termos de potência ativa e reativa, para o próximo dia de operação. Para isso, são levados em conta: previsões de carga na rede e de capacidade de produção dos REDs, os limites de produção das gerações distribuídas que não podem ser controladas e o estado inicial dos elementos armazenadores de energia. Então, a PLIM é utilizada de modo a minimizar a soma do custo de operação das unidades geradoras.

Na segunda parte da metodologia, o problema de controle Volt/VAr é linearizado, e a PLIM é utilizada para otimizar o cronograma estabelecido inicialmente a cada 15 minutos. O objetivo do problema é minimizar a diferença entre o novo valor de potência ativa e reativa das unidades geradoras em relação ao valor do cronograma inicial, as perdas técnicas na rede e a diferença do nível de tensão nas barras em relação ao valor de referência.

A metodologia foi implementada em Matlab e aplicada a uma rede de 120 barras, composta de dois alimentadores urbanos e dois rurais, em um total de dois OLTCs e dez REDs controláveis. Ao comparar os resultados da metodologia com a simulação da rede sem os equipamentos de CVV, foram observadas melhoras tanto nos perfis de tensão dos alimentadores, que se aproximaram do valor de referência

estabelecido, quanto na redução de perdas técnicas na rede (40% no patamar de menor carga e 15% no patamar de maior carga).

- Recozimento simulado

Em [11] é utilizada a meta-heurística do recozimento simulado, em inglês *simulated annealing*, com o auxílio da lógica difusa para obtenção de um cronograma de estados do OLTC e de BCs instalados na subestação e ao longo da rede para um dia de operação.

O problema é formulado de modo que se deve encontrar a posição de tap do OLTC e o estado dos BCs para os 24 patamares do dia seguinte de operação, visando minimizar as funções de pertinência relativas ao módulo da diferença entre a tensão na barra de saída da subestação e uma tensão de referência, ao fluxo de potência reativa no transformador, às perdas técnicas nos alimentadores e ao número de chaveamentos do OLTC e dos BCs.

Nas restrições são considerados os limites diários de chaveamentos realizados pelos equipamentos e limites de tensão nas barras da rede.

A metodologia é aplicada para um dia de operação de uma rede de 32 barras, com um OLTC e onze BCs, sendo um localizado na subestação e os outros dez distribuídos em cinco alimentadores. Os resultados são comparados com as medições feitas em campo no dia de operação escolhido.

O cronograma de estados dos equipamentos de CVV encontrado pela metodologia apresentou melhores resultados do que o executado pelo operador, tanto em relação aos níveis de tensão na rede quanto em relação à redução no fluxo de reativos no transformador da subestação, com significativa redução nas funções de pertinência destas grandezas (40% e 49%, respectivamente). Já a função de pertinência relativa às perdas técnicas na rede foi próxima nos dois casos, sendo o resultado da função de pertinência da metodologia cerca de 2% maior.

- Evolução diferencial

Em [12], a otimização do fluxo de potência reativa na rede é realizada através da evolução diferencial. O algoritmo busca o tap do OLTC e a potência de compensadores estáticos de reativos com valores discretos e escalonados de modo a minimizar as perdas técnicas no sistema, com a restrição de manter a tensão nas barras dentro de um limite especificado.

O algoritmo é aplicado a três redes teste do IEEE, de 14, 30 e 57 barras, todas com um transformador com OLTC e dois compensadores estáticos de reativos. Como resultado, foi obtida uma redução nas perdas técnicas de 8%, 8% e 16% em relação ao caso base para cada rede, respectivamente.

O algoritmo também é comparado a outros algoritmos, como o algoritmo genético canônico e à otimização por enxame de partículas, em relação à qualidade da solução encontrada e ao número de cálculos de fluxo de potência necessários para a otimização do CVV, sendo mais eficiente em ambos os critérios.

- Sistemas imunológicos artificiais

Em [13] é utilizado um algoritmo de sistema imunológico artificial, em inglês *artificial immune system* (AIS), para otimizar o controle de tensão em sistemas de distribuição de energia.

O problema consiste em coordenar a operação dos OLTCs, RTs e BCs de modo a otimizar o controle de tensão na rede, minimizando o custo de operação desses equipamentos, com a restrição de manter o nível de tensão em todos os nós da rede dentro dos limites especificados pelo PRODIST.

A metodologia consiste em aplicar o AIS para otimizar o controle de tensão sempre que houver alguma barra do sistema com a tensão fora do limite especificado. São adotadas algumas modificações no algoritmo visando restringir o espaço de busca e limitar o número de chaveamentos dos equipamentos. Por exemplo, soluções em que dois reguladores de tensão diferentes alterem o tap de uma mesma fase são descartadas, prevenindo que as ações dos reguladores se cancelem ou se amplifiquem.

Para testar o método, são realizadas simulações em duas redes diferentes. No primeiro caso, é utilizada a rede IEEE de 34 barras, com um OLTC, dois reguladores de tensão e dois bancos de capacitores. São utilizadas duas curvas de carga características para obtenção da tensão nas barras. Além de zerar o número de chaveamentos simultâneos, o algoritmo proposto apresenta redução de 78% a 82% (dependendo da carga considerada) no número de chaveamentos diários quando comparado ao método de controle executado pelos relés dos equipamentos (*line drop compensation*).

No segundo caso é utilizada uma rede real de 176 barras, com um OLTC, dois reguladores de tensão e um banco de capacitores. Nesse caso é utilizada uma curva de carga obtida através de medições realizadas na subestação e ao longo do alimentador. Os resultados obtidos foram semelhantes aos do caso anterior: não ocorreram chaveamentos simultâneos dos equipamentos e os chaveamentos realizados ao longo do dia de operação foram reduzidos em 72%.

- Algoritmos genéticos

Algoritmos genéticos são algoritmos baseados na teoria da evolução de Darwin. Consistem na aplicação de uma sequência de operadores genéticos a uma população de indivíduos, representantes de soluções do problema, a fim de modificá-los e torná-los mais aptos a sobreviverem.

Em [14] é utilizado um algoritmo genético básico, porém com seleção pelo método de torneio, para obtenção de um cronograma de estados do OLTC e de BCs para o próximo dia de operação. A função objetivo do problema é relacionada à minimização da perda de energia ao longo do dia, com as restrições de manter a tensão dentro de um limite especificado, limitar o número de chaveamentos dos BCs e de limitar as mudanças de tap do OLTC.

Em [15] é utilizado um algoritmo genético básico, porém com elitismo, com o objetivo de minimizar a perda de energia no sistema com a restrição de manter a tensão nas barras dentro de um limite especificado. O algoritmo se mostra eficiente e robusto na realização do controle da posição de tap do OLTC e no dimensionamento do banco

de capacitores da subestação, além da definição de valores de referência de tensão para as unidades de geração distribuída.

Em [16] é utilizado um algoritmo genético auto adaptativo com codificação real na resolução do problema de otimização do despacho de potência reativa. O objetivo desejado é minimizar as perdas técnicas no sistema através do controle de OLTCs, RTs e BCs. O algoritmo é comparado a um algoritmo de programação evolutiva, tendo sua eficiência e robustez evidenciados.

Em [17], a otimização multiobjetivo e a lógica fuzzy são aplicados ao planejamento do controle Volt/VAr em sistemas de distribuição. Tem como objetivos a minimização da perda anual de energia no sistema e a minimização do desvio da tensão nas barras em relação à tensão nominal, através da alocação de reguladores de tensão e de bancos de capacitores.

Em [18] é utilizado um algoritmo genético multiobjetivo, o *non-dominated sorting genetic algorithm* (NSGA-II), para otimização do controle Volt/VAr, visando a redução do pico de consumo durante a fase de operação do sistema.

O problema é tal que se deve encontrar a posição de tap dos OLTCs e RTs e o estado dos BCs de modo a minimizar as duas funções objetivo definidas, sendo uma delas referente à minimização da potência ativa total do sistema (potência demandada pelas cargas e perdas técnicas) e a outra, referente à minimização do desvio da tensão em cada barra do sistema em relação à tensão nominal.

Nas restrições do problema são considerados os limites superior e inferior de tensão definidos pela agência regulatória e limites de operação para o fator de potência na subestação.

A técnica de otimização é aplicada para um dia de operação em uma rede de 95 barras, com um OLTC, dois RTs e um BC com seis degraus de potência reativa injetada.

Por conta da otimização multiobjetivo, que busca minimizar as funções objetivo referentes à potência ativa total do sistema e ao desvio da tensão de cada barra do sistema em relação à tensão nominal, um conjunto de soluções para o problema é

encontrado. São analisados três casos: a solução com maior economia de energia, uma solução com economia moderada de energia, e uma solução híbrida, com máxima economia nos patamares de pico de consumo e economia moderada nos outros patamares de carga.

As três soluções respeitam o limite regulatório de tensão em todas as barras da rede para todos os patamares horários da curva de carga.

Foram alcançadas reduções no consumo de energia entre 2,28% e 4,55% e nas perdas técnicas entre 3,09% e 4,65%, com a ressalva de que o caso com máxima economia de energia opera com a tensão nas barras em um nível mais próximo ao limite inferior definido. Além disso, as três soluções apresentam um fator de potência na subestação mais elevado que o caso base.

Outro resultado mostrado pelo artigo é a redução no consumo de energia no horário de pico, sendo de 5,62% na solução de maior economia e de 3,11% na solução de economia moderada. Esse resultado é importante pois demonstra que o CVV pode ser utilizado para aumentar a capacidade de carga suportada pelos alimentadores, postergando a necessidade de investimentos na rede.

- Algoritmos meméticos

Algoritmos meméticos apresentam funcionamento análogo à evolução de indivíduos no ramo das artes marciais, buscando aprimorar sequências de golpes através de treinamento, cooperação e competição. Consistem na aplicação de uma sequência de operadores a uma população de indivíduos, a fim de submetê-los ao processo de evolução cultural. São uma derivação dos algoritmos genéticos, com a realização de buscas locais em cada um dos indivíduos da população.

Em [19] é utilizado um algoritmo mémetico no problema de alocação ótima de bancos de capacitores em redes de distribuição radiais de grande porte. Esse problema precede o problema de otimização do controle Volt/VAr, além de apresentar semelhanças matemáticas, visto que ambos possuem como objetivo a minimização das perdas técnicas na rede através do uso de bancos de capacitores.

- Colônia de formigas

A otimização por colônia de formigas é um algoritmo baseado no comportamento das formigas em busca de alimento. Consiste na busca do menor caminho entre a colônia e a fonte de alimento, que é encontrado devido à relação de proporcionalidade entre a chance de uma formiga escolher certo caminho e a quantidade de feromônio, substância depositada pelas formigas ao caminhar, existente neste caminho.

Em [20], o controle de tensão na rede é realizado através da otimização por colônia de formigas. O algoritmo é aplicado em um espaço de busca contínuo e, a partir das tensões de saída dos OLTCs encontradas, são definidos os respectivos taps de modo a minimizar as perdas técnicas na rede.

O algoritmo é aplicado na rede IEEE de 30 barras, com quatro transformadores com OLTC. São realizadas simulações para dez condições de demanda de potência reativa numa das barras do sistema.

No melhor caso, obteve-se uma redução de 3,59% nas perdas do sistema e uma melhora de 5,61% no nível de tensão na barra.

Outro resultado exibido no artigo é que o número de formigas na colônia aparentemente não influencia no resultado obtido.

- Enxame de partículas

A otimização por enxame de partículas é um algoritmo baseado no comportamento das revoadas de pássaros em busca de alimento. Consiste em encontrar a melhor região do espaço de busca através da movimentação das partículas dentro deste espaço, sendo a localização da partícula alterada a cada iteração por sua velocidade, determinada em função da melhor solução encontrada por ela e da melhor solução encontrada pelo enxame.

Em [21], a otimização do controle Volt/VAr é realizada através da otimização por enxame de partículas paralelizada. O algoritmo busca valores de tensão de referência para os RTs, tap dos OLTCs e potência injetada pelos bancos de capacitores de modo a minimizar as perdas técnicas no sistema.

Nas restrições são considerados os limites de fluxo de potência nos trechos da rede e os limites inferior e superior de tensão nas barras.

O processo de avaliação das partículas (responsável pela maior parte do tempo computacional de otimização por conta do cálculo de fluxo de potência) é paralelizado, visando aumentar o desempenho do algoritmo.

O algoritmo foi aplicado na rede IEEE de 14 barras, com quatro reguladores de tensão, três transformadores com OLTC e dois bancos de capacitores. Foram realizadas 100 simulações e o algoritmo reduziu as perdas na rede em 1,93% em média, quando comparado com o caso base.

Também foram realizadas simulações em que os equipamentos utilizados no CVV apresentam falha e não executam os comandos propostos pelo algoritmo, e mesmo assim foram obtidas reduções nas perdas técnicas, ainda que, em média, de menores proporções.

