

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
CURSO DE ENGENHARIA DE COMPUTAÇÃO**

MURIEL MAZZETTO

INTELIGÊNCIA COMPUTACIONAL PARA SISTEMAS *SELF-HEALING*: UM ESTUDO DE CASO EM REDES ELÉTRICAS INTELIGENTES

TRABALHO DE CONCLUSÃO DE CURSO

PATO BRANCO

2016

MURIEL MAZZETTO

INTELIGÊNCIA COMPUTACIONAL PARA SISTEMAS *SELF-HEALING*: UM ESTUDO DE CASO EM REDES ELÉTRICAS INTELIGENTES

Trabalho de Conclusão de Curso como requisito parcial à obtenção do título de Bacharel em Engenharia de Computação, do Departamento Acadêmico de Informática da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Dalcimar Casanova
Coorientador: Prof. Dr. Richardson Ribeiro

PATO BRANCO

2016



MINISTÉRIO DA EDUCAÇÃO
Universidade Tecnológica Federal do Paraná
Câmpus Pato Branco
Departamento Acadêmico de Informática
Curso de Engenharia de Computação



TERMO DE APROVAÇÃO

Às 13 horas e 30 minutos do dia 28 de junho de 2016, na sala V006, da Universidade Tecnológica Federal do Paraná, Câmpus Pato Branco, reuniu-se a banca examinadora composta pelos professores Dalcimar Casanova (orientador), Cesar Augusto Portolann e Marco Antonio de Castro Barbosa para avaliar o trabalho de conclusão de curso com o título **Inteligência computacional para sistemas self-healing: um estudo de caso em redes elétricas inteligentes**, do aluno **Muriel Mazzetto**, matrícula 01374770, do curso de Engenharia de Computação. Após a apresentação o candidato foi arguido pela banca examinadora. Em seguida foi realizada a deliberação pela banca examinadora que considerou o trabalho aprovado.

Dalcimar Casanova
Orientador (UTFPR)

Cesar Augusto Portolann
(UTFPR)

Marco Antonio de Castro Barbosa
(UTFPR)

Beatriz Terezinha Borsoi
Coordenador de TCC

Pablo Gauterio Cavalcanti
Coordenador do Curso de
Engenharia de Computação

A Folha de Aprovação assinada encontra-se na Coordenação do Curso.

RESUMO

MAZZETTO, Muriel. Inteligência computacional para sistemas *self-healing*: um estudo de caso em redes elétricas inteligentes. 2016. 72 f. Trabalho de Conclusão de Curso de bacharelado em Engenharia de Computação - Universidade Tecnológica Federal do Paraná. Pato Branco, 2016.

Este trabalho emprega técnicas de inteligência computacional em problemas de otimização encontrados nos sistemas *smart grid*. Uma característica da *smart grid* é a capacidade da auto recuperação de um sistema, como por exemplo, restaurar a normalidade de uma rede de distribuição de energia após a ocorrência de uma falta. Quando um sistema tem a capacidade da auto recuperação pós falta, esse é denominado de *self-healing*. Uma alternativa para emergir um sistema *self-healing* é a aplicação de técnicas baseadas em população. Algoritmos de otimização por enxames de partículas são alternativas para encontrar topologias capazes de restaurar um sistema. Para isso foi modelada a rede de distribuição de energia utilizando a teoria dos grafos, bem como utilizado o método da soma das correntes para o cálculo do fluxo de potência. A recuperação da rede pós falta é realizada utilizando algoritmos bio-inspirados adaptados ao problema de otimização em *smart grids*. Os resultados avaliam os diferentes fatores que influenciam na execução do algoritmo e a sua capacidade de resolução do problema abordado.

Palavras-chave: Sistemas de distribuição de energia. *Smart grid*. *Self-healing*. Enxame de partículas.

ABSTRACT

MAZZETTO, Muriel. Computational intelligence for self-healing systems: a case study on smart grids. 2016. 72 f. Trabalho de Conclusão de Curso de bacharelado em Engenharia de Computação - Universidade Tecnológica Federal do Paraná. Pato Branco, 2016.

This work employs computational intelligence techniques in optimization problems found in smart grid systems. A feature of the smart grid is the auto-recovery capability of a system, for example, restore normalcy of a power distribution network after occurrence of a fault. When a system has the capability of auto-recovery after failure, this is called self-healing. An emerging alternative to a self-healing system is the application of population-based techniques. Optimization algorithms by particle swarms are alternatives to find topologies able to restore a system. To this the power distribution network was modeled using graph theory, as well used the sum of the currents method for calculating the power flow. The recovery of network after fault is performed using bio-inspired algorithms adapted to the optimization problem in smart grids. The results evaluate the different factors that influence the algorithm execution and its resolution capability of the problem addressed.

Keywords: Energy distribution systems. Smart grid. Self-healing. Particle swarm.

LISTA DE FIGURAS

Figura 1 – <i>Self-healing loop</i>	16
Figura 2 – Topologia radial de um sistema de distribuição.....	22
Figura 3 – Modelagem de uma rede de distribuição em grafo.....	28
Figura 4 – Detecção e isolamento de falta	30
Figura 5 – Exemplo de uma rede com topologia radial	31
Figura 6 – Exemplo de estudo de fluxo de potência	32
Figura 7 – Representação da partícula formada pela rede da Figura 3.....	35
Figura 8 – Fluxograma do cálculo de recompensa	39
Figura 9 – Fluxograma do método proposto.....	41
Figura 10 – Rede de distribuição para testes	42
Figura 11 – Média e desvio padrão para Teste 1	45
Figura 12 – Média e desvio padrão para Teste 2	45
Figura 13 – Convergência PSO x AG variando w	46
Figura 14 – Média e desvio padrão para Teste 3	48
Figura 15 – Convergência PSO x AG variando partículas e episódios	48
Figura 16 – Convergência de funções objetivo para $c1=0,4$, $c2=0,4$ e $c3=0,2$	51
Figura 17 – Convergência de funções objetivo para $c1=0,5$, $c2=0,4$ e $c3=0,1$	53
Figura 18 – Média e Desvio Padrão de tempo e recompensa	55
Figura 19 – Média e desvio padrão para critério de parada variável	58
Figura 20 – Rede com 24 chaves para Teste 1	59
Figura 21 – Soluções para rede da Figura 20.....	61
Figura 22 – Rede com 24 chaves para Teste 2	62
Figura 23 – Soluções para rede da Figura 22.....	63

LISTA DE TABELAS

Tabela 1 – Exemplo de dados de uma rede	28
Tabela 2 – Comparação de métodos para fluxo de potência	43
Tabela 3 – Corrente das subestações da rede da Figura 10.....	43
Tabela 4 – Resultados para rede da Figura 20	60
Tabela 5 – Resultados para redes da Figura 23.....	64

LISTA DE CÓDIGOS

Código 1 – Adaptação da busca em profundidade para ordenar varreduras	38
Código 2 – Iteração para cálculo do fluxo de potência	38
Código 3 – Código de execução da busca por PSO.....	40

LISTA DE SIGLAS

ACO	<i>Ant Colony Optimization</i>
ACS	<i>Ant Colony System</i>
AHP	<i>Analytical Hierarchy Process</i>
ANEEL	Agência Nacional de Energia Elétrica
GRA	<i>Gray Relational Analysis</i>
PRODIST	Procedimentos de Distribuição
TI	Tecnologia da Informação
PSO	<i>Particle Swarm Optimization</i>
AG	Algoritmo Genético
pu	Por Unidade
kW	Quilowatt

SUMÁRIO

1	INTRODUÇÃO E CONTEXTUALIZAÇÃO	11
1.1	PROBLEMA E JUSTIFICATIVA	12
1.2	OBJETIVOS.....	13
1.2.1	Objetivo Geral	13
1.2.2	Objetivos Específicos	13
1.3	ESTRUTURA DO TRABALHO	13
2	REDES ELÉTRICAS INTELIGENTES	14
2.1	SMART GRID.....	14
2.2	AUTO RECUPERAÇÃO EM SMART GRID	15
3	INTELIGENCIA DE ENXAMES.....	18
3.1	ALGORITMO PSO.....	19
4	SELF-HEALING COM SISTEMAS DE APRENDIZAGEM.....	21
4.1	SELF-HEALING EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA.....	21
4.1.1	Fluxo de potência elétrica.....	22
4.2	SISTEMAS DE APRENDIZAGEM EM REDES ELÉTRICAS INTELIGENTES	24
5	MÉTODO PROPOSTO	27
5.1	MODELAGEM DO SISTEMA DE DISTRIBUIÇÃO	27
5.2	DETECÇÃO E ISOLAMENTO DA FALTA.....	29
5.3	ESTUDO DE FLUXO DE POTÊNCIA	30
5.4	FUNÇÕES OBJETIVO	33
5.5	MODELAGEM PARA APRENDIZAGEM POR PSO	35
5.6	IMPLEMENTAÇÃO	35
5.6.1	Entrada de dados e modelagem da rede.....	36
5.6.2	Cálculo do fluxo de potência	37
5.6.3	Cálculo da recompensa.....	39
5.6.4	Busca usando PSO.....	40
5.6.5	Métodos comparativos.....	41
6	RESULTADOS	42
6.1	PARÂMETROS DO PSO.....	43
6.2	FUNÇÃO MULTIOBJETIVO	49
6.3	TEMPO DE EXECUÇÃO	54
6.4	RESPOSTA DO SISTEMA	59
7	CONCLUSÃO.....	65
	REFERÊNCIAS	66
	APÊNDICES.....	69

1 INTRODUÇÃO E CONTEXTUALIZAÇÃO

Os sistemas elétricos de potência envolvem estudos dedicados às suas diferentes áreas de atuação, como geração, transmissão e distribuição de energia elétrica. A necessidade de tornar os sistemas elétricos mais confiáveis e eficientes aproximou áreas como computação, telecomunicação e engenharias, com foco no desenvolvimento de tecnologias para esses sistemas (LISERRE; SAUTER; HUNG, 2010).

Das aplicações desses avanços nas infraestruturas elétricas emergiram as *redes elétricas inteligentes*, denominadas de *smart grids* (LISERRE; SAUTER; HUNG, 2010). Essas redes objetivam melhorar a eficiência, a segurança e a durabilidade dos sistemas, podendo integrar fontes de energias alternativas e renováveis, bem como utilizar controles automatizados e sistemas de comunicação (AMIN; WOLLENBERG, 2005; U.S. DEPARTMENT OF ENERGY, 2010).

Podendo promover o desenvolvimento de produtos e/ou serviços, em termos de inovação ou gestão, as *smart grids* compreendem em especial o uso de subáreas da computação, como a inteligência artificial e os sistemas distribuídos, como forma de melhorar as funcionalidades dos serviços e produtos de um sistema de geração e distribuição de energia (AMIN; WOLLENBERG, 2005). Portanto, percebe-se que o conceito de *smart grid* pode ir além do desenvolvimento e implantação de produtos, como, por exemplo, medidores digitais de energia, concebidos como forma de acompanhar o consumo dos usuários em tempo real.

Dentro das etapas de distribuição de energia, em um sistema elétrico de potência, surge a capacidade do sistema identificar e recuperar-se de faltas, como por exemplo, um defeito em um transformador que impossibilite o abastecimento de uma região. Sistemas com essas características são denominados de *self-healing* (GHOSH et al., 2007). *Self-healing* fornece os recursos necessários para a reconfiguração de forma autônoma de um sistema *smart grid*, visando, por exemplo, automatizar o processo da recuperação de uma rede de distribuição na ocorrência de uma falta (LIM et al., 2013).

Várias abordagens têm sido empregadas como forma de permitir a auto recuperação de um sistema. A aprendizagem baseada em população ocorre quando um conjunto de agentes autônomos ou enxames (por exemplos robôs) aprendem por recompensas ao interagir com o ambiente e com outros indivíduos. A fonte de aprendizado é a própria experiência do agente, cujo objetivo é adquirir comportamentos que melhorem seu aprendizado através das recompensas adquiridas nas interações.

O foco desse projeto é aplicar técnicas de inteligência computacional como forma de maximizar um conjunto de funções objetivo, por meio da reconfiguração dos dispositivos de fechamento e abertura do fluxo de energia em uma rede. Portanto, exhibe-se neste trabalho que técnicas de Inteligência Artificial podem ser empregadas para auxiliar na recuperação de uma rede ao ser identificada uma falha.

1.1 PROBLEMA E JUSTIFICATIVA

A maioria dos sistemas atuais de distribuição de energia são parcialmente automatizados, fazendo com que a configuração das chaves seja realizada de maneira manual. Esse processo pode demandar mais tempo do que um serviço de auto recuperação (*self-healing*), como, por exemplo, a necessidade do deslocamento de equipes para encontrar e analisar uma falha. Detectar e isolar locais com falha em serviços de restauração está entre os principais aspectos para o desenvolvimento de sistemas *smart grids* (MAMO et al., 2009). O serviço de restauração em uma rede de distribuição é definido como encontrar subestações (*feeders*) com capacidade suficiente para atender a maior quantidade possível das demandas (CHEN, 2010). A restauração é alcançada através das operações de fechamento e abertura das chaves (*switches*) do sistema, habilitando ou restringindo o fluxo de corrente entre as subestações e consumidores (demandas).

Diferentes métodos de restauração implicam diferentes configurações, que podem afetar a qualidade do serviço. Além disso, devido a tarefa de restauração ser normalmente realizada sob condições de emergência, restrições de tempo são adicionadas à complexidade do problema (CHEN, 2010; TSAI, 2008).

A habilidade de reconfigurar a rede para restaurar as demandas (cargas) não atendidas, representa um dos aspectos mais importantes para o sistema. A técnica para o *self-healing* deve observar as restrições da rede, tais como, topologia radial, limites de tensão e corrente, bem como as funções objetivo determinadas, como por exemplo, atendimentos as demandas prioritárias, balanceamento das subestações, entre outros.

Uma maneira de avaliar essas restrições é por meio de ferramentas para a análise do sistema elétrico, denominadas de fluxo de carga ou potência. Tal metodologia pode auxiliar na análise de restrições de componentes do sistema, como condutores, cargas consumidoras e subestações de fornecimento de energia, bem como outros aspectos relacionados às grandezas elétricas (DURCE, 2012).

Diante do exposto, pode-se observar que o problema da restauração pode ser formulado como um problema de otimização multiobjetivo e de múltiplas restrições. Acredita-se que técnicas oriundas da busca baseada em enxames podem ser adaptadas a tal problema, observando as restrições e maximizando as formulações do problema.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Aplicar técnicas de inteligência computacional em problemas de otimização encontrados nos sistemas *smart grids*, voltado para o estudo de *self-healing*.

1.2.2 Objetivos Específicos

- Definir e modelar as principais funções objetivo apresentados na metodologia do projeto em questão.
- Potencializar o uso dos sistemas de aprendizagem em sistemas de distribuição de energia;
- Aplicar técnicas de otimização baseadas em enxame de partículas em sistemas de distribuição de energia;
- Aplicar as técnicas em um problema prático;

1.3 ESTRUTURA DO TRABALHO

Este trabalho está organizado da seguinte maneira: No Capítulo 2 é introduzido o conceito das redes elétricas inteligentes e a atuação de sistemas *self-healing* sobre essas redes. No Capítulo 3 é abordada a pesquisa sobre sistemas de busca e alguns dos seus derivados, principalmente os métodos de inteligência por enxames. O Capítulo 4 faz uma descrição do estado da arte voltado para a utilização de técnicas de aprendizagem em sistemas *self-healing* para *smart grids*. A metodologia elaborada e a sequência das etapas para o desenvolvimento do sistema proposto são apresentadas no Capítulo 5. Os resultados são divididos em seções, apresentados e discutidos no Capítulo 6.

2 REDES ELÉTRICAS INTELIGENTES

As redes de energia elétrica convencionais estão sendo modificadas devido a necessidade das demandas e desenvolvimento de novas tecnologias. Isso pode ser visto nos estudos que apresentam o uso de fontes renováveis de energia, adaptação e divisão de abastecimento em subestações, adaptações para a segurança em sistemas de transmissão e de distribuição, etc. (U.S. DEPARTMENT OF ENERGY, 2010).

A necessidade por avanços para tornar tais sistemas efetivos e confiáveis, aproximaram as áreas de computação, telecomunicações, automação e engenharia no intuito de emergirem tecnologias voltadas aos sistemas elétricos de potência. Das aplicações desses avanços nas infraestruturas elétricas fizeram surgir as redes elétricas inteligentes, denominadas de *smart grids* (LISERRE; SAUTER; HUNG, 2010).

O conceito de redes elétricas inteligentes gera alterações para os padrões de sistemas de potência convencionais, sendo um deles a possibilidade da rede se auto reparar de faltas, como por exemplo, um curto circuito. Essa capacidade é proveniente de um conjunto de sistemas modulares de uma subárea de *smart grid*, denominada *self-healing*.

2.1 SMART GRID

Devido ao crescimento da demanda pela energia elétrica, os elementos da infraestrutura das redes de energia estão mais interconectados, causando alterações na concepção da estrutura inicial. A dificuldade de manter os padrões ideais com o crescimento da demanda, fizeram com que algumas alterações pudessem influenciar em determinadas atividades, como por exemplo, a dificuldade no gerenciamento das manutenções devido à ausência de mecanismos para a observação completa da rede (AMIN; WOLLENBERG, 2005).

Com a necessidade de tornar as redes observáveis, no intuito de facilitar sua compreensão, surgiram mecanismos de comunicação e automatização por meio da integração das áreas de telecomunicação e engenharia. Dessa forma, com sensores instalados na rede, se tornou possível analisar fatores como nível de tensão na rede de distribuição e falhas no abastecimento. As inclusões de pesquisas na área de ciência da computação, integrada com as pesquisas anteriores da rede, transformaram os dados que as implementações de sensores automatizados traziam em informações conceituais para a rede, como a utilidade dos valores de tensão para uma aplicação global, como auxílio do controle de fluxo de potência.

Fatores que influenciaram a pesquisa e implementação nos setores de *smart grids* estão representados em três categorias base para a política social. Como apresentado pela comissão europeia de pesquisa, pode ser expresso como o conjunto de preocupações com: i) o mercado interno, que envolve a autorização de geradores auxiliares à infraestrutura, incentivo de competição e inovação, queda de preços e ainda melhora na eficiência; ii) segurança de fornecimento, tratando de problemas de disponibilidade, qualidade, controle de capacidade da rede e confiança; e iii) questões ligadas ao ambiente, focando em novas fontes de geração de energia e maior aproveitamento da geração de energia (COMMISSION, 2006).

