

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

VINÍCIUS YUITI FUKASE

**ALOCÇÃO OTIMIZADA DE SENSORES INDICADORES DE FALTA EM
SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA UTILIZANDO BUSCA
HARMÔNICA**

ILHA SOLTEIRA

2023

PROGRAMA DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

VINÍCIUS YUITI FUKASE

**ALOCÇÃO OTIMIZADA DE SENSORES INDICADORES DE FALTA
EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA
UTILIZANDO BUSCA HARMÔNICA**

Trabalho de Conclusão de Curso
apresentado à Faculdade de Engenharia de
Ilha Solteira – UNESP como parte dos
requisitos para obtenção do título de
Bacharel em Engenharia Elétrica.

Fábio Berthequini Leão
Orientador

Ilha Solteira

2023

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

F961a Fukase, Vinícius Yuiti.
Alocação otimizada de sensores indicadores de falta em sistemas de distribuição de energia elétrica utilizando busca harmônica / Vinícius Yuiti Fukase. -- Ilha Solteira: [s.n.], 2023
74 f. : il.

Trabalho de conclusão de curso (Graduação em Engenharia Elétrica) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2023

Orientador: Fábio Bertequini Leão

Inclui bibliografia

1. Alocação otimizada. 2. Indicadores de falta. 3. Busca harmônica.

ATA DE DEFESA DE TRABALHO DE GRADUAÇÃO

Aos vinte e três dias do mês de junho do ano de dois mil e vinte e três, o discente *Vinícius Yuiti Fukase*, matriculado sob o nº 162053622, tendo como banca examinadora seu orientador, o *Prof. Dr. Fábio Bertequini Leão*, o *Doutorando Lucas do Carmo Yamaguti* e o *Mestrando Rafael Yuki de Souza Yamamoto*, apresentou o Trabalho de Graduação intitulado "Alocação Otimizada de Sensores Indicadores de Falta em Sistemas de Distribuição de Energia Elétrica utilizando Busca Harmônica" obtendo a nota 10 (DEZ) e conceito APROVADO.

Fábio Bertequini Leão

Fábio Bertequini Leão

- Orientador -

Vinícius Fukase

Vinícius Yuiti Fukase

- Discente -

Lucas do Carmo Yamaguti

Lucas do Carmo Yamaguti

- Membro da Banca -

Rafael Y. S. Yamamoto

Rafael Yuki de Souza Yamamoto

- Membro da Banca -

AGRADECIMENTOS

Aos meus pais, Noboru Fukase e Marcena Sadako Yamauchi Fukase, pelo carinho, incentivo e apoio durante toda minha vida.

Ao professor Fábio Bertequini Leão, meu orientador, por aceitar conduzir minha pesquisa, por sua orientação e ensinamentos, além do seu apoio e confiança em meu trabalho.

Aos professores do curso de Engenharia Elétrica da Universidade Estadual Paulista (UNESP) pela excelência na qualidade técnica que cada um ofereceu.

Aos amigos e colegas da UNESP pela companhia e ajuda durante todos esses anos de graduação.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento do projeto de pesquisa que deu início a este trabalho, através dos processos nº 2019/24666-4 e 2015/21972-6

RESUMO

As concessionárias de energia elétrica sempre tiveram o objetivo de manter e melhorar a confiabilidade das redes de distribuição, com o intuito de fornecer qualidade de energia aos consumidores e atender às normas regulatórias. Para alcançar esses objetivos, as empresas devem investir em tecnologia para monitorar e operar a rede de forma estratégica, ao mesmo tempo em que buscam reduzir os custos operacionais e de investimento na rede. Os sensores Indicadores de Falta (IF) são uma das tecnologias disponíveis para monitoramento e operação da rede, que podem ser usados para reduzir o tempo para localização da falta e, consequentemente, reduzir o Custo da Energia Não Suprida (*CENS*), melhorando a confiabilidade da rede. No entanto, é importante lembrar que há um custo envolvido na instalação desses sensores, o que pode tornar inviável a sua instalação em todos os ramais do sistema. Neste trabalho, o problema de alocação de sensores IF em sistemas de distribuição será abordado como um problema de otimização combinatória, levando em consideração dois objetivos conflitantes: *CENS* e o Custo de Investimento na alocação de sensores. Para resolver este problema, é desenvolvido e implementado um Algoritmo de Busca Harmônica baseado no processo de improvisação musical, em que o vetor solução é análogo a uma harmonia. Serão realizados testes experimentais com o método proposto, utilizando sistemas testes da literatura. Os resultados obtidos mostram que o algoritmo é robusto e eficiente, considerando que o problema deve ser resolvido na fase de planejamento e não exige sua resolução em tempo real.

Palavras-chave: Alocação Otimizada, Indicadores de Falta, Busca Harmônica.

ABSTRACT

Electric utilities has the goal of maintaining and improving the reliability of distribution networks in order to provide power quality to consumers and meet regulatory standards. To achieve these goals, utilities must invest in technology to strategically monitor and operate the grid, while seeking to reduce network investment and operational costs. Fault Indicator (FI) sensors are one of the available technologies for monitoring and operating the grid, which can be used to reduce the time to locate the fault and consequently reduce the Cost of Unsupplied Energy (*CUE*), improving grid reliability. However, it is important to remember that there is a cost involved in the installation of these sensors, which may make it unfeasible to install them in all branches of the system. In this paper, the problem of FI sensor allocation in distribution systems will be approached as a combinatorial optimization problem, taking into account two conflicting objectives: *CUE* and Investment Cost in sensor allocation. To solve this problem, a Harmonic Search Algorithm will be developed and implemented based on the musical improvisation process, where the solution vector is analogous to a harmony. Experimental tests will be performed with the proposed method, using a test system from the literature. The results obtained show that the algorithm is robust and efficient, considering that the problem should be solved in the planning phase and does not require its resolution in real time.

Keywords: Optimal Allocation, Fault Indicators, Harmonic Search.

LISTA DE FIGURAS

Figura 1 – Arquitetura do Hardware do IF com interface de comunicação.	12
Figura 2 – Conceito do interruptor magnético baseado no módulo de detecção de falta.....	13
Figura 3 – <i>Smart Navigator 2.0</i>	14
Figura 4 – SEL-FT50 e SEL-FR12	14
Figura 5 - Sistema de distribuição com a alocação de 4 sensores indicadores de falta.....	17
Figura 6 – Codificação para o ABH – harmonia/solução apresentada no sistema da Figura 5.	21
Figura 7 – Diagrama de blocos.....	27
Figura 8 – SDEE teste de 5 barras utilizado	29
Figura 9 – SDEE teste exemplo.....	31
Figura 10 – Codificação da alocação da Figura 9	31
Figura 11 – Função incumbente para $HMCR = 0,5$ com destaque para as primeiras iterações	39
Figura 12 – Gráfico da função média para $HMCR = 0,5$	40
Figura 13 – Função incumbente para $HMCR = 0,7$ com destaque para as primeiras iterações	41
Figura 14 – Gráfico da função média para $HMCR = 0,7$	41
Figura 15 – Gráfico da função incumbente para $HMCR = 0,9$	42
Figura 16 – Gráfico da função média para $HMCR = 0,9$	43
Figura 17 – Função incumbente para os três valores de $HMCR$ analisados.....	44
Figura 18 – Função média para os três valores de $HMCR$ analisados.....	44
Figura 19 – Sistema teste de 19 barras	45
Figura 20 – Gráfico do comportamento da função objetivo em relação ao número de iterações para os três algoritmos quando $w_1=0,2$ e $w_2=0,8$	49
Figura 21 – Gráfico do comportamento da função objetivo em relação ao número de iterações para os três algoritmos quando $w_1=0,5$ e $w_2=0,5$	52
Figura 22 – Gráfico do comportamento da função objetivo em relação ao número de iterações para os três algoritmos quando $w_1=0,8$ e $w_2=0,2$	55
Figura 23 – Sistema teste de 34 barras	57
Figura 24 – Gráfico do comportamento da função objetivo em relação ao número de iterações - Parte A.....	59
Figura 25 – Gráfico do comportamento da função objetivo em relação ao número de iterações - Parte B.....	59

Figura 26 – Gráfico do comportamento da função objetivo em relação ao número de iterações ampliado para as primeiras 25 iterações - Parte A	60
Figura 27 – Gráfico do comportamento da função objetivo em relação ao número de iterações ampliado para as primeiras 25 iterações - Parte B.....	60
Figura 28 – Gráfico da função objetivo do melhor resultado.....	61
Figura 29 – Fronteira de Pareto para sistema de 34 barras.....	67
Figura 30 – Fronteira de Pareto para sistema de 34 barras (ampliado)	67

LISTA DE TABELAS

Tabela 1 – Valores da função objetivo para todas as 32 soluções do sistema teste da Figura 8	33
Tabela 2 – Valores da função objetivo para todas as 32 soluções variando o comprimento das seções.....	37
Tabela 3 – Melhores alocações para os pesos $w_1 = 0,2$ e $w_2 = 0,8$	47
Tabela 4 – Dados da melhor solução para os pesos $w_1=0,2$ e $w_2=0,8$	48
Tabela 5 – Melhores alocações para os pesos $w_1 = 0,5$ e $w_2 = 0,5$	50
Tabela 6 – Dados da melhor solução para os pesos $w_1=0,5$ e $w_2=0,5$	51
Tabela 7 – Melhores alocações para os pesos $w_1 = 0,8$ e $w_2 = 0,2$	53
Tabela 8 – Dados da melhor solução para os pesos $w_1=0,8$ e $w_2=0,2$	54
Tabela 9 – Resultados para a fronteira de Pareto do sistema de 34 barras – Parte A.....	64
Tabela 10 – Resultados para a fronteira de Pareto do sistema de 34 barras – Parte B.....	65
Tabela 11 – Resultados para a fronteira de Pareto do sistema de 34 barras – Parte C.....	66
Tabela 12 – Dados de entrada do sistema teste de 19 barras.....	73
Tabela 13 – Dados de entrada do sistema teste de 34 barras.....	74