Além desses resultados, o artigo mostra que o tempo necessário para a otimização do CVV é quatro vezes menor se o problema for paralelizado em oito núcleos de cálculo ao invés de se utilizar um único núcleo.

Em [22], um algoritmo de otimização por enxame de partículas com abordagem multiobjetivo é aplicado ao problema de dimensionamento de motores de corrente contínua sem escovas. Pela versatilidade do algoritmo, ele pode ser adaptado para a resolução do problema de otimização do controle Volt/VAr.

Em [23], diferentes métodos são aplicados à otimização do controle Volt/VAr com o intuito de compará-los. Entre eles estão: algoritmo genético básico, colônia de formigas, enxame de partículas, evolução diferencial e busca tabu.

A função objetivo do problema visa minimizar a soma dos custos: das perdas técnicas na rede, dos chaveamentos dos bancos de capacitores, da potência reativa injetada pelas unidades de geração distribuída e dos desvios de tensão em relação à nominal.

Nas restrições são considerados, além dos limites operacionais dos equipamentos, limites operacionais para o fator de potência na subestação e limites inferior e superior para a tensão nas barras da rede.

Os algoritmos foram aplicados na rede IEEE de 34 barras, com um OLTC, dois BCs e três unidades de geração distribuída, para um dia de operação.

A otimização por colônia de formigas apresentou melhor desempenho em todos os aspectos analisados: menor tempo de execução, menor média de função objetivo e menor desvio padrão em 200 execuções, além da menor perda de energia durante o dia de operação.

2.3 Organização das referências

A Tabela 4 destaca algumas características das referências estudadas em relação à otimização do controle Volt/VAr, tais como o método de otimização utilizado, os equipamentos de controle de tensão e reativos considerados, os aspectos do CVV incluídos na função objetivo do problema, a dimensão da rede na qual o método proposto foi testado e as condições de carga analisadas.

Com base na tabela, algumas observações podem ser feitas:

- Diversos e variados métodos podem ser utilizados na otimização do controle Volt/VAr.
- Os equipamentos de controle de tensão e de reativos mais utilizados são os OLTCs, reguladores de tensão e bancos de capacitores. Os compensadores estáticos e a geração distribuída são utilizados de forma complementar em algumas referências.
- O objetivo de minimizar as perdas técnicas no sistema é considerado em quase todas as referências estudadas. A manutenção do nível de tensão dentro de um limite adequado ou próximo de um valor de referência ora é considerado na função objetivo do problema, ora é considerado nas restrições. A minimização dos chaveamentos dos equipamentos de controle, visando preservar a vida útil

desses equipamentos e minimizar custos de manutenção, é considerada em algumas das referências.

- Na maioria das referências estudadas, o método proposto foi testado em redes de pequeno porte, com menos de 100 barras, nas quais o cálculo do fluxo de potência não é computacionalmente custoso.

Os métodos propostos são testados para uma ou, na maioria das vezes, para algumas condições de carga das redes. Ainda, em algumas das referências os resultados da otimização do controle Volt/Var são analisados considerando um dia completo de operação.

Tabela 4 - Característica das referências estudadas

Referência	Método de otimização	Equipamentos de controle	(Função objetivo) / (Restrições)	Rede de teste	Condições de teste
[9]	Redes Neurais Artificiais + Programação Dinâmica	1 OLTC 1 BC	(V, FP, Ch) / (V, FP, Ch)	4 barras	1 dia de operação
[10]	Programação Linear Inteira Mista	2 OLTCs 10 GDs	(\$GDs + V, J, Δ GDs) / (-)	120 barras	1 dia de operação + ajuste a cada 15 minutos
[11]	Recozimento Simulado	1 OLTC 11 BCs	(V, Q, J, Ch) / (V, Ch)	32 barras	1 dia de operação
[12]	Evolução Diferencial	1 OLTC 2 CEs	(J) / (V)	IEEE 14/30/57	1 condição de carga
[13]	Sistemas Imunológicos Artificiais	1 OLTC 2 RTs 1 BC	(Ch) / (V)	176 barras	1 dia de operação
[14]	Algoritmo Genético	1 OLTC 7 BCs	(J) / (V, Ch)	30 barras	1 dia de operação
[15]	Algoritmo Genético	1 OLTC 2 RTs 3 BCs 3 GDs	(J) / (Ch)	IEEE 34	3 condições de carga
[16]	Algoritmo Genético	4 RTs 2 BCs 5 GDs	(J) / (-)	IEEE14/30	2 condições de carga
[17]	Algoritmo Genético Multiobjetivo (SPEA2)	1 RT 4 BCs (alocação)	(J, V) / (-)	69 barras	3 condições de carga
[18]	Algoritmo Genético Multiobjetivo (NSGA-II)	1 OLTC 2 RTs 1 BC	(V, P, J) / (V, FP)	95 barras	1 dia de operação
[20]	Colônia de Formigas	4 OLTCs	(V, J) / (-)	IEEE 30	10 condições de carga
[21]	Enxame de Partículas	3 OLTCs 4 RTs 2 BCs;	(J) / (V)	IEEE 14	1 condição de carga
[23]	AG, OCF, OEP, ED, BT	1 OLTCs 2 BCs 3 GDs	(V, J, Ch, \$GDs) / (V, FP)	IEEE 34	1 dia de operação

Fonte: Autor

Considerando a seguinte legenda para a tabela:

BT: Busca tabu

Ch: Objetivo/restrição referente ao número de chaveamentos dos equipamentos

ED: Evolução diferencial

FP: Objetivo/restrição referente ao fator de potência na subestação

J: Objetivo referente às perdas técnicas na rede

P: Objetivo referente à redução da potência ativa na rede

Q: Objetivo referente ao fluxo de potência reativa no transformador da subestação

V: Objetivo/restrição referente ao nível de tensão nas barras do sistema

\$GDs: Objetivo referente ao custo de geração de energia pelas unidades de geração distribuída

Δ GDs: Objetivo referente à variação de geração de energia pelas unidades de geração distribuída

3 Desenvolvimento do modelo

Este capítulo apresenta a formulação geral do problema de otimização do controle Volt/VAr desta dissertação, tanto em sua versão com único objetivo quanto na versão multiobjetivo. Além disso, são descritos o funcionamento e a terminologia dos métodos meta-heurísticos de otimização que serão utilizados na resolução do problema sendo eles o algoritmo genético básico e uma de suas variantes, o algoritmo memético, a otimização por colônia de formigas, a otimização por enxame de partículas e o algoritmo de otimização multiobjetivo SPEA2.

3.1 O problema de otimização do controle Volt/VAr

O problema de otimização do controle Volt/VAr consiste em definir o tap de OLTCs e reguladores de tensão e o estado de bancos de capacitores, com o objetivo de minimizar as perdas técnicas do sistema, com a restrição de manter o nível de tensão dentro dos limites aceitáveis em todas as barras da rede e manter o número de chaveamentos dos equipamentos o mais baixo possível, de modo a evitar que cada equipamento tenha sua vida útil reduzida.

Do ponto de vista matemático, trata-se de um problema de otimização multiobjetivo, não linear e inteira, com restrições de igualdade e desigualdade.

Para tratar a expressão “o mais baixo possível”, referente ao número de chaveamentos executados pelos equipamentos de controle Volt/VAr, esse objetivo será avaliado através de uma nota, ou função de pertinência. Para que a dimensão da função objetivo seja coerente, os outros dois objetivos, referentes às perdas técnicas na rede e ao nível de tensão nas barras, também serão avaliados através de notas, ou funções de pertinência. Sendo assim, tanto a restrição relativa ao nível de tensão nas barras quanto a restrição relativa ao número de chaveamentos dos equipamentos ficam incluídas na função objetivo do problema.

Por meio de uma agregação da função objetivo em forma de soma ponderada, com os coeficientes de cada nota sendo definidos a priori, o problema de otimização

multiobjetivo passa a se comportar como um problema de único objetivo, como mostra a equação (3.1).

$$\mu_{objetivo} = (\lambda_J * \mu J + \lambda_V * \mu V + \lambda_{Ch} * \mu Ch) \quad (3.1)$$

onde: λ_J é o coeficiente da nota referente às perdas técnicas na rede (μJ),

λ_V é o coeficiente da nota referente aos níveis de tensão nas barras (μV),

λ_{Ch} é o coeficiente da nota referente ao número de chaveamentos executados pelos equipamentos de CVV (μCh),

e $\mu_{objetivo}$ é a função objetivo agregada.

Como o transformador da subestação com OLTC é responsável por controlar a tensão da barra inicial de todos os alimentadores à sua jusante e sua atuação deve ser coordenada com os RTs e BCs presentes nestes alimentadores, um bloco de rede constituído por um OLTC e a rede à sua jusante é a menor unidade de rede na qual o problema de otimização do CVV deve ser solucionado. Neste trabalho, os algoritmos foram implementados de maneira que, caso a rede possua mais de um OLTC, a otimização para cada bloco de rede seja executada em paralelo, visando reduzir o tempo computacional necessário para a realização do processo de otimização.

Para avaliar as perdas técnicas na rede a jusante de um dado OLTC, serão atribuídas notas às possíveis soluções do problema de modo que as soluções com redução de perdas técnicas em relação às perdas na rede antes da otimização do controle Volt/VAr sejam melhor avaliadas. Sendo assim, será utilizada uma função trapezoidal (μJ), mostrada na Figura 6.

Figura 6 - Função trapezoidal μJ para as perdas técnicas da rede

Fonte: Autor

Sendo $Perdas_{solução_j}$ as perdas técnicas na rede de uma possível solução para o problema e $Perdas_{pré-otimização}$ as perdas técnicas na rede antes do processo de otimização do CVV.

Para avaliar o nível de tensão nas barras do sistema, serão atribuídas notas aos valores de tensão de fase de todas as barras com carga das possíveis soluções do problema, de modo que valores de tensão dentro do limite parametrizado sejam melhor avaliadas. Esta nota será atribuída de acordo com uma função trapezoidal (μV), mostrada na Figura 7.

Figura 7 - Função trapezoidal μV para o nível de tensão das barras com carga da rede

Fonte: Autor

A avaliação do nível de tensão nas barras para uma possível solução do problema se dará pela média aritmética das notas atribuídas aos valores de tensão de fase das barras com carga, como mostra a equação (3.2).

$$\mu V_i = \frac{\sum_{x=1}^{N_{Barras_i}} (\sum_{y=1}^3 (\mu V_{Barra_x}^{Fase_y}))}{3 * N_{Barras_i}} \quad (3.2)$$

onde: N_{Barras_i} é o número de barras com carga na rede a jusante do OLTC.

A quantidade de chaveamentos dos equipamentos utilizados no controle Volt/VAr será avaliada através de uma nota atribuída também de acordo com uma função trapezoidal (μCh), mostrada na Figura 8. A abordagem escolhida neste trabalho envolveu a monitoração dos equipamentos que tenham executado poucos chaveamentos nas últimas 24 horas. Nessas condições, atribui-se nota máxima para esses equipamentos, enquanto equipamentos com maior número de chaveamentos terão nota linearmente reduzida até o valor nulo quando extrapolarem o limite diário de chaveamentos, o qual pode ser definido pelo operador do sistema. O número de chaveamentos deve ser restrito, visando preservar a vida útil do equipamento e minimizar seu custo de manutenção.

Figura 8 - Função trapezoidal μCh para os chaveamentos executados pelos equipamentos do CVV

Fonte: Autor

Onde $N_{ChavEqpto_z}$ é o número de chaveamentos executado pelo equipamento nas últimas 24 horas e $N_{max_{ChavEqpto_z}}$ é o número máximo de chaveamentos diários que o equipamento pode executar, de modo a não ter sua vida útil reduzida.

Para realizar a contagem do número de chaveamentos dos OLTCs e RTs, são somadas as variações de tap, patamar a patamar, nas últimas 24 horas. Por exemplo, se um OLTC estava no tap -2 das 00h00 até 10h00 e passou para o tap 1 das 10h00 até o final do dia, esse OLTC realizou três chaveamentos nesse dia de operação.

A contagem do número de chaveamentos dos BCs se dá pelo número de alterações de estado (ligado/desligado) do BC nas últimas 24 horas. Por exemplo, se um BC ligou as 09h00 e desligou as 21h00, esse BC realizou dois chaveamentos nesse dia de operação.

A avaliação de uma possível solução para o problema em relação ao número de chaveamentos executados se dará pela média aritmética das notas atribuídas aos equipamentos da rede, como mostra a equação (3.3).

$$\mu Ch_i = \frac{\sum_{z=1}^{N_{Eqptos_i}} (\mu C_{Eqpto_z})}{N_{Eqptos_i}} \quad (3.3)$$

onde: N_{Eqptos_i} é o número de equipamentos utilizados no CVV presentes na rede.