A adição de uma rede computadorizada em conjunto com as redes de sensores automatizados, faz com que a rede tenha uma capacidade de computar por meio de algoritmos os dados do sistema de potência. Algumas aplicações potenciais para as redes inteligentes incluem aspectos de gerenciamento e controle; confiabilidade da rede; redução de gastos com perdas do sistema antes não observáveis, como perda de potência e controle de consumo; sustentabilidade no meio de geração de energia descentralizada; redução de tempo sem abastecimento de energia; e ainda redução de custos em manutenção e especialização de mão de obra, possibilitando em alguns casos a automatização de serviços de recuperação da rede.

2.2 AUTO RECUPERAÇÃO EM SMART GRID

Auto recuperação vem da adaptação do termo *self-healing*, utilizado em diversas áreas de pesquisa que designam a característica de algo que possa se regenerar, ou ainda, se restituir de um problema. O termo original foi definido em função dos sistemas inclusos nessa categoria, que podem se ‘curar’ no sentido de se recuperar de situações e retomar sua performance original (GHOSH et al., 2007). Por se tratar de um conceito abrangente, aqui o termo é exposto em relação aos sistemas de *smart grid*.

Os sistemas de *self-healing* tem subentendido em sua definição a característica de autonomia em relação a alguma atividade. De modo geral, como apresentado na *survey* de Psaiet (2011), para abstrair a análise de autonomia são descritos cinco funções distintas com tarefas individuais:

- i. Monitoramento: responsável por coleta e processamento dos dados;
- ii. Análise: define se a informação gerada pelo monitor deve tomar uma ação específica;

- iii. Plano: desenvolvimento de ações de acordo com o sistema, requisitadas pelo analisador;
- iv. Execução: executa as ações previamente estabelecidas pelo plano de acordo com a análise; e
- v. Conhecimento: representa a base de conhecimento produzida ou consumida pelas tarefas mencionadas anteriormente.

Antes de ajustar um sistema para torná-lo auto reparável, é necessário identificar quais são as características consideradas normais para sua execução. Em sistemas de distribuição, uma rede em funcionamento normal é quando está fornecendo energia para todas as demandas, ou seja, livre de faltas e de acordo com as limitações dos componentes da rede. Critérios que determinam uma rede adequada descrevem os estados normais do sistema, e ao defini-los é possível determinar com maior facilidade os limiares que indicam quando é atingido um estado anormal, que requisitará as funções de auto recuperação (GHOSH et al., 2007).

Uma representação dos passos de como um mecanismo de auto recuperação funciona é ilustrado na Figura 1.




Figura 1 – Self-healing

Fonte: Adaptado de Psaiier e Dustdar (2011, p. 7).

O modelo apresentado na Figura 1 pode ser visualizado sobre um sistema de redes elétricas inteligentes, o qual possui uma rede de sensores de monitoramento sobre o sistema de potência. Os dados que são capturados pelos sensores servem de entrada para um sistema de análise, constantemente verificando as alterações na rede. Assim, dados como queda no abastecimento de energia são enviados para a unidade de diagnóstico. Ao receber esses dados, a unidade realiza uma verificação entre os limites da rede, posteriormente gerando um plano para recuperação. A etapa de recuperação é responsável por analisar o plano e adaptá-lo para as situações da rede, agindo através dos atuadores.

O conceito de auto recuperação pode ser aplicado nas *smart grids* em um sistema de potência, em conjunto de alguma heurística aplicada para a automatização dos processos de detecção e atuação. Para se alcançar a infraestrutura de uma rede *self-healing* é necessário

atender um conjunto de operações associadas ao aperfeiçoamento de performance, adequação dos recursos, limitação dos sistemas e equipamentos, e estratégias de *back-up* para os sistemas e componentes da rede (MOSLEHI; KUMAR, 2006). A tomada de decisões de um sistema inteligente é realizada através de um conjunto computacional de softwares.

Mecanismos com conhecimentos adicionais do sistema, como regras que tratem as limitações e comparação dos resultados da rede, costumam utilizar algoritmos com algum paradigma de aprendizagem. Esses possuem a possibilidade de, em um sistema complexo, analisar a situação atual do sistema e buscar corrigi-lo conforme lidam com as alterações da rede, assim podem ser geradas mais de uma saída para solucionar o mesmo problema.

Problemas com características de *self-healing*, que simulem ou atuem em sistemas reais, devem atender a múltiplos objetivos e múltiplas restrições, requisitos que geram espaços de solução complexos e crescentes de acordo com as variáveis analisadas. Isso caracteriza o sistema como um problema de otimização, que são pouco determinísticos e de baixa escalabilidade através de métodos simplificados (tentativa e erro).

Para tratar esses problemas e buscar soluções aceitáveis (máximos locais e até mesmo global), trazendo a complexidade de tempos exponenciais (soluções exaustivas) para tempos polinomiais, existem metaheurísticas que realizam buscas pelo espaço de soluções baseados em diferentes paradigmas. Modelos de aprendizagem por enxame de partículas são alternativas para emergir um sistema com características de *self-healing*, pois seguem o paradigma de interação com o espaço de soluções do sistema, e tem provas de convergência para soluções ótimas ou muito próximas (EBERHART; SHI; KENNEDY, 2001). Neste caso, esse paradigma pode ser usado na reconfiguração de um sistema de distribuição de energia, descobrindo soluções que satisfazem as funções objetivo e restrições em um tempo polinomial.

3 INTELIGENCIA DE ENXAMES

A inteligência de enxames é um modelo para resolver problemas de acordo com um comportamento coletivo de agentes reativos dentro de ambientes dinâmicos (EBERHART; SHI; KENNEDY, 2001). O método se inspira na interação presente em grupos da natureza, como cardumes de peixes, colônias de formigas e bando de pássaros.

Os agentes de um enxame se comunicam para agir sobre um ambiente, e embora sigam regras simples, possuem uma grande capacidade de auto-organização (EBERHART; SHI; KENNEDY, 2001).

O objetivo dos modelos computacionais baseados em enxames é de utilizar o comportamento dos indivíduos e das interações locais, com o ambiente e seus vizinhos, assim o procedimento conjunto é utilizado para resolução de problemas de busca por soluções mais complexas (RIBEIRO, 2010).

Os insetos sociais de um enxame atuam localmente, mas devem satisfazer o objetivo global do sistema (comunidade de agentes). A comunidade pode ser formada por um conjunto de indivíduos e as conectividades indicam suas relações. Um conjunto de indivíduos, computadores, organizações, equipamentos ou elementos computacionais que estão conectados podem estar relacionados por algum tipo de objetivo comum (RIBEIRO; ENEMBRECK, 2013).

Conforme os exemplos citados, existem trabalhos dedicados a modelagem desses comportamentos aplicados em métodos computacionais de resolução de problemas e aprendizagem. Algumas dessas pesquisas são a utilidade de inteligência baseada em cardume de peixes (FILHO et al., 2008), otimização por enxame de partículas e otimização por colônia de formigas (DORIGO; MANIEZZO; COLORNI, 1991).

O exemplo de um mecanismo bio-inspirado, que segue o modelo proposto baseado em comportamento conjunto de um enxame, é o de modelar o comportamento social de aves e cardumes de peixes. Esse método consiste em utilizar a característica de organização do deslocamento desses indivíduos por um espaço geográfico, os quais possuem suas próprias direções e posições, porém tendem a se manter em busca conjunta por um ponto que proporcione o alimento, levando em consideração o deslocamento de seus vizinhos.

O estudo do método de otimização por enxame de partículas (PSO do inglês *Particle Swarm Optimization*) consiste em um modelo adaptativo social e cognitivo em alto nível, que observa os padrões formados pelos indivíduos e as suas habilidades individuais de resolver um problema, e em baixo nível, seguindo os comportamentos de três principais termos, *avaliar*, *comparar* e *imitar* (EBERHART; SHI; KENNEDY, 2001). A *avaliação* é essencial pois

trata como o agente se comporta no seu ambiente, se está favorável ou não, se está positivo ou negativo, ou outros métodos que avaliem sua condição. A *comparação* trata de impor padrão de medida entre os organismos de um enxame, comparando com os seus vizinhos para identificar suas ações em conjunto. Já a *imitação* é, de forma efetiva, a própria aprendizagem, pois o indivíduo tende a convergir para o comportamento dos seus vizinhos mais bem-sucedidos. Esse algoritmo é abordado a seguir com detalhes.

3.1 ALGORITMO PSO

O algoritmo de otimização por enxame de partículas (PSO) é utilizado para a otimização de funções não lineares a partir do ajuste de trajetórias de uma população de partículas por um espaço de soluções de um problema, baseado em informações como a sua própria performance anterior e a melhor de seus vizinhos (EBERHART; KENNEDY, 1995; KENNEDY; EBERHART, 1997).

O algoritmo de PSO faz uso de uma população de partículas, onde cada indivíduo é marcado por um conjunto de coordenadas de um hiperespaço, que designa a sua posição no espaço de soluções, e um conjunto de velocidades, representando o vetor de deslocamento para cada indivíduo. Cada partícula mantém um registro de sua melhor localização, ou seja, o ponto em que obteve melhor resultado para o problema, e também um valor global que indica a melhor posição já alcançada por algum indivíduo da população (EBERHART; KENNEDY, 1995).

O algoritmo de PSO consiste em alterar o valor da velocidade de cada indivíduo, mudando sua direção e sentido, baseando-se nos valores de melhor posição própria da partícula e do melhor alcançado na população, realizando uma convergência para uma solução ótima ou um máximo local que se aproxime da melhor solução. Para manter os aspectos de busca de um enxame natural, os fatores são acompanhados de termos aleatórios, que alteram a proporção de relevância, e por um valor denominado de inércia, o qual é a relevância que se deve dar para o caminho anterior da partícula.

Com base nessas informações, a equação 1 é usada para alterar a velocidade referente a cada coordenada j para cada partícula i .

$$v_{ij}(t + 1) = wv_{ij}(t) + c_1r_1(p_{ij} - x_{ij}) + c_2r_2(g_j - x_{ij}) \quad (1)$$

Os coeficientes w , c_1 e c_2 são arbitrariamente determinados para cada problema analisado, dando ênfase para a inércia, melhor posição da partícula e melhor posição global do enxame, respectivamente. Os termos r_1 e r_2 são valores aleatórios que geram uma alteração proposital na proporção em cada iteração. O termo p_{ij} refere-se ao valor da melhor posição no índice j da partícula i , e o termo g_j define o valor da melhor posição global no índice j . Nessa equação é realizada a atualização do valor da velocidade, para posteriormente atualizar o valor da posição de cada partícula, dentro de um processo iterativo de deslocamento pelo hiperespaço.

Após a atualização da velocidade de cada partícula, é possível reposicioná-las no espaço de soluções. A equação 2 define o processo de alteração da posição para o caso onde o hiperespaço é baseado em números reais.

$$x_{ij}(t + 1) = x_{ij}(t) + v_{ij}(t) \quad (2)$$

A nova posição do índice j da partícula i é calculada utilizando a soma do valor da velocidade já atualizada com a posição atual. Porém para casos discretos e binários, é necessário adaptar o valor de velocidade para manter os limites do domínio do hiperespaço do problema. Um exemplo de adaptação para o caso binário é realizado pela utilização de normalização da velocidade e uma função de ativação (KENNEDY; EBERHART, 1997), como mostrado na equação 3.

$$x_{ij}(t + 1) = \begin{cases} 1, & \text{se } r_{ij} < S(v_{ij}(t)) \\ 0, & \text{se } r_{ij} > S(v_{ij}(t)) \end{cases} \quad (3)$$

Onde o valor de r_{ij} define um valor aleatório para analisar a função de ativação descrita por $S(v_{ij}(t))$. É importante que a função de ativação e a variável aleatória possuam o mesmo domínio de valores.

Os fatores de exploração e convergência para soluções ótimas dependem da determinação dos coeficientes da equação de velocidade, e se estiverem no domínio discreto dependem também da determinação da função de ativação selecionada. A importância do método utilizado pelo PSO está no modelo de exploração conjunta dos agentes, utilizando a abordagem de proximidade para a convergência dos termos, sem perder a exploração por soluções distintas.

4 SELF-HEALING COM SISTEMAS DE APRENDIZAGEM

Como discutido anteriormente, sistemas com múltiplos indivíduos são conectados por alguma relação comum para trabalharem dentro da teoria de inteligência baseada em enxames, por exemplo, em um sistema de distribuição de energia os equipamentos podem estar relacionados conforme a demanda para entrega de energia, prioridades na execução de tarefas, redução nos custos de manutenções, tempo de recuperação de um sistema numa falta, topologia da rede, segurança ou proteção, assim como uma população pode estar relacionados devido à sua atividade em comum.

Agentes de um enxame podem determinar a recomposição de um sistema *smart grid*, por meio de técnicas capazes de direcionar o compartilhamento de informações. Esses comportamentos são mantidos por valores que determinam as atitudes dos indivíduos/agentes, sendo denominados de recompensas e capazes de influenciar na manutenção do sistema.

4.1 SELF-HEALING EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA

Dentro de um sistema de distribuição de energia, responsável pela entrega de energia da rede de transmissão para os consumidores finais, um dos atuadores de uma *smart grid* é o mecanismo de chaveamento. Em redes de distribuição o sistema normalmente mantém uma topologia radial, ou seja, a partir de uma fonte de energia a distribuição é gerada como um grafo acíclico e direcionado. Algumas redes possuem malhas, quando conveniente, porém exigem requisitos que necessitam de cuidado para que possam funcionar, como manter os mesmos níveis de tensão e frequência.

Para recuperar o sistema em eventuais quedas de energia, o sistema possui caminhos com chaves em estado normalmente aberto posicionados nos barramentos de distribuição, as quais são manipuladas para redistribuir o fluxo de energia. Uma representação desse sistema é apresentada a seguir, como um exemplo de uma rede de distribuição com topologia radial.




Figura 2 – Topologia radial de um sistema de distribuição

Na rede de distribuição de energia a falha mais comum é a de defeitos em segmentos entre as barras que interrompem o fluxo de energia, causando um problema em cascata que pode originar um *blackout*. Esses defeitos podem estar ligados ao mal funcionamento de componentes intermediários, como transformadores, ou ainda em acidentes com queda de postes e rompimento de cabamentos de condução.

A aplicação do conceito de auto recuperação em um sistema de *smart grid* pode ser visualizado sobre a reparação do fluxo de energia em uma rede de distribuição com a reconfiguração automatizada da topologia pelo chaveamento da rede, em ocorrências de faltas na alimentação para alguma região, baseado em sistemas como os da Figura 2. Essa recuperação do fluxo pode ser feita sobre a manipulação das chaves intermediárias que conectam outros ramos da rede, reparando o sistema provisoriamente para que a topologia original seja recuperada de acordo com a falha que a originou, respeitando os limites com análise do fluxo de potência.

4.1.1 Fluxo de potência elétrica

Os limites básicos, abordados em uma rede de distribuição de energia, estão relacionados com o fluxo de corrente da rede de condutores e transformadores, que expressam o conjunto de condutores para os consumidores finais, e a tensão das barras. O limite de fluxo de corrente está relacionado com o efeito de aquecimento dos condutores conforme a taxa de corrente transmitida aumenta. Os valores de tensão são estabelecidos pelas unidades reguladoras de fornecimento de energia elétrica para cada país.

A Agência Nacional de Energia Elétrica (ANEEL) possui uma resolução referente aos fatores de qualidade de distribuição de energia para o Brasil. Baseado na resolução 505, de 26 de novembro de 2001, e do módulo de qualidade de distribuição de energia dos Proce-

dimentos de Distribuição (PRODIST), ambos provenientes da ANEEL, estabeleceu-se um limite de tensão medido em função do valor normalizado pela tensão da subestação, em 1 pu (por unidade) para os nós, ou seja, as unidades distribuidoras para os consumidores finais. Esses limites são separados em três categorias que definem o estado da unidade em: crítica, entregando tensão menor que 0,9 pu ou maior que 1,05 pu; precária, fornecendo tensão entre 0,9 pu e 0,93 pu; e por fim, níveis de tensão adequados, sendo esse mantido entre 0,93 pu e 1,05 pu (AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA, 2001).

O fluxo de potência é o estudo de sistemas de potência que angariou diferentes metodologias de cálculos para sistemas complexos de energia, sendo uma ferramenta eficaz na determinação da corrente e tensão de todos os nós e barramentos do sistema (DURCE, 2012). O conceito do fluxo de potência, ou também chamado de fluxo de carga, baseia-se na análise do balanceamento de tensão entre os nós consumidores de uma rede com um fornecedor, normalmente utilizando os dados de resistência, reatância, potência reativa e potência ativa de uma rede em regime permanente.

O estudo de fluxo de potência é importante no planejamento de expansões dos sistemas de potência e também para as melhores operações a serem realizadas sobre a rede atual (GRAINGER; STEVENSON, 1994). Como descrito por Grainger e Stevenson (1994), as principais informações fornecidas pelo estudo do fluxo de carga são a magnitude e ângulo de fase da tensão em cada barramento e a potência ativa e reativa em cada linha, logo essa ferramenta de análise é útil em sistemas inteligentes utilizados em uma rede de distribuição que contenham o mecanismo de auto recuperação.

Existem alguns mecanismos de cálculo de fluxo de potência simplificados que podem ser utilizados na análise em sistemas de distribuição, especificamente por características que esses sistemas exibem, como o aspecto de topologia radial. A origem vem das análises derivadas de Newton e varredura de rede, alguns são o método Escalonado, método da Soma das Correntes e o método da Soma das Potências (DURCE, 2012).

Um método robusto e simplificado, para a análise de sistemas de distribuição de energia e sistemas de transmissão radiais e fracamente malhados, é o método da Soma das Correntes, que é abordado na implementação do sistema proposto neste documento. O método descreve a análise do fluxo de potência baseado no método Escalonado, usando técnicas de compensação e formulação básica nas leis de Kirchhoff (SHIRMOHAMMADI et al., 1988).