Sumário

1. Introdução.....	10
2. Sensores Indicadores de Falta (IFs).....	12
2.1. Princípio de funcionamento.....	12
2.2. Modelos de IF e suas características.....	13
3. Modelo Matemático para Alocação Otimizada de Sensores IF	15
3.1. Estudo da alocação de sensores IF em uma rede de distribuição	17
3.2. Exemplo de aplicação do modelo matemático	18
4. Algoritmo de Busca Harmônica aplicado ao problema de alocação ótima de sensores IF.....	20
4.1. Conceitos Gerais sobre o Algoritmo de Busca Harmônica.....	20
4.2. Implementação do Algoritmo de Busca Harmônica	21
4.3. Modificações no ABH e diagrama de blocos	23
4.3.1. Mudanças no ABH proposto	24
4.3.2. Mudanças nos cálculos de CENS e CINV.....	26
5. Resultados.....	29
5.1. Resultados para o sistema de 5 barras	29
5.1.1. Análise de todas as possíveis alocações para o sistema teste de 5 barras	29
5.1.2. Análise das soluções variando o comprimento de cada seção	34
5.1.3. Resultados empregando o ABH proposto	38
5.1.4. Discussão sobre a análise de sensibilidade do ABH	43
5.2. Resultados para o sistema de 19 barras	45
5.2.1. Considerações sobre os dados de entrada	45
5.2.2. Simulações.....	46
5.2.3. Discussões sobre as simulações	55
5.2.4. Discussões sobre gráficos das melhores soluções das alocações	56
5.3. Resultados para o sistema de 34 barras	57
5.3.1. Considerações sobre os dados de entrada	57
5.3.2. Resultados empregando o ABH modificado	57
5.3.3. Análise Multicritério dos Resultados da Alocação de IFs em Redes de Distribuição de Energia Elétrica.....	62
6. Conclusões	69
7. Referências	70
Anexo A – Sistemas teste de 19 e 34 barras	73

1. Introdução

Devido ao rápido aumento do número de consumidores e a necessidade de incorporar a geração distribuída, as concessionárias de energia elétrica enfrentam uma crescente pressão das agências reguladoras para melhorar a confiabilidade e a qualidade da energia fornecida. Portanto, elas precisam investir em tecnologia para monitorar e proteger seus sistemas de distribuição de energia elétrica (SDEE). Entre as tecnologias disponíveis, destacam-se os sensores Indicadores de Falta (IF) ou *Fault Passage Indicators* (FPI) em inglês. Esses sensores emitem um sinal luminoso no próprio dispositivo ou enviam um sinal em tempo real para o Centro de Operação da Distribuição (COD) quando uma corrente maior do que a corrente de carga ou corrente de curto-circuito passa por eles. Com o avanço da tecnologia, novos sensores inteligentes (*smart sensors*) estão se tornando cada vez mais acessíveis para o monitoramento e proteção de sistemas de distribuição, (MUENCH; WRIGHT, 1984; LUAN; TENG; CHEN, 2011; TENG; LUAN; HUANG; LEE; HUANG, 2015; INCON-POWER REABILITY SYSTEMS, 2017).

Se o custo dos sensores for baixo, muitos deles podem ser instalados na rede de distribuição, principalmente em áreas críticas. A informação dos sensores pode ser usada pelos operadores do COD para identificar qual ramo ou região do sistema está potencialmente sob falta, reduzindo assim o tempo necessário para localizar a falta no sistema de distribuição. Isso ajuda a diminuir os custos de operação do sistema, principalmente o Custo de Energia Não Suprida (*CENS*), e a melhorar sua confiabilidade (TENG; HUANG; LUAN, 2014).

É importante destacar que instalar sensores indicadores de falta em todos os ramos da rede de distribuição não é viável nem necessário para melhorar o monitoramento e a confiabilidade. Por isso, o problema de alocação desses sensores pode ser formulado como um problema de otimização combinatória, onde os dispositivos são alocados de forma estratégica para minimizar o *CENS* e também reduzir o custo de investimento na compra e instalação dos sensores. Esse problema leva em consideração dados da rede de distribuição, como a quantidade e densidade das cargas, a taxa de falhas e o tempo de reparo de cada trecho da rede. No entanto, como esse é um problema com muitas variáveis, a resolução pode ser difícil. Algumas técnicas de solução propostas na literatura incluem otimização exata (VILELA; SOUZA; LEÃO, 2018^o; VILELA; SOUZA; LEÃO, 2018b), Algoritmo Genético Adaptativo (AGA) (CRUZ, 2016; OGURA; LEÃO, 2017), Lógica Fuzzy (SOUZA; SILVA; ZIOLKOWSKI; FLAUZINO, 2009) e Algoritmo Imune (AI) (HO; LEE; LIN, 2011; CARNIO; LEÃO, 2019).

Com base nos estudos prévios, o objetivo deste trabalho de conclusão de curso é utilizar modelos matemáticos para resolver o problema de alocação de sensores por meio da otimização combinatória. A formulação a ser utilizada neste estudo é a mesma sugerida nas referências (CRUZ, 2016; OGURA; LEÃO, 2017), que busca minimizar o *CENS* e, simultaneamente, o Custo de Investimento (*CINV*) na alocação dos sensores. Estes dois objetivos são conflitantes, uma vez que a instalação de mais sensores aumenta a confiabilidade, mas também eleva os custos de investimento.

Para resolver o problema, será proposto o uso de uma metaheurística baseada no Algoritmo de Busca Harmônica (ABH), como descrito em (KONG; GAO; OUYANG; LI, 2015). O ABH não requer muitos requisitos matemáticos e não precisa de valores iniciais para as variáveis de decisão. Ele emprega busca estocástica aleatória, o que significa que não necessita de informações derivativas. Além disso, o ABH é capaz de gerar novos vetores após considerar todos os vetores existentes, o que o torna mais eficiente em comparação com algoritmos genéticos, que só consideram dois vetores pais. Para validar o ABH, são utilizados três sistemas testes com 5 barras, 19 barras e 34 barras. Os resultados obtidos demonstram a eficiência do algoritmo e indicam seu potencial para ser aplicado em sistemas de distribuição de energia elétrica.


2. Sensores Indicadores de Falta (IFs)

No contexto das redes de distribuição de energia elétrica, é essencial fornecer um serviço de qualidade aos clientes. Para garantir a confiabilidade da rede, os sensores IF são amplamente utilizados para detectar faltas no sistema. Durante uma falta, esses dispositivos detectam o campo magnético gerado pelo fluxo de corrente no condutor e acionam um mecanismo de alerta, como um diodo emissor de luz, *Light Emitting Diode* (LED), ou dispositivo remoto, para indicar a presença do defeito. A detecção rápida de defeitos pode resultar em uma redução nos custos operacionais da concessionária devido à minimização do *CENS*. Neste trabalho, apresenta-se uma visão geral do funcionamento dos sensores IF, sua implementação em sistemas de distribuição de energia elétrica e alguns modelos existentes no mercado.

2.1. Princípio de funcionamento

Neste capítulo, será abordada a arquitetura do hardware do sensor indicador de falta, que é composto por três módulos principais: o módulo de detecção de corrente de falta, o módulo de interface de comunicação e o módulo da unidade micro controladora (UMC). A UMC é responsável por conectar os módulos por meio dos pinos de entrada e saída (E/S) e dos pinos de solicitação de interrupção (PSI). O módulo de detecção de corrente de falta é composto por interruptores magnéticos e LEDs de alarme, que são acionados quando há a detecção de uma falta no sistema. Na Figura 1 é ilustrada a arquitetura do *hardware* do IF.


Figura 1 – Arquitetura do Hardware do IF com interface de comunicação.



Fonte: Adaptado de (TENG; HUANG; LUAN, 2014).

Durante a ocorrência de uma corrente de falta no condutor, a força magnética gerada induz o interruptor magnético presente no sensor indicador de falta se magnetizar e, consequentemente, fechar os contatos. Como resultado, um LED é acionado, indicando a presença da falta. Na Figura 2 é exibido este conceito.

Figura 2 – Conceito do interruptor magnético baseado no módulo de detecção de falta.



Fonte: Adaptado de (TENG; HUANG; LUAN, 2014).

Quando uma falta é detectada pelo módulo de detecção de corrente de falta, um sinal é enviado para o módulo UMC, que ativa a unidade. A informação pode ser reportada para o centro de controle através da interface de comunicação, que pode ser feita via cabo ou sem fio. O centro de controle coleta a informação pela rede de comunicação e a apresenta em uma interface gráfica para o operador.

É crucial que os parâmetros de operação dos sensores sejam adequadamente ajustados para garantir seu funcionamento eficiente. É recomendado instalar os IFs em conjunto com dispositivos de seccionamento da rede, o que permite o restabelecimento parcial da rede enquanto o reparo é feito no ramo danificado.

Regularmente, os IFs apresentam três principais modos de operação:

- Modo normal, quando a corrente que passa pelo sensor está dentro da faixa nominal de operação preestabelecida. Isso indica que não há falta no ramo do sistema.
- Modo de falta, quando a corrente que passa pelo sensor ultrapassa a faixa de operação. Isso indica a ocorrência de uma falta no sistema, e a falta é sinalizada de alguma forma.
- Modo de reparo, que é necessário para o processo de rearme do IF. Após todo o processo de atuação, localização da falta e reparo da rede, o sensor passa do modo de falta para o modo normal.

2.2. Modelos de IF e suas características

Nesta seção serão apresentados alguns modelos de sensores IF disponíveis no mercado pelos fabricantes HORSTMANN GERMANY e SEL (SSchweitzer Engineering Laboratories), e suas características. O enfoque será em modelos aéreos, uma vez que são os mais utilizados no Brasil.

Na Figura 3 é apresentada o *Smart Navigator 2.0*, um sensor autosuficiente de linha aérea, que possui grande eficácia em linhas de média tensão, monitoramento remoto e rápida detecção de falta.

Figura 3 – *Smart Navigator 2.0*



Fonte: (HORSTMANN GERMANY CATALOGUE, 2020).

Na Figura 4 é exibida o SEL-FT50 e SEL-FR12, que possuem um sistema sem fio para comunicação, fácil instalação (utilizando um simples bastão isolado para manobra – “*hot stick*”) e melhora a confiabilidade, eliminando atrasos desnecessários na coordenação.

Figura 4 – SEL-FT50 e SEL-FR12



Fonte: (SCHWEITZER ENGINEERING LABORATORIES, 2020).

3. Modelo Matemático para Alocação Otimizada de Sensores IF

A função objetivo (FO) – função de uma ou mais variáveis de projeto que se quer otimizar, minimizando-a ou maximizando-a – para alocação de IFs em SDEE considera duas parcelas conflitantes:

- Custo de Energia Não Suprida – relacionado ao tempo para localização da seção sob falta devido a alocação do sensor (R\$);
- Custo de Investimento – para alocação dos sensores no sistema (R\$).