Descritas estas funções, o problema de otimização do controle Volt/VAr pode ser formulado da seguinte maneira:

$$Min f_{obj} = 1 - \frac{(\mu J_i + \mu V_i + \mu Ch_i)}{3} \quad (3.4)$$

onde: μJ_i é a nota referente às perdas técnicas na rede, calculada conforme o gráfico da Figura 6,

μV_i é a média aritmética das notas referentes ao nível de tensão atribuídas às barras com carga da rede, calculada conforme a equação (3.2)

e μCh_i é a média aritmética das notas referentes à quantidade de chaveamentos atribuídas aos equipamentos do controle de tensão e reativos, calculada conforme a equação (3.3).

Deve-se ressaltar que a função objetivo deve estar sujeita às restrições do problema de fluxo de potência que, de forma sucinta, pode ser expressa por:

$$g(P, Q, V, \delta) = 0 \quad (3.5)$$

onde: P e Q são, respectivamente, as potências ativa e reativa injetadas nas barras da rede,

V é o vetor dos módulos de tensão nas barras

e δ é o vetor dos ângulos de tensão nas barras.

As restrições referentes ao nível de tensão nas barras e ao número diário de chaveamentos nos equipamentos foram consideradas na função objetivo do problema. Alguns autores consideram tais restrições como penalização na função objetivo, os quais encontram dificuldades na ponderação de tais penalizações. Na formulação aqui exposta, por múltiplos objetivos, tal dificuldade é muito atenuada.

A seguir, serão apresentados os algoritmos de otimização que serão utilizados na resolução do problema.

3.2 Algoritmos genéticos

Os algoritmos genéticos (AGs) são algoritmos baseados na teoria da evolução de Darwin elaborados por John Holland em 1975. Trata-se de uma técnica de otimização que mescla procedimentos de busca direcionada e aleatória [24], análogos ao princípio da seleção natural. Os AGs são considerados algoritmos robustos e facilmente adaptáveis a problemas de otimização de diferentes características.

Seu funcionamento consiste em submeter uma população de indivíduos, ou seja, um conjunto de possíveis soluções do problema, ao processo de evolução. Para isso, é aplicada uma sequência de operadores genéticos (seleção, cruzamento e mutação), responsáveis por selecionar os indivíduos mais aptos a sobreviverem e garantir a diversidade genética da população.

O processo, mostrado no fluxograma da Figura 9, termina após um determinado número de iterações ($N_{\max}$) ser executado, e a solução do problema é representada pelo indivíduo melhor avaliado. Os passos apresentados no diagrama serão descritos na sequência, com ênfase na aplicação ao problema de otimização do controle Volt/VAr.

Figura 9 - Fluxograma de um algoritmo genético

Fonte: Autor, modificado de [24]

- Codificao

Nos algoritmos genticos, a codificao do problema feita em vetores de comprimento fixo que guardam os valores referentes s solues do problema, de maneira anloga ao armazenamento de informaes genticas em cromossomos nos seres vivos. Na codificao aqui apresentada, estes vetores guardam a posio de tap dos OLTCs e reguladores de tenso e o estado (ligado ou desligado) dos bancos de capacitores presentes no sistema de distribuio.

Alm disso, neste trabalho, ser utilizada a codificao binria, tanto para representao do tap dos OLTCs e reguladores de tenso quanto para a representao do estado dos bancos de capacitores. Para armazenar um valor de tap utilizado um conjunto de bits, sendo um bit destinado ao sinal (positivo ou negativo) e os demais bits para a representao da posio do tap, desconsiderando-se o sinal, na base binria (so utilizados tantos bits quanto necessrios para representar todos os possveis valores de tap dos equipamentos).

Para armazenar o estado de cada BC é utilizado um bit, que assume valor “0” caso o BC esteja desligado e valor “1” caso contrário. A Figura 10 apresenta um exemplo de codificação de uma possível solução para o problema de otimização do controle Volt/VAr.

Figura 10 - Exemplo de codificação de um indivíduo do AG

Fonte: Autor

- População inicial

O primeiro passo do algoritmo genético consiste em gerar um número pré-definido de indivíduos de maneira aleatória, formando a população inicial. O tamanho dessa população é um dos parâmetros importantes do AG.

Trata-se de um problema computacionalmente simples, visto que basta utilizar uma função que gere números aleatórios com distribuição uniforme de probabilidade para sortear valores referentes aos taps dos OLTCs e RTs e ao estado dos BCs.

- Avaliação

Nesse passo do algoritmo genético os indivíduos da população são avaliados, de modo a verificar quão aptos a sobreviver ao processo evolutivo eles estão. Essa aptidão é medida por uma função de avaliação, ou função de ajuste, que nesse caso deve ser diretamente relacionada com a função objetivo do problema.

Para cada indivíduo, a rede é alterada de acordo com os dados de seu genótipo, ou seja, a posição de tap dos OLTCs e RTs e o estado dos BCs são definidos de acordo com os dados armazenados no vetor do indivíduo. Em seguida, um cálculo de fluxo de potência na rede é executado. Com o resultado do fluxo de potência, as funções de pertinência (notas) relativas às perdas técnicas na rede, ao nível de tensão nas barras com carga e ao número de chaveamentos executados pelos equipamentos são atribuídas.

A partir das notas, a função de avaliação do indivíduo é calculada, de acordo com a equação (3.6), a qual é diretamente relacionada à função objetivo do problema, apresentada na equação (3.4). O número obtido representa a qualidade da solução codificada nesse indivíduo, e deve ser tão maior quanto melhor for a qualidade da solução, ao contrário da função objetivo, que deve ser minimizada. A escolha dessa função de avaliação tem o objetivo de facilitar a implementação do operador genético de seleção, descrito a seguir.

$$f_{avaliação} = \mu J_i + \mu V_i + \mu Ch_i \quad (3.6)$$

A etapa de avaliação dos indivíduos é mostrada no fluxograma da Figura 11.

Figura 11 - Fluxograma da etapa de avaliação dos indivíduos

Fonte: Autor

- Seleção

O operador genético da seleção é responsável por escolher quais indivíduos irão transmitir seu material genético para a próxima geração de indivíduos. Diferentes métodos podem ser utilizados para o processo de seleção, influenciando na velocidade de convergência do algoritmo e na confiabilidade da solução encontrada [25].

No algoritmo genético básico, esse processo é feito pelo método da roleta. Os indivíduos são alocados em uma roleta, sendo a faixa que cada indivíduo ocupa proporcional ao valor de sua função de avaliação. Sendo assim, ao girar a roleta, a probabilidade de cada indivíduo ser selecionado é diretamente proporcional à sua função de avaliação. O sorteio é realizado tantas vezes quanto o necessário para manter o tamanho da população constante ao longo das gerações. A Figura 12 mostra o processo.

Figura 12 - Seleção pelo método da roleta

Fonte: Autor

Outra maneira de realizar a seleção é através do método do torneio. Consiste em sortear dois (no caso de torneio binário) ou mais indivíduos da população para a disputa de um torneio, onde o indivíduo melhor avaliado é selecionado para a próxima geração. São realizados tantos torneios quanto necessários para manter o tamanho da população constante ao longo das gerações. A Figura 13 mostra a seleção por torneio binário.

Figura 13 - Seleção pelo método do torneio binário

Fonte: Autor

Nos dois exemplos mostrados, o indivíduo número 2, que possuía a pior função de avaliação, foi eliminado no processo de seleção. Com isso, a população resultante do processo nestes exemplos apresentou pares de indivíduos com o mesmo material genético, ou seja, soluções idênticas para o problema. Essa aparente falta de diversidade genética é solucionada na fase de cruzamento.

- Cruzamento

Após a seleção dos indivíduos é aplicado o operador genético do cruzamento. Esse operador é responsável pela troca de material genético entre os indivíduos, possibilitando a exploração de diferentes regiões do espaço de busca.

Esse operador consiste em escolher aleatoriamente pares de indivíduos da população e efetuar, eventualmente, a troca de informações genéticas entre eles, fazendo com que o algoritmo explore novas regiões do espaço de busca. Esta troca de informações é realizada com certa probabilidade, chamada de probabilidade de cruzamento (parâmetro do AG definido a priori).

Considerando o algoritmo genético básico, o processo é feito pelo método do cruzamento em um ponto. Consiste em sortear um *locus* do genótipo, ou posição dos vetores, dos indivíduos a partir do qual os valores armazenados nestes vetores serão trocados entre eles. O processo é mostrado na Figura 14.

Figura 14 - Cruzamento em um ponto

Fonte: Autor

Como alternativa, o cruzamento pode ser realizado através do método de cruzamento uniforme. Nesse método, os vetores dos indivíduos submetidos ao cruzamento são comparados posição a posição. Caso os valores armazenados em determinado *locus* sejam diferentes, eles são trocados entre os indivíduos. Essa troca é feita com certa probabilidade, neste trabalho fixada em 50%. A Figura 15 mostra o processo.

Figura 15 - Cruzamento uniforme

Fonte: Autor

- **Mutação**

A mutação é o operador responsável por garantir a diversidade genética da população, evitando que o algoritmo fique restrito a alguma região do espaço de busca.

Esse operador consiste em efetuar, eventualmente, pequenas alterações no genótipo dos indivíduos, fazendo com que o algoritmo explore uma região próxima do espaço

de busca. Essas alterações são realizadas com certa probabilidade, chamada de probabilidade de mutação (parâmetro do AG definido a priori).

Todos os *locus* do genótipo do indivíduo são percorridos. Caso fique definido que a mutação deve ocorrer em determinada posição (isto é, no caso do número aleatório gerado ser inferior ou igual à probabilidade de mutação), seu valor é invertido, ou seja, se o valor é 1, passa a ser 0, e vice-versa. Exemplos de mutação são mostrados na Figura 16.

Figura 16 - Mutação (bits destacados sofreram mutação)

Nº indiv.	População atual						Funç. aval.	Nº indiv.	Exemplo de população após mutação						Funç. aval.
1	1	0	1	1	1	0	91	1	1	0	1	1	1	1	99
2	1	1	1	0	1	1	41	2	1	1	1	0	1	1	41
3	0	1	1	0	1	1	57	3	0	1	1	0	1	1	57
4	1	1	0	1	0	1	61	4	1	0	0	1	0	1	48

Fonte: Autor

3.3 Algoritmo memético

O algoritmo memético (AM) é um algoritmo baseado na evolução de indivíduos no ramo das artes marciais proposto por Pablo Moscato em 1989 [26]. Tem como base o princípio de que o conhecimento de artes marciais é repassado pelos mestres através de sequências de movimentos (similares aos cromossomos do AG), sendo que os movimentos mais importantes, denominados *memes*, não podem ser divididos (similares aos genes do AG).

Seu funcionamento é similar ao do algoritmo genético, porém com a inclusão de uma etapa extra: realização de buscas locais em um ou mais indivíduos da população.

Sendo assim, os indivíduos, chamados de agentes no AM, são submetidos ao processo de evolução cultural.

O processo, mostrado no fluxograma da Figura 17, termina após um determinado número de gerações (N_{max}) ser executado, e a solução do problema é representada pelo agente melhor avaliado. As etapas de codificação, criação da população inicial, avaliação e mutação são idênticas às descritas nos algoritmos genéticos, com exceção da terminologia característica de cada algoritmo.

As etapas de busca local, competição e cooperação serão descritas na sequência.

Figura 17 - Fluxograma de um algoritmo memético

Fonte: Autor

- Busca local

Essa etapa do algoritmo memético é análoga ao treinamento realizado pelos lutadores na busca por aperfeiçoar seus movimentos, fazendo com que eles evoluam seu conhecimento das artes marciais.

Consiste em realizar uma busca local, ou seja, na vizinhança do espaço de busca, em um ou mais agentes da população, de modo a melhorar suas funções de avaliação. Como vizinhos, são definidos indivíduos com alteração (inversão) de valor em somente uma posição do vetor onde a solução do problema é armazenada.

Uma maneira de implementar a busca local é através do método *Hill Climbing*. O método consiste em escolher o melhor vizinho do indivíduo no qual a busca está sendo realizada e comparar suas funções de avaliação. Caso a avaliação do melhor vizinho seja melhor que a do indivíduo, este é substituído pelo vizinho. O processo é repetido enquanto a função de avaliação estiver melhorando. A Figura 18 mostra as duas primeiras iterações de um exemplo do processo.

Figura 18 - Busca local pelo método Hill Climbing

Fonte: Autor

Como são necessárias inúmeras avaliações durante esse tipo de busca e essas avaliações são computacionalmente custosas no problema de otimização do controle Volt/VAr por conta da necessidade do cálculo do fluxo de potência, o operador é utilizado apenas no indivíduo melhor avaliado da população, somente por determinado número de iterações da busca local.