Desenvolvido por Shirmohammadi (1988) o método consiste em duas varreduras da rede, aplicando as equações das leis de Kirchhoff, executadas sucessivamente e divididas em duas etapas básicas (DURCE, 2012): i) a primeira é dada pela varredura a montante, ou seja,

das barras finais para a subestação da rede, onde se determinam as correntes em todos os ramos do sistema radial; ii) a segunda é caracterizada pela varredura a jusante, isto é, a partir da subestação até as barras, para definir os valores de tensão das barras. A convergência é dada por um valor de erro absoluto das tensões dos nós, e alcançado pela repetição dessas etapas.

A escolha desse método é devido à sua característica de fácil compreensão e por proporcionar uma boa aproximação dos valores encontrados a partir do equacionamento de Kirchhoff, sendo utilizado principalmente para redes de distribuição de energia.

4.2 SISTEMAS DE APRENDIZAGEM EM REDES ELÉTRICAS INTELIGENTES

Os paradigmas de sistemas de aprendizagem têm sido empregados na otimização de problemas encontrados nas redes elétricas inteligentes. Dentro das metodologias propostas para a resolução desses problemas, surgem diferentes formas de modelagem para adaptar-se a alguma heurística de controle ou aprendizagem. Em geral, o problema tende a ser multiobjetivo, aumentando a dificuldade na resolução de um problema de otimização.

Algumas pesquisas estão ligadas à utilidade de lógica *fuzzy* e inclusão de heurísticas e adaptações ao processo de restauração da rede. Como apresentado por Das (2006), uma modelagem multiobjetivo da rede pode considerar o balanceamento de carga entre os fornecedores de energia, minimizar a variação da tensão nos barramentos, minimizar a perda de potência e restringir os valores de corrente nas linhas, enquanto atende a especificação de manter a rede radial e alimentar o maior conjunto de nós possível. No seu trabalho, o autor modelou o sistema usando lógica *fuzzy*, que busca adicionar um estado entre os já existentes dentro da teoria de *self-healing* (estados “saudáveis” e “não saudáveis”). O estado adicionado representa áreas de imprecisão para o sistema, sendo representado por uma faixa de valores dos limites das restrições do sistema e assim podendo antecipar os valores de cada objetivo. Ainda, foi utilizada uma solução para o fluxo de potência adaptada do método de Newton Raphson, que utiliza uma interface interativa para resolver os valores da restrição de balanceamento entre os nós (GHOSH; DAS, 1999).

Métodos de aprendizagem baseados em comportamentos coletivos também representam parte dos sistemas de aprendizagem voltados para a otimização de chaveamento e auto recuperação da rede de distribuição. Utilizando uma metodologia derivada de aprendizagem por enxames, a pesquisa realizada por Watanabe (2005) utiliza um *framework* para implementação do sistema de aprendizagem por *Ant Colony Optimization* (ACO), e define como condi-

ção principal a otimização da sequência de chaveamento sobre a rede. Outro método derivado da aprendizagem por reforço, voltado para o serviço de restauração do sistema de distribuição, é apresentado por Lacerda e Medeiros (2007), propondo um algoritmo de ACO com prioridade em minimizar o número de operações de chaveamento na rede.

No trabalho de Vlachogiannis e Hatziargyriou (2004) é utilizada aprendizagem por reforço de forma que o sistema evolua de acordo com as especificações do problema, utilizando recompensas conforme a perda de potência do sistema e a relacionando com o cálculo do fluxo de potência.

Uma outra abordagem de resolução consiste na utilização de um sistema multiagente, que implementa as limitações da rede e age de forma descentralizada, a partir de mecanismo de comunicação pelos agentes introduzidos no sistema de distribuição. No método implementado por Zidan (2012), um sistema multiagente foi especificado em duas diferentes camadas de atuação, uma focando nas observações para o controle do sistema, e outra responsável pela análise conjunta, a qual faz a relação dos dados dos agentes da primeira camada com as limitações estabelecidas pela rede.

Um mecanismo de heurística de programação orientada a objetivo, também foi apresentada para a resolução da restauração de sistemas de distribuição, utilizando raciocínio lógico em um sistema baseado em conhecimentos. O artigo de Tsai (2008) utiliza esses paradigmas para otimizar a reconfiguração de energia adicionando a variação de tensão da rede, propondo múltiplos planos de restauração para a mesma situação.

Existem ainda outros métodos aplicados ao mesmo problema de restauração por reconfiguração de topologia, por exemplo, a minimização de perdas elétricas por uso de algoritmos genéticos por seleção, cruzamento e mutação (BENTO; KAGAN, 2008); o uso de corte seletivo de cargas do sistema para conservar o abastecimento de regiões prioritárias (FERREIRA, 2014); e modelos de tomada de decisão quantitativos, como o uso de processos baseados em hierarquia analítica (da sigla americana AHP), métodos adaptados de lógica *fuzzy* e análise relacional cinza (da sigla americana GRA) (CHEN, 2010).

Uma abordagem sobre o problema de restauração de sistemas de distribuição utilizando busca por nuvem de partículas (*Particle Swarm Optimization*) é realizada por Abdelaziz (ABDELAZIZ et al., 2009) e por Batrinu (BATRINU; CARPANETO; CHICCO, 2005), ambos agindo sobre a otimização para minimizar a perda de potência, focando somente no quesito de balanceamento do sistema e não em reconfiguração com ocorrência de faltas. Esses trabalhos sugerem modificações no algoritmo original do PSO, como heurísticas e metodolo-

gias de inércia variante na execução do algoritmo, com o intuito de modificar a exploração e convergência da busca, no entanto não trabalham firmemente sobre o conceito de *self healing*.

De modo geral, os métodos aplicados ao problema de reconfiguração da topologia de um sistema de distribuição de energia são caracterizados pelos múltiplos objetivos (conflitantes em muitos casos) e múltiplas restrições. Essas características tornam o espaço de soluções grande e não determinístico, sendo um problema de otimização.

Para otimizar a resposta, o problema possui soluções simples e que extraem respostas ótimas, como o método exaustivo combinatório que realiza a avaliação de todas as combinações possíveis de chaves do sistema para escolher a melhor. Porém o método exaustivo é uma solução exponencial, na qual a adição de uma chave a mais sobre a mesma rede dobra a quantidade de combinações a serem analisadas.

Os trabalhos citados estão dentro das várias pesquisas em torno de adaptação de heurísticas e do uso da inteligência computacional voltadas para a reconfiguração do sistema de distribuição tratando da questão de complexidade, buscando soluções em tempos polinomiais. Assim não somente as técnicas oriundas da aprendizagem por enxames podem ser adaptadas à tal situação, como também se pode analisar a variação de resultados que a escolha das funções objetivo, inseridas no método de aprendizagem, implicam sobre o sistema.

5 MÉTODO PROPOSTO

Neste capítulo são apresentadas as etapas para o desenvolvimento de um *framework* para simular um sistema *smart grid*.

5.1 MODELAGEM DO SISTEMA DE DISTRIBUIÇÃO

Um sistema de distribuição de energia pode ser formalizado através da teoria dos grafos. Antes de apresentar a modelagem proposta, sumarizam-se os principais conceitos dessa teoria. Formalmente, um grafo é um conjunto $G=(V,A)$ onde (FEOFILOFF; KOHAYAKAWA; WAKABAYASHI, 2011):

- V é um conjunto de vértices ou nós; e
- A é um conjunto de arestas, formados por dois elementos $u, v \in V$, comumente entendido como conexões.

Neste trabalho, a representação da rede de distribuição é entendida como um caso particular de grafos. É representado como um conjunto denominado de floresta, um caso especial definido por ser *acíclico* e *não conexo* (FEOFILOFF; KOHAYAKAWA; WAKABAYASHI, 2011). Um grafo não conexo indica que, para todo par de vértices, não necessariamente existam caminhos de conexão entre eles. Já a característica acíclica indica que, em todo o grafo, não existem caminhos que gerem um ciclo, ou seja, retorno ao mesmo vértice.

As florestas podem ser denotadas ainda como um conjunto de árvores, outra denominação para um caso particular de grafos, que nesse caso se caracterizam por serem acíclicas e conexas (FEOFILOFF; KOHAYAKAWA; WAKABAYASHI, 2011). Assim, pode-se expressar a raiz dessa árvore como sendo o nó inicial, o qual representa uma subestação do sistema, e os demais nós como os barramentos. O conjunto de diferentes árvores compõe a floresta que representa o sistema de distribuição.

Outras características adicionais a um grafo são: i) ponderações relacionadas aos nós e arestas, que determinam alguma característica particular, como um peso ou valor utilizado pelo algoritmo para a tomada de decisão; ii) direção do percurso, assumindo que o fluxo de corrente ocorra da raiz para os nós.

Modelando a rede de distribuição, conforme o exemplo apresentado na Figura 2, os barramentos da rede são expressos como os nós, e as conexões são as arestas (condutores e

transformadores), responsáveis pelo fluxo de corrente. Uma ilustração da rede de distribuição modelada em grafo é ilustrada na Figura 3, com a representação dos componentes (subestações, barramentos e conexões) baseados na Figura 2 e nas propriedades abordadas nesse capítulo.

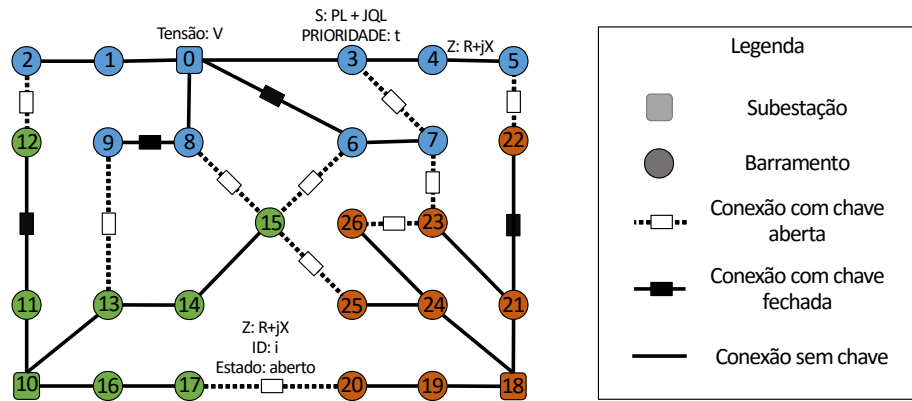


Figura 3 – Modelagem de uma rede de distribuição em grafo

As arestas são representadas por um par ordenado (i,j) , que indica o fluxo de corrente do nó i para o nó j . Esses nós possuem valores de prioridade (que indicam sua importância), e um valor de potência exigida (potência ativa e reativa). Para as subestações da rede são informados a tensão de fornecimento (V). As arestas representam os condutores de energia, e todas contêm um valor de impedância (Z), em reatância e resistência associadas. Ainda, nas arestas que possuem chaves são adicionados campos com identificação da chave e uma indicação do estado de condução (chave aberta ou fechada) na rede. Para melhor compreensão visual, apenas um de cada elemento contém as informações da modelagem sendo exibidas. As cores utilizadas na Figura 3 representam as diferentes árvores que compõem o grafo.

A rede da Figura 3 representa uma topologia radial, ou seja, nós conectados a apenas uma subestação e com as arestas sem formação de ciclos. Nessa modelagem é possível observar os aspectos da topologia, e características de cada elemento, como os dados fornecidos para cada aresta e nó. Na Tabela 1 são apresentados elementos e alguns dados necessários para estruturar uma rede.

Tabela 1 – Exemplo de dados de uma rede

Nó fonte i	Nó receptor j	Identificação da chave (se existente)	Estado da alimentação do nó j	Estado da chave (se existente)	Prioridade de alimentação do nó j	Resistência da aresta (Ω)	Reatância da aresta (Ω)	Potência Ativa do nó j (kW)	Potência Reativa do nó j (kVAr)
0	1	X	ENERG.	X	0.25	1.89	0.8	100	89
1	2	0	ENERG	FECHADA	0.5	1.5	0.7	107	80
2	3	1	ENERG	ABERTA	0.5	1.3	1.12	100	99
3	4	2	ENERG	FECHADA	1	1.2	1.56	150	112

Os dados anteriores remetem a uma divisão básica de três categorias para a modelagem da rede. As três primeiras colunas referem à representação em grafo propriamente dita da rede de distribuição, representando um par ordenado que especifica a conexão entre dois nós com a orientação do nó i para o nó j e uma identificação estabelecida para a chave da aresta, caso exista. Os valores do ‘estado de alimentação’ e ‘estado da chave’ são da categoria que definem a topologia atual da rede, e representam respectivamente se o nó i está sendo energizado e se a chave presente na aresta está aberta ou fechada. A última categoria define os dados intrínsecos à rede de distribuição, valores que ditam as especificações aos nós e arestas do grafo, formados pela prioridade, que representa o nível de relevância que o nó específico tem sobre os demais em estar energizado; pela resistência e reatância, que formam a impedância sobre a aresta para a condução de energia; e pelas potências ativa e reativa, que determinam a demanda da barra para um dado momento do sistema.

5.2 DETECÇÃO E ISOLAMENTO DA FALTA

Uma falta pode ocorrer por falhas em dispositivos da rede ou danos causados pela natureza ou vandalismo ao sistema de distribuição. Nas simulações, é assumido que uma falta ocorre devido a interrupção do fluxo de energia em um condutor. A detecção foi modelada como um dos parâmetros de entrada, subentendendo uma rede automatizada que possui detectores de tensão e corrente pelo sistema.

Para que o sistema possa ser reconfigurado após uma falta, é necessário isolar o local do incidente do restante da rede, buscando minimizar a quantidade de cargas próximas afetadas. Ao isolar as redondezas da falta se previne que o problema possa se alastrar aos demais componentes, danificando aparelhos da rede. Também é necessário deixar o local transparente para o algoritmo, ou seja, como se não fizesse parte do sistema, de modo que ele não exerça nenhuma alteração dentro dessa região.

Para isolar uma falta, as chaves adjacentes mais próximas são alteradas para o estado aberto. Computacionalmente, o método utilizado consiste em percorrer um caminho em profundidade a partir do local com falha até encontrar a primeira chave em cada ramo percorrido. A Figura 4 ilustra um exemplo.




Figura 4 – Detecção e isolamento de falta

Após selecionar as chaves que estão próximas ao local de falta, elas são sinalizadas para que o algoritmo não execute ação sobre elas, e então são alteradas para permanecerem abertas. Ao abrir as chaves selecionadas, a região da falta ficará sem energia (tracejado vermelho na Figura 4), garantindo a segurança do sistema de distribuição.

5.3 ESTUDO DE FLUXO DE POTÊNCIA

Para analisar o fluxo de potência é utilizado o método da soma das correntes, conforme apresentado no Capítulo 4. Os valores utilizados para a análise são:

- i) Impedância (Z_{ij}) de cada condutor, composto por um valor de resistência e reatância;
- ii) Potência consumida (S_i), composto por potência ativa e reativa; e
- iii) Tensão da fonte de alimentação (Ref), também usada para normalizar os valores da análise.

Por convenção é utilizada a normalização em sistema por unidade, expressa em pu , que proporciona o cálculo de todas as grandezas em função de valores de uma tensão V_{base} e uma potência S_{base} . Isso possibilita simplificações nos cálculos de sistemas de potência, como uso de uma constante para sistemas trifásicos, simplificação da representação dos transformadores sobre a rede e similaridade nos valores das grandezas dos componentes do sistema (GRAINGER; STEVENSON, 1994).

Na Figura 5 é ilustrada uma rede de distribuição para auxiliar na explanação do fluxo de potência. Esse método consiste em dois tipos de varredura na rede. Em cada processo de busca é calculado uma das saídas do sistema, ou seja, a tensão (V_i) ou a corrente (I_{ij}) em cada

componente. Com este método são realizadas iterações até que ocorra a convergência para um erro absoluto estabelecido no início do processo.




Figura 5 – Exemplo de uma rede com topologia radial

Partindo da convenção de que as conexões compostas pelos condutores e transformadores são chamadas de rede, e o conjunto de consumidores como barramentos de distribuição do sistema, o método é realizado conforme as seguintes etapas (DURCE, 2012):

- i) Assume-se inicialmente a tensão referencial normalizada (da fonte de alimentação), e denota-se o seu valor normalizado em 1 pu. Posteriormente é atribuída para cada consumidor o valor de tensão igual ao da referência;
- ii) A varredura a montante, partindo dos nós finais (sem ramos posteriores), é realizada para determinar os valores das correntes do sistema. O valor de cada ramo é calculado baseada na lei de corrente de Kirchhoff, descrita na equação 4:

$$I_{ij} = \left(\frac{S_j}{V_j} \right)^* + \sum I_k \quad (4)$$

- iii) A varredura a jusante, partindo da subestação para as barras finais, é realizada para determinar os valores das tensões do sistema. O valor em cada nó é calculado, baseado na lei de tensão de Kirchhoff, descrita na equação 5:

$$V_j = V_i - Z_{ij} I_{ij} \quad (5)$$

- iv) Após atualizar os valores de tensão com a varredura a jusante, é realizado um teste de erro absoluto entre o valor anterior da tensão V^0 e o valor atual V^1 , para um limite ε previamente especificado, como descrito na equação 6:

$$|V_i^0 - V_i^1| \leq \varepsilon \quad (6)$$

- v) Se todos os valores do erro absoluto convergirem para o teste realizado na etapa anterior, para-se a iteração e a solução é constituída pelos últimos valores calculados. Caso contrário, se continua da etapa ii até convergência.

A equação 4 é descrita pela somada da corrente I_{ij} consumida pelo nó j em conjunto com as correntes I_k dos ramos posteriores a este nó. Como exemplo, segundo a Figura 4, o cálculo para as correntes é dado pela seguinte ordem de varredura:

$$I_{23} = \left(\frac{S_3}{V_3} \right)^* \quad (7)$$

$$I_{24} = \left(\frac{S_4}{V_4} \right)^* \quad (8)$$

$$I_{12} = \left(\frac{S_2}{V_2} \right)^* + I_{23} + I_{24} \quad (9)$$

A equação 5 descreve o valor da tensão de uma determinada barra a partir da diferença de potencial entre o barramento antecessor e a impedância bem como a corrente da rede entre eles. Como exemplo (com base na Figura 5), o cálculo das tensões é dado pela seguinte ordem de varredura:

$$V_2 = V_1 - Z_{12}I_{12} \quad (10)$$

$$V_3 = V_2 - Z_{23}I_{23} \quad (11)$$

$$V_4 = V_2 - Z_{24}I_{24} \quad (12)$$

Para a rede hipotética da Figura 6 (a), os resultados de saída são exibidos na Figura 6 (b) (somente os módulos), de acordo com o método descrito acima.