Desta forma, pode-se modelar a função objetivo como:

$$\text{Min } FO = w_1 \times CENS + w_2 \times CINV \quad (1)$$

Sujeito a:

$$0 \leq N \leq N_{max}$$

$$w_1 + w_2 = 1$$

Sendo:

w_1, w_2 : pesos para refletir maior importância ao $CENS$ e $CINV$, respectivamente. Tratam-se de uma ponderação convexa, logo $w_1 \geq 0$ e $w_2 \geq 0$;

N : Número de sensores a serem instalados no sistema;

N_{max} : Número máximo de sensores que podem ser instalados no sistema;

O primeiro termo da equação (1) pode ser modelado através de:

$$CENS = Ce \times \sum_{z=1}^{NZ} \sum_{i \in NL_z} L_i \times \left(\sum_{j \in NS_z} \lambda_j \times t_j^m \right) \quad (2)$$

Sendo:

$CENS$: Custo da Energia Não Suprida anual (R\$/ano);

Ce : Custo da energia (R\$/kWh);

nz : Número de zonas do sistema;

NL_z : Conjunto de cargas dentro da zona z ;

NS_z : Conjunto de seções/ramos dentro da zona z ;

L_i : Potência demandada pela barra i (kW);

λ_j : Taxa de falha da seção/ramo j (falhas/ano);

t_j^m : Tempo para localização da falta na seção j com sensor $m=1$ ou sem sensor $m=0$ (horas).

Leva em consideração o tempo que o sensor demora para enviar sinal para o COD mais o tempo médio de reparo gasto pelas equipes de manutenção incluindo o tempo de deslocamento das equipes. Quando existe sensor alocado então $m=1$; e quando não existe sensor alocado $m=0$.

A taxa de falha da seção j é dada por:

$$\lambda_j = \bar{\lambda} \times C_j \quad (3)$$

Sendo:

$\bar{\lambda}$: Taxa de falha média (falhas/ano.km);

C_j : Comprimento da seção j em quilômetros (km);

E o tempo para a localização da falta é escrito como:

$$t_j^0 = tss \times Dj \quad (4)$$

$$t_j^1 = tcs \times Dj \quad (5)$$

Sendo:

tss : tempo sem sensor (horas/km);

tcs : tempo com sensor (horas/km);

Dj : distância total em quilômetros da subestação até a seção j conectada na barra em que será ou não instalado o sensor (km);

O segundo termo da equação (1) pode ser escrito como:

$$CINV = N \times \left(\frac{CFI + CIFI}{IDFI} + CMFI \right) \quad (6)$$

Sendo:

CINV: Custo de investimento total anual com a instalação dos sensores no sistema (R\$/ano);

CFI: Preço de compra de cada sensor (R\$);

CIFI: Custo de instalação do sensor (R\$);

IDFI: Tempo de vida útil média do sensor (anos);


CMFI: Custo de manutenção do sensor (R\$/ano);

Assim é possível modelar a função objetivo do problema de alocação otimizada de sensores IF através da equação (1) sendo o *CENS* e o *CINV* dados pelas equações (2) e (6), respectivamente. De acordo com o interesse da concessionária, é possível no cálculo da função objetivo mínima (*MinFO*) ajustar os pesos w_1 e w_2 de modo a priorizar uma maior confiabilidade da rede (*CENS* mínimo, cujo $w_1 > w_2$) ou um menor investimento em alocação de sensores (*CINV* mínimo, cujo $w_2 > w_1$). Se $w_1 = w_2$ então tem-se a mesma prioridade aos dois objetivos conflitantes.

3.1. Estudo da alocação de sensores IF em uma rede de distribuição

Nesta seção é apresentado o estudo da alocação de sensores na rede de distribuição teste. Este sistema é composto por 5 barras e para apresentação do estudo de forma didática são alocados 4 sensores IF como apresentado na Figura 5.

Figura 5 - Sistema de distribuição com a alocação de 4 sensores indicadores de falta.



Z: Zona de atuação do sensor.

Fonte: Elaborado pelo autor.

Nota-se que 4 zonas foram criadas devido a alocação dos sensores, sendo a zona Z1 delimitada entre os sensores IF1 e IF2; a zona Z2 delimitada entre os sensores IF2 e IF3; a zona Z3 delimitada entre os sensores IF3 e IF4 e a zona Z4 após o sensor IF4. Desta forma, para faltas em cada uma das zonas os sensores a montante desta zona devem atuar e enviar um sinal de atuação (*trip*) ao COD indicando que existe falta. Assim, caso a falta seja permanente, os operadores do sistema podem rapidamente enviar uma equipe de manutenção ao local. Por exemplo, uma falta na zona Z3, os sensores IF1, IF2 e IF3 devem atuar indicando que existe uma falta em uma zona à jusante desses. Devido somente os 3 sensores terem atuado pode-se concluir que a falta é na zona Z3.

O tipo de falta pode ser identificado pela atuação da proteção da subestação (SD), sendo temporária se a proteção da SD atuar e após o religamento do disjuntor através da função 79 o sistema permanecer em estado normal. Ou será permanente se após as tentativas de religar o sistema o disjuntor permanecer aberto, indicando que deve haver intervenção para reparo da falta no sistema. Nesta condição as informações dos sensores atuados são de grande importância para indicar com maior precisão e menor tempo o local da falta.

Vale salientar que no caso da zona Z3 existe somente um sensor alocado no ramo/seção 3-4, este fato dificulta indicar com precisão onde ocorre a falta. Se a falta é no ramo 3-4 a equipe deve levar um tempo t_3^1 que leva em conta a presença do sensor. Caso a falta seja no ramo 4-5, que não possui o sensor, o tempo que a equipe deve levar é t_4^0 , que é um tempo maior que t_3^1 .

Logo, o problema de alocação dos sensores indicadores de falta é alocá-los de maneira otimizada, considerando a quantidade de carga, a taxa de falha e o tempo de reparo de cada trecho do circuito referente às zonas de proteção criadas pelos sensores de modo a minimizar o *CENS* com o mínimo de investimento *CINV* em sensores.

3.2. Exemplo de aplicação do modelo matemático

Com base na Figura 5 é possível obter os seguintes dados:

- $nz = 4$
- $NL_1 = \{1\}$
- $NL_2 = \{2\}$
- $NL_3 = \{3,4\}$
- $NL_4 = \{5\}$
- $NS_1 = \{1\}$
- $NS_2 = \{2\}$
- $NS_3 = \{3,4\}$
- $NS_4 = \{5\}$

Assim, pode-se formular a primeira parcela da função objetivo (2) como:

$$\begin{aligned}
 CENS &= Ce \times \left[\sum_{z=1}^4 \sum_{i \in NL_z} L_i \times \left(\sum_{j \in NS_z} \lambda_j \times t_j^m \right) \right] \\
 &= Ce \times \left[\sum_{i \in NL_1} L_i \times \left(\sum_{j \in NS_1} \lambda_j \times t_j^m \right) + \sum_{i \in NL_2} L_i \times \left(\sum_{j \in NS_2} \lambda_j \times t_j^m \right) + \sum_{i \in NL_3} L_i \right. \\
 &\quad \left. \times \left(\sum_{j \in NS_3} \lambda_j \times t_j^m \right) + \sum_{i \in NL_4} L_i \times \left(\sum_{j \in NS_4} \lambda_j \times t_j^m \right) \right] \\
 CENS &= Ce \times [L_1 \times \lambda_1 \times t_1^1 + L_2 \times \lambda_2 \times t_2^1 + (L_3 + L_4) \times (\lambda_3 \times t_3^1 + \lambda_4 \times t_4^0) + L_5 \times \lambda_5 \\
 &\quad \times t_5^1] \tag{7}
 \end{aligned}$$

Para formular a equação (6) no sistema da Figura 5, basta substituir $N = 4$ visto que os custos envolvidos na alocação e manutenção são considerados iguais para todos os sensores. Deste modo, nota-se que quanto mais sensores forem alocados no sistema, mais seções serão monitoradas por sensores, menores serão os tempos de localização da falta para cada seção, assim reduzindo o *CENS*. Todavia, quanto maior a quantidade de sensores, maior é o custo de investimento na alocação destes dispositivos, contribuindo no aumento do *CINV*, o que torna os dois objetivos conflitantes. Uma forma de resolver o problema é a aplicação de técnicas de otimização combinatória como o ABH que será apresentado na próxima seção.

4. Algoritmo de Busca Harmônica aplicado ao problema de alocação ótima de sensores IF

Nesta seção é apresentado o ABH, técnica de otimização que foi implementada para a solução da função objetivo dada pela equação (1).

A utilização do ABH no problema de alocação de sensores é vantajoso devido à sua capacidade de explorar o espaço de busca de forma inteligente, lidar com restrições do problema, adaptar-se às características específicas e tratar de problemas de otimização multicritério, oferecendo soluções aproximadas de alta qualidade em um tempo razoável.

4.1. Conceitos Gerais sobre o Algoritmo de Busca Harmônica

O Algoritmo de Busca Harmônica foi desenvolvido em analogia com o processo de improvisação musical, em que o músico improvisa os tons do seu instrumento para obter uma melhor harmonia. Uma harmonia é definida por uma relação especial entre várias ondas sonoras de diferentes frequências, e a qualidade da harmonia improvisada é determinada pela estimativa estética. Para melhorar a música e encontrar a melhor harmonia, os compositores treinam exaustivamente. (WANG; YANG; XU; NIU; PARDALOS; FEI, 2013)

Assim, é possível notar a similaridade entre a improvisação musical realizada pelo músico e o processo de otimização combinatória. Em um problema de otimização, o objetivo final é encontrar o resultado ótimo global da função objetivo considerando um número de variáveis de decisão. As variáveis de decisão definem um vetor solução, e os valores das variáveis de decisão são utilizados de forma coerente na função objetivo para avaliar a qualidade do vetor solução. Durante as iterações, o vetor solução é atualizado até que se obtenha o ótimo global, ou seja, para este caso, o menor valor para a função objetivo.

Com base nessa analogia, é possível concluir que os processos de improvisação musical e de otimização apresentam as seguintes similaridades:

- No processo musical, a qualidade da harmonia é determinada pela estimativa estética. No processo de otimização, a qualidade do vetor solução é determinada pelo valor da função objetivo.
- No processo musical, o objetivo final é obter a melhor e mais fantástica harmonia. No processo de otimização, o objetivo final é obter o ótimo global.