- Competição

A etapa de competição tem a mesma função do processo de seleção nos algoritmos genéticos, ou seja, é responsável pela seleção dos indivíduos melhor avaliados para a próxima geração. Neste trabalho, o processo da competição utilizado é idêntico à seleção pelo método do torneio binário descrito anteriormente e mostrado na Figura 13.

- Cooperação

A etapa de cooperação tem a mesma função do processo de cruzamento nos algoritmos genéticos, ou seja, é responsável pela troca de informações entre os indivíduos da população. Neste trabalho, o processo de cooperação implementado é idêntico ao cruzamento uniforme, descrito anteriormente e mostrado na Figura 15.

3.4 Colônia de formigas

A otimização por colônia de formigas é um algoritmo proposto por Marco Dorigo em 1991. Trata-se de um modelo estocástico que tenta reproduzir o comportamento das formigas na busca por alimento [27].

Através da observação do comportamento desses insetos na natureza e de experiências realizadas em laboratório, foi constatado que após certo tempo de busca a maioria das formigas encontra o menor caminho entre a colônia e a fonte de alimento. O fato foi explicado pela deposição de feromônio pelas formigas ao caminhar e pela proporcionalidade entre a chance de uma formiga escolher certa rota e a quantidade de feromônio existente nessa rota.

No início da busca, quando feromônio nenhum foi depositado, as chances de uma formiga escolher entre uma ou outra rota são iguais. Ao percorrer certo caminho até a fonte de alimento e voltar para o formigueiro as formigas depositam feromônio pelas rotas que passam. Essa substância química sofre uma evaporação natural com o passar do tempo, fazendo com que rotas mais longas, que demoram mais para ser percorridas, se tornem menos atrativas. Em rotas mais curtas, a concentração de

feromônio tende a ser maior, por conta da deposição mais frequente da substância, fazendo com que essas rotas sejam mais atrativas.

O funcionamento do algoritmo consiste em submeter uma população de formigas, ou seja, um conjunto de possíveis soluções do problema, à uma sequência de deslocamentos entre a colônia e a fonte de alimento. A cada iteração, a quantidade de feromônio presente em cada rota (percorrida ou não) é atualizada, de modo a atualizar a probabilidade de cada rota ser escolhida por uma formiga.

O processo, mostrado no fluxograma da Figura 19, termina após um determinado número de iterações ($N_{\max}$) ser executado, e a solução do problema é representada pela formiga que percorreu o menor caminho. Os passos apresentados no diagrama serão descritos na sequência.

Figura 19 - Fluxograma da otimização por colônia de formigas

Fonte: Autor

- Codificação

Na otimização por colônia de formigas, as possíveis soluções para o problema são caminhos entre a colônia e a fonte de alimento percorridos pelas formigas. Esses caminhos são salvos em vetores, que armazenam quais rotas foram percorridas pelas formigas para completar o caminho. Nesse caso, os trechos do caminho são associados à posição de tap dos OLTCs e reguladores de tensão e ao estado dos bancos de capacitores presentes no sistema de distribuição.

Neste trabalho será utilizada a codificação binária, tanto para representação do tap dos OLTCs e RTs quanto para a representação do estado dos BCs. A Figura 20 apresenta um exemplo de codificação de uma possível solução para o problema de otimização do controle Volt/VAr.

Figura 20 - Exemplo de codificação de um caminho feito por uma formiga

Fonte: Autor

- Deslocamento das formigas

Nessa etapa do algoritmo as formigas da colônia se deslocam, uma a uma, da colônia para a fonte de alimento, ou seja, do início ao final do vetor de codificação, o que compõe os trechos (bit a bit) do caminho percorrido por uma formiga. Esse deslocamento é feito trecho a trecho, e para cada trecho é realizado um sorteio para definir se a formiga irá percorrer a rota superior ou inferior, determinando o valor que será guardado em seu vetor (1 ou 0, respectivamente). A probabilidade de uma

formiga escolher certa rota depende da quantidade de feromônio presente nela. O processo, mostrado na Figura 21, que representa a solução da Figura 20, é repetido até que todas as formigas da colônia cheguem na fonte de alimento.

Figura 21 - Deslocamento de uma formiga no diagrama de rotas

Fonte: Autor

- Avaliação

Nesse passo do algoritmo, os caminhos percorridos pelas formigas da colônia são avaliados. Esta avaliação ocorre de maneira idêntica à avaliação de um indivíduo no algoritmo genético, descrita anteriormente.

Para cada formiga, a rede é alterada de acordo com o caminho percorrido por ela, ou seja, a posição de tap dos OLTCs e RTs e o estado dos BCs são definidos de acordo com os dados armazenados em seu vetor. Em seguida, um cálculo de fluxo de potência na rede é executado. Com o resultado do fluxo de potência, as notas relativas às perdas técnicas na rede, ao nível de tensão nas barras com carga e ao número de chaveamentos dos equipamentos são atribuídas.

A partir das notas, a função de avaliação é calculada, de acordo com a equação (3.6). O número obtido representa a qualidade da solução codificada nesta formiga, e deve ser tão maior quanto menor for o caminho percorrido, ou seja, quanto melhor for a qualidade da solução.

- Atualização do feromônio

Nessa etapa do algoritmo, a quantidade de feromônio existente em todas as rotas (percorridas ou não) é atualizada. Essa quantidade, que é numericamente igual à probabilidade de a rota ser escolhida por uma formiga, é inicializada com o valor de 0,5 e a cada iteração sofre alterações por conta da evaporação do feromônio e da deposição da substância pelas formigas.

Primeiramente, um fator de convergência (cf) é calculado. Esse fator, mostrado na equação (3.7), é igual à média aritmética da diferença entre a probabilidade de uma formiga escolher a rota inferior ou superior dos trechos existentes no caminho. Sendo assim, o fator é nulo no início do algoritmo e tende à unidade na convergência do algoritmo.

$$cf = \frac{\sum_{i=1}^n |\tau_{i0} - \tau_{i1}|}{n} \quad (3.7)$$

onde: n é número total de trechos,

τ_{i0} é a probabilidade de uma formiga escolher a rota inferior no i -ésimo trecho

e τ_{i1} é a probabilidade de uma formiga escolher a rota superior no i -ésimo trecho.

Em seguida, a quantidade de feromônio nas rotas é atualizada de acordo com a equação (3.8).

$$\tau_{is}(t+1) = (1 - \rho) * \tau_{is}(t) + \rho * \sum_{x \in S_{upd} | is \in x} (w_x) \quad (3.8)$$

onde: $\tau_{is}(t+1)$ é a quantidade de feromônio na s -ésima rota (superior ou inferior) do i -ésimo trecho após a atualização,

$\tau_{is}(t)$ é a quantidade de feromônio na s -ésima rota (superior ou inferior) do i -ésimo trecho antes da atualização,

ρ é o parâmetro de evaporação,

S_{upd} é o grupo de soluções que depositam feromônio, quais sejam (i) melhor solução global, (ii) melhor solução desde a última reinicialização e (iii) melhor solução da iteração

e w_x são os pesos para cada solução $x \in S_{\text{upd}}$, sendo que $0 \leq w_x \leq 1$ e $\sum_{x \in S_{\text{upd}} | i \in x} (w_x) = w_{ib} + w_{rb} + w_{gb} = 1$.

A evaporação do feromônio, representada na primeira parcela da soma da equação (3.8), é controlada pelo parâmetro ρ e ocorre em todas as rotas.

Já a deposição de feromônio, representada na segunda parcela, é proporcional ao parâmetro de evaporação ρ e aos pesos w_x , e ocorre nas rotas percorridas pela formiga melhor avaliada na iteração (peso w_{ib}), pela formiga melhor avaliada desde a última reinicialização (peso w_{rb}) e pela formiga globalmente melhor avaliada (peso w_{gb}). Dependendo do valor do fator de convergência, esses três parâmetros assumem determinados valores, alterando a quantidade de feromônio depositada por essas formigas. Com isso, é possível fazer com que a formiga melhor avaliada na iteração deposite mais feromônio no início do algoritmo e que a formiga globalmente melhor avaliada deposite mais feromônio conforme o algoritmo se aproxima da convergência, por exemplo.

O cálculo da evaporação e deposição de feromônio nas rotas garante que, para todos os trechos, a soma da probabilidade de uma formiga escolher a rota superior e a rota inferior seja unitária.

No caso de convergência do algoritmo antes do número máximo de iterações ser alcançado, a quantidade de feromônio nas rotas é reinicializada. Esta reinicialização, que permite que o algoritmo explore outras regiões de busca do problema nas iterações restantes, é feita de modo que as rotas percorridas pela formiga melhor avaliada até o momento comecem com quantidade maior de feromônio, fazendo com que o algoritmo seja direcionado de acordo com a busca já realizada ao invés de reiniciá-la por completo.

O detalhamento desta etapa do algoritmo é descrito em [28].

3.5 Enxame de partículas

A otimização por enxame de partículas é um algoritmo baseado em pesquisas sobre o comportamento de revoadas de pássaros desenvolvido por James Kennedy e

Russell Eberhart em 1995. Tem como base a coletividade destes animais na busca por alimento.

Seu funcionamento consiste em fazer com que um conjunto de pássaros, chamados de partículas, se movimentem pelo espaço de busca do problema. A cada iteração, o espaço em que cada partícula se encontra é alterado com base na sua velocidade, sendo que esta é determinada em função da melhor solução encontrada pela partícula e da melhor solução encontrada pelo enxame.

O processo, mostrado no fluxograma da Figura 22, termina após um determinado número de iterações ($N_{\max}$) ser executado, e a solução do problema é representada pela melhor localização encontrada por uma partícula. Os passos apresentados no diagrama serão descritos na sequência.

Figura 22 - Fluxograma da otimização por enxame de partículas

Fonte: Autor

- Codificação

Na otimização por enxame de partículas, as possíveis soluções para o problema são localizações das partículas no espaço de busca. Essas localizações são salvas em vetores, nos quais cada posição é responsável por armazenar uma coordenada referente a uma dimensão no espaço de busca do problema. Nesse caso, as coordenadas são associadas à posição de tap dos OLTCs e reguladores de tensão e ao estado dos bancos de capacitores presentes no sistema de distribuição.

Neste trabalho será utilizada a codificação binária, tanto para representação do tap dos OLTCs e RTs quanto para a representação do estado dos BCs. A Figura 23 apresenta um exemplo de codificação de uma possível solução para o problema de otimização do controle Volt/VAr.

Figura 23 - Exemplo de codificação da localização de uma partícula

Fonte: Autor

- População inicial

O primeiro passo da otimização por enxame de partículas consiste em alocar as partículas no espaço de busca de maneira aleatória. Para isso, basta utilizar uma função que gere números aleatórios com distribuição uniforme de probabilidade para sortear os valores binários.

- Avaliação

Nesse passo do algoritmo, as localizações de cada partícula no espaço de busca são avaliadas. Essa avaliação ocorre de maneira idêntica à avaliação de um indivíduo no algoritmo genético, descrita anteriormente, com exceção da terminologia característica de cada algoritmo.

- Atualização das velocidades

Nessa etapa do algoritmo, as velocidades das partículas são calculadas. Para cada dimensão do espaço de busca, ou seja, para cada posição do vetor de coordenadas (X_i) de uma partícula, uma velocidade é calculada. Essas compõem o vetor de velocidades (V_i) da partícula.

Na otimização por enxame de partículas binária, a velocidade armazenada em cada posição de V_i é numericamente igual à probabilidade do bit armazenado na mesma posição de X_i ter o seu valor invertido.

O cálculo das componentes do vetor de velocidades leva em conta a melhor localização encontrada pela própria partícula, a melhor localização encontrada pelo enxame e uma componente aleatória, que representa a habilidade de exploração da partícula.

A Tabela 5 mostra o comportamento da velocidade de uma partícula para uma das posições de seu vetor.

É possível observar que caso o bit da localização atual da partícula e os bits da melhor localização desta partícula e da melhor localização global sejam iguais, a velocidade nesta direção de busca diminui (casos 1 e 8, mostrados nas linhas verdes).

Caso o bit da localização atual da partícula seja o inverso dos bits da melhor localização desta partícula e da melhor localização global, a velocidade nesta direção de busca aumenta (casos 4 e 5, mostrados nas linhas vermelhas).

Nos demais casos (2, 3, 6 e 7, mostrados em amarelo) a velocidade da partícula pode aumentar, diminuir ou não ser alterada, dependendo dos valores definidos na

parametrização do algoritmo e de valores aleatórios sorteados na etapa de atualização das velocidades.

O equacionamento completo desta etapa do algoritmo é detalhado em [29].