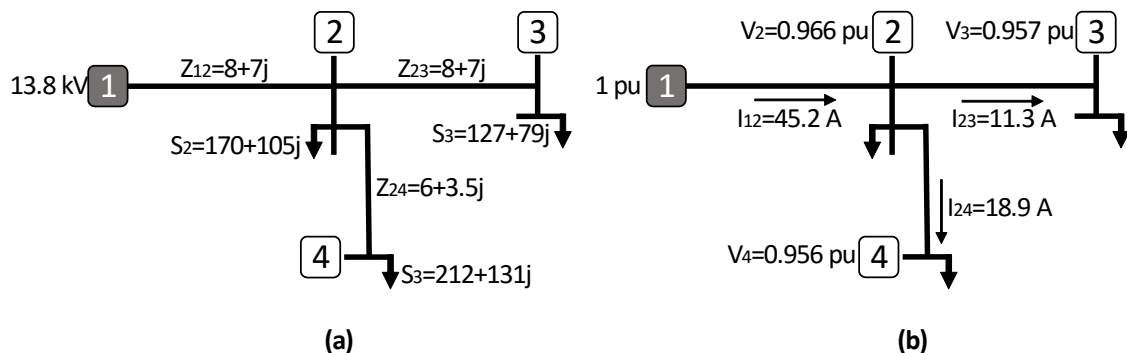


Figura 6 – Exemplo de estudo de fluxo de potência

Devido a semelhança da varredura desse método com a descrita pela busca em profundidade, o desenvolvimento do código pode ser realizado com os cálculos da corrente e atualização dos dados e comparação dos valores de tensão sobre a ordem definida na busca em profundidade.

Essa ferramenta possibilita analisar se as alterações na topologia da rede são válidas para manter os níveis de limite de tensão e de corrente para os barramentos, e se está atendendo também às demandas de potência. Logo, essas informações são utilizadas pelos algoritmos de aprendizagem.

5.4 FUNÇÕES OBJETIVO

O problema de reconfiguração do sistema de distribuição pode ser estruturado em múltiplos objetivos e múltiplas restrições. As alterações da rede, realizadas pelas operações das chaves, devem ser analisadas pelo algoritmo de modo a atender os objetivos segundo normas e restrições técnicas. Os objetivos propostos são:

- Maximizar a quantidade de cargas restauradas, considerando as demandas com maior prioridade, como hospitais e indústrias;
- Minimizar o número de operações das chaves, na intenção de reduzir o tempo e custo necessário para a restauração;
- Minimizar a perda de potência real do sistema.

As restrições descritas para o problema são formuladas de acordo com o órgão responsável pela padronização dos sistemas em cada região, em geral eles devem atender restrições comuns com as seguintes:

- Manter a estrutura da rede em topologia radial, para facilidade de manutenção e estudo da rede;
- Manter os limites de tensão nos barramentos, restringindo de acordo com a capacidade do equipamento;
- Manter os limites de corrente entre os barramentos, estipulando valores de condução máxima a cada conexão entre cargas.

Das restrições descritas anteriormente, os limites de tensão e corrente são modelados como testes em intervalos inseridos no algoritmo de fluxo de potência, com valores informados pela ANEEL (2008).

A modelagem da minimização de barras sem abastecimento de energia e requisitos de fluxo de potência são modelados como uma equação ponderada. O cálculo para o gerenci-

amento de consumidores com energia é dado pela equação 13, sendo a primeira função objetivo do sistema:

$$FO1 = \sum_{c=0}^n \text{prioridade}_c * \text{estado}_c * \text{potência}_c \quad (13)$$

Esse cálculo é dado pelo somatório das n barras da rede, em função do valor de potência exigida para consumo; com o *estado* de energização, sendo -1 para sem abastecimento e 1 para com abastecimento; e o valor de *prioridade* para cada barra. A análise do balanceamento de carga entre as subestações é modelada como uma análise em tempo ocioso da rede, ou seja, enquanto não estiver tratando falhas e a rede estiver atendendo à demanda. Com isso, é possível analisar uma topologia que não exija demanda em excesso de algum fornecedor de energia, equilibrando entre os demais que possuam recursos em sobra.

Após a análise da rede pelo fluxo de potência, é calculado o valor de perda de potência. O retorno da função é o valor da perda de potência real, ou ativa, expressando a segunda função objetivo, denominada *FO2*. Esse cálculo é realizado a partir da diferença entre o somatório de potência consumida e da potência fornecida pelas subestações, calculadas pelos seus respectivos valores de tensão e corrente.

A terceira função objetivo, denominada de *FO3*, é representada pela comparação dos estados do conjunto de chaves inicial com o conjunto de chaves da iteração atual, retornando um valor de quantidade de chaves distintas entre os dois conjuntos.

Considerando os valores das funções normalizadas no intervalo [0,1], é então calculada a equação de recompensa como uma soma ponderada, denominada de equação multiobjetivo. A recompensa define diretamente o valor que é utilizado como *fitness* para a aprendizagem do método proposto. O termo recompensa se refere ao valor da equação multiobjetivo, determinado pela equação 14.

$$\text{recompensa} = c_1 * FO1 + c_2 * FO2 + c_3 * FO3 \quad (14)$$

Os coeficientes são distribuídos para manter o resultado normalizado, no intervalo de 0 a 1. Para fins de facilitar o algoritmo, os retornos devem ser ajustados para que a equação tenha seu valor maximizado.

5.5 MODELAGEM PARA APRENDIZAGEM POR PSO

Como abordado no Capítulo 3, o PSO utiliza uma representação de localização das partículas em um hiperespaço, representando cada uma por seu conjunto de coordenadas e de velocidade, com magnitude e sentido.

A busca por PSO baseia-se na alteração da localização de cada partícula, de acordo com o valor da velocidade, baseando-se nos resultados encontrados pelos seus vizinhos. O problema em questão consiste em encontrar um conjunto de chaves, e o estado de cada uma, que deverá maximizar a equação multiobjetivo estabelecida na equação 14.

A modelagem do PSO representa um conjunto de chaves como coordenadas de cada partícula, sobre um hiperespaço binário. Tal situação pode ser representada, dentro de um espaço tridimensional, pela localização do ponto nas extremidades de um cubo, representando as coordenadas de forma binária. No entanto, o problema analisado possui um hipercubo de tamanho proporcional ao número de chaves do sistema, fazendo que cada chave represente um eixo do hiperespaço. Um exemplo para a rede da Figura 3 é representado abaixo.

ID	0	1	2	3	4	5	6	7	8	9	10	11	12	13
ESTADO	0	1	0	0	1	0	0	0	1	0	0	0	1	0

Figura 7 – Representação da partícula formada pela rede da Figura 3

Por se tratar de uma busca em um espaço binário de soluções, o PSO é adaptado para trabalhar com a normalização dos valores de velocidade e com o uso de funções de ativação, descritos no Capítulo 3. A otimização é realizada sobre um conjunto de partículas avaliando seus deslocamentos no hiperespaço, utilizando os valores de recompensa gerados por cada partícula de acordo com sua localização, e iterativamente alterando as velocidades das partículas até que atinjam uma convergência estabelecida por um fator de erro.

5.6 IMPLEMENTAÇÃO

Nessa seção são apresentadas as etapas de desenvolvimento para a construção de um simulador com características de *self-healing* no problema de reconfiguração de sistemas de distribuição de energia. O simulador foi desenvolvido usando a linguagem de programação C.

5.6.1 Entrada de dados e modelagem da rede

Inicialmente foi implementada uma biblioteca com as diferentes estruturas de dados utilizados, bem como as funções de leitura e geração da rede, responsável por modelar a rede em um grafo adequado para o uso das demais funções. Para isso são utilizados:

- Uma matriz de adjacência, para armazenar os dados das conexões (i,j) entre cada barra i e j do sistema, identificadas como arestas. Os dados são:
 - Número de identificação da chave, caso exista na aresta;
 - Variável para armazenar o estado da chave, caso exista na aresta;
 - Limite máximo de corrente para o condutor;
 - Impedância da aresta, considerando todos os componentes;
 - Variável para armazenar o valor do fluxo de corrente entre as barras.
- Uma lista de estruturas, para armazenar os dados de cada barra i e j do sistema, identificadas como nós. Os dados são:
 - *Flag* de identificação de subestação;
 - Variável para armazenar o estado da barra, se energizada ou não;
 - Prioridade de importância da barra, ponderada em 0.25, 0.50, 0.75 ou 1;
 - Identificação da barra i no nó j , do par ordenado (i,j) , onde o sentido do fluxo de corrente se estabelece de i para j ;
 - *Flag* para sinalização no processo de busca em profundidade;
 - *Flag* para sinalizar a convergência de cada nó;
 - Potência exigida pela barra;
 - Variável para armazenar o valor da tensão da barra.
- Uma lista de estruturas, para identificar as chaves no sistema. Os dados são:
 - Número de identificação das barras i e j do par (i,j) conectado pela chave;
 - Número de identificação da chave.

Um exemplo de dado de entrada para formar as estruturas descritas anteriormente e realizar a simulação é apresentado no Apêndice A, esses dados são:

- Limite inferior e superior de tensão para as barras;
- Quantidade de barras na rede;

- Quantidade de chaves na rede;
- Valor de potência base;
- Valor de tensão base;
- Limiar para análise de convergência durante o estudo de fluxo de potência;
- Conexão entre duas barras i e j , expressa por um par (i, j) ;
- Identificação da chave, caso presente na aresta;
- Estado da chave, caso presente na aresta;
- Prioridade de cada barra;
- Impedância da conexão, expressa em resistência e reatância;
- Potência da conexão, expressa em potência ativa e reativa;
- Limite de corrente no condutor.

Após essa etapa, foi implementado o processo de identificação do estado inicial da rede, como: quantidade de nós sem energia; valor da perda de potência; e se houve a formação de rede não radial. Também, são calculados os máximos e mínimos possíveis de cada função objetivo para a situação da rede sem nenhuma falha.

5.6.2 Cálculo do fluxo de potência

O método de estudo de fluxo de potência escolhido é baseado em varreduras pela rede, que necessitam de uma ordem específica para que as somas das correntes em cada nó sejam realizadas de forma correta, mantendo a integridade do cálculo de acordo com as leis de Kirchhoff. Como descrito na seção 5.3, o método utilizado tem semelhanças com o método de varredura da busca em profundidade em grafos.

A partir da estrutura da varredura de uma busca em profundidade, é possível determinar a ordem para as varreduras a jusante e a montante do método. A função tem como parâmetro um nó inicial (raiz de cada árvore), sendo uma subestação da rede.

No Código 1 é exibida a função implementada.

```

void profundidade(int raiz)
{
    int i,j;
    i = raiz;
    empilha(i);
    Vordem[Vf] = i;
    Vf++;
    consumidor[i].cor = CINZA;
    j=0;
    do
    {
        while(j<GridSize)
        {
            if(rede[i][j].conexao == FECHADO && consumidor[j].cor==BRANCO)
            {
                empilha(i);
                Vordem[Vf] = j;
                Vf++;
                consumidor[j].cor = CINZA;
                i=j;
                j=0;
            }
            else j++;
        }

        Iordem[Ij] = i;
        Ij++;
        i = desempilha();
        j = 0;
    }while(pfim>0);
}

```

Código 1 – Adaptação da busca em profundidade para ordenar varreduras

De acordo com a composição da busca em profundidade, a adaptação consiste em armazenar a sequência ao empilhar, para a varredura a jusante, e a sequência de desempilhar, para a varredura a montante. A função é executada uma vez para determinar a ordem de varredura, e após isso é realizado o cálculo de acordo com as equações descritas na seção 5.3. Um trecho do código é exibido no Código 2, demonstrando a forma de utilizar a sequência de varreduras para calcular iterativamente o fluxo de potência.

```

[...]
for(i = 0; i < Ij; i++)
{
    atualizarCorrente(Iordem[i]);
}
for(i = 0; i < Vf; i++)
{
    atualizarTensao(Vordem[i]);
}
[...]
```

Código 2 – Iteração para cálculo do fluxo de potência

5.6.3 Cálculo da recompensa

A função de *fitness* de cada indivíduo é calculada utilizando a equação 14, com base nos valores de cada função objetivo e restrições do sistema. As funções utilizadas são exibidas nos itens abaixo:

- i. Função para avaliação da topologia da rede, indicando se a topologia está radial;
- ii. Função para cálculo do fluxo de potência, indicando se o limite de tensão e corrente está adequado;
- iii. Primeira função objetivo, indicando a relação de cargas restauradas;
- iv. Segunda função objetivo, retornando o complemento do valor normalizado da perda de potência real, utilizado para minimizar a perda;
- v. Terceira função objetivo, retornando o complemento do valor normalizado da quantidade de chaves alteradas, utilizado para minimizar o conjunto de chaves alteradas entre a situação pós falta e pós reconfiguração;
- vi. Cálculo da recompensa usando a equação 14.

As funções que recebem o complemento de um valor normalizado (iv e v), consistem na subtração entre o valor a ser minimizado e o unitário total, para tornar a equação multiobjetivo uma função de maximização. Por exemplo, se a terceira função objetivo possuir um valor de 0.6 para ser minimizado, a função irá retornar 0.4 para ser maximizado.

Com esse conjunto de funções é definido o valor de recompensa, utilizado como *fitness* de cada indivíduo. O fluxograma da Figura 8 mostra a sequência das funções, e representa a estrutura do algoritmo implementado.

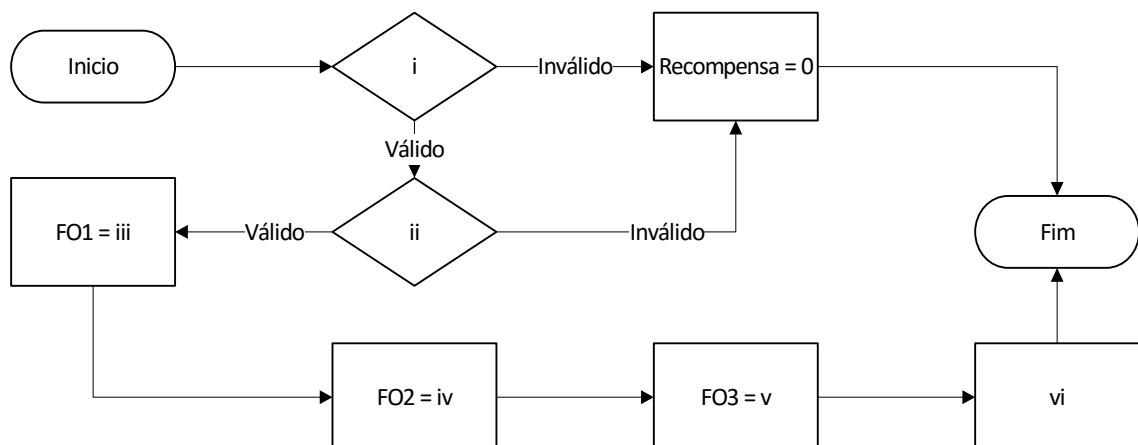


Figura 8 – Fluxograma do cálculo de recompensa

5.6.4 Busca usando PSO

O mecanismo central do sistema de reconfiguração é a forma de busca da solução, com a proposta de utilização do algoritmo PSO. O PSO implementado utiliza a recompensa para auxiliar nas regras de deslocamento do hiperespaço de soluções.

O sistema é composto por uma análise de convergência de forma iterativa, executando uma sequência bem definida até que um dos critérios de parada seja alcançado, e é exemplificado pelo Código 3.

```
void Run(){
  Init();

  while(gen < m && best < n){
    Eval();
    Vel();
    Pos();
    gen++;
    best++;
  }
}
```

Código 3 – Código de execução da busca por PSO

O Código 3 é a principal iteração do algoritmo de busca. Nele a função `Init()` é responsável por inicializar todas as variáveis utilizadas, como as velocidades, posições e recompensas iniciais de cada partícula. O processo iterativo é iniciado com a avaliação de cada partícula por `Eval()`, verificando as recompensas. Após a avaliação é determinada a velocidade, pela função `Vel()`, e a posição, pela função `Pos()`.

As variáveis *gen* e *best* são utilizadas para avaliar critérios de parada no processo de busca. A variável *gen* é utilizada para definir uma quantidade *m* máxima de iterações para o algoritmo. Utilizando a variável *best* é possível analisar se o algoritmo convergiu antes de realizar as *m* iterações, parando a execução caso tenha sido a melhor resposta durante *n* execuções.

O algoritmo geral proposto para solução é descrito pelo fluxograma abaixo, abstraindo as principais funções pelos blocos.

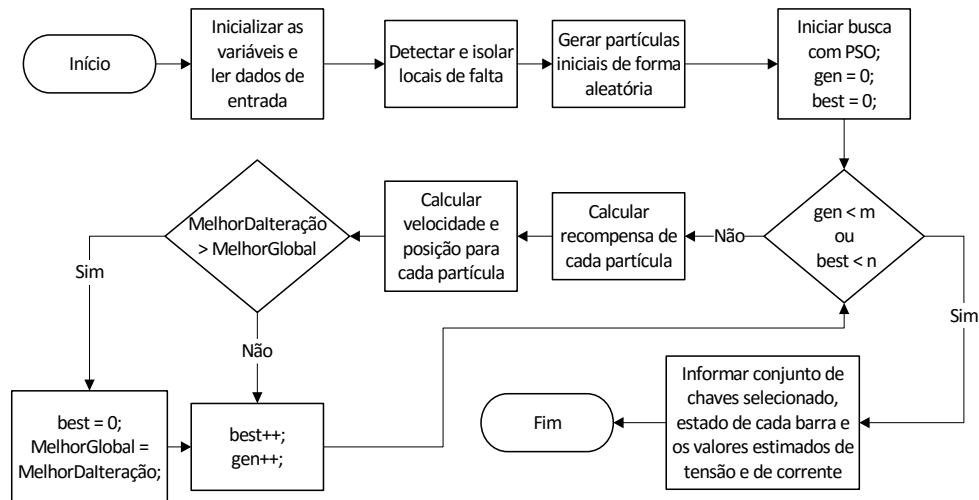


Figura 9 – Fluxograma do método proposto

5.6.5 Métodos comparativos

Para realizar os testes, apresentados no próximo capítulo, foram utilizadas outras duas metodologias de solução do problema, implementadas e descritas por Mazzetto e Casanova (2016). Os algoritmos utilizados para comparação são:

- Busca exaustiva, o qual encontra com garantia a melhor solução buscando por todo o espaço; e
- Algoritmo Genético, baseado em busca evolutiva no espaço de soluções.