- No processo musical, o músico troca o tom do seu instrumento. O algoritmo de otimização muda os valores das variáveis de decisão.
- No processo musical, toda tentativa de tocar uma harmonia é chamada prática. No processo de otimização, cada tentativa para atualizar o vetor solução é chamada iteração.

Em geral, quando um músico quer alterar o tom do seu instrumento (por exemplo violino, saxofone, violão, etc) e soar uma nota, ele utiliza uma das três possíveis maneiras: 1) tocar uma nota aleatória; 2) tocar uma nota da sua memória e 3) tocar uma nota próxima a uma nota de sua memória. Essas regras constituem o processamento principal do ABH.

4.2. Implementação do Algoritmo de Busca Harmônica

A codificação binária proposta permite representar todas as possíveis alocações de sensores IF no sistema elétrico. Com isso, torna-se possível gerar um conjunto de soluções iniciais aleatórias para iniciar a busca harmônica. Durante o processo de busca, as harmonias são atualizadas por meio de operadores de seleção, memória harmônica e outros processos de atualização, como o ajuste de frequência e o ajuste de tom. Dessa forma, o ABH pode explorar o espaço de busca de forma mais eficiente em busca da melhor solução.

Figura 6 – Codificação para o ABH – harmonia/solução apresentada no sistema da Figura 5.



Fonte: Elaborado pelo autor.

Para cada solução possível do problema (como por exemplo, a harmonia da Figura 6) é necessário calcular os tempos de localização das faltas para cada seção do sistema e com estes dados calcular a função objetivo na equação (1). Em particular para a harmonia da Figura 6 seria necessário utilizar o primeiro termo da função objetivo que está desenvolvido na equação (7).

O ABH apresenta os seguintes passos (KONG; GAO; OUYANG; LI, 2015), (GEEM; KIM; LOGANATHAN, 2001):

1. Inicialização dos parâmetros do algoritmo. Tipicamente existem 5 parâmetros necessários para serem calibrados: tamanho da memória harmônica *HMS* (*Harmony Memory Size*), taxa considerando memória harmônica *HMCR* (*Harmony Memory Considering Rate*), taxa de ajuste do passo *PAR* (*Pitch Adjusting Rate*), largura de banda *bw* (*Bandwidth*) e número máximo de improvisações *NI*.
2. Inicialização da memória harmônica. Inicialmente a memória harmônica é formada com *HMS* harmonias geradas aleatoriamente. Portanto a conjunto de harmonias pode ser organizado na memória harmônica (*HM*) conforme a matriz da equação (8). Na equação (8) n é o número de variáveis da harmonia ou o número de variáveis do problema.

$$HM = \begin{vmatrix} x_1^1 & x_2^1 & \dots & x_n^1 & f(x^1) \\ x_1^2 & x_2^2 & \dots & x_n^2 & f(x^2) \\ \dots & \dots & \dots & \dots & \dots \\ x_1^{HMS} & x_2^{HMS} & \dots & x_n^{HMS} & f(x^{HMS}) \end{vmatrix} \quad (8)$$

3. Improvisação para geração da nova harmonia candidata. A improvisação é realizada para gerar a nova harmonia candidata x^{new} empregando três regras conforme o Algoritmo 1.
4. Atualização da memória harmônica *HM* equação (8). A harmonia do conjunto *HM* que apresenta a pior qualidade de solução para o problema será substituída pela nova harmonia quando a nova harmonia candidata x^{new} for melhor que a pior harmonia do conjunto *HM*.
5. Verificação do critério de convergência. Se *NI* harmonias foram criadas, terminar o algoritmo, e a melhor harmonia do conjunto *HM* é a solução para o problema. Do contrário retorne ao passo 3 e repetir o algoritmo de improvisação.

O ABH padrão apresentado é adequado para resolver problemas com variáveis contínuas ou reais. Como o problema a ser resolvido é codificado empregando variáveis binárias é necessário realizar modificações, principalmente na improvisação apresentada no Algoritmo 1 (passo 3).

```

Para i=1 a n faça
    Se  $U(0,1) \leq HMCR$ 
         $x_i^{new} = x_i^r, r \in \{1, 2, \dots, HMS\}$ 
        % consideração de memória (regra 1)
        Se  $U(0,1) \leq PAR$ 
             $x_i^{new} = x_i^r, r \in \{1, 2, \dots, HMS\}$ 
            % ajuste de frequência (regra 2)
        Fim Se
    Senão
         $x_i^{new} = x_{i,min} + U(0,1) \times (x_{i,max} - x_{i,min})$ 
        % busca aleatória (regra 3)
    Fim Se
Fim Para
Sendo  $U(0,1)$  um número aleatório entre 0 e 1.

```

(Algoritmo 1)

4.3. Modificações no ABH e diagrama de blocos

Na referência (KONG; GAO; OUYANG; LI, 2015) é apresentada uma revisão bibliográfica com as principais variantes propostas na literatura para resolver problemas binários empregando o ABH (ZOU; GAO; LI; WU, 2011; WANG; YANG; XU; NIU; PARDALOS; FEI, 2013). Neste trabalho de graduação emprega-se a mesma técnica proposta em (KONG; GAO; OUYANG; LI, 2015) para resolver problemas binários baseado em duas regras conforme o Algoritmo 2.

```

Para i=1 a n faça
    Se  $U(0,1) \leq HMCR$ 
         $x_i^{new} = x_i^{r1} + (-1)^{(x_i^{r1})} \times |x_i^{best} - x_i^{r2}|$ 
        % improvisação (regra 1)
    Senão
         $x_i^{new} \begin{cases} 0, se U(0,1) \leq 0,5 \\ 1, caso contrário \end{cases}$ 
        % reinicialização (regra 2)
    Fim Se
Fim Para

```

(Algoritmo 2)

No início, os parâmetros do algoritmo são inicializados e a memória harmônica é preenchida com vetores solução aleatórios, que são obtidos por meio do cálculo da função objetivo $f(x)$, conforme descrito na equação (1).

Após isso, inicia-se o processo de improvisação, que para um determinado valor aleatório entre 0 e 1 $[U(0,1)]$ comparado ao HMCR define como será calculado o novo vetor improvisado. A equação do cálculo de x_i^{new} é a parte mais importante da improvisação, de forma que, para um x_i^{r1} escolhido que seja idêntico ao x_i^{best} , haverá um processo de troca que aumentará a diversidade da HM, assim então evitando que caia em um ótimo local que apresente uma solução de baixa qualidade. Todavia, se x_i^{r1} é diferente de x_i^{best} , este processo pode aumentar a velocidade de convergência da HM para a solução otimizada.

O novo vetor improvisado é então comparado com o pior vetor da memória harmônica atual. Se a função objetivo for menor, ou seja, mais próxima da solução otimizada, a nova harmonia é inserida no lugar da pior harmonia.

Por fim, o critério de convergência é verificado e, assim que o valor de NI é atingido, o algoritmo é finalizado e as melhores soluções obtidas são apresentadas.

4.3.1. Mudanças no ABH proposto

A partir da realização de diversos testes com o sistema de 19 barras da Figura 19, conclui-se que o bom desempenho do algoritmo para o sistema teste de 5 barras não era alcançado. Desta forma fez-se necessária algumas alterações no ABH proposto para que haja melhoria no processo de convergência do algoritmo. A seguir, serão apresentadas cada uma delas.

4.3.1.1. Estratégia de Diversidade e Dinamicidade do parâmetro HMCR

Foi visto na seção anterior o desempenho do algoritmo para valores de HMCR fixos que funcionou como o esperado no sistema de 5 barras. Porém, no sistema teste de 19 barras, valores fixos de HMCR não foram suficientes para atingir o resultado desejado. Logo, tornou-se necessário elaborar um método de variação dinâmica do HMCR no processo de improvisação.

A diversidade refere-se à presença de soluções distintas e não redundantes no conjunto de soluções encontradas. Uma boa diversidade implica em ter soluções representativas que abrangem diferentes regiões do espaço de busca e não estão excessivamente concentradas em uma única região.

Uma estratégia eficiente baseada na diversidade da HM utiliza a taxa de diversidade da população para realizar o controle dinâmico do processo de improvisação do algoritmo. A taxa de diversificação é dada pela equação (9).

$$Divers = \left(1 - \frac{Ceq}{HMS}\right) \times 100 \quad (9)$$

Sendo:

Divers: Taxa de diversificação (percentual);

Ceq: Número máximo de configurações iguais;

HMS: Tamanho da memória harmônica.

Na equação (9) verifica-se que a estratégia se baseia em determinar o percentual máximo de indivíduos diferentes em relação ao tamanho da memória harmônica do algoritmo.

Com esse parâmetro, foi possível testar diversos métodos de variação dinâmica do HMCR, como por exemplo, linear, exponencial, senoidal, entre outros. A equação do HMCR dinâmico, que melhor performou dentre as demais, é a que segue:

$$HMCR = Divers \times e^{(Divers - 1)} \quad (10)$$

4.3.1.2. Improvisação acelerada

No ABH original é realizada apenas uma improvisação para cada iteração do programa, o que resulta em um processo lento de convergência. Sendo assim, foi proposto que para cada iteração fossem improvisadas HMS harmonias, acelerando assim o processo de convergência. Fazendo uma analogia com o processo de improvisação musical, é como se aumentássemos o repertório do músico, permitindo-lhe fazer mais improvisações.

Além disso, a regra de atualização da memória harmônica foi reformulada para que apenas os melhores arranjos harmônicos estivessem na memória. A nova regra proposta compara o melhor valor do vetor de improvisações com o pior valor da memória harmônica; se aquele for menor, a substituição é feita. Em seguida, são comparados o segundo melhor valor do vetor de improvisações com o segundo pior valor da memória harmônica, e assim sucessivamente.

Por fim, também foi alterado a regra de improvisação pois de caso $U(0,1) \leq 0,5$ então x^{new} sempre será 1, limitando a “criatividade do músico” na geração aleatória de uma solução.

Então foi proposto modificar esta parte do algoritmo como segue: se $U(0,1) \leq \frac{1+HMCR}{2}$ então $x^{new} = 0$, senão $x^{new} = 1$. Deste modo, pode-se ter a certeza de que quando o algoritmo entrar nesta condicional a harmonia candidata x^{new} terá a mesma probabilidade de ser 0 ou 1.

4.3.1.3. Diagrama de blocos atualizado

Após estas alterações no ABH, faz-se necessário atualizar o diagrama de blocos para melhor compreensão da solução do problema. Na Figura 7 é apresentado o diagrama de blocos atualizado do ABH implementado para resolver o problema de alocação de indicadores de faltas no sistema teste da Figura 19.