Tabela 5 - Comportamento da velocidade de uma partícula

Caso	Bit da localização atual da partícula (X_i)	Bit da melhor localização global	Bit da melhor localização da partícula	Velocidade (probabilidade do bit da localização atual ser invertido)
1	0	0	0	Diminui
2	0	0	1	Aumenta, diminui ou não é alterada
3	0	1	0	
4	0	1	1	Aumenta
5	1	0	0	Aumenta
6	1	0	1	Aumenta, diminui ou não é alterada
7	1	1	0	
8	1	1	1	Diminui

Fonte: Autor

- Atualização das localizações

Nesta etapa do algoritmo, as localizações das partículas no espaço de busca são atualizadas de acordo com suas velocidades. O processo consiste em verificar, para todas as partículas, quais posições do vetor de coordenadas devem ter seu valor invertido. Isso é feito através da comparação do vetor de velocidades da partícula com números aleatórios gerados com distribuição uniforme de probabilidade.

O exemplo da Figura 24 mostra a localização de uma partícula antes e depois da etapa de atualização das localizações. Nesse exemplo, onde deseja-se definir ações de controle para dois bancos de capacitores, uma partícula que estava na localização (0,1), ou seja, com o BC₁ desligado e o BC₂ ligado, tem a sua localização alterada para (1,1), onde os dois BCs estão ligados.

Figura 24 - Atualização da localização de uma partícula

Fonte: Autor

3.6 O problema de otimização multiobjetivo do controle Volt/Var

Uma das abordagens para resolução do problema de otimização multiobjetivo do controle Volt/VAr, conforme visto na seção 3.1, é através da agregação dos objetivos em um único. Porém, a dificuldade desta abordagem é a escolha do peso que cada função de pertinência tem na função objetivo.

Na abordagem multiobjetivo, mais de uma função objetivo deve ser otimizada. Com isso, busca-se encontrar a fronteira de Pareto para o problema [17], [18], [30].

Dessa forma, essa abordagem é capaz de tratar o problema de forma generalizada, portanto pode ser aplicada a diferentes subestações com diversas características de consumo, ou até mesmo diferentes distribuidoras de energia elétrica, sem a necessidade de parametrizações específicas. A partir do conjunto de soluções

fornecido pelo algoritmo, a decisão de qual solução deve ser aplicada pode ser tomada com base no objetivo mais relevante para o momento.

Em muitos casos, esses objetivos são conflitantes, com isso, otimizar um dos objetivos pode fazer com que os outros sejam prejudicados.

No caso do problema de otimização do CVV, dois dos objetivos são o de minimizar as perdas técnicas do sistema e o de controlar o nível de tensão nas barras da rede. Dependendo das características dos alimentadores e dos tipos de carga presentes no sistema, o controle de tensão pode levar a uma variação na corrente ao longo dos alimentadores, influenciando nas perdas técnicas do sistema.

Com base nesses objetivos, o problema pode ser formulado da seguinte maneira:

$$Max f_{obj} = [\mu J_i, \mu V_i]^t \quad (3.9)$$

onde: μJ_i é a função de pertinência referente às perdas técnicas na rede, calculada conforme o gráfico da Figura 6

e μV_i é a média aritmética das notas referentes ao nível de tensão atribuídas às barras com carga da rede, calculada conforme a equação (3.2).

A seguir, será apresentado o algoritmo de otimização que será utilizado na resolução do problema.

3.7 Strength Pareto Evolutionary Algorithm 2

O *Strength Pareto Evolutionary Algorithm* (SPEA) é um algoritmo proposto por Eckart Zitzler e Lothar Thiele em 1999. É uma técnica que visa encontrar ou obter uma aproximação da fronteira de Pareto para problemas de otimização multiobjetivo [30]. Em 2001 foram propostas melhorias pelos próprios autores, originando uma nova versão do algoritmo, o SPEA2.

Seu funcionamento é similar ao do algoritmo genético, ou seja, consiste em submeter uma população de indivíduos, isto é, um conjunto de possíveis soluções do problema,

ao processo de evolução, através da aplicação de uma sequência de operadores genéticos.

Porém, duas etapas são incluídas no algoritmo de modo a contemplar as necessidades da otimização multiobjetivo, sendo estas: a avaliação da relação de dominância entre as soluções e a atualização do arquivo responsável por armazenar as soluções não-dominadas que foram encontradas.

O processo, mostrado no fluxograma da Figura 25, termina após um determinado número de iterações ($N_{\max}$) ser executado, e a fronteira de Pareto é obtida através do conjunto de soluções não-dominadas armazenadas no arquivo. Os passos apresentados no diagrama são descritos na sequência.

Figura 25 - Fluxograma do SPEA2

Fonte: Autor

- Sorteio da população inicial

O primeiro passo do algoritmo consiste em gerar um número pré-definido de indivíduos de maneira aleatória, formando a população inicial. Isso é feito utilizando uma função que gera números aleatórios com distribuição uniforme de probabilidade.

Nessa etapa também é criado o arquivo responsável por armazenar as soluções não dominadas, inicialmente vazio.

- Avaliação das soluções em relação ao problema de otimização

Nesse passo do algoritmo, a qualidade das soluções codificadas nos indivíduos da população é avaliada. Essa avaliação ocorre de maneira similar à avaliação de um indivíduo no algoritmo genético, descrita anteriormente.

Para cada indivíduo, a rede é alterada de acordo com os dados de seu genótipo, ou seja, a posição de tap dos OLTCs e RTs e o estado dos BCs são definidos de acordo com os dados armazenados no vetor do indivíduo. Em seguida, é executado um cálculo de fluxo de potência na rede. Com o resultado do fluxo de potência, são calculados os valores das funções de pertinência referentes às perdas técnicas na rede e ao nível de tensão nas barras com carga. Esses valores são numericamente iguais às duas funções objetivo do problema.

- Avaliação da relação de dominância entre as soluções

Nessa etapa do algoritmo, são calculadas funções de ajuste para os indivíduos da população e para as soluções armazenadas no arquivo. Essas funções de ajuste visam avaliar a relação de dominância entre eles.

Define-se que uma dada solução domina outra se, e somente se, essa solução é melhor ou igual em relação a todos os objetivos do problema e estritamente melhor em relação a pelo menos um dos objetivos, ou seja, se essa solução possui valor de função de pertinência maior ou igual em relação a todos os objetivos do problema e estritamente maior em relação a pelo menos um deles.

Primeiramente, a força (S) de cada solução é calculada. Esse valor representa o número de soluções que essa solução domina.

Com base nestes valores, a função de ajuste bruta, em inglês *raw fitness* (R), de cada solução é calculada. O valor desta função para um certo indivíduo é determinado pela soma das forças das soluções que dominam esse indivíduo. Ou seja, quanto menor o valor de R de um indivíduo, mais próximo da fronteira de Pareto ele está. Caso o valor de R seja nulo, o indivíduo é não-dominado. Valores elevados de R indicam que o indivíduo é dominado por outros indivíduos, que por sua vez dominam outros indivíduos, ou seja, é dominado por indivíduos que possuem valores elevados de S.

O exemplo da Figura 26 mostra os valores das funções de ajuste brutas de um conjunto de soluções para um problema no qual se deseja maximizar as funções objetivo f_1 e f_2 .

Figura 26 - SPEA2: funções de ajuste brutas, maximização de f_1 e f_2

Fonte: Autor, modificado de [30]

Além da função de ajuste bruta, outra função utilizada para avaliar os indivíduos é a densidade (D). Essa função fornece informações adicionais sobre a relação de dominância entre as soluções no caso de muitas delas serem não-dominantes, ou seja, possuírem valor nulo de função de ajuste bruta.

O cálculo desta função, que está relacionada com a distância entre o indivíduo e as outras soluções, é feito de modo que o seu valor seja maior que zero e menor que 1.

Finalmente, esse valor é somado ao valor da função de ajuste bruta, resultando na função de ajuste (F) de um indivíduo. Quanto menor o valor de F , mais dominante é a solução, sendo que valores de F menores que 1 indicam uma solução não-dominada.

O detalhamento dessa etapa do algoritmo é descrito em [30].

- Atualização do arquivo

Nessa etapa do algoritmo o arquivo responsável por armazenar as soluções não-dominadas é atualizado. Esse processo é feito de modo que o número de soluções armazenadas no arquivo seja constante ao longo das iterações.

O primeiro passo consiste em copiar todas as soluções não-dominadas, isto é, com valor de função de ajuste menor que 1, para o arquivo. Caso o número de soluções copiadas para o arquivo neste passo seja igual ao tamanho do arquivo (parâmetro definido inicialmente no algoritmo), a etapa está concluída.

Caso o número de soluções copiadas para o arquivo seja menor que o tamanho do arquivo, os melhores indivíduos dominados, ou seja, os indivíduos que possuem as menores funções de ajuste com valor maior ou igual a 1, também são copiados para o arquivo até que este seja completado.

Caso o número de soluções copiadas no primeiro passo dessa etapa seja maior que o tamanho do arquivo, é realizado um processo de truncamento. Nesse processo, são retiradas soluções do arquivo, uma a uma, até que o tamanho do arquivo fique de acordo com o parametrizado. A escolha de qual solução deve ser removida é feita em função da distância entre as soluções, e previne que soluções da borda da fronteira de Pareto sejam removidas.

A etapa de atualização do arquivo é detalhada em [30].

- Seleção

O operador genético de seleção é responsável por selecionar quais indivíduos irão transmitir seu material genético para a próxima geração de indivíduos. No SPEA2, este operador é aplicado nos indivíduos armazenados no arquivo, formando um grupo

de indivíduos que, após o cruzamento e a mutação, dão origem à população da próxima geração.

O processo de seleção é feito através do método de torneio binário, descrito na seção 3.2.

- Cruzamento

O operador genético de cruzamento é responsável pela troca de material genético entre os indivíduos, possibilitando a exploração de diferentes regiões do espaço de busca. No SPEA2, este operador é aplicado no grupo de indivíduos formado após a seleção.

O processo de cruzamento é feito através do método de cruzamento uniforme, descrito na seção 3.2.

- Mutação

O operador genético de mutação é responsável por garantir a diversidade genética da população, evitando que o algoritmo fique restrito a alguma região do espaço de busca. No SPEA2, este operador é aplicado no grupo de indivíduos formado após o cruzamento, dando origem à população da próxima geração do algoritmo.

O processo de mutação é descrito na seção 3.2.

4 Aplicação

Nesta seção são apresentados três casos de aplicação dos algoritmos estudados à resolução de problemas de otimização do controle Volt/VAr. O primeiro deles tem o objetivo de comparar os indicadores de desempenho dos algoritmos. O segundo tem como enfoque a qualidade das soluções em relação aos objetivos do CVV. O terceiro visa ilustrar a aplicação do algoritmo de otimização multiobjetivo. Nos três casos foram utilizadas redes reais de distribuição de energia.

Os algoritmos estudados foram implementados na linguagem de programação C++ no software Embarcadero C++Builder XE7 e executados em uma máquina com 4 GB RAM e processador Intel Core i7-4500U.

Os casos de aplicação foram realizados em ambiente de simulação com o auxílio da plataforma SINAPGrid [31], ferramenta com representação gráfica do sistema de distribuição e que é utilizada como motor de cálculo para os cálculos elétricos necessários no processo de otimização do CVV, tal como o fluxo de potência.

4.1 Caso I - Análise de desempenho dos algoritmos

Nesse caso de aplicação, os algoritmos foram executados de forma a realizar a otimização do controle Volt/VAr em uma rede urbana contendo uma subestação com um transformador com OLTC, responsável por controlar a tensão na barra inicial de quatro alimentadores de média tensão (13,8kV). No total, considerando os quatro alimentadores, a rede possui 1112 barras, sendo que existem cargas em 294 delas.

Para avaliar o desempenho dos algoritmos foram definidos três indicadores, sendo estes: (i) o tempo de execução do algoritmo até encontrar a solução, (ii) a iteração em que a solução foi encontrada e (iii) valor da função objetivo da solução encontrada pelo algoritmo.

Além do OLTC (com 17 taps no enrolamento primário entre +8% e -8%), existem 11 bancos de capacitores chaveados instalados nos alimentadores, sendo 4 de 600kVAr

e 7 de 1200kVAr, totalizando 12 equipamentos de controle e um espaço de busca para cada instante (patamar) de 34816 soluções possíveis para o problema.

Em nenhum dos casos de aplicação os BCs instalados na subestação foram considerados, visto que sua função é de compensar o fluxo de reativos nos transformadores, sendo operados através de uma lógica local específica. A Figura 27 mostra o diagrama unifilar da rede.