O método de busca exaustiva é utilizado como um comparativo para visualizar, dentro de um intervalo de tempo viável, se os algoritmos alcançam o resultado ótimo. Porém, esse mecanismo se torna inviável a partir de uma determinada quantidade de chaves, pois a metodologia utilizada é baseada na varredura de todas as combinações possíveis, armazenando sempre a de melhor resultado. Logo, o método é descartado para se aplicar em um problema com grande quantidade de chaves no sistema, por ser de complexidade exponencial.

A solução com Algoritmos Genéticos possui semelhanças ao método desenvolvido. Para fins de compreensão os parâmetros utilizados nessa implementação foram:

- Avaliação conforme a equação 14;
- Seleção pelo método da roleta;
- Cruzamento uniforme;
- Taxa de mutação de um para mil;
- Quantidade de gerações e indivíduos adaptada aos cenários.

6 RESULTADOS

Para validar os resultados da aplicação do PSO na resolução do problema, foram avaliados os seguintes casos:

- Influência dos parâmetros do PSO no resultado final;
- Influência dos coeficientes da função multiobjetivo na resposta final;
- Comparação do tempo de execução dos algoritmos busca exaustiva e genético. Incluindo uma discussão sobre os critérios de parada.

Os estudos são baseados na rede de distribuição disponível no artigo de Das (2006) ilustrada na Figura 10, por se tratar de uma rede de fácil abstração que possui múltiplas subestações, *tie-switches* e topologia radial.

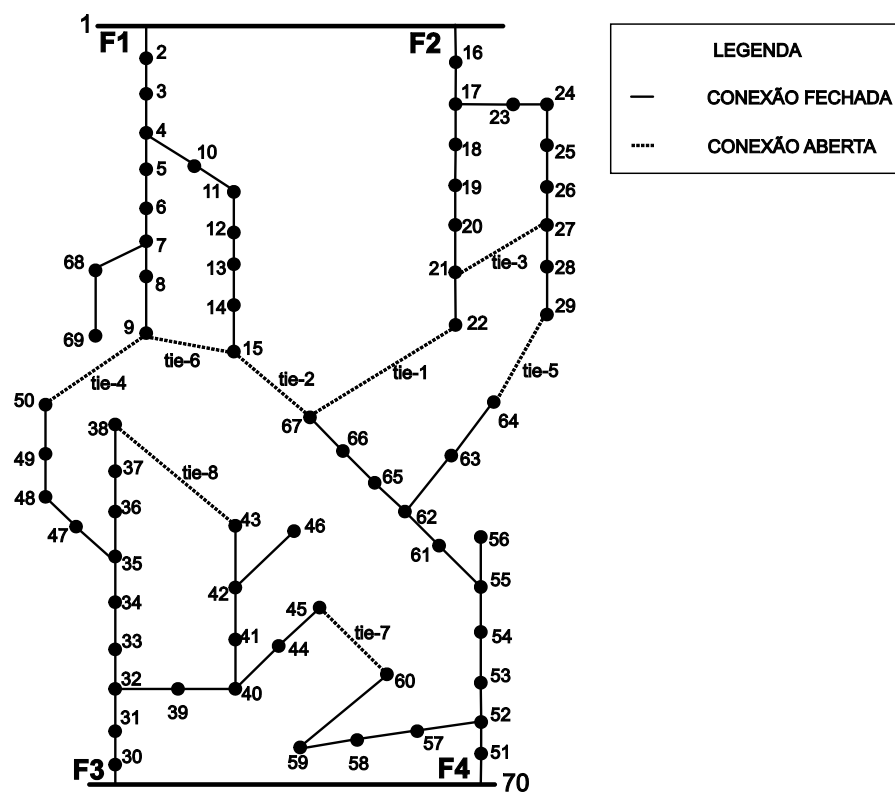


Figura 10 – Rede de distribuição para testes
Fonte: Adaptado de Das (2006, p. 336).

Na Figura 10 é possível visualizar os *tie-switches* (*tie-1*, *tie-2*, *tie-3*, *tie-4*, *tie-5*, *tie-6*, *tie-7*, *tie-8*), que representam as conexões que separam as cargas de subestações diferentes. Nos experimentos foram usados os mesmos valores em termos de topologia e componentes da

rede, disponíveis no apêndice do artigo de Das (2006), adaptando a rede para diferentes cenários, alterando algumas conexões (arestas do grafo) para conexões chaveadas.

Inicialmente se verificou a implementação do método de Soma das Correntes, utilizando a rede da Figura 10. A Tabela 2 exibe a comparação entre os valores do nó com menor tensão e da perda de potência, para comparação do método descrito no artigo de Das (2006) e do método proposto neste trabalho, ambos com diferentes resoluções para o estudo do fluxo de potência. A Tabela 3 exibe os valores de corrente para cada uma das subestações.

Tabela 2 – Comparação de métodos para fluxo de potência

Método	Nó com menor tensão	Valor da menor tensão (pu)	Perda de potência real (kW)
Das (2006)	67	0,883890	337,4
Soma das Correntes	67	0,883892	341,4

Tabela 3 – Corrente das subestações da rede da Figura 10

Subestação	Das (A)	Soma das Correntes (A)
F1	121,0	124,4
F2	132,3	132,3
F3	197,2	199,8
F4	181,5	181,4

Não é possível realizar uma comparação de reconfiguração entre o método utilizado por Das (2006) e o método proposto neste trabalho, dado que Das propõem uma formulação diferente das funções objetivo, e conseqüentemente gera avaliações e resultados diferentes. Assim, os resultados expostos nesse capítulo possuem comparações com outros dois métodos de resolução sugeridos para o problema, como descritos na seção 5.6.5.

6.1 PARÂMETROS DO PSO

Os parâmetros que o algoritmo utiliza para realizar o deslocamento no espaço de soluções dão maior liberdade ao algoritmo para se ajustar conforme o domínio do problema, porém a tarefa de adequação desses parâmetros é um trabalho exaustivo (EBERHART; YUHUI, 2001).

Os parâmetros presentes no PSO são:

- Quantidade de partículas: usado para definir o tamanho da população;

- Quantidade de iterações: critério de parada, representado como *gen* no Código 3;
- w : coeficiente de inércia (equação 1);
- c_1 : coeficiente de relevância da melhor posição da partícula (equação 1);
- c_2 : coeficiente de relevância da melhor posição global (equação 1);
- Função de ativação: quando o domínio do espaço de soluções for discreto;

Existem pesquisas que descrevem métodos de escolha para os parâmetros acima, porém atuam sobre problemas dentro de um espaço de solução no domínio dos números racionais (EBERHART; YUHUI, 2001). Outro fator, é que os resultados tendem a ser influenciados pela função objetivo analisada (EBERHART; YUHUI, 1999).

Para analisar a influência de tais parâmetros, alguns casos de teste foram formulados e selecionados, comparando a resolução do problema com uma busca exaustiva e com uma implementação alternativa de algoritmos genéticos.

Nessa etapa, as análises foram feitas considerando o valor da melhor recompensa encontrada pelos algoritmos. As recompensas são utilizadas para analisar a convergência do algoritmo e avaliar a confiabilidade, ou seja, se mantém respostas próximas em diferentes análises sobre o mesmo cenário, através da média e do desvio padrão desses valores.

Conforme especificado, o gráfico da Figura 11 denota a comparação entre os métodos de busca exaustiva e AG com a implementação proposta do PSO, mantendo uma falta localizada na conexão entre as barras 68 e 69 da Figura 10.

O primeiro estudo foi realizado sobre a rede da Figura 10, alterando a quantidade e composição das chaves sobre as arestas, resultando em redes com 24, 27, 30, 32 e 76 chaves.

Os gráficos da Figura 11 e da Figura 12 exibem o resultado da variação no coeficiente w da equação de velocidade do PSO. Foram realizados testes para os coeficientes c_1 e c_2 dentro de um intervalo proposto por Eberhart (2001), e fixados em 1,5 e 2,5, respectivamente.

Os parâmetros do PSO para o primeiro teste foram definidos como: $w = 1,2$; $c_1 = 1,5$; $c_2 = 2,5$; 100 partículas; e 10.000 iterações. Os resultados são apresentados na Figura 11.

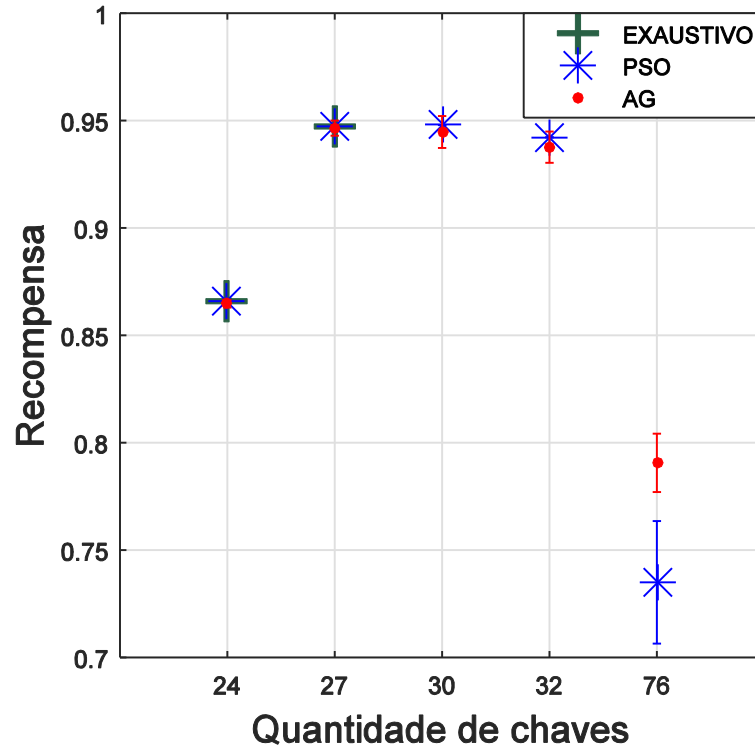


Figura 11 – Média e desvio padrão para Teste 1

Os parâmetros do PSO para o segundo teste foram definidos como: $w = 0,8$; $c_1 = 1,5$; $c_2 = 2,5$; 100 partículas; e 10.000 iterações. Os resultados são apresentados na Figura 12.

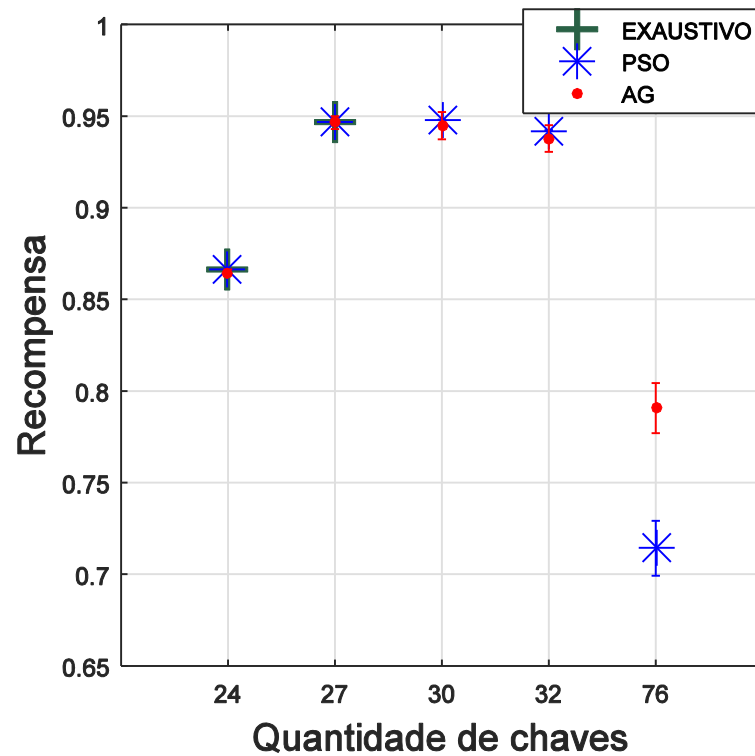


Figura 12 – Média e desvio padrão para Teste 2

A primeira observação é a pouca variação dos valores de recompensa em ambos os testes. É observado nas Figuras Figura 11-Figura 12 que na maioria dos casos o desvio padrão foi próximo de zero.

Nos dois primeiros cenários (24 e 27 chaves) é apresentado o valor ótimo, encontrado pelo algoritmo exaustivo, a qual não foi realizada para os demais cenários devido ao tempo para executá-los aumentar exponencialmente, pois as combinações a serem analisadas aumentam de 2^{27} para 2^{30} , 2^{32} e 2^{76} .

É possível observar no cenário 5 (76 chaves) das Figuras Figura 11-Figura 12 que as recompensas geradas pelo algoritmo PSO são baixas. Isso ocorre, devido a quantidade de combinações possíveis, bem como a influência da quantidade de iterações e demais parâmetros. A alteração do parâmetro w diminuiu o desvio padrão, porém isso não foi suficiente para que o algoritmo encontrasse soluções melhores, como a encontrada pelo AG.

A Figura 13 exibe a variação das recompensas dos algoritmos AG, PSO com $w=0,8$ e PSO com $w=1,2$.

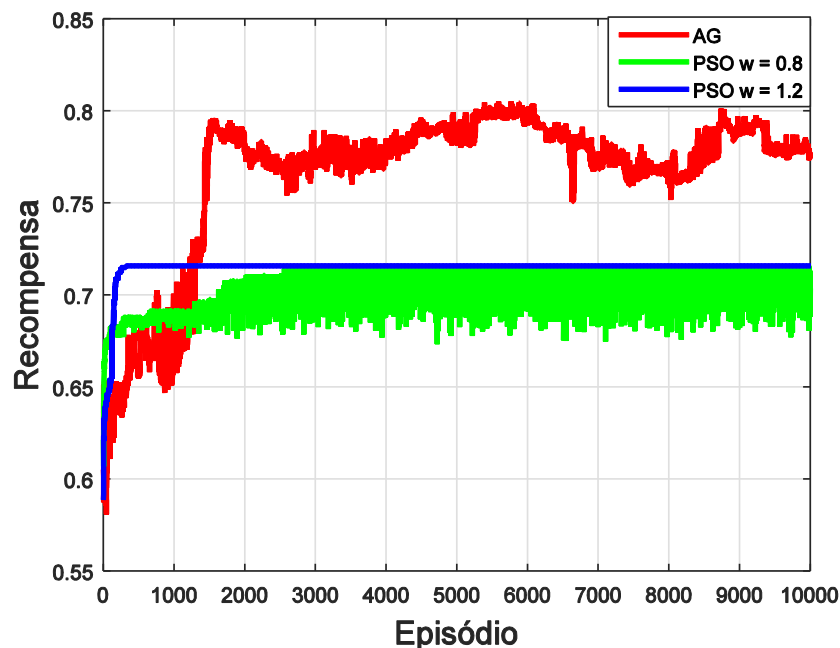


Figura 13 –Convergência PSO x AG variando w

O PSO possui uma convergência acelerada, que traz a possibilidade de trabalhar com um número de episódios menor. Porém exibe uma tendência alta para máximos locais. Já o AG tem a capacidade de explorar mais do espaço de soluções devido às suas mutações durante cada iteração e não tende tão rapidamente para máximos locais.

O PSO com $w=1,2$ converge rapidamente para um máximo local, conforme observado na Figura 13. Isso ocorre devido a influência do valor de w na movimentação das partículas, fazendo-as aglomerarem em um único ponto dentro do espaço de soluções.

Um valor de $w=0,8$ exibe uma convergência mais lenta e uma baixa estabilidade, visto na Figura 13, pois as partículas tendem facilmente a mudar seu caminho pelo espaço quando encontram uma solução local.

Para entender outros comportamentos relativos aos parâmetros do PSO, foram realizados testes sobre o cenário de 76 chaves, procurando alterar fatores como quantidade de partículas e quantidade de iterações realizadas, e analisar a influência causada por eles.

O gráfico apresentado na Figura 14 exibe a média e o desvio padrão da recompensa para três variações de parâmetros do PSO e uma do AG para o mesmo cenário, com 76 chaves. Nele as parametrizações do PSO diferem na quantidade de iterações realizadas e a quantidade de partículas inseridas no espaço de soluções. O eixo y representa o valor de recompensa gerado pela equação 14.

Analisando a diferença de comportamento (exibido na Figura 14) entre o caso de teste com 1.000 partículas e 1.000 episódios, e o caso de teste com 500 partículas e 20.000 episódios, percebe-se que a quantidade elevada de iterações não tem relevância sobre o resultado final, pois o algoritmo exibe uma convergência rápida para uma solução e tende a ficar sobre ela. No caso com 1.000 partículas e 3.000 episódios é encontrado um valor muito próximo ao do AG, mostrando uma quantidade de iterações suficiente para estabilizar a convergência do algoritmo.