4.3.2. Mudanças nos cálculos de CENS e CINV

Para o sistema teste de 34 barras, fez-se necessário algumas alterações nos cálculso de CENS e CINV para que possa comparar os resultados do ABH com o AGA (CRUZ, 2016). A seguir, serão apresentadas cada uma delas.

4.3.2.1. Alteração no cálculo do CENS

O cálculo do Custo de Energia Não Suprida em suma não foi alterado, apenas o termo do tempo (t_j^m) será calculado de uma forma diferente. Da forma que, o tempo de restabelecimento do serviço é a soma de três tempos diferentes e são relacionados na seguinte expressão:

$$t_j^m = t_j^{local} + t_j^{reparo} + t_j^{desloca} \quad (11)$$


Sendo:

t_j^{local} : O tempo de localização da falta, que varia se o ramo possui IF alocado ou não.

t_j^{reparo} : O tempo médio de reparo do defeito gasto pelas equipes de manutenção.

$t_j^{desloca}$: O tempo que as equipes de manutenção demoram em se deslocar até o local da falta.

Figura 7 – Diagrama de blocos



Fonte: Elaborado pelo autor.

No terceiro termo ($t_j^{desloca}$), é necessário calcular, para cada barra, o comprimento total da linha desde a subestação (considerando que o ponto de partida das equipes é a subestação) até a barra j , além de conhecer a velocidade média de deslocamento das equipes de manutenção. A expressão utilizada para o cálculo desse tempo é:

$$t_j^{desloca} = \frac{l_{SE-j}}{V_{equipes}} \quad (12)$$

Sendo:

l_{SE-j} : a distância total desde a subestação até a barra j .

$V_{equipes}$: velocidade média das equipes de manutenção.

4.3.2.2. Alteração no cálculo do CINV

Para o cálculo do CINV, foram consideradas a quantidade de fases de cada ramo do sistema da Figura 23. Para ramos que são trifásicos necessitam de um conjunto de 3 sensores, que totalizam R\$3628,80. Por outro lado para ramos monofásicos, é necessário apenas 1 sensor, que custa R\$1209,60.


5. Resultados

Neste capítulo são apresentados os resultados do trabalho. Na seção 5.1 são apresentados os estudos base do sistema teste de 5 barras. Na seção 5.2 são apresentados os resultados do sistema teste de 19 e as propostas de melhoria do algoritmo. Nesta etapa os resultados do ABH são comparados com o AI e o AGA. Na seção 5.3 são apresentados os resultados do sistema teste de 34 barras, as alterações realizadas e a Fronteira de Pareto aproximada criada a partir da variação dos pesos da função objetivo.

5.1. Resultados para o sistema de 5 barras

Nesta seção são apresentados os resultados obtidos a partir do estudo realizado para o sistema teste da Figura 8, de modo a calcular a função objetivo que descreve o problema para todas possíveis alocações de IFs. Deve-se notar que o problema de alocação, considerando o sistema analisado, possui um total de $2^5 = 32$ soluções possíveis no espaço de busca do problema. Desta maneira, é possível compreender como o problema de otimização se comporta em função das seções em que os IFs são alocados. Nesta seção também são apresentados os resultados obtidos empregando o ABH implementado.

Figura 8 – SDEE teste de 5 barras utilizado



Fonte: Elaborado pelo autor.

5.1.1. Análise de todas as possíveis alocações para o sistema teste de 5 barras

Para o cálculo de (1) considera-se os seguintes dados:

- $C_e = \text{R\$}0,51041/\text{kWh}$;
- $CFI = \text{R\$}800,00$;
- $CIFI = \text{R\$}170,00$;
- $IDFI = 8$ anos;

- $CMFI = R\$80,00/\text{ano}$;
- $t_{ss} = 45\text{min}/\text{km} = 0,75\text{horas}/\text{km}$ (tempo médio sem sensor);
- $t_{cs} = 5\text{ min}/\text{km} = 0,0833\text{horas}/\text{km}$ (tempo médio com sensor).

Os valores das potências de cada barra como sendo:

- $L1 = 100\text{kW}$;
- $L2 = 100\text{kW}$;
- $L3 = 200\text{kW}$;
- $L4 = 300\text{kW}$;
- $L5 = 300\text{kW}$.

Considerou-se também que:

- Taxa de falha média $\bar{\lambda} = 0,149$ falhas/ano.km;
- Comprimento de cada trecho $C_j = 10\text{km}$.


Portanto, através da equação (3), calculou-se a taxa de falha de cada seção:

- $\lambda_1 = \lambda_2 = \lambda_3 = \lambda_4 = \lambda_5 = 1,49$ falhas/ano.

De modo a agilizar o processo de cálculos da função objetivo, elaborou-se uma planilha no Excel considerando os dados. Todavia, para melhor entendimento dos cálculos será utilizado uma das 32 possibilidades como exemplo.


Na Figura 9 é apresentada a configuração de alocação de 4 sensores IF. A codificação do sistema para esta alocação é apresentada na Figura 10.

Figura 9 – SDEE teste exemplo



Fonte: Elaborado pelo autor.

Figura 10 – Codificação da alocação da Figura 9 – SDEE teste exemplo



Fonte: Elaborado pelo autor.

O cálculo do *CENS* é realizado empregando a equação (7), levando-se em consideração os dados apresentados nesta seção. Para isto, calculam-se os tempos para localização da falta nas seções através das equações (4) e (5):

- $t_1^1 = \frac{0,08333h}{km} \times 10km = 0,8333h$
- $t_2^1 = \frac{0,08333h}{km} \times 20km = 1,6666h$
- $t_3^0 = \frac{0,75h}{km} \times 30km = 22,5000h$
- $t_4^1 = \frac{0,08333h}{km} \times 40km = 3,3333h$
- $t_5^1 = \frac{0,08333h}{km} \times 50km = 4,1667h$

De acordo com a Figura 9 obtêm-se os seguintes dados:

- $nz = 4$
- $NL1 = \{1\}$
- $NL2 = \{2,3\}$
- $NL3 = \{4\}$
- $NL4 = \{5\}$
- $NS1 = \{1\}$

- $NS2 = \{2,3\}$
- $NS3 = \{4\}$
- $NS4 = \{5\}$

Tem-se então pela equação (7) que:

$$CENS = Ce \times [L1 \times \lambda_1 \times t_1^1 + (L2 + L3) \times (\lambda_2 \times t_2^1 + \lambda_3 \times t_3^0) + L4 \times \lambda_4 \times t_4^1 + L5 \times \lambda_5 \times t_5^1]$$

$$CENS = 0,51041 \times [100 \times 1,49 \times 0,833 + (100 + 200) \times (1,49 \times 1,6667 + 1,49 \times 22,5) + 300 \times 1,49 \times 3,3333 + 300 \times 1,49 \times 4,1667]$$

$$CENS = R\$7288,288/ano$$

Calcula-se também o CINV pela equação (6):

$$CINV = N \times \left(\frac{CFI + CIFI}{IDFI} + CMFI \right) = 4 \times \left(\frac{800 + 1710}{8} + 80 \right) = R\$805/ano$$

Assim, com estes valores, pode-se calcular a função objetivo dada por (1) levando em consideração diferentes pesos para cada termo da equação (w_1 e w_2)

- $w_1 = 0,2$ e $w_2 = 0,8$

$$FO = 0,2 \times 7288,288 + 0,8 \times 805 = R\$2101,646/ano$$

- $w_1 = 0,5$ e $w_2 = 0,5$

$$FO = 0,5 \times 7288,288 + 0,5 \times 805 = R\$4046,614/ano$$

- $w_1 = 0,8$ e $w_2 = 0,2$

$$FO = 0,8 \times 7288,288 + 0,2 \times 805 = R\$5991,583/ano$$

Desta maneira, com os valores do *CENS* e do *CINV* calculados para cada um dos 32 casos distintos de alocações de sensores IF no sistema teste, é possível calcular a função objetivo (1) para os três pesos considerados acima, obtendo assim os resultados apresentados na Tabela 1.

Tabela 1 – Valores da função objetivo para todas as 32 soluções do sistema teste da Figura 8