Figura 27 - Diagrama unifilar da rede do primeiro caso de aplicação

Fonte: Autor

A parametrização dos algoritmos foi feita de modo que eles busquem deixar a tensão nas barras com carga dentro do intervalo de -5% e +5% em relação a tensão nominal, conforme gráfico da Figura 7.

Como as regiões do espaço de busca exploradas pelas meta-heurísticas variam cada vez que são executadas, cada um dos algoritmos foi executado 100 vezes para a resolução do problema de otimização do CVV no patamar da curva de carga do transformador com maior demanda, das 09h00 às 10h00. Desse modo, é possível

verificar o desempenho médio dos algoritmos em relação aos indicadores de desempenho definidos.

Os algoritmos foram executados por 20 iterações com uma população de 6 indivíduos/formigas/partículas. No AG básico a seleção é feita pelo método da roleta e o cruzamento em um ponto. No AG modificado a seleção é feita pelo método do torneio binário e o cruzamento uniforme. No AM a busca local é realizada através da primeira iteração do método *Hill Climbing*, somente no melhor indivíduo da população, e os operadores evolutivos são os mesmos do AG modificado. As taxas de cruzamento/cooperação e mutação foram fixadas em 75% e 1%, respectivamente.

O gráfico da Figura 28 mostra a evolução do valor médio das menores funções objetivo obtidas em cada algoritmo ao longo das iterações. A Tabela 6 mostra os valores máximo, mínimo e médio dos indicadores de desempenho de cada algoritmo, quais sejam (i) tempo até encontrar a solução, (ii) iteração em que a solução foi encontrada e (iii) valor da função objetivo da solução.

Figura 28 - Evolução média da função objetivo

Fonte: Autor

Tabela 6 - Comparação dos indicadores de desempenho dos algoritmos

Algoritmo	(i) Tempo solução [s]			(ii) Iteração solução			(iii) Função objetivo			
	Menor	Maior	Média	Menor	Maior	Média	Menor	Maior	Média	σ
AG básico	1	34	8,0	0	18	3,7	0,001	0,781	0,069	0,117
AG modificado	1	44	14,4	0	19	6,3	0,001	0,589	0,018	0,064
AM	1	123	31,9	0	19	4,8	0,001	0,327	0,024	0,052
OCF	1	25	5,9	0	13	2,5	0,001	0,677	0,010	0,069
OEP	1	31	6,1	0	16	2,7	0,001	0,001	0,001	0,000

Fonte: Autor

Analisando o gráfico da Figura 28 e a Tabela 6, observa-se que, em média, o AG modificado e o AM encontraram soluções melhores que o AG básico, apesar desse último encontrar as soluções mais rapidamente. Isso mostra que o AG básico possui dificuldades para evoluir sua população de indivíduos, encontrando uma solução após 3,7 iterações apenas, porém uma solução de qualidade inferior aos outros. Ressalta-se que o AM demora mais tempo que os outros algoritmos a cada iteração, devido às avaliações extras realizadas na etapa de busca local, levando 31,9 segundos, em média, para encontrar a solução, pouco mais que o dobro do que o AG modificado (14,4 segundos).

A OCF e a OEP mostraram desempenho superior aos outros três algoritmos, apresentando uma evolução mais acelerada no valor da função objetivo e convergindo para soluções de melhor qualidade em relação aos outros. Apesar do desempenho parecido destes dois algoritmos, a OEP se mostrou mais acurada, obtendo o menor valor de função objetivo encontrado por todos os algoritmos (0,001134) em 100% das execuções. Já a OCF chegou a este valor de função objetivo em 87 das 100 execuções.

Também se observa na Tabela 6 que todos os algoritmos, em pelo menos uma das execuções, encontraram a solução na iteração inicial, após um segundo de execução. Nestes casos, ao longo de todas as iterações executadas, não foi encontrada uma solução melhor do que a codificada em um dos indivíduos/formigas/partículas sorteados na população inicial de possíveis soluções para o problema.

Pelo gráfico da Figura 28, observa-se que, diferentemente do que ocorreu com a OCF e com a OEP, o comportamento do valor médio da menor função objetivo encontrada

pelos outros três algoritmos ainda não havia se estabilizado na décima nona iteração. De fato, um maior número de iterações possivelmente faria com que o AG básico, o AG modificado e o AM encontrassem melhores soluções para o problema. Por conta disso, foi feito um estudo de caso extra, onde os algoritmos foram executados por um número maior de iterações. A partir desse estudo, observou-se que a evolução do valor médio da melhor função objetivo encontrada por esses três algoritmos tende a se estabilizar por volta da quadragésima iteração, e nesse período maior de execução são encontradas soluções melhores, porém não tão boas quanto às encontradas pela OCF e OEP.

Portanto, o desempenho da otimização por enxame de partículas, mostrado no gráfico da Figura 28 e na Tabela 6, mostrou-se superior tanto no caso em que os algoritmos foram executados por 20 iterações quanto no caso em que os algoritmos foram executados por um número maior de iterações.

4.2 Caso II - Análise de qualidade em relação aos objetivos do CVV

Nesse caso de aplicação, os algoritmos foram executados de forma a realizar a otimização do controle Volt/VAr em uma rede urbana contendo uma subestação com três transformadores com OLTC, responsáveis por controlar a tensão na barra inicial de onze alimentadores de média tensão (13,8kV). No total, a rede possui 3805 barras, sendo que existem cargas em 712 delas.

Além dos OLTCs (cada um com 17 taps no enrolamento primário entre +8% e -8%), existem 30 bancos de capacitores chaveados distribuídos nos alimentadores, sendo 18 de 600kVAr e 12 de 1200kVAr, totalizando 33 equipamentos de controle. Tal combinação corresponde a um espaço de busca de 42,2 trilhões de soluções possíveis para o problema. A Figura 29 mostra o diagrama unifilar da rede.

Como os algoritmos foram implementados de modo que a otimização do controle Volt/VAr é feita em paralelo para cada bloco de rede, contendo um OLTC e a rede à sua jusante, o problema é fracionado em três problemas menores.

O processo de otimização em paralelo é realizado através da segmentação dos vetores responsáveis por armazenar os valores referentes às possíveis soluções para o problema, de modo que cada segmento contenha somente a posição de tap e o estado dos equipamentos presentes em um bloco de rede. Além disso, a etapa de avaliação executada pelos algoritmos é aplicada a cada segmento. Nos algoritmos genético e memético, os operadores de seleção e cruzamento também são aplicados considerando a segmentação dos vetores de possíveis soluções. Nas otimizações por colônia de formigas e por enxame de partículas, a atualização do feromônio e a atualização das velocidades também levam em conta essa segmentação. Desse modo, a evolução da população de possíveis soluções para o problema é direcionada de acordo com os resultados obtidos para cada bloco.

Sendo assim, o espaço de busca do problema é fracionado em três espaços de busca menores, de 34816, 17408 e 8704 soluções possíveis para cada patamar horário.

Figura 29 - Diagrama unifilar da rede do segundo caso de aplicação

Fonte: Autor

Para a execução dos algoritmos, foi mantida a mesma parametrização do caso anterior, e cada um deles foi executado para todos os patamares horários ao longo de um dia de operação. Cada algoritmo foi executado somente uma vez para cada patamar horário.

O gráfico da Figura 30 apresenta as perdas técnicas na rede para cada patamar horário do dia de operação. A Tabela 7 mostra a redução nas perdas técnicas que cada algoritmo obteve ao fim de um dia de operação.

Figura 30 - Perdas técnicas na rede por patamar horário

Fonte: Autor

Tabela 7 - Redução nas perdas técnicas

Algoritmo	Redução [MW]	Redução [%]
AG básico	0,035	0,7
AG modificado	0,153	2,9
AM	0,220	4,2
OCF	0,268	5,2
OEP	0,324	6,2

Fonte: Autor

Observa-se que os resultados seguem a tendência mostrada no caso de aplicação anterior, com a otimização por enxame de partículas obtendo o melhor resultado, 6,2% de redução de perdas técnicas na rede em comparação ao valor base, sem CVV, com BCs desligados e tap dos transformadores na posição zero. No gráfico, nota-se que esta redução é mais acentuada nos períodos de maior demanda.

O gráfico da Figura 31 mostra a tensão da fase A nas barras com carga da rede durante o patamar de maior demanda na subestação, das 09h00 às 10h00. O gráfico mostra os valores de tensão ordenados de maneira decrescente. Ressalta-se, portanto, não se tratar de um perfil de tensão no tronco do alimentador, mas sim uma ordenação dos valores de tensão, do maior para o menor, que não leva em conta a topologia da rede. Esta ordenação foi chamada de “perfil de tensão”. A Tabela 8 mostra as notas referentes ao nível de tensão nas barras com carga para cada bloco de rede (OLTC e a rede à sua jusante) e a soma das três notas.

Figura 31 - Tensão nas barras com carga da rede no patamar de maior demanda

Fonte: Autor

Tabela 8 - Notas referentes ao nível de tensão nas barras com carga

Algoritmo	Notas referentes ao nível de tensão nas barras com carga			
	Bloco 1	Bloco 2	Bloco 3	Soma
AG básico	0,977977	0,349958	1,000000	2,327935
AG modificado	0,998600	0,962290	1,000000	2,960890
AM	0,981765	1,000000	1,000000	2,981765
OCF	0,981859	1,000000	1,000000	2,981859
OEP	0,998866	1,000000	1,000000	2,998866

Fonte: Autor

O gráfico mostra que, com exceção do AG básico, todos os algoritmos obtiveram soluções de boa qualidade, elevando a tensão nas barras com carga e fazendo com que a maioria dos valores de tensão ficasse dentro da faixa de nota máxima, entre 1,0p.u. e 1,05p.u., sendo esta faixa parametrizada em conformidade com a faixa de tensão aceitável especificada no PRODIST. Novamente, a otimização por enxame de partículas foi o algoritmo que apresentou o melhor resultado, com a soma de notas igual a 2,999, sendo que a soma máxima possível é 3,0 no caso de todos os valores de tensão ficarem dentro da faixa citada acima.

Por ter encontrado uma solução ruim para o bloco 2, referente ao OLTC 2 e as redes à sua jusante, o AG básico apresentou certa quantidade de barras fora da faixa de nota máxima, porém ainda dentro da faixa parametrizada, entre 0,95p.u. e 1,05p.u. As quedas bruscas de tensão em sua curva, vermelha, ocorreram pelo fato de que o algoritmo definiu valores de tap consideravelmente diferentes para os OLTCs de cada bloco de rede. Como consequência, ao se ordenar os valores de tensão de maneira decrescente, primeiro (barras 1 a 218) foram apresentados os valores de tensão das barras na rede à jusante do OLTC com menor valor de tap, ou seja, maior tensão no enrolamento secundário, sendo este o OLTC 3, na posição de tap -3. Em seguida, foram apresentados os valores de tensão das barras na rede à jusante do OLTC com valor de tap intermediário (OLTC 1, tap -1, barras 219 a 512). Por fim foram apresentados os valores de tensão das barras na rede à jusante do OLTC com maior valor de tap (OLTC 2, tap 2, barras 513 a 712).

A Tabela 9 apresenta o número de chaveamentos executados pelos três OLTCs e o número médio de chaveamentos executados para cada tipo de equipamento, de

acordo com as soluções propostas pelos algoritmos, após as 24 horas do dia de operação.

Tabela 9 - Número médio de chaveamentos por equipamento

Algoritmo	Número de chaveamentos				
	OLTC 1	OLTC 2	OLTC 3	OLTCs (média)	BCs (média)
AG básico	34	27	30	30,3	12,1
AG modificado	27	19	25	23,7	10,0
AM	32	24	28	28,0	9,6
OCF	26	16	28	23,3	7,9
OEP	18	9	16	14,3	6,5

Fonte: Autor

A tabela mostra que a otimização por enxame de partículas foi o algoritmo que encontrou soluções com menor número de chaveamentos diários por equipamento. Com 14,3 chaveamentos em um dia, os OLTCs chavearam pouco mais do que o esperado e do que usualmente ocorreria caso eles estivessem sendo controlados por uma lógica local. Para os BCs, o número de 6,5 chaveamentos diários pode ser considerado elevado caso eles possuam chaves a óleo, porém seria um número aceitável no caso de chaves a vácuo.

A Tabela 10 e a Tabela 11 mostram a posição de tap dos OLTCs e o estado de seis bancos de capacitores ao longo do dia de operação de acordo com as soluções propostas pelo AG básico e pela OEP, respectivamente, em cada patamar horário.