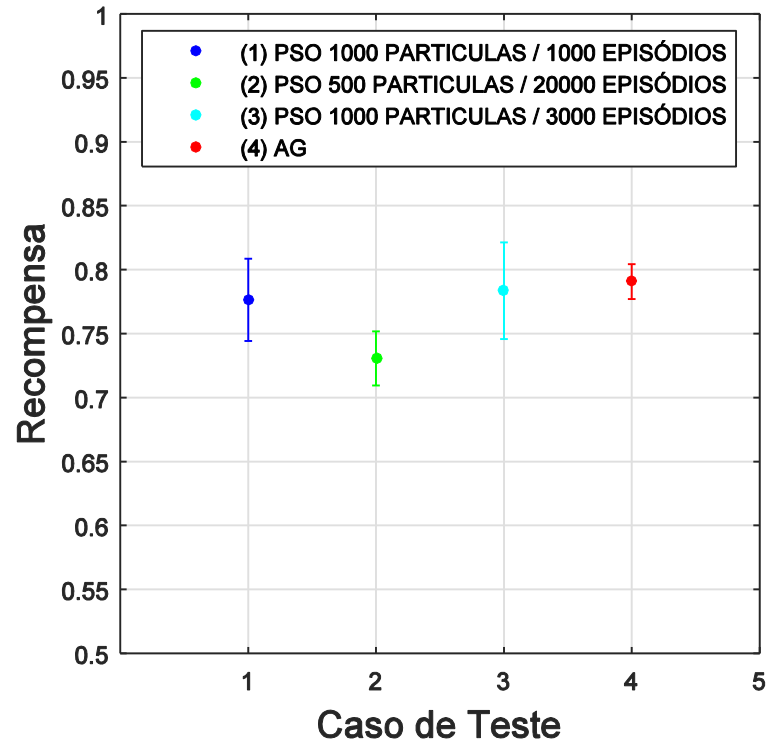


Figura 14 – Média e desvio padrão para Teste 3

As curvas da Figura 15 exibem, respectivamente, a convergência em cada caso de teste da Figura 14.

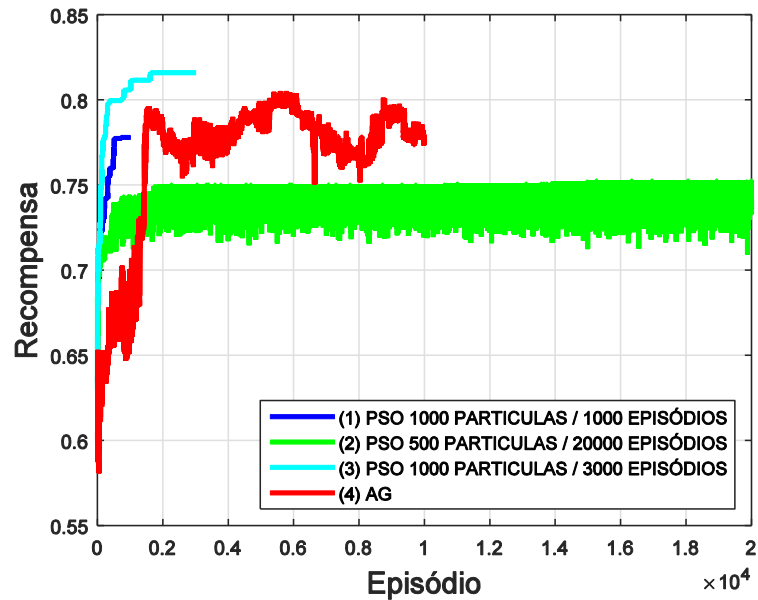


Figura 15 – Convergência PSO x AG variando partículas e episódios

A ideia de utilizar uma quantidade elevada de partículas e uma quantidade menor de episódios serve para popular ainda mais o espaço de soluções e aproveitar a característica de

rápida convergência do algoritmo. Seguindo essa análise, se vê pela curva 2 da Figura 15 (curva em verde), que o número elevado de iterações não auxiliou na busca por soluções melhores.

A curva para o caso de teste com maior número de partículas apresentou uma rápida subida e alcançou níveis maiores de recompensa. É importante entender que a Figura 15 aborda apenas uma simulação para cada caso, e que o comportamento da convergência do algoritmo tende a ser similar dentro da média e desvio padrão exibidos pela Figura 14.

Existem outros fatores que influenciam na convergência e exploração do espaço de soluções, como a limitação em uma velocidade máxima para cada partícula, abordado em um dos artigos de Eberhart (EBERHART; YUHUI, 1999). Nesse trabalho, esse valor foi fixado em 6. Para o caso em que o PSO é binário, sua influência não é tão relevante, pois os valores são limitados por uma função de ativação, e somente em alterações extremas (elevando muito o limite) que se mostraram diferenças entre cada aplicação. A função de ativação utilizada na implementação foi a sigmoid, no intervalo de 0 a 1.

Além da relevância dos parâmetros do PSO sobre a recompensa da solução final, outro fator que influencia a taxa de convergência é a função objetivo. Essa análise é apresentada na próxima seção.

6.2 FUNÇÃO MULTIOBJETIVO

Segundo Eberhart e Yuhui (1999), a definição dos parâmetros das equações utilizadas pela aprendizagem do PSO tem muita correlação com as funções objetivo utilizadas, de forma que a parametrização se torna parcialmente empírica. Tomando conhecimento desse fato, é necessário também avaliar como a função multiobjetivo (equação de recompensa) do problema está sendo influenciada pelas suas componentes.

Foram realizadas simulações para exemplificar a diferença gerada na resposta do PSO, em comparação ao AG, trabalhando com diferentes coeficientes para a equação 14.

O PSO utilizado nessa etapa foi parametrizado com $w = 1,2$; $c_1 = 1,8$; $c_2 = 2,5$, 100 partículas e 10.000 iterações, para a mesma rede de 76 chaves da seção anterior.

Com relação ao percentual de relevância para cada um dos coeficientes, é possível verificar que quanto maior for o coeficiente respectivo à função de minimização da alteração de chaves (*FO3*) menor será o resultado da reconfiguração, ou seja, a nova topologia será muito parecida com a rede após a falta.

Ainda sobre essa função objetivo, é necessário interpretar que para redes onde a quantidade de chaves é muito alta, e que não possui um sistema autônomo ou com atuadores controlados a distância, é exigido o deslocamento de uma equipe para realizar a alteração do estado de cada uma das chaves, demandando tempo e custos para realizar a manutenção. Logo, o objetivo dessa função é de balancear os custos com a reconfiguração do sistema, sem demandar muito esforço físico (deslocamento de equipe especializada) para esses casos. Já em redes com automação, modeladas no conceito de *smart grids*, essa função não é necessária, visto que a atuação sobre uma chave a distância não gera custos adicionais e o tempo se torna relativamente irrelevante.

Quanto aos coeficientes para a perda de potência e para a restauração de carga, os valores devem ser compostos de acordo com a intenção da companhia de abastecimento de energia, balanceando algo que gere conforto para os consumidores e que mantenha a qualidade de energia sobre a rede.

Na Figura 16 são exibidos os gráficos analisando separadamente a convergência de cada função objetivo. O primeiro gráfico mostra a convergência da recompensa, calculado pela equação 14, inicialmente utilizando os coeficientes $c_1=0,4$, $c_2=0,4$ e $c_3=0,2$. A escolha dos coeficientes se deu de forma arbitrária, atribuindo mesma importância para a maximização de cargas restauradas e para a minimização da perda de potência da rede.

No teste é comparada a convergência do PSO com o AG, e é visível a rápida convergência do PSO para um valor constante.

O PSO mostrou resultados individuais muito significativos para as funções objetivo 2 e 3, enquanto que para balancear esse peso na recompensa final teve que diminuir o valor da função objetivo 1, e devido a rápida convergência não explorou outros resultados no espaço de soluções.

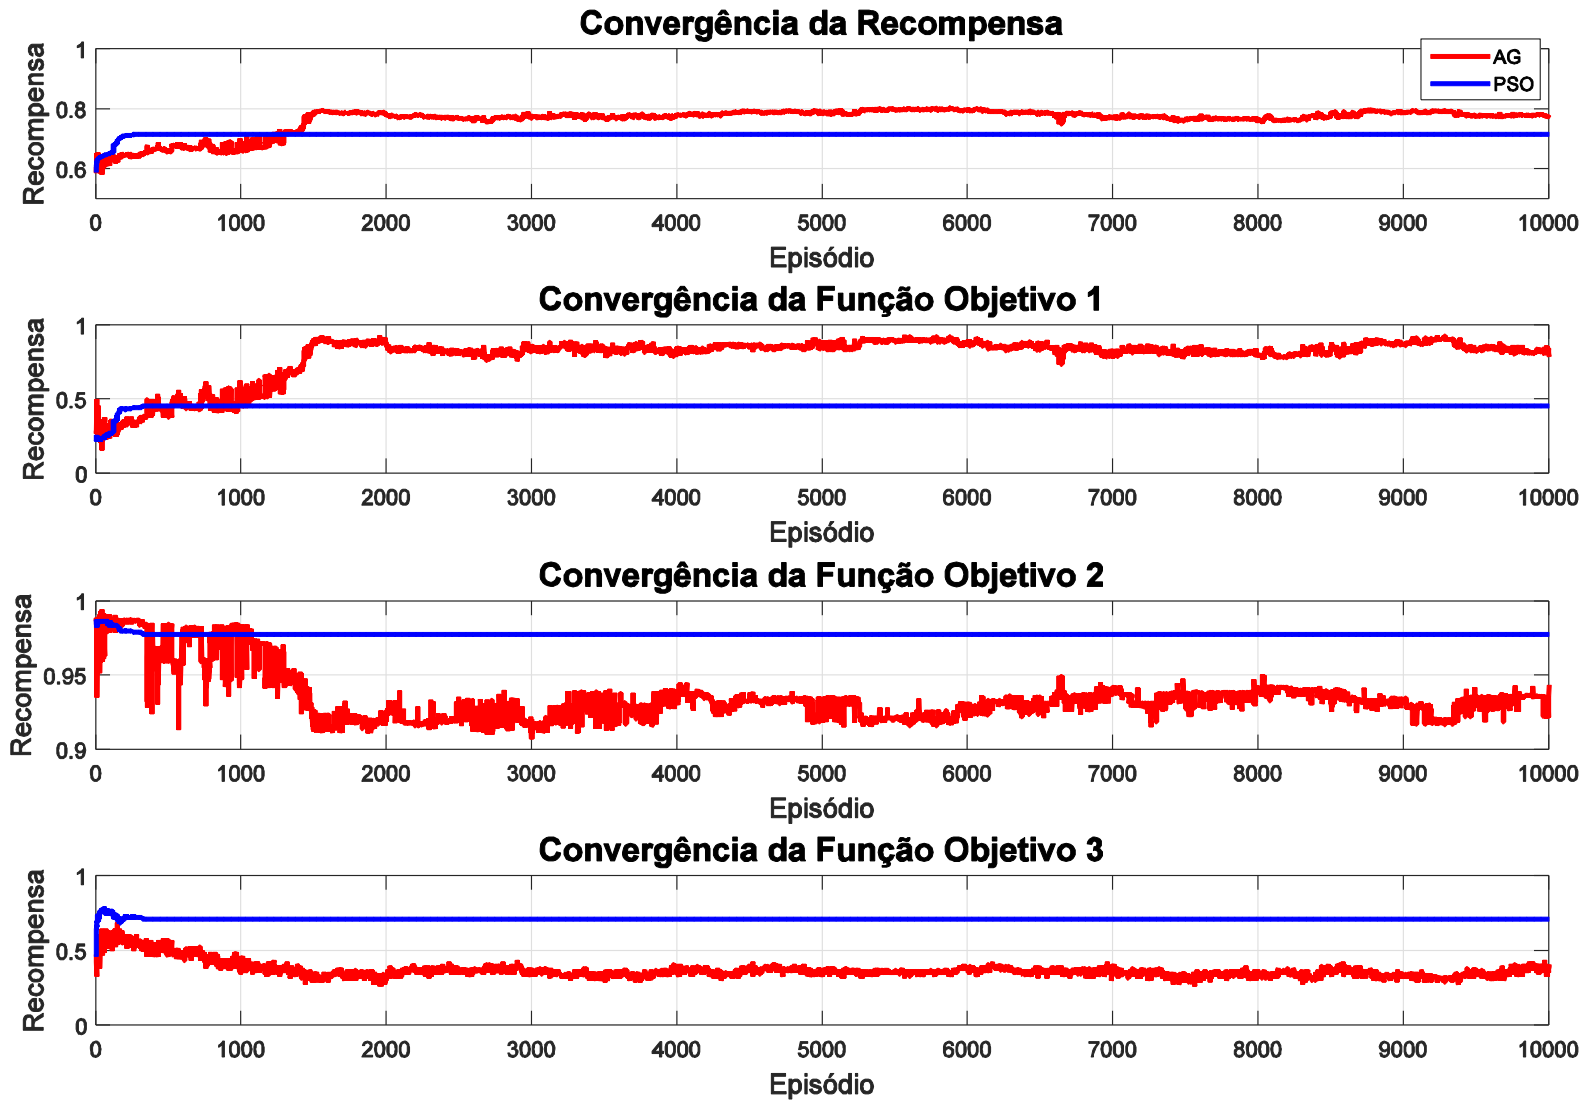


Figura 16 – Convergência de funções objetivo para $c_1=0,4$, $c_2=0,4$ e $c_3=0,2$

Para verificar o estudo de Eberhart e Yuguí (1999), sobre a influência das funções objetivo no método de busca do PSO, os coeficientes foram alterados buscando não causar impasse no balanceamento da recompensa. Mantendo a mesma rede utilizada no teste anterior, os novos coeficientes para a equação 14 foram $c_1=0,5$, $c_2=0,4$ e $c_3=0,1$. Os gráficos são exibidos na Figura 17.

Ao observar a convergência do PSO para a recompensa se nota uma exploração mais lenta e crescente no espaço de soluções até mil iterações, atingindo seu valor máximo e mantendo esse valor, sendo mais rápida em comparação ao AG, que sobe bruscamente nos primeiros quinhentos episódios, mas somente alcança um valor similar ao do PSO em nove mil iterações.

De acordo com o comportamento separado de cada uma das funções, se verifica que no início a rede busca reestabelecer a quantidade de cargas restauradas, alterando demasiadamente as chaves. É observável a relação inversamente proporcional na convergência do PSO na primeira e terceira função objetivo.

A parametrização da equação multiobjetivo se torna uma função complexa para análise, exigindo um trabalho mais detalhado sobre as características funcionais de um sistema de distribuição para então modelar a importância de cada objetivo de forma adequada.

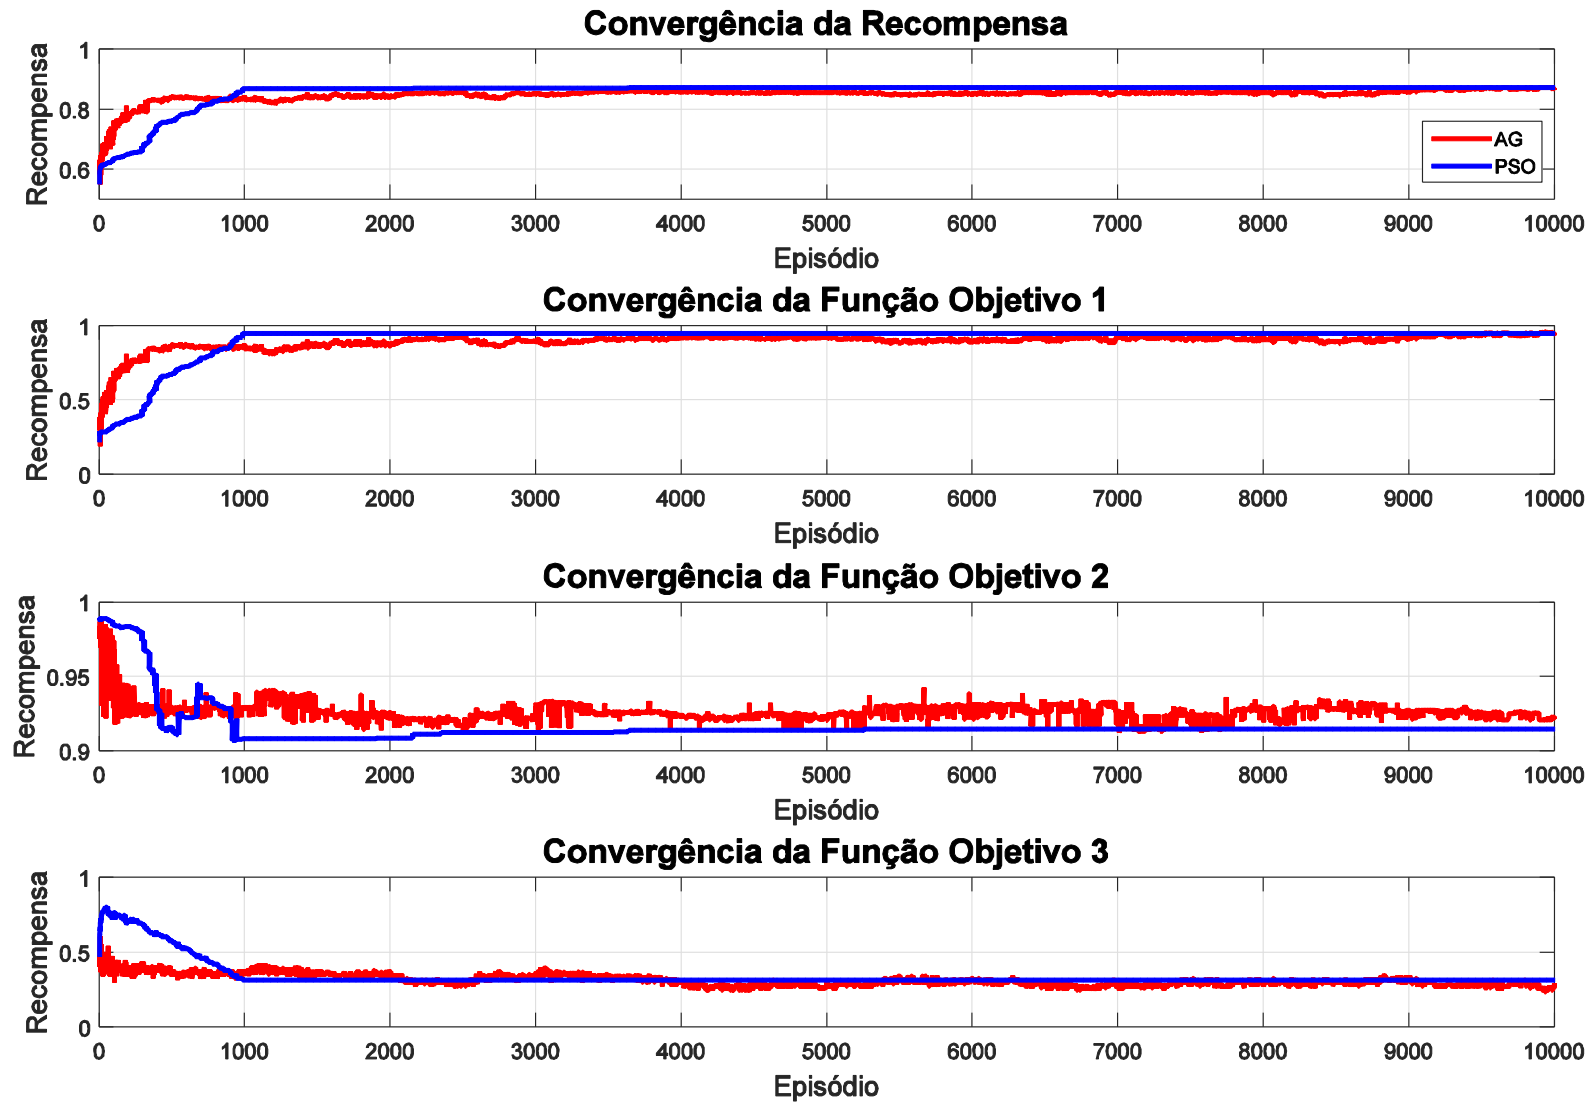


Figura 17 – Convergência de funções objetivo para $c1=0,5$, $c2=0,4$ e $c3=0,1$

Analisando a ponderação proposta de $c_1=0,5$, $c_2=0,4$ e $c_3=0,1$, o comportamento do PSO exibiu média de 0,8754 e desvio padrão de 0,0035, já o AG exibiu média de 0,8692 e desvio padrão de 0,0079.