Solução	Codificação da solução					CENS (R\$/ano)	CINV (R\$/ano)	Função Objetivo (R\$/ano)		
								w1 = 0,2	w1 = 0,5	w1 = 0,8
								w2 = 0,8	w2 = 0,5	w2 = 0,2
1	0	0	0	0	0	R\$ 85.557,48	R\$ 0,00	R\$ 17.111,50	R\$ 42.778,74	R\$ 68.445,98
2	1	0	0	0	0	R\$ 80.487,40	R\$ 201,25	R\$ 16.258,48	R\$ 40.344,33	R\$ 64.430,17
3	0	1	0	0	0	R\$ 63.312,53	R\$ 201,25	R\$ 12.823,51	R\$ 31.756,89	R\$ 50.690,28
4	1	1	0	0	0	R\$ 62.805,52	R\$ 402,50	R\$ 12.883,10	R\$ 31.604,01	R\$ 50.324,92
5	0	0	1	0	0	R\$ 46.010,91	R\$ 201,25	R\$ 9.363,18	R\$ 23.106,08	R\$ 36.848,98
6	1	0	1	0	0	R\$ 44.996,89	R\$ 402,50	R\$ 9.321,38	R\$ 22.699,70	R\$ 36.078,02
7	0	1	1	0	0	R\$ 43.285,74	R\$ 402,50	R\$ 8.979,15	R\$ 21.844,12	R\$ 34.709,10
8	1	1	1	0	0	R\$ 42.778,74	R\$ 603,75	R\$ 9.038,75	R\$ 21.691,24	R\$ 34.343,74
9	0	0	0	1	0	R\$ 32.321,71	R\$ 201,25	R\$ 6.625,34	R\$ 16.261,48	R\$ 25.897,62
10	1	0	0	1	0	R\$ 30.293,68	R\$ 402,50	R\$ 6.380,74	R\$ 15.348,09	R\$ 24.315,45
11	0	1	0	1	0	R\$ 24.716,60	R\$ 402,50	R\$ 5.265,32	R\$ 12.559,55	R\$ 19.853,78
12	1	1	0	1	0	R\$ 24.209,60	R\$ 603,75	R\$ 5.324,92	R\$ 12.406,67	R\$ 19.488,43
13	0	0	1	1	0	R\$ 22.435,07	R\$ 402,50	R\$ 4.809,01	R\$ 11.418,79	R\$ 18.028,56
14	1	0	1	1	0	R\$ 21.421,06	R\$ 603,75	R\$ 4.767,21	R\$ 11.012,40	R\$ 17.257,59
15	0	1	1	1	0	R\$ 19.709,91	R\$ 603,75	R\$ 4.424,98	R\$ 10.156,83	R\$ 15.888,68
16	1	1	1	1	0	R\$ 19.202,90	R\$ 805,00	R\$ 4.484,58	R\$ 10.003,95	R\$ 15.523,32
17	0	0	0	0	1	R\$ 40.877,46	R\$ 201,25	R\$ 8.336,49	R\$ 20.539,36	R\$ 32.742,22
18	1	0	0	0	1	R\$ 37.328,41	R\$ 402,50	R\$ 7.787,68	R\$ 18.865,45	R\$ 29.943,23
19	0	1	0	0	1	R\$ 26.237,63	R\$ 402,50	R\$ 5.569,53	R\$ 13.320,06	R\$ 21.070,60
20	1	1	0	0	1	R\$ 25.730,62	R\$ 603,75	R\$ 5.629,12	R\$ 13.167,18	R\$ 20.705,24
21	0	0	1	0	1	R\$ 16.731,24	R\$ 402,50	R\$ 3.668,25	R\$ 8.566,87	R\$ 13.465,49
22	1	0	1	0	1	R\$ 15.717,22	R\$ 603,75	R\$ 3.626,44	R\$ 8.160,49	R\$ 12.694,53
23	0	1	1	0	1	R\$ 14.006,07	R\$ 603,75	R\$ 3.284,21	R\$ 7.304,91	R\$ 11.325,61
24	1	1	1	0	1	R\$ 13.499,07	R\$ 805,00	R\$ 3.343,81	R\$ 7.152,03	R\$ 10.960,25
25	0	0	0	1	1	R\$ 15.400,35	R\$ 402,50	R\$ 3.402,07	R\$ 7.901,42	R\$ 12.400,78
26	1	0	0	1	1	R\$ 13.372,32	R\$ 603,75	R\$ 3.157,46	R\$ 6.988,03	R\$ 10.818,60
27	0	1	0	1	1	R\$ 7.795,24	R\$ 603,75	R\$ 2.042,05	R\$ 4.199,49	R\$ 6.356,94
28	1	1	0	1	1	R\$ 7.288,23	R\$ 805,00	R\$ 2.101,65	R\$ 4.046,61	R\$ 5.991,58
29	0	0	1	1	1	R\$ 5.513,70	R\$ 603,75	R\$ 1.585,74	R\$ 3.058,73	R\$ 4.531,71
30	1	0	1	1	1	R\$ 4.499,69	R\$ 805,00	R\$ 1.543,94	R\$ 2.652,34	R\$ 3.760,75
31	0	1	1	1	1	R\$ 2.788,54	R\$ 805,00	R\$ 1.201,71	R\$ 1.796,77	R\$ 2.391,83
32	1	1	1	1	1	R\$ 2.281,53	R\$ 1.006,25	R\$ 1.261,31	R\$ 1.643,89	R\$ 2.026,48

Fonte: Elaborado pelo autor.

A partir da Tabela 1, nota-se que as soluções 31 e 32 apresentam os menores valores de CENS, o que resulta em um menor tempo médio de reparo gasto pelas equipes de manutenção. Todavia, essas soluções possuem os dois maiores valores de CINV devido ao maior número de sensores indicadores de falta alocados na rede. No entanto, nesse caso, o CINV possui pouca influência no custo operacional da rede em comparação com o CENS quando poucos sensores são alocados.

Quando se dá maior importância ao CINV do que ao CENS ($w_1 = 0,2$ e $w_2 = 0,8$), observa-se que a solução 31 apresenta o menor valor da função objetivo, onde $FO = R\$1201,708/\text{ano}$, justificado pela alocação dos sensores nas barras com potência mais elevada, o que diminui o CENS. Outro fator é que o número de sensores utilizados é de apenas 4, tornando o CINV menor em comparação com a solução 32.

Por outro lado, quando se dá maior relevância ao *CENS* do que ao *CINV* ($w_1 = 0,8$ e $w_2 = 0,2$), ou quando se considera os pesos iguais ($w_1 = 0,5$ e $w_2 = 0,5$), nota-se que a melhor opção apresentada foi a solução 32, na qual os sensores foram alocados em todos os ramos da rede, com $FO = R\$2026,476/\text{ano}$ e $FO = R\$1643,891/\text{ano}$, respectivamente.

Cabe a concessionária a escolha da solução mais conveniente, considerando maior ênfase na redução do *CENS* ou no menor investimento em tecnologia de monitoramento da rede de acordo com suas preferências e regras.

Ao analisar as soluções 16, 24, 28 e 30, observa-se que foram alocados 4 sensores de modos diferentes. Nas soluções 16 e 24, o *CENS* foi relativamente elevado em comparação com as outras duas porque um dos sensores não está localizado na barra de maior potência. Esse aumento do *CENS* também se deve ao fato de que se ocorrer uma falta no ramo sem sensor, o tempo para encontrar a falta e o tempo de reparo médio são maiores devido à localização da falta estar mais distante da subestação. A solução 28 apresenta um *CENS* maior em relação à solução 30, isso ocorre pois na solução 28 o ramo que está sem sensor está mais afastado da subestação em relação ao da solução 30, levando a um aumento nos tempos para encontrar a falta e para realizar o reparo, o que em consequência aumenta o *CENS*.

Quando não são alocados sensores, a função objetivo tem um valor máximo de *CENS* e um valor mínimo de *CINV*, o que gera inviabilidade desta solução para a concessionária devido ao elevadíssimo *CENS* comparado a todas as outras soluções.

5.1.2. Análise das soluções variando o comprimento de cada seção

Para a realização dos cálculos manteve-se o *tss* igual a 45min/km (0,75 horas/km) e o *tcs* igual a 5min/km (0,08333horas/km).

Os valores das potências de cada barra foram mantidos de acordo com o item 5.1.:

$$L1 = 100\text{kW} \quad L2 = 100\text{kW} \quad L3 = 200\text{kW} \quad L4 = 300\text{kW} \quad L5 = 300\text{kW}$$

Considerou-se a $\bar{\lambda}$ igual a 0,149 falhas/ano.km e cada C_j como segue

$$C1 = 10\text{km} \quad C2 = 15\text{km} \quad C3 = 20\text{km} \quad C4 = 25\text{km} \quad C5 = 30\text{km}$$

Portanto através da equação (3) obteve-se a taxa de falha de cada seção:

- $\lambda_1 = 1,49 \text{ falhas/ano};$
- $\lambda_2 = 2,23 \text{ falhas/ano};$

- $\lambda_3 = 2,98 \text{ falhas/ano};$
- $\lambda_4 = 3,72 \text{ falhas/ano};$
- $\lambda_5 = 4,47 \text{ falhas/ano}.$

Mantiveram-se os seguintes dados:

- $Ce = R\$0,51041/\text{kWh};$
- $CFI = R\$800,00;$
- $CIFI = R\$170,00;$
- $IDFI = 8 \text{ anos};$
- $CMFI = R\$80,00/\text{ano};$

O processo de cálculo da função objetivo foi automatizada no Excel, contudo, são apresentados os cálculos do sistema ilustrado pela Figura 9 levando em consideração os dados anteriormente definidos. Para isto, calculam-se os tempos para localização da falta nas seções através das equações (4) e (5):

- $t_1^1 = \frac{0,08333h}{km} \times 10km = 0,8333h$
- $t_2^1 = \frac{0,08333h}{km} \times 25km = 2,0833h$
- $t_3^0 = \frac{0,75h}{km} \times 45km = 33,75h$
- $t_4^1 = \frac{0,08333h}{km} \times 70km = 5,8333h$
- $t_5^1 = \frac{0,08333h}{km} \times 100km = 8,3333h$

De acordo com a Figura 9 obtêm-se os seguintes dados:

- | | | |
|-------------------|-----------------|-------------------|
| • $nz = 4$ | • $NL1 = \{1\}$ | • $NL2 = \{2,3\}$ |
| • $NL3 = \{4\}$ | • $NL4 = \{5\}$ | • $NS1 = \{1\}$ |
| • $NS2 = \{2,3\}$ | • $NS3 = \{4\}$ | • $NS4 = \{5\}$ |

Tem-se então pela equação (7) que:

$$CENS = Ce \times [L1 \times \lambda_1 \times t_1^1 + (L2 + L3) \times (\lambda_2 \times t_2^1 + \lambda_3 \times t_3^0) + L4 \times \lambda_4 \times t_4^1 + L5 \times \lambda_5 \times t_5^1]$$

$$CENS = 0,51041 \times [100 \times 1,49 \times 0,833 + (100 + 200) \times (1,49 \times 2,083 + 1,49 \times 33,75) + 300 \times 1,49 \times 5,8333 + 300 \times 1,49 \times 8,3333]$$

$$CENS = R\$25207,73/ano$$

Calcula-se também o *CINV* pela equação (6):

$$CINV = N \times \left(\frac{CFI + CIFI}{IDFI} + CMFI \right) = 4 \times \left(\frac{800 + 1710}{8} + 80 \right) = R\$805/ano$$

Assim, com estes valores, pode-se calcular a função objetivo dada por (1) levando em consideração diferentes pesos para cada termo da equação (w_1 e w_2) como segue:

- $w_1 = 0,2$ e $w_2 = 0,8$

$$FO = 0,2 \times 25207,73 + 0,8 \times 805 = R\$5685,55/ano$$

- $w_1 = 0,5$ e $w_2 = 0,5$

$$FO = 0,5 \times 25207,73 + 0,5 \times 805 = R\$13006,36/ano$$

- $w_1 = 0,8$ e $w_2 = 0,2$

$$FO = 0,8 \times 25207,73 + 0,2 \times 805 = R\$20327,18/ano$$

Desta maneira, com os valores do *CENS* e do *CINV* calculados para cada um dos 32 casos distintos de alocações de sensores IF no sistema teste, foi possível calcular a função objetivo, para os três pesos considerados acima, obtendo assim os resultados apresentados na Tabela 2.