Tabela 10 - Posição de tap dos OLTCs e estado de seis BCs durante um dia de operação - AG Básico

Algoritmo genético básico																									
Eqpto	Patamar																							Nº Chav	
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22		23
OLTC 1	0	0	1	-1	0	-3	0	-1	-1	-1	-3	-3	-1	-1	1	-3	-3	-1	-1	0	-3	0	-2	0	34
OLTC 2	-2	-1	-1	-3	-1	-3	-3	-2	-2	2	-1	-2	-3	-3	-2	-2	-2	-2	0	-3	-2	-3	-2	-3	27
OLTC 3	-1	0	-1	-3	-4	-2	-3	-2	-1	-3	-2	-2	-2	-3	-1	-2	-1	-4	-3	0	-3	-2	-2	-1	30
BC 3	0	1	0	0	0	1	1	0	1	0	1	1	0	1	0	1	0	1	0	1	0	1	0	0	16
BC 11	1	0	1	1	0	1	1	1	0	0	1	1	0	0	0	1	1	1	0	1	0	0	0	1	12
BC 12	0	0	0	0	1	1	0	0	0	1	1	1	1	1	1	0	0	0	1	0	1	1	1	1	7
BC 18	1	0	0	1	1	1	1	0	1	0	1	1	0	0	0	0	1	0	1	0	0	1	1	1	12
BC 25	0	1	1	0	0	0	0	1	0	1	1	0	0	0	1	0	0	0	0	1	0	1	1	0	12
BC 30	0	0	1	0	0	1	0	0	1	1	0	1	0	0	0	1	1	0	1	1	0	0	1	1	13

Fonte: Autor

Tabela 11 - Posição de tap dos OLTCs e estado de seis BCs durante um dia de operação - OEP

Otimização por enxame de partículas																									
Eqpto	Patamar																							Nº Chav	
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22		23
OLTC 1	-1	-2	-2	-3	-2	-2	-2	-1	-3	-2	-3	-3	-2	-3	-4	-3	-2	-3	-1	-2	-2	-2	-2	-3	18
OLTC 2	-2	-2	-2	-2	-2	-2	-3	-3	-2	-3	-3	-3	-3	-2	-3	-3	-3	-3	-2	-2	-2	-3	-2	-3	9
OLTC 3	-3	-1	-1	-3	-1	-1	-3	-4	-3	-2	-3	-3	-3	-2	-3	-3	-2	-3	-2	-3	-2	-3	-3	-3	16
BC 3	0	0	0	0	0	0	1	0	0	1	1	1	1	1	1	0	0	0	0	1	1	1	0	0	6
BC 11	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	0	0	1	4
BC 12	0	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	5
BC 18	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0
BC 25	0	1	1	1	1	0	1	0	1	1	1	1	0	0	1	1	0	0	1	0	0	0	0	1	11
BC 30	0	1	1	1	0	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	6

Fonte: Autor

A partir das tabelas, observa-se que as soluções propostas pela otimização por enxame de partículas fazem com que, de maneira geral, os equipamentos realizem menor número de chaveamentos ao longo do dia de operação.

4.2.1 Análise de sensibilidade

De modo a verificar a influência dos pesos de cada função de pertinência na função objetivo do problema, foi realizada uma análise de sensibilidade. Nessa análise, o algoritmo de otimização por enxame de partículas foi aplicado na mesma rede do caso apresentado na seção 4.2, mostrada na Figura 29.

Além da aplicação inicial (OEP), foram realizados outros três casos de aplicação, cada um deles com alterações nos pesos de cada função de pertinência na função objetivo, conforme mostra a Tabela 12.

Os pesos foram definidos com base nos valores das funções de pertinência obtidos no caso de aplicação anterior, de modo que o valor da função de pertinência referente ao objetivo a ser priorizado em cada um dos três casos da análise de sensibilidade fosse predominante no cálculo da função objetivo do problema.

Tabela 12 - Funções objetivo a minimizar para análise de sensibilidade

Caso	Função objetivo
OEP	$1 - \frac{(\mu J_i + \mu V_i + \mu Ch_i)}{3}$
OEP Perdas	$1 - \frac{(2,99 * \mu J_i + 0,005 * \mu V_i + 0,005 * \mu Ch_i)}{3}$
OEP Tensão	$1 - \frac{(0,005 * \mu J_i + 2,99 * \mu V_i + 0,005 * \mu Ch_i)}{3}$
OEP Chav.	$1 - \frac{(0,005 * \mu J_i + 0,005 * \mu V_i + 2,99 * \mu Ch_i)}{3}$

Fonte: Autor

O gráfico da Figura 32 apresenta as perdas técnicas na rede para cada patamar horário do dia de operação. A Tabela 13 mostra a redução nas perdas técnicas que cada caso obteve ao fim de um dia de operação.

Figura 32 - Perdas técnicas na rede por patamar horário

Fonte: Autor

Tabela 13 - Redução nas perdas técnicas

Caso	Redução [MW]	Redução [%]
OEP	0,324	6,2
OEP Perdas	0,393	7,6
OEP Tensão	0,294	5,7
OEP Chav	0,124	2,4

Fonte: Autor

Observa-se na tabela que, conforme o esperado, o caso em que a função de pertinência referente às perdas técnicas foi priorizada na função objetivo (OEP Perdas) alcançou o melhor resultado ao fim de um dia de operação, com redução de 7,6% nas perdas técnicas na rede em comparação ao valor base, sem CVV, com BCs desligados e tap dos OLTCs na posição zero. Os outros dois casos, com priorização nas funções de pertinência referentes ao nível de tensão nas barras (OEP Tensão) e ao número de chaveamentos dos equipamentos (OEP Chav) apresentaram resultados inferiores à redução de 6,2% obtida no caso de aplicação inicial (OEP).

Da mesma forma que o gráfico da Figura 31, o gráfico da Figura 33 mostra a tensão da fase A nas barras com carga da rede durante o patamar de maior demanda na subestação, das 09h00 às 10h00, para cada um dos casos. O gráfico mostra os valores de tensão ordenados de maneira decrescente. A Tabela 14 mostra as notas referentes ao nível de tensão nas barras com carga para cada bloco de rede (OLTC e a rede à jusante) e a soma das três notas.

Figura 33 - Tensão nas barras com carga da rede no patamar de maior demanda

Fonte: Autor

Tabela 14 - Notas referentes ao nível de tensão nas barras com carga

Caso	Notas referentes ao nível de tensão nas barras com carga			
	Bloco 1	Bloco 2	Bloco 3	Soma
OEP	0,998866	1,000000	1,000000	2,998866
OEP Perdas	0,998866	1,000000	0,000000	1,998866
OEP Tensão	0,998866	1,000000	1,000000	2,998866
OEP Chav	0,997909	1,000000	0,951898	2,949807

Fonte: Autor

A tabela mostra que o caso OEP Tensão obteve a mesma nota referente ao nível de tensão nas barras com carga da rede que o caso de aplicação inicial, sendo essa a nota máxima entre os quatro casos, com o valor de 2,999. Esse resultado também é representado no gráfico, onde se observa que a maioria dos valores de tensão das curvas referentes a esses casos, nas cores marrom e roxa, respectivamente, se encontra na faixa de nota máxima.

No caso OEP Perdas, mostrado na curva azul do gráfico, observa-se que há certa quantidade de barras com valor de tensão na faixa crítica, ou seja, acima de 1,05p.u. Além disso, ocorre uma queda brusca nos valores de tensão entre as barras de

número 218 e 219. Como nesse caso a função de pertinência referente ao nível de tensão nas barras possui peso quase nulo na função objetivo, o algoritmo encontrou uma solução ruim para o bloco de rede número 3 em relação a este objetivo. Foi definido que o tap do OLTC 3 deveria ficar na posição -7, fazendo com que o valor de tensão nas barras com carga da rede à sua jusante fosse muito elevado, se encontrando na faixa crítica de tensão. Como consequência, ao se ordenar os valores de tensão de maneira decrescente, esses valores foram apresentados no início da curva (barras 1 a 218).

A Tabela 15 apresenta o número de chaveamentos executados pelos três OLTCs e o número médio de chaveamentos executados para cada tipo de equipamento, de acordo com as soluções de cada caso, ao longo de um dia de operação.

Tabela 15 - Número médio de chaveamentos por equipamento

Caso	Número de chaveamentos				
	OLTC 1	OLTC 2	OLTC 3	OLTCs (média)	BCs (média)
OEP	21	12	19	17,3	6,9
OEP Perdas	109	63	107	93,0	4,3
OEP Tensão	13	7	1	7,0	8,0
OEP Chav	5	4	5	4,7	10,8

Fonte: Autor

A tabela mostra que no caso OEP Chav há uma redução considerável no número de chaveamentos que os OLTCs executam ao longo do dia de operação, de 17,3 para 4,7 chaveamentos, em média, em comparação com o caso de aplicação inicial. Apesar disso, o número de chaveamentos executados pelos BCs aumentou de 6,9 para 10,8, em média, mostrando que o algoritmo não foi totalmente eficiente quando focado nesse objetivo.

Por outro lado, o número de chaveamentos dos OLTCs também foi reduzido no caso OEP Tensão e o número médio de chaveamentos dos BCs foi mínimo no caso OEP Perdas. Entretanto, esses resultados são consequência de características específicas desse caso de aplicação. Devido ao comportamento das curvas de consumo das cargas presentes na rede e da curva de demanda de potência reativa, foi possível que o caso OEP Tensão encontrasse boas soluções para todos os patamares horários

sem que fosse necessária grande quantidade de chaveamentos dos OLTCs, e foi possível que o caso OEP Perdas encontrasse boas soluções, mesmo com 10 dos 30 BCs permanecendo em apenas um estado (ligado ou desligado) durante todo o período.

4.3 Caso III - Análise da resolução multiobjetivo do problema (A)

Nesse caso de aplicação, o algoritmo SPEA2 foi executado de forma a realizar a otimização do controle Volt/VAr na mesma rede do caso apresentado na seção 4.1, mostrada na Figura 27, no patamar de maior demanda na subestação, das 09h00 às 10h00. A distribuição das soluções encontradas pelo algoritmo no espaço de busca do problema é apresentada na Figura 34.

Figura 34 - Distribuição das soluções no espaço de busca

Fonte: Autor

Os pontos em azul representam o conjunto de soluções que formariam a aproximação da fronteira de Pareto caso o algoritmo não tivesse encontrado uma única solução dominante, representada pelo ponto verde.

Essa solução dominante, que definiu que o tap do OLTC deveria ficar na posição -3 e que cinco dos onze BCs deveriam ser ligados, possui nota referente ao nível de tensão nas barras com carga tão alta quanto a solução representada pelo ponto azul mais à esquerda do gráfico (nota máxima para esta situação, no valor de 0,998866), e além disso, possui a nota referente às perdas técnicas da rede mais alta entre as soluções encontradas.

Nessa situação, a solução dominante fez com que a fronteira de Pareto fosse aproximada por um único ponto, o que leva a crer que, nesse caso específico, os objetivos não são conflitantes. Sendo assim, foi realizado um estudo de caso extra para análise da resolução multiobjetivo do problema de otimização do CVV.

4.4 Caso IV- Análise da resolução multiobjetivo do problema (B)

Nesse caso de aplicação, o algoritmo SPEA2 foi executado de forma a realizar a otimização do controle Volt/VAr em uma rede contendo uma subestação com um transformador com OLTC, responsável por controlar a tensão na barra inicial de um alimentador de média tensão (13,8kV). No total, a rede possui 7592 barras, sendo que existem cargas em 820 delas. A Figura 35 mostra o diagrama unifilar da rede. O único equipamento de controle nesse caso é o transformador com OLTC localizado na subestação

O conjunto de soluções não-dominadas encontradas pelo algoritmo no espaço de busca do problema é apresentado na Figura 36.

Figura 35 - Diagrama unifilar da rede do quarto caso de aplicação

Fonte: Autor

Figura 36 - Distribuição das soluções não-dominadas no espaço de busca

Fonte: Autor

A linha tracejada entre os pontos em azul representa a aproximação da fronteira de Pareto encontrada pelo algoritmo. O ponto azul à esquerda, com nota referente ao nível de tensão nas barras com carga no valor de 0,5446 e nota referente às perdas técnicas na rede no valor de 0,6613 corresponde à solução que definiu a posição -7 para o tap do OLTC. O outro ponto, com as notas 0,5080 e 0,6705 para esses dois objetivos, respectivamente, corresponde à solução que definiu a posição -6 para o tap.

5 Conclusões

Inicialmente, no capítulo 2, descreve-se o controle de tensão e reativos, incluindo características dos equipamentos utilizados, abordagens de implantação nos sistemas de distribuição e sua importância em relação à qualidade da energia elétrica distribuída. Além disso, diversos métodos para realizar a otimização deste controle foram apresentados.

Evidenciou-se que a abordagem de otimização do controle Volt/VAr baseada em um modelo do sistema elétrico de distribuição se adequa completamente aos requisitos das redes elétricas inteligentes, por permitir a otimização global do sistema com objetivos operacionais flexíveis, independente da presença ou ausência de geração distribuída no sistema e de situações de reconfiguração de rede.