Em um cenário real, a tarefa de seleção dos coeficientes para a equação deve ser realizada por analistas e engenheiros responsáveis pelo sistema de abastecimento, prezando características de qualidade de fornecimento de energia. As simulações exibem a característica explorada por Eberhart e Yuguí (1999) de se obter diferentes respostas de acordo com alteração da função objetivo sobre o sistema de aprendizagem.

6.3 TEMPO DE EXECUÇÃO

O tempo de execução é relevante quando pretende-se utilizar alguma aplicação em sistemas reais, considerando que ocorrências de faltas em sistemas de distribuição tenham urgência de correção. No entanto, medir o tempo de execução não é uma tarefa trivial, pois em ambientes simulados não é possível obter a mesma infraestrutura que poderia ser utilizada em uma instalação real de uma companhia de energia, com servidores especializados para computar grande quantidade de dados. Assim, em um contexto de testes e avaliação do sistema desenvolvido, as simulações foram realizadas em um desktop com processador Intel Core 2 Quad e 8 GB de memória RAM, sobre o sistema Ubuntu 14.04 LTS 64-bit.

Os testes foram conduzidos por uma sequência de simulações individuais, rodando vinte vezes a mesma situação para cada cenário analisado, sobre os métodos PSO, AG e busca exaustiva, utilizando duas ferramentas distintas para medir o tempo, uma em segundos e outra em *clock ticks* do processador (posteriormente convertidos em milissegundos). Os múltiplos testes têm como objetivo gerar uma média e um desvio padrão para as simulações, apresentados na Figura 18.

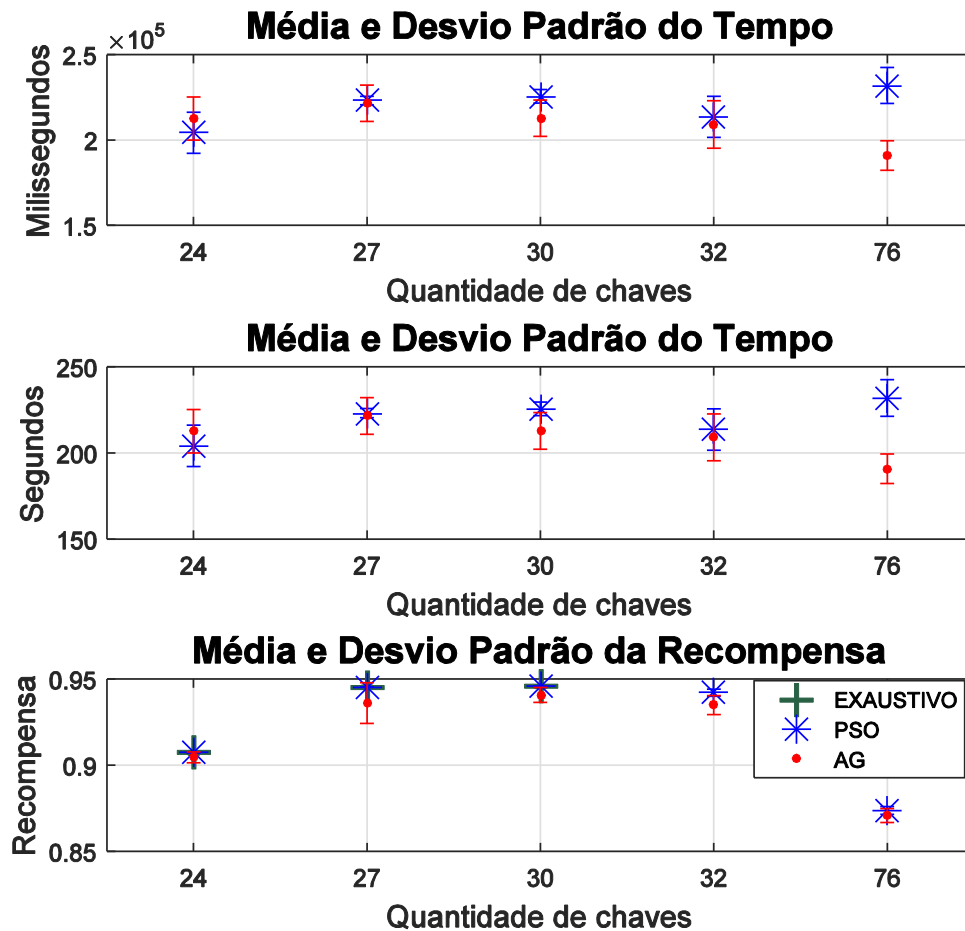


Figura 18 – Média e Desvio Padrão de tempo e recompensa

O primeiro gráfico da Figura 18 é referente a medida dos *clock ticks* do processador convertidos em milissegundos, já o segundo gráfico exibe a medida em segundos através de uma função da biblioteca padrão *time.h*, da linguagem C.

O método de busca exaustiva tende a dobrar o tempo a cada inclusão de uma nova chave no sistema, assim foram analisados somente os cenários iniciais para comparação e com viés didático. Os valores para os testes de tempo com a busca exaustiva não foram plotados por serem muito maiores que os encontrados com o PSO e AG, e dificultariam a interpretação do gráfico.

Os valores de tempo para a busca exaustiva foram medidos para as redes de 24, 27 e 30 chaves, obtendo o tempo médio de 25 minutos, 164 minutos e 1.246 minutos, respectivamente. Em uma análise numérica, é visível que os valores se aproximam muito da teoria de dobrarem o tempo a cada chave adicionada, com uma diferença devido aos componentes não determinísticos do método de fluxo de potência.

Observando o tempo de execução do AG, na Figura 18, nota-se uma queda de tempo com o aumento das chaves. Essa característica é explicada pelo componente de mutação do

algoritmo, onde a chance de mutações sobe quanto mais chaves a rede possuir, alterando a estrutura de convergência do algoritmo. Alterações por mutação podem originar redes não radiais e que não atendem aos requisitos de tensão ou corrente, logo não realizam os cálculos de recompensa durante a execução, como observado no fluxograma da Figura 8. Assim, para o AG, as chances de não executar as funções de cálculo de recompensa sobem quando a quantidade de chaves aumenta.

Já o PSO não possui uma mutação, e sua convergência e estabilidade é mais rápida devido a isso. Porém, também faz a maioria das partículas executarem os cálculos de recompensa, já que tendem a se aglomerar sobre o mesmo ponto de resposta no espaço de soluções, diminuindo a ocorrência de redes não radiais ou fora dos limites. Uma heurística que pode ser utilizada para tratar essa questão é utilizar uma verificação para não recalcular valores para partículas que já foram analisadas, minimizando ainda mais o tempo de execução com auxílio de uma lista que armazene esses valores.

Apesar do tempo de execução do PSO subir conforme o aumento da quantidade de chaves, ele exibiu menor desvio padrão nas simulações. Isso mostra que o algoritmo é confiável por manter uma taxa de resposta próxima, não sendo algo aleatório.

A partir do gráfico da Figura 18 é possível observar que o PSO não necessita da mesma quantidade de iterações que o AG, pois tende a convergir mais rápido. Partindo disso, foram realizados testes com diferentes critérios de parada com o objetivo de diminuir o tempo de execução mantendo o baixo desvio padrão.

O teste consiste em utilizar um critério de parada secundário n no PSO e no AG, conforme definido no fluxograma da Figura 9, fixado em n_1 , de 5.000 iterações, e n_2 , de 2.000 iterações. Tais resultados são exibidos nos gráficos da Figura 19.

Como observado na Figura 19, o desvio padrão do tempo de execução das simulações é maior, por não se tratar de um critério determinístico para o algoritmo, alterando o tempo em cada nova simulação. No entanto, comparando os resultados obtidos entre o PSO com critério fixo de parada em 10.000 iterações e os resultados do PSO com os critérios secundários n_1 e n_2 , os valores são suficientes para tratar o caso de forma eficiente e em menor tempo de execução, e por ter uma convergência muito rápida as respostas encontradas pelo PSO com n_1 e n_2 foram muito próximas.

Dentre os fatores que influenciam na escalabilidade estão a quantidade de barras e chaves adicionadas ao sistema de distribuição. A análise costuma levar em consideração casos extremos de aumento, e se as respostas continuam satisfatórias.

Analisando o critério de parada fixo m do algoritmo e os gráficos de tempo de execução para as diferentes simulações, exibidas nessa seção, o método mantém-se dentro de uma média muito próxima para os cenários de 24 e 76 chaves, isso se deve ao fato do sistema executar uma quantia similar de operações fixas. Porém, além da influência do número de iterações que podem diminuir o tempo de execução, outro fator que influencia diretamente é a quantidade de barras.

A influência da quantidade de barras está ligada ao módulo de avaliação, onde são calculadas as recompensas, pois o estudo do fluxo de potência está diretamente ligado ao número de barras analisadas em cada iteração das funções de varredura. A influência da quantidade de chaves sobre o sistema está no módulo de aprendizagem, o qual trabalha a busca pelo melhor conjunto de chaves, onde a quantidade de operações cresce conforme o número de chaves aumenta.

O objetivo ao se trabalhar com o PSO sobre esse problema é de manter a característica de rápida convergência com uma resposta satisfatória e diminuir o tempo de execução. Esse comportamento foi observado na análise da Figura 16 e Figura 17, seguindo o aumento da rede.

É natural que com o aumento da rede será exigido um maior intervalo de tempo para executar e auxiliar a tomada de decisões. Uma análise mais complexa e detalhada poderá ser abordada em um trabalho futuro sobre esse estudo de caso, observando parâmetros de uma rede real comparando com outros *benchmarks*.

Os valores de episódios para n_1 e n_2 são, respectivamente, 5.000 e 2.000.




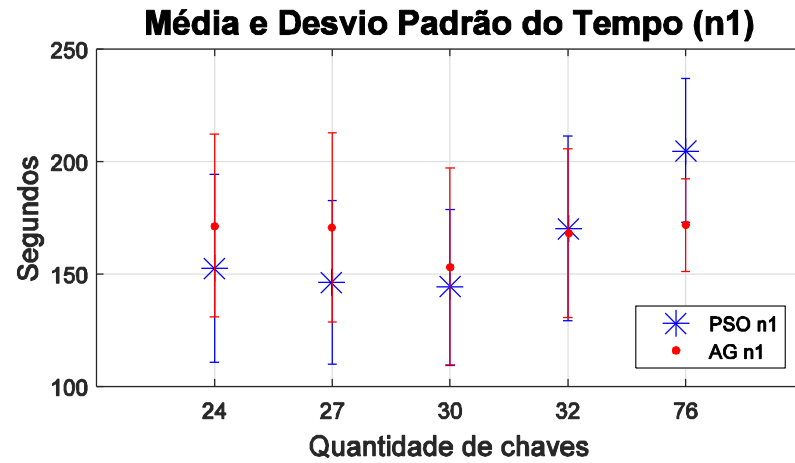


Figura 19 – Média e desvio padrão para critério de parada variável

6.4 RESPOSTA DO SISTEMA

O método proposto tem como objetivo gerar uma saída com um conjunto de chaves abertas e fechadas que otimizam a rede de distribuição segundo as funções objetivo, diretamente influenciado pela recompensa que deriva da equação 14, e tem como saída: um conjunto de chaves com seus estados (aberta ou fechada); o número de barras energizadas; o valor estimado da perda de potência real; e o número de chaves alteradas.

Para compreender a alteração realizada sobre a rede, e o significado da recompensa final, a seguir são exibidos testes sobre uma rede em diferentes cenários. A rede utilizada é apresentada na Figura 20, baseada na Figura 10, com 24 chaves e 8 *tie switches*, incluindo uma falha em uma das conexões.

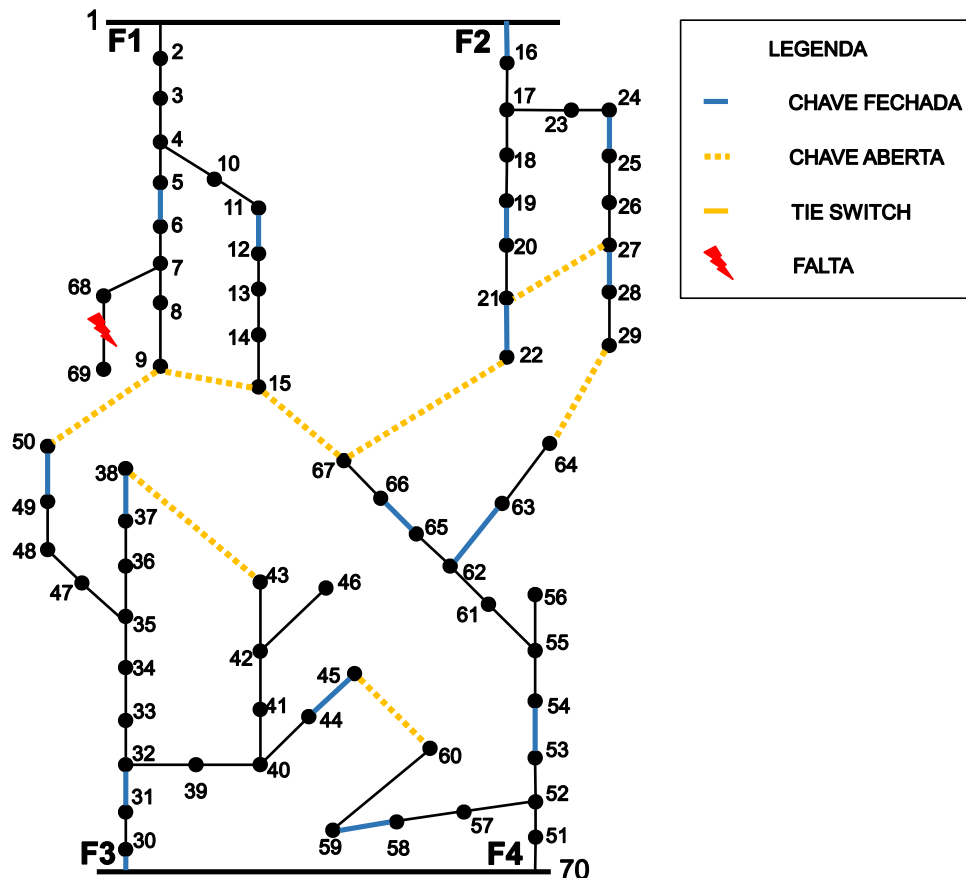


Figura 20 – Rede com 24 chaves para Teste 1

Baseado no sistema de distribuição acima foram utilizados dois casos de teste, um onde o limite de tensão das barras está entre 0,8 pu e 1,05 pu, e outro entre 0,9 pu e 1,05 pu, com os parâmetros da equação 14 sendo $c_1=0,5$, $c_2=0,4$ e $c_3=0,1$. Os resultados são exibidos na Tabela 4.


Tabela 4 – Resultados para rede da Figura 20

	Rede reconfigurada Limite de 0,8 a 1,05 pu	Rede reconfigurada Limite de 0,9 a 1,05 pu
Recompensa	0,939882	0,930882
Barras Energizadas	66	66
Perda de Potência	321,4 kW	331,1 kW
Chaves Alteradas	3	5
Barra com menor tensão e seu valor	Barra 67 com 0,8839 pu	Barra 67 com 0,9014 pu

É possível perceber que com um limite de tensão menor para as barras se possibilitou que o sistema encontrasse uma recompensa relativamente maior, obtendo uma menor alteração nas chaves e uma perda de potência menor. Isso ocorre pois com intervalos maiores se resultam redes com consumidores abastecidos pela mesma subestação (nós 63 e 64 da Figura 21).

Ao se alterar o limite de tensão, o sistema exigiu mais modificações de chaves para distribuir as barras entre as subestações e manter as tensões acima de 0,9 pu, assim outra subestação teve de ser escolhido para alimentar uma parcela dos consumidores (nós 63 e 64 da Figura 21). Consequentemente, isso gerou uma perda de potência maior.

A topologia final de ambas as soluções é exibida na Figura 21, facilitando a compreensão da resposta do sistema. Na imagem é possível ver que são poucas alterações entre as topologias, resultando em uma mesma zona de isolamento, porém com respostas diferenciadas de acordo com os limites pré-estabelecidos da rede de distribuição.



Uma forma de medir a ‘melhora’ da rede pode ser observando os dados de cada característica imediatamente após a falta (já isolada) e compará-los com seus respectivos valores após a reconfiguração. Para esse caso de teste foi utilizada a rede da Figura 22, com os coeficientes da equação 14 sendo $c_1=0,5$, $c_2=0,4$ e $c_3=0,1$, e os níveis de tensão fixados em 0,8 e 1,05 pu.




Figura 22 – Rede com 24 chaves para Teste 2

Os estados de pós isolamento e pós reconfiguração são exibidos na Figura 23, e na imagem (a) é possível observar que as barras 28 e 29 ficaram separadas do restante do sistema, sem estarem inseridas no local de isolamento e sem abastecimento por outra subestação.