Tabela 2 – Valores da função objetivo para todas as 32 soluções variando o comprimento das seções

Solução	Codificação da solução					CENS (R\$/ano)	CINV (R\$/ano)	Função Objetivo (R\$/ano)		
								w1 = 0,2	w1 = 0,5	w1 = 0,8
								w2 = 0,8	w2 = 0,5	w2 = 0,2
1	0	0	0	0	0	R\$ 349.359,70	R\$ 0,00	R\$ 69.871,94	R\$174.679,85	R\$279.487,76
2	1	0	0	0	0	R\$ 344.289,62	R\$ 201,25	R\$ 69.018,92	R\$172.245,44	R\$275.471,95
3	0	1	0	0	0	R\$ 292.749,16	R\$ 201,25	R\$ 58.710,83	R\$146.475,21	R\$234.239,58
4	1	1	0	0	0	R\$ 292.242,15	R\$ 402,50	R\$ 58.770,43	R\$146.322,33	R\$233.874,22
5	0	0	1	0	0	R\$ 226.727,29	R\$ 201,25	R\$ 45.506,46	R\$113.464,27	R\$181.422,08
6	1	0	1	0	0	R\$ 225.713,28	R\$ 402,50	R\$ 45.464,66	R\$113.057,89	R\$180.651,12
7	0	1	1	0	0	R\$ 222.116,70	R\$ 402,50	R\$ 44.745,34	R\$111.259,60	R\$177.773,86
8	1	1	1	0	0	R\$ 221.609,69	R\$ 603,75	R\$ 44.804,94	R\$111.106,72	R\$177.408,50
9	0	0	0	1	0	R\$ 140.694,49	R\$ 201,25	R\$ 28.299,90	R\$ 70.447,87	R\$112.595,84
10	1	0	0	1	0	R\$ 138.666,46	R\$ 402,50	R\$ 28.055,29	R\$ 69.534,48	R\$111.013,67
11	0	1	0	1	0	R\$ 126.007,12	R\$ 402,50	R\$ 25.523,42	R\$ 63.204,81	R\$100.886,20
12	1	1	0	1	0	R\$ 125.500,11	R\$ 603,75	R\$ 25.583,02	R\$ 63.051,93	R\$100.520,84
13	0	0	1	1	0	R\$ 115.882,82	R\$ 402,50	R\$ 23.498,56	R\$ 58.142,66	R\$ 92.786,76
14	1	0	1	1	0	R\$ 114.868,80	R\$ 603,75	R\$ 23.456,76	R\$ 57.736,28	R\$ 92.015,79
15	0	1	1	1	0	R\$ 111.272,22	R\$ 603,75	R\$ 22.737,44	R\$ 55.937,99	R\$ 89.138,53
16	1	1	1	1	0	R\$ 110.765,21	R\$ 805,00	R\$ 22.797,04	R\$ 55.785,11	R\$ 88.773,17
17	0	0	0	0	1	R\$ 130.475,13	R\$ 201,25	R\$ 26.256,03	R\$ 65.338,19	R\$104.420,35
18	1	0	0	0	1	R\$ 126.926,08	R\$ 402,50	R\$ 25.707,22	R\$ 63.664,29	R\$101.621,36
19	0	1	0	0	1	R\$ 98.391,07	R\$ 402,50	R\$ 20.000,21	R\$ 49.396,79	R\$ 78.793,36
20	1	1	0	0	1	R\$ 97.884,06	R\$ 603,75	R\$ 20.059,81	R\$ 49.243,91	R\$ 78.428,00
21	0	0	1	0	1	R\$ 63.882,88	R\$ 402,50	R\$ 13.098,58	R\$ 32.142,69	R\$ 51.186,80
22	1	0	1	0	1	R\$ 62.868,87	R\$ 603,75	R\$ 13.056,77	R\$ 31.736,31	R\$ 50.415,85
23	0	1	1	0	1	R\$ 59.272,28	R\$ 603,75	R\$ 12.337,46	R\$ 29.938,02	R\$ 47.538,57
24	1	1	1	0	1	R\$ 58.765,28	R\$ 805,00	R\$ 12.397,06	R\$ 29.785,14	R\$ 47.173,22
25	0	0	0	1	1	R\$ 40.402,10	R\$ 402,50	R\$ 8.402,42	R\$ 20.402,30	R\$ 32.402,18
26	1	0	0	1	1	R\$ 38.374,07	R\$ 603,75	R\$ 8.157,81	R\$ 19.488,91	R\$ 30.820,01
27	0	1	0	1	1	R\$ 25.714,74	R\$ 603,75	R\$ 5.625,95	R\$ 13.159,25	R\$ 20.692,54
28	1	1	0	1	1	R\$ 25.207,73	R\$ 805,00	R\$ 5.685,55	R\$ 13.006,37	R\$ 20.327,18
29	0	0	1	1	1	R\$ 15.590,43	R\$ 603,75	R\$ 3.601,09	R\$ 8.097,09	R\$ 12.593,09
30	1	0	1	1	1	R\$ 14.576,42	R\$ 805,00	R\$ 3.559,28	R\$ 7.690,71	R\$ 11.822,14
31	0	1	1	1	1	R\$ 10.979,83	R\$ 805,00	R\$ 2.839,97	R\$ 5.892,42	R\$ 8.944,86
32	1	1	1	1	1	R\$ 10.472,83	R\$ 1.006,25	R\$ 2.899,57	R\$ 5.739,54	R\$ 8.579,51

Fonte: Elaborado pelo autor.

Aumentando o comprimento do trecho de cada seção foi observado que o *CENS* também aumentou, o que implica que quanto maiores forem os trechos e a rede, maior será o *CENS*. Nota-se também que ao aumentar-se o tamanho das seções, as soluções com melhor desempenho permaneceram as mesmas (soluções 31 e 32), o que implica que o tamanho da seção torna-se pouco relevante na determinação dos pontos de alocação de sensores IF na rede. Notou-se também que neste caso, a taxa de falhas das seções difere, o que implica que quanto maior for a taxa de falha da seção maior será o *CENS* da rede no caso de não alocação de sensores IF. Ressalta-se que se a rede apresentasse outra configuração seria necessário novamente o cálculo das soluções o que provavelmente resultaria em conclusões distintas.

Dessa forma, do item 5.1 pode-se fazer analogia de que são redes urbanas em que possui elevado número de consumidores e no item 5.1.1 pode-se fazer analogia de que são redes rurais devido a suas grandes extensões. Ambas as analogias são problemas críticos pois acarretam em um *CENS* mais elevado. A primeira eleva o *CENS* devido a maior concentração de cargas e a segunda devido ao aumento das taxas de falhas na rede, portanto necessitam de instalações de sensores.

5.1.3. Resultados empregando o ABH proposto

Nesta seção são apresentados os resultados obtidos a partir da implementação computacional do modelo matemático de alocação otimizada de sensores IF e da técnica de solução proposta baseada no ABH. O método proposto foi implementado em linguagem C++ na plataforma de programação Visual Studio 2019 e o computador utilizado nas simulações é um Intel(R) Core(TM) i5-7400 CPU @ 3.00 GHz e 16,0 GB de memória RAM instalada.

Os métodos foram executados em máquinas distintas, portanto, as diferenças nos tempos de execução podem ser comparadas, porém não devem ser consideradas como um critério definitivo para determinar qual método é superior nesse aspecto.

São realizados diversos testes considerando três valores constantes do parâmetro *HMCR* do ABH, sendo: 0,5; 0,7; e 0,9.

A ideia dos testes é verificar a sensibilidade do parâmetro *HMCR* no ABH desenvolvido visto que este é o principal parâmetro no processo de improvisação.

Os dados de entrada para as simulações são os apresentados na seção 5.1. enquanto os demais parâmetros do algoritmo são calibrados para obter a melhor solução conforme seguem: *HMS*=5 e *NI*=20.


5.1.3.1. Análise da sensibilidade do ABH para *HMCR* = 0,5

Para *HMCR* = 0,5 são obtidas 10 soluções, que para cada improvisação tem-se os valores das funções objetivo calculadas do ABH (função incumbente, que é a melhor solução para determinada iteração) e valor médio da Memória Harmônica (função média), conforme apresentado nas Figuras 11 e 12, respectivamente.

Com a função incumbente, é possível observar o comportamento da função objetivo ao longo das iterações, pelo fato de que esta função apresenta o vetor com menor valor da FO da memória harmônica, o que indica a velocidade de convergência para a melhor solução.

Enquanto a função média apresenta o valor médio da FO de todas as harmonias da HM, o que indica a evolução do conjunto de vetores improvisados para a melhoria do resultado final.

Figura 11 – Função incumbente para $HMCR = 0,5$ com destaque para as primeiras iterações




Fonte: Elaborado pelo autor.

No gráfico da Figura 11 é possível verificar que para um valor de $HMCR=0,5$ a convergência nas primeiras iterações é bem rápida, muitas vezes convergindo para a solução otimizada ($FO=R\$1201,708/\text{ano}$). Todavia a solução fica presa em um ótimo local caso demore muito para alcançar a solução otimizada, como por exemplo a solução em marrom claro.

Vale ressaltar que as iterações são números discretos, logo a interligação entre elas é somente a tendência da função.

No gráfico da Figura 12 pode se observar que a evolução do valor médio também é mais rápido, possui maior decaimento, nas primeiras iterações e posteriormente nota-se que essa evolução estagna em um ótimo local.

Figura 12 – Gráfico da função média para $HMCR = 0,5$



Fonte: Elaborado pelo autor.

5.1.3.2. Análise da sensibilidade do ABH para $HMCR = 0,7$

Para $HMCR = 0,7$ são obtidas 10 soluções, que para cada improvisação tem-se os valores das funções objetivo calculadas do ABH (função incumbente) e valor médio da Memória Harmônica (função média), conforme apresentado nas Figuras 13 e 14, respectivamente.

No gráfico da Figura 13 é possível verificar que para um valor de $HMCR=0,7$ a convergência nas primeiras iterações é rápida, e em todas as vezes o ABH obteve a solução otimizada do problema ($FO = R\$1201,708/\text{ano}$) para o sistema teste de 5 barras. Todavia, nota-se que para a solução em amarelo, o valor da função incumbente ficou preso em uma solução não adequada (ótimo local) e foram necessárias várias iterações para que o ABH pudesse obter uma solução melhor.

No gráfico da Figura 14 pode-se observar que a evolução do valor médio é menos agressiva em relação às simulações com $HMCR = 0,5$. Todavia ainda é possível notar que há uma evolução rápida do ABH para a melhor solução nas primeiras iterações.


5.1.3.3. Análise da sensibilidade do ABH para $HMCR = 0,9$

Para $HMCR = 0,9$ são obtidas 10 soluções, que para cada improvisação tem-se os valores das funções objetivo calculadas do ABH (função incumbente) e valor médio da Memória Harmônica (função média), conforme apresentado nas Figuras 15 e 16, respectivamente.