No capítulo 3, algumas meta-heurísticas bio-inspiradas foram apresentadas, implementadas e aplicadas à resolução do problema de otimização do controle Volt/VAr, quais sejam o algoritmo genético básico e uma de suas variantes, o algoritmo memético, a otimização por colônia de formigas, a otimização por enxame de partículas e o SPEA2.

Três casos de aplicação foram estudados, em redes de distribuição de energia elétrica com dimensões reais, de modo a comparar os indicadores de desempenho dos algoritmos, tanto em relação à velocidade de busca quanto em relação à qualidade da solução encontrada.

Todos os algoritmos analisados apresentaram bons resultados ao serem utilizados na resolução do problema de otimização do controle Volt/VAr em comparação ao caso base, sem CVV, com BCs desligados e tap dos transformadores na posição zero. As soluções propostas pelos algoritmos levaram os níveis de tensão nas barras com carga da rede para dentro do limite em todos os casos, com perdas técnicas na rede sendo reduzidas.

A otimização por enxame de partículas foi o algoritmo que apresentou os melhores resultados de desempenho, encontrando as soluções de melhor qualidade entre os algoritmos em apenas 2,7 iterações em média. Ao ser aplicado durante um dia completo de operação, apresentou 6,2% de redução de perdas técnicas na rede em

comparação ao valor base, sem CVV, com BCs desligados e tap dos transformadores na posição zero.

Foi feita uma análise de sensibilidade em relação à influência de peso de cada função de pertinência na função objetivo do problema. No caso em que a função de pertinência referente às perdas técnicas foi priorizada, o algoritmo alcançou o valor mínimo de perdas técnicas ao longo de um dia de operação, com redução de 7,6% em comparação ao valor base, sem CVV, com BCs desligados e tap dos OLTCs na posição zero. No caso em que a função de pertinência referente ao nível de tensão nas barras foi priorizada, o algoritmo alcançou nota máxima em relação a este objetivo no patamar horário analisado. No caso em que a função de pertinência referente ao número de chaveamentos foi priorizada, o algoritmo obteve redução do número de chaveamentos executados pelos OLTCs em um dia de operação, porém o número de chaveamentos dos BCs foi o maior entre os casos, mostrando que o algoritmo não foi totalmente eficiente quando focado nesse objetivo.

No primeiro estudo de caso para análise da resolução multiobjetivo do problema de controle Volt/VAr, o algoritmo SPEA2 encontrou um conjunto de soluções que foi dominada por uma única solução. Sendo assim, a fronteira de Pareto foi aproximada por um ponto apenas, levando a crer que os objetivos, nesse caso, não são conflitantes. No segundo caso, onde o algoritmo foi aplicado a outra rede, foram encontradas duas soluções não-dominadas, sendo uma melhor avaliada em relação ao nível de tensão nas barras com carga, e outra melhor avaliada em relação às perdas técnicas na rede. Nesse caso, a fronteira de Pareto foi aproximada por uma reta.

Os algoritmos mostraram-se aplicáveis a sistemas de distribuição de dimensões reais, sendo capazes de definir ações de controle para dezenas de equipamentos em questão de minutos. No Caso II de aplicação estudado, a otimização por enxame de partículas encontrou boas soluções, definindo o estado de 33 equipamentos, em pouco mais de um minuto. Esse tempo, que é dependente do algoritmo utilizado, das configurações do computador e do tamanho da rede estudada, é compatível para aplicação da funcionalidade de controle Volt/VAr em campo.

Parte do sucesso desse desempenho se deu pela modelagem adotada, onde a rede na qual o CVV está sendo aplicado é dividida em blocos, constituídos de um transformador de subestação com OLTC e a respectiva rede à sua jusante, possibilitando que a otimização para cada bloco (OLTC) seja executada em paralelo.

5.1 Tópicos para ulterior desenvolvimento

O presente trabalho tem o objetivo de servir como base para outros estudos na área de distribuição de energia elétrica, relacionados à área de operação de sistemas elétricos. Além do estudo apresentado no *17th International Conference on Harmonics and Quality of Power* (ICHQP 2016), organizado pelo IEEE e realizado Belo Horizonte, algumas possíveis extensões do trabalho são citadas a seguir:

- Estudo do problema de otimização do controle Volt/VAr em redes com diferentes graus de penetração de unidades de geração distribuída: a modelagem adotada neste trabalho permite que fontes alternativas de geração de energia incorporadas à rede sejam consideradas no processo de otimização do controle de tensão e reativos, sejam elas controladas pelo algoritmo, conforme visto em [10], [15], [16] e [23], ou seja a influência delas na rede de distribuição apenas considerada no modelo do sistema elétrico.
- Estudo do comportamento dos algoritmos apresentados neste trabalho em outros problemas de otimização na área de operação do sistema elétrico: uma das principais qualidades das meta-heurísticas é a facilidade com que estes algoritmos são modelados de forma a aplicá-los a diferentes tipos de problema. Sendo assim, poderiam ser aplicados a outros problemas com necessidade de otimização automática e dinâmica na área de operação do sistema de distribuição, tal como o problema de reconfiguração de redes em condições de emergência (self-healing).

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ANEEL. **Procedimentos de distribuição de energia elétrica no sistema elétrico nacional**: módulo 8 - qualidade da energia elétrica. Brasília: ANEEL, 2018.
- [2] ULUSKI, R. W. VVC in the smart grid era. In: IEEE PES GENERAL MEETING, **Proceedings...** Mineápolis, 2010.
- [3] RAHIMI, S.; MARINELLI, M.; SILVESTRO, F. Evaluation of requirements for Volt/VAr control and optimization function in distribution management systems. In: IEEE INTERNATIONAL ENERGY CONFERENCE AND EXHIBITION, **Proceedings...** Florença, 2012.
- [4] ANEEL. Indicadores e informações gerenciais. Disponível em: <http://www.aneel.gov.br/>. Acesso em: Janeiro 2018.
- [5] ULUSKI, R. W. Volt/VAr control and optimization concepts and issues. Apresentação para o Smart Energy Laboratory. Washington, 2011.
- [6] JAUCH, T. E. Smart Grid Volt/Var Magagement: Challenges of Integrating Distribution DG. In: IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES, **Proceedings...** Washington, 2011.
- [7] REDES INTELIGENTES BRASIL. Disponível em: <http://redesinteligentesbrasil.org.br/>. Acesso em: Janeiro 2018.
- [8] BALDICK, R.; WU, F. F. Efficient integer optimization algorithms for optimal coordination of capacitors and regulators. **IEEE Transactions on Power Systems**, v. 5, n. 3, p. 805-812, 1990.
- [9] HSU, Y. Y.; LU, F. C. A combined artificial neural network-fuzzy dynamic programming approach to reactive power/voltage control in a distribution substation. **IEEE Transactions on Power Systems**, v. 13, n. 4, p. 1265-1271, 1998.
- [10] BORGHETTI, A.; BOSETTI, M.; GRILLO, S.; MASSUCCO, S.; NUCCI, C. A.; PAOLONE, M.; SILVESTRO, F. Short-term scheduling and control of active distribution systems with high penetration of renewable resources. **IEEE Systems Journal**, v. 4, n. 3, p. 313-322, 2010.

- [11] LIANG, R. H.; WANG, Y. S. Fuzzy-based reactive power and voltage control in a distribution system. **IEEE Transactions on Power Delivery**, v. 18, n. 2, p. 610-618, 2003.
- [12] LIANG, C. H.; CHUNG, C. Y.; WONG, K. P. ; DUAN, X. Z.; TSE, C. T. Study of differential evolution for optimal reactive power flow. **IET Generation, Transmission & Distribution**, v. 1, n. 2, p. 253-260, 2007.
- [13] OLIVEIRA, D. Q.; ZAMBRONI DE SOUZA, A. C.; DELBONI, L. F. N.; SANTOS, M. V.; MARUJO, D.; CARVALHO FILHO, J. M.; BONATTO, B. D.; GUERRERO, C. A. V. Optimal voltage control on power distribution systems using artificial immune systems. In: CIGRÉ REGIONAL SOUTH-EAST EUROPEAN CONFERENCE, **Proceedings...** Timisoara, 2014.
- [14] HU, Z.; WANG, X.; CHEN, H.; TAYLOR, G. A. Volt/VAr control in distribution systems using a time-interval based approach. **IEE Proceedings - Generation, Transmission and Distribution**, v. 150, n. 5, p. 448-554, 2003.
- [15] NIKNAM, T.; RANJBAR, A. M.; SHIRANI, A. R. Impact of distributed generation on Volt/VAr control in distribution networks. In: IEEE BOLOGNA POWERTECH CONFERENCE, **Proceedings...** Bolonha, 2003.
- [16] SUBBARAJ, P.; RAJNARAYANANB, P. N. Optimal reactive power dispatch using self-adaptive real coded genetic algorithm. **Electric Power Systems Research**, v. 79, n. 2, p. 374-381, 2009.
- [17] SOUZA, B. A.; 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**, v. 25, n. 3, p. 1274-1281, 2010.
- [18] PADILHA-FELTRIN, A.; RODEZNO, D. A. Q.; MANTOVANI, J. R. S. Volt-VAr multiobjective optimization to peak-load relief and energy efficiency. **IEEE Transactions on Power Delivery**, v. 30, n. 2, p. 618-626, 2014.
- [19] MENDES, A.; FRANÇA, P. M.; LYRA, C.; PISSARRA, C.; CAVELLUCCI, C. Capacitor placement in large-sized radial distribution networks. **IEE Proceedings - Generation, Transmission and Distribution**, v. 152, n. 4, p. 496-502, 2005.
- [20] MUSTAFAR, M. F.; MUSIRIN, I.; KALIL, M. R.; IDRIS, M. K. Ant colony optimization (ACO) based technique for voltage control and loss minimization

- using transformer tap setting. In: 5TH STUDENT CONFERENCE ON RESEARCH AND DEVELOPMENT, **Proceedings...** Selangor, 2007.
- [21] FUKUYAMA, Y. Parallel particle swarm optimization for reactive power and voltage control verifying dependability. In: IEEE CONGRESS ON EVOLUTIONARY COMPUTATION, **Proceedings...** Sendai, 2015.
- [22] COELHO, L. S.; BARBOSA, L. Z.; LEBENSZTAJN, L. Multiobjective particle swarm approach for the design of a brushless DC wheel motor. **IEEE Transactions on Magnetics**, v. 46, n. 8, p. 2994-2997, 2010.
- [23] OLAMAIE, J.; NIKNAM, T. Daily Volt/VAr control in distribution networks with regard to DGs - A comparison of evolutionary methods. IEEE POWER INDIA CONFERENCE, **Proceedings...** Nova Delhi, 2006.
- [24] KAGAN, N.; SCHMIDT, H. P.; OLIVEIRA, C. C. B.; KAGAN, H. Algoritmos evolutivos. In: KAGAN, N. et al. **Métodos de otimização aplicados à sistemas elétricos de potência**. São Paulo: Blucher, 2009, p. 131-178.
- [25] BENTO, E. P.; KAGAN, N. Algoritmo genético e variantes na solução de problemas de configuração de redes de distribuição. **Controle & Automação**, v. 19, n. 3, p. 302-315, 2008.
- [26] MOSCATO, P. On evolution, search, optimization, genetic algorithms and martial arts – Towards memetic algorithms. Caltech Concurrent Computation Program 158-79. California Institute of Technology, Pasadena, 1989.
- [27] GASPAR-CUNHA, A.; TAKAHASHI, R.; ANTUNES, C. H. Colônia de formigas. In: GASPAR-CUNHA, A.; TAKAHASHI, R.; ANTUNES, C. H. **Manual de computação evolutiva e metaheurística**. Belo Horizonte, UFMG, 2013, p. 87-106.
- [28] KONG, M.; TIAN, P. Introducing a binary ant colony optimization. In: KONG, M.; TIAN, P. **Ant colony optimization and swarm intelligence**. Bruxelas, Springer Berlin Heidelberg, 2006, p. 444-451.
- [29] KHANESAR M. A.; TESHNEHLAB, M.; SHOOREHDELI, M. A. A novel binary particle swarm optimization. In: MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION, **Proceedings...** Atenas, 2007.

- [30] ZITZLER, E.; LAUANN, M.; THIELE, L. SPEA2: Improving the strength pareto evolutionary algorithm. Technical report 103, Computer Engineering and Networks Laboratory. Swiss Federal Institute of Technology, Zurich, 2001.
- [31] SINAPSIS. Plataforma SINAPgrid: plataforma para a análise de redes elétricas. Disponível em: <http://www.sinapsisenergia.com>. Acesso em: Janeiro 2018.