Figura 23 – Soluções para rede da Figura 22

Após a reconfiguração, na imagem (b) da Figura 23, as barras 28 e 29 foram conectadas a outra subestação, e somente as barras do local isolado ficaram sem fornecimento de energia.

Os valores de saída do sistema para as redes da Figura 23 são apresentados na Tabela 5, para comparação entre a rede somente isolada e reconfigurada.

Tabela 5 – Resultados para redes da Figura 23

	Rede isolada	Rede reconfigurada
Barras Energizadas	67	69
Perda de Potência	281,9 kW	368,2 kW
Chaves Alteradas	2	3
Barra com menor tensão e seu valor	Barra 67 com 0,8839 pu	Barra 28 com 0,8367 pu

Quanto aos limites de tensão utilizados e aos níveis de importância para cada um dos objetivos (coeficientes da equação 14), esses devem ser analisados de acordo com a padronização em que o sistema de distribuição se enquadra, e em que tipo de estrutura estará sendo implementado (se uma rede automatizada ou não), considerando o objetivo desejado da empresa de distribuição de energia no momento da falha.

Os objetivos de restauração de uma rede podem ser, entre outros, (a) restaurar o maior número de cargas possíveis; (b) minimizar o trabalho de recuperação em campo (reconfiguração das chaves manualmente) e (c) evitar ao máximo desperdício de energia.

Como observado pela relação do valor de recompensa com os valores particulares de cada uma das funções objetivo, é possível ver o conflito entre a maximização de uns e minimização de outros. Isso impossibilita uma relação visivelmente direta entre cada função objetivo e a recompensa, a nível de usuário.

Uma forma que pode ser utilizada para melhorar a visibilidade da relação entre a melhoria da rede com os valores das funções objetivo, é através da alteração da modelagem multiobjetivo, utilizando métodos de equacionamento diferentes que possam exibir uma relação direta com seus componentes. Alguns métodos para problemas multiobjetivo são Método Lexicográfico, Min-Max Ponderado e Produto Ponderado (MARLER; ARORA, 2004), que ficam de sugestões para trabalhos futuros.

7 CONCLUSÃO

O problema de reconfiguração de sistemas de distribuição de energia elétrica é um exemplo prático da intersecção das áreas de ciência de computação e engenharia elétrica, sendo um tópico de interesse público e com pouca aplicação devido a infraestrutura inadequada da rede de energia elétrica (não automatizada).

A utilização de sistemas inteligentes nesse campo tem como objetivo auxiliar a tomada de decisões e reduzir esforços na retomada do funcionamento. A proposta de utilizar o PSO para recuperação da rede após faltas mostrou-se satisfatória, especialmente quando se comparam os resultados com outros métodos da família de algoritmos evolutivos. Os resultados das simulações apresentam soluções próximas da solução ótima com um tempo computacional aceitável.

Um aspecto importante a ser considerado é a respeito da influência da função objetivo na convergência do algoritmo. As simulações demonstraram que a correta escolha dos pesos é fator fundamental na busca pela solução para o objetivo desejado. Esse objetivo, no entanto, deve ser dado pela administradora do sistema de energia, a qual deve escolher entre (a) restaurar o maior número de cargas possíveis; (b) minimizar o trabalho de recuperação em campo (reconfiguração das chaves manualmente) e (c) evitar ao máximo desperdício de energia.

O baixo desvio padrão exibido pelo método PSO é um dos seus pontos fortes, demonstrando ser um algoritmo confiável mantendo as respostas similares em diferentes simulações.

Sobre a escalabilidade, logicamente se demandará maior tempo computacional para achar uma solução adequada conforme a rede aumenta. Nesse sentido, os critérios de parada variável demonstraram respostas que aproveitaram bem a característica de rápida convergência do PSO sem penalizar em excesso o tempo computacional.

A reconfiguração dos sistemas de distribuição exhibe um vasto campo de características que podem ser observadas e analisadas, tanto do lado de aprendizagem, em complexidade e tempo de execução, quanto no aspecto físico, como a qualidade das respostas fornecidas e seu significado. Assim, trabalhos futuros podem ser realizados em direção ao completo entendimento do problema, tais como: a pesquisa de heurísticas que realizem podas na execução do algoritmo; diferentes formas de resolução do problema; uma análise mais profunda das funções objetivo e a relação direta delas com a aplicação física; modularização dos processos de cálculo por métodos de automação supervisionada; e utilização de métodos de aprendizagem distribuída.

REFERÊNCIAS

ABDELAZIZ, A. Y. et al. A Modified Particle Swarm Algorithm for Distribution Systems Reconfiguration. 2009.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução nO 505: Disposições relativas à conformidade dos níveis de tensão de energia elétrica em regime permanente**, 2001.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. Módulo 8 – Qualidade da Energia Elétrica. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST**, p. 53, 2008.

AMIN, M.; WOLLENBERG, B. F. Toward a Smart Grid. **IEEE power & energy magazine**, n. october, p. 34–41, 2005.

BATRINU, F.; CARPANETO, E.; CHICCO, G. A novel particle swarm method for distribution system optimal reconfiguration. **2005 IEEE Russia Power Tech, PowerTech**, p. 1–6, 2005.

BENTO, E. P.; KAGAN, N. Algoritmos genéticos e variantes na solução de problemas de configuração de redes de distribuição. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 19, n. 3, 2008.

CHEN, W. H. Quantitative decision-making model for distribution system restoration. **IEEE Transactions on Power Systems**, v. 25, n. 1, p. 313–321, 2010.

COMMISSION, E. European technology platform smart grids: vision and strategy for Europe's electricity networks of the future. **EUR 22040**, v. 19, n. 3, p. 44, 2006.

DAS, D. Reconfiguration of distribution system using fuzzy multi-objective approach. **International Journal of Electrical Power & Energy Systems**, v. 28, n. 5, p. 331–338, 2006.

DORIGO, M.; MANIEZZO, V.; COLORNI, A. **Ant System: An Autocatalytic Optimizing Process**. Itália: Politecnico di Milano, 1991.

DURCE, C. C. **Normalização Complexa e Cálculo de Fluxo de Potência para Sistemas Elétricos Emergentes**. Curitiba: Universidade Federal do Paraná, 2012.

EBERHART, R. C.; SHI, Y.; KENNEDY, J. **Swarm intelligence**. San Francisco: Morgan Kaufmann Publishers, 2001.

EBERHART, R. C.; YUHUI, S. Empirical study of particle swarm optimization. **Proceedings of the 1999 Congress on Evolutionary Computation-CEC99**, p. 1945–1950, 1999.

EBERHART, R. C.; YUHUI, S. **Particle swarm optimization: developments, applications and resources** *Evolutionary Computation, 2001. Proceedings of the 2001 Congress on, 2001.*

EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. **MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science**, p. 39–43, 1995.

FEOFILOFF, P.; KOHAYAKAWA, Y.; WAKABAYASHI, Y. **Uma Introdução Sucinta à Teoria dos Grafos**. Disponível em: <<http://www.ime.usp.br/~pf/teoriadosgrafos>>.

FERREIRA, L. R. **Algoritmo de autorrecuperação com corte seletivo de carga para redes elétricas inteligentes**. Curitiba: Universidade Federal do Paraná, 2014.

FILHO, C. J. A. B. et al. A novel search algorithm based on fish school behavior. **Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics**, p. 2646–2651, 2008.

GHOSH, D. et al. Self-healing systems - survey and synthesis. **Decision Support Systems**, v. 42, n. 4, p. 2164–2185, 2007.

GHOSH, S.; DAS, D. Method for load-flow solution of radial distribution networks. **IEE Proceedings - Generation, Transmission and Distribution**, v. 146, n. 6, p. 641, 1999.

GRAINGER, J. J.; STEVENSON, W. **Power System Analysis**. New York: McGraw-Hill Inc, 1994.

KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. **1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation**, v. 5, p. 4–8, 1997.

LACERDA, E. G. M.; MEDEIROS, M. F. Minimum Number of Switching Operations Via Ant Colony Optimization. **CIRE**, p. 21–24, 2007.

LIM, K. W. et al. On the self-healing mechanism in smart grid networks. **International Journal of Smart Home**, v. 7, n. 2, p. 27–38, 2013.

LISERRE, M.; SAUTER, T.; HUNG, J. Y. Future Energy Systems. **IEEE Ind. Electron. Mag.**, v. 4, n. 1, p. 18–37, 2010.

MAMO, X. et al. Distribution automation: The cornerstone for Smart Grid development strategy. **2009 IEEE Power and Energy Society General Meeting, PES '09**, p. 1–6, 2009.

MAZZETTO, M.; CASANOVA, D. **Aplicação de algoritmos genéticos para recuperação de sistemas de distribuição de energia: um estudo de caso em redes elétricas inteligentes**. Pato Branco: Universidade Tecnológica Federal do Paraná, 2016. A ser publicado.

MOSLEHI, K.; KUMAR, R. Vision for a self- healing power grid. **Abb Review**, p. 21–25, 2006.

PSAIER, H.; DUSTDAR, S. A survey on self-healing systems: Approaches and systems. **Computing (Vienna/New York)**, v. 91, n. 1, p. 43–73, 2011.

RIBEIRO, R. **Análise Do Impacto Da Teoria Das Redes Sociais Em Técnicas de Otimização E Aprendizagem Multiagente Baseadas em Recompensa**. Curitiba: Pontifícia Universidade Católica do Paraná, 2010.

RIBEIRO, R.; ENEMBRECK, F. A sociologically inspired heuristic for optimization algorithms: A case study on ant systems. **Expert Systems with Applications**, v. 40, n. 5, p. 1814–1826, 2013.

SHIRMOHAMMADI, D. et al. A compensation-based power flow method for weakly meshed distribution and transmission networks. **IEEE Transactions on Power Systems**, v. 3, n. 2, p. 753–762, 1988.

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

U.S. DEPARTMENT OF ENERGY. the SMART GRID. **Communication**, v. 99, p. 48, 2010.

VLACHOGIANNIS, J. G.; HATZIARGYRIOU, N. Reinforcement Learning (RL) to Optimal Reconfiguration of Radial Distribution System (RDS). **Springer-Verlag**, p. 439–446, 2004.

WATANABE, I. An improved ACO algorithm for service restoration in power distribution systems. **IEEE Congress on Evolutionary Computation**, v. 3, p. 2864–2871, 2005.

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

APÊNDICES

A – Exemplo de entrada de dados

Tal exemplo de entrada é referente a um cenário composto apenas pelos *tie-switches* como chaves seccionadoras, e sem presença de falhas, representando a topologia da rede da Figura 10. Os dados da rede são baseados nos dados fornecidos pelo artigo de Das (2006).

Na modelagem realizada, os nós foram adaptados iniciando do nó 0 como a barra 1, dando uma defasagem entre a representação da Figura 10 e a entrada ao sistema. Na entrada as subestações são definidas como quatro diferentes nós, sendo: subestação F1 o nó 0; subestação F2 o nó 70; subestação F3 o nó 69; e subestação F4 o nó 71.

A primeira linha é referente aos valores de coeficientes das funções objetivo, seguindo a ordem *FO1*, *FO2* e *FO3*, e por último o valor *n* de episódios de critério de parada variável. A segunda linha expressa os valores de limite inferior e superior de tensão das barras em *pu*, respectivamente. A terceira linha, segundo a ordem de valores apresentados, contém os valores de: quantidade de nós da rede; quantidade de chaves da rede; valor de tensão base, em volts; valor de potência base, em watts; e limiar de convergência para o cálculo do fluxo de potência.

Na sequência, as próximas linhas definem a estrutura do grafo, no qual cada uma representa uma aresta entre barras *i* e *j*. Os dados de cada linha, segundo a ordem de valores apresentados, são: identificação numérica (valor inteiro de contagem iniciado em 0) da barra *i*; identificação numérica (valor inteiro de contagem iniciado em 0) da barra *j*; identificação numérica (valor inteiro de contagem iniciado em 0, ou -1 para ausência) da chave na aresta, caso existente; estado da chave (1 para fechada ou -1 para aberta/ausente) na aresta, caso existente; valor de prioridade da barra *j* (0,25, 0,50, 0,75 ou 1); valor de resistência da aresta, em ohms; valor da reatância da aresta, em ohms; valor da potência ativa da barra *j*, em quilowatts; valor da potência reativa da barra *j*, em quilowatts; limite máximo de corrente na aresta, em ampere; e por último, uma identificação de localização da aresta com falha (0 para aresta sem falha ou 1 para aresta com falha). A seguir é apresentado o exemplo de entrada segundo as especificações anteriores.

0.4	0.4	0.2	2000
0.8	1.05		
72	8	11000	1000 0.0001

0	1	-1	-1	0.25	1.097	1.074	120	108	270	0
1	2	-1	-1	0.25	1.463	1.432	72	48	270	0
2	3	-1	-1	1	0.731	0.716	180	156	270	0
3	4	-1	-1	0.25	0.366	0.358	90	60	270	0
4	5	-1	-1	0.25	1.828	1.79	21.6	13	270	0
5	6	-1	-1	0.5	1.097	1.074	21.6	17	270	0
6	7	-1	-1	0.5	0.731	0.716	15.6	12	270	0
7	8	-1	-1	0.5	0.731	0.716	19	13	270	0
3	9	-1	-1	0.5	1.08	0.734	24	12	208	0
9	10	-1	-1	0.5	1.62	1.101	19.2	11	208	0
10	11	-1	-1	0.75	1.08	0.734	60	48	208	0
11	12	-1	-1	0.75	1.35	0.917	126	108	208	0
12	13	-1	-1	0.75	0.81	0.55	30	18	208	0
13	14	-1	-1	0.25	1.944	1.321	48	30	208	0
6	67	-1	-1	1	1.08	0.734	120	72	208	0
67	68	-1	-1	0.25	1.62	1.101	48	36	208	0
70	15	-1	-1	0.25	1.097	1.074	72	36	270	0
15	16	-1	-1	0.25	0.366	0.358	48	30	270	0
16	17	-1	-1	0.25	1.463	1.432	18	11	270	0
17	18	-1	-1	0.5	0.914	0.895	15.6	8.4	270	0
18	19	-1	-1	0.5	0.804	0.787	36	24	270	0
19	20	-1	-1	1	1.133	1.11	108	60	270	0
20	21	-1	-1	1	0.475	0.465	60	36	270	0
16	22	-1	-1	0.5	2.214	1.505	72	48	208	0
22	23	-1	-1	0.25	1.62	1.11	120	96	208	0
23	24	-1	-1	0.25	1.08	0.734	96	78	208	0
24	25	-1	-1	0.25	0.54	0.367	120	72	208	0
25	26	-1	-1	0.25	0.54	0.367	120	66	208	0
26	27	-1	-1	0.5	1.08	0.734	144	84	208	0
27	28	-1	-1	0.5	1.08	0.734	126	84	208	0
69	29	-1	-1	0.75	0.366	0.358	96	60	270	0
29	30	-1	-1	0.75	0.731	0.716	72	48	270	0
30	31	-1	-1	1	0.731	0.716	15.6	9.6	270	0
31	32	-1	-1	0.75	0.804	0.787	19.2	11.8	270	0

32	33	-1	-1	0.5	1.17	1.145	60	36	270	0
33	34	-1	-1	0.5	0.768	0.752	48	33.6	270	0
34	35	-1	-1	0.5	0.731	0.716	72	48	270	0
35	36	-1	-1	0.5	1.097	1.074	48	36	270	0
36	37	-1	-1	0.5	1.463	1.432	36	30	270	0
31	38	-1	-1	0.5	1.08	0.734	180	120	208	0
38	39	-1	-1	0.5	0.54	0.367	72	42	208	0
39	40	-1	-1	0.5	1.08	0.734	144	84	208	0
40	41	-1	-1	0.75	1.836	1.248	108	72	208	0
41	42	-1	-1	0.75	1.296	0.881	21.6	12	208	0
39	43	-1	-1	0.75	1.188	0.807	19.2	12	208	0
43	44	-1	-1	0.75	0.54	0.367	120	60	208	0
41	45	-1	-1	0.75	1.08	0.734	72	48	208	0
34	46	-1	-1	0.75	0.54	0.367	108	84	208	0
46	47	-1	-1	0.75	1.08	0.734	122.4	79.2	208	0
47	48	-1	-1	0.75	1.08	0.734	120	84	208	0
48	49	-1	-1	0.75	1.08	0.734	168	108	208	0
71	50	-1	-1	0.75	0.366	0.358	72	48	270	0
50	51	-1	-1	0.75	1.463	1.432	24	13.2	270	0
51	52	-1	-1	1	1.463	1.432	48	36	270	0
52	53	-1	-1	1	0.914	0.895	43.2	28.8	270	0
53	54	-1	-1	1	1.097	1.074	36	24	270	0
54	55	-1	-1	0.5	1.097	1.074	51.6	36	270	0
51	56	-1	-1	0.25	0.27	0.183	96	60	208	0
56	57	-1	-1	1	0.27	0.183	288	144	208	0
57	58	-1	-1	1	0.81	0.55	150	132	208	0
58	59	-1	-1	1	1.296	0.881	30	12	208	0
54	60	-1	-1	0.25	1.188	0.807	12	6	208	0
60	61	-1	-1	0.25	1.188	0.807	180	156	208	0
61	62	-1	-1	0.5	0.81	0.55	60	36	208	0
62	63	-1	-1	0.5	1.62	1.101	36	24	208	0
61	64	-1	-1	0.5	1.08	0.734	156	144	208	0
64	65	-1	-1	1	0.54	0.367	180	156	208	0
65	66	-1	-1	1	1.08	0.734	30	18	208	0

21	66	0	-1	1	1.08	0.734	30	18	208	0
66	14	1	-1	0.25	1.944	1.321	48	30	208	0
20	26	2	-1	0.25	0.54	0.367	120	66	208	0
8	49	3	-1	0.75	1.08	0.734	168	108	208	0
28	63	4	-1	0.5	1.62	1.101	36	24	208	0
44	59	5	-1	1	1.296	0.881	30	12	208	0
42	37	6	-1	0.5	1.463	1.432	36	30	270	0
8	14	7	-1	0.25	1.944	1.321	48	30	208	0