No gráfico da Figura 15 é possível verificar que a convergência nas primeiras iterações leva mais iterações do que para os outros valores de $HMCR$. Todavia, nota-se que a convergência ocorre de maneira mais abrupta após algumas iterações.

No gráfico da Figura 16 pode-se observar que a evolução do valor médio é a mais lenta dentre os três valores de $HMCR$ analisados. Por outro lado, é a que possui maior evolução para as últimas iterações.

Figura 15 – Gráfico da função incumbente para $HMCR = 0,9$



Fonte: Elaborado pelo autor.

Figura 16 – Gráfico da função média para $HMCR = 0,9$ 


Fonte: Elaborado pelo autor.

5.1.4. Discussão sobre a análise de sensibilidade do ABH

De modo a melhorar a comparação para os diferentes valores do parâmetro $HMCR$, traçou-se os gráficos das Figuras 17 e 18 que apresentam as funções incumbente e média, respectivamente, utilizando a média das 10 soluções apresentadas nas seções anteriores para cada valor de $HMCR$.


Ao analisar o gráfico da Figura 17, nota-se que para $HMCR=0,5$ e $HMCR=0,7$, a convergência é mais rápida em comparação com o gráfico para $HMCR=0,9$ nas primeiras iterações. Isso também é visível ao observar o gráfico da Figura 18, cuja evolução do valor médio da memória harmônica é mais rápida para os mesmos valores de $HMCR$. Todavia, observando as últimas iterações, nota-se que o desempenho do ABH para $HMCR=0,9$ é superior aos das outras duas, convergindo rapidamente para a solução otimizada.

Figura 17 – Função incumbente para os três valores de *HMCR* analisados



Fonte: Elaborado pelo autor.

Figura 18 – Função média para os três valores de *HMCR* analisados




Fonte: Elaborado pelo autor.

Portanto, pode-se dizer que um valor maior de HMCR favorece a busca local, visto que a tendência é que a improvisação altere a solução em torno da melhor encontrada até o momento pelo algoritmo. Por outro lado, para melhorar a habilidade de exploração, o valor de HMCR deve ser pequeno, para que o ABH possa realizar a busca da melhor solução em todo o espaço de variáveis do problema. Em outras palavras, um HMCR pequeno tende, durante o processo de improvisação, a fazer com que o ABH altere mais agressivamente as variáveis do problema, o que favorece a exploração de outras regiões do espaço de soluções do problema.

5.2. Resultados para o sistema de 19 barras

Nesta seção serão apresentados os testes experimentais realizados utilizando o método implementado e o sistema teste da Figura 19.

Figura 19 – Sistema teste de 19 barras



Fonte: Adaptado de (HO; LEE; LIN, 2011).

5.2.1. Considerações sobre os dados de entrada

O sistema teste possui 19 barras de carga e 20 seções/ramos. A Figura 19 ilustra uma possível solução para alocação otimizada de IFs, onde foram alocados 6 sensores de falta.

Conforme a Tabela III do artigo (HO; LEE; LIN, 2011), para a realização das simulações considera-se o t_{ss} igual a 20min/km (0,3333horas/km) e o t_{cs} igual a 5min/km (0,0833horas/km). O tempo utilizado para definir os tempos de reparo de cada ramo do sistema considera-se a distância do ramo a subestação (local de partida das equipes de manutenção). Quanto maior a distância da seção em relação à subestação, maior será o tempo de reparo desta seção.

O alimentador possui $\bar{\lambda}$ por ramo igual a 0,149 falhas/ano.km. A partir desses tempos podem-se definir os tempos totais para localização da falta para cada seção/ramo j com sensor alocado e sem sensor alocado. Considerou-se cada C_j igual a 1km, portanto através da equação (3) obteve-se a taxa de falha de cada seção:

- $\lambda_1 = \lambda_2 = \lambda_3 = \dots = \lambda_{20} = 0,149 \text{ falhas/ano}$

E o valor de cada carga pode ser obtido da Tabela IV do artigo (HO; LEE; LIN, 2011) como sendo:

- L1 = 70kW • L2 = 143kW • L3 = 168kW • L4 = 113kW
- L5 = 100kW • L6 = 265kW • L7 = 251kW • L8 = 331kW
- L9 = 188kW • L10=1205kW • L11 = 210kW • L12 = 989kW
- L13 = 43kW • L14 = 96kW • L15 = 129kW • L16 = 44kW
- L17 = 80kW • L18 = 75kW • L19 = 115kW

Consideram-se ainda os seguintes dados de entrada:

- $C_e = R\$0,51041/\text{kWh}$;
- $CFI = R\$800,00$;
- $CIFI = R\$170,00$;
- $IDFI = 8$ anos;
- $CMFI = R\$80,00/\text{ano}$.

5.2.2. Simulações

A partir dos conhecimentos adquiridos em etapas anteriores do trabalho resolveu-se computacionalmente o problema de alocação otimizada de sensores IF empregando a técnica de solução baseada no ABH ilustrada no diagrama de blocos da Figura 7. O método foi implementado utilizando o software Visual Studio 2019 em que a linguagem de programação empregada é o C++ e o computador utilizado nas simulações é um Intel(R) Core(TM) i5-7400 CPU @ 3.00 GHz e 16,0 GB de memória RAM instalada.

Os métodos foram executados em máquinas distintas, portanto, as diferenças nos tempos de execução podem ser comparadas, porém não devem ser consideradas como um critério definitivo para determinar qual método é superior nesse aspecto.

São realizados diversos testes considerando três pares de pesos diferentes (w_1 e w_2) da função objetivo dada na equação (1), sendo:

- $w_1 = 0,2$ e $w_2 = 0,8$;
- $w_1 = 0,5$ e $w_2 = 0,5$;
- $w_1 = 0,8$ e $w_2 = 0,2$.

A ideia dos testes é verificar a dependência da qualidade das soluções em relação a maior importância para minimização do custo da energia não suprida (*CENS*) quando se escolhe $w_1 > w_2$ ou a minimização do custo de investimento em sensores IFs (*CINV*) quando se escolhe $w_2 > w_1$, ou quando se consideram ambos os termos de mesma prioridade $w_1 = w_2$.

Além disso, outra análise importante é a comparação dos resultados obtidos com o ABH, comparados a outros algoritmos propostos na literatura como o AGA e o AI propostos pelos autores das referências (OGURA; LEÃO, 2017; CARNIO; LEÃO, 2019), respectivamente. Esta comparação é realizada tanto para os valores das FOs obtidas quanto para os tempos computacionais gastos por cada um dos algoritmos.

5.2.2.1. Pesos $w_1 = 0,2$ e $w_2 = 0,8$

Para os parâmetros $w_1 = 0,2$ e $w_2 = 0,8$, foram obtidas as 3 melhores soluções apresentadas pelo ABH, exibidas na Tabela 3. Essas soluções foram obtidas com os seguintes parâmetros:

- $w_1 = 0,2$ e $w_2 = 0,8$;
- HMS = 100 (tamanho da memória harmônica);
- NI = 40 (número de iterações).

Tabela 3 – Melhores alocações para os pesos $w_1 = 0,2$ e $w_2 = 0,8$

Solução	Tempo comp. (ms)	Nº de sensores	Localização dos sensores na barra	CENS (R\$)	CINV (R\$)	FO (R\$)
1ª	39	5	7; 10; 11; 13; 17	2011,95	1006,25	1207,39
2ª	39	4	8; 11; 13; 17	2817,97	805,00	1207,59
3ª	39	5	7; 10; 11; 13; 16	2028,77	1006,25	1210,75

Fonte: Elaborado pelo autor.

De acordo com a Tabela 3, a 1ª solução do algoritmo encontrada para os pesos $w_1 = 0,2$ e $w_2 = 0,8$ é a melhor obtida através de testes exaustivos do algoritmo. Na Tabela 4 são apresentados os valores das funções objetivo calculadas para cada iteração do ABH considerando a simulação para a melhor solução.


Tabela 4 – Dados da melhor solução para os pesos $w_1=0,2$ e $w_2=0,8$

NI	FO (R\$)	Divers	HMCR
1	1425,52	1,00	1,00
2	1410,23	1,00	1,00
3	1410,23	1,00	1,00
4	1410,23	1,00	1,00
5	1410,23	1,00	1,00
6	1225,08	1,00	1,00
7	1225,08	1,00	1,00
8	1225,08	1,00	1,00
9	1225,08	1,00	1,00
10	1225,08	0,98	0,96
11	1207,39	0,98	0,96
12	1207,39	0,98	0,96
13	1207,39	0,98	0,96
14	1207,39	0,98	0,96
15	1207,39	0,98	0,96
16	1207,39	0,98	0,96
17	1207,39	0,98	0,96
18	1207,39	0,98	0,96
19	1207,39	0,98	0,96
20	1207,39	0,98	0,96
21	1207,39	0,98	0,96
22	1207,39	0,98	0,96
23	1207,39	0,97	0,94
24	1207,39	0,97	0,94
25	1207,39	0,96	0,92
26	1207,39	0,96	0,92
27	1207,39	0,96	0,92
28	1207,39	0,96	0,92
29	1207,39	0,96	0,92
30	1207,39	0,96	0,92
31	1207,39	0,95	0,90
32	1207,39	0,95	0,90
33	1207,39	0,95	0,90
34	1207,39	0,95	0,90
35	1207,39	0,95	0,90
36	1207,39	0,95	0,90
37	1207,39	0,95	0,90
38	1207,39	0,95	0,90
39	1207,39	0,94	0,89
40	1207,39	0,94	0,89

Fonte: Elaborado pelo autor.

A partir da Tabela 4 nota-se que o ABH encontrou a melhor solução na 11ª geração a qual se manteve como a melhor solução até o final das iterações. Na Figura 20 são ilustrados os gráficos do comportamento do AGA, do AI e do ABH, o que possibilita uma melhor compreensão do processo de convergência.

Figura 20 – Gráfico do comportamento da função objetivo em relação ao número de iterações para os três algoritmos quando $w_1=0,2$ e $w_2=0,8$



Fonte: Elaborado pelo autor.

De acordo com a Tabela 3, é possível verificar que o ABH converge na 11ª iteração para a solução mínima (R\$1207,39). Por outro lado para o AGA, este mesmo valor da função objetivo é alcançada quando NI=21 (OGURA; LEÃO, 2017) e para o AI, quando NI=33 (CARNIO; LEÃO, 2019). Isto indica que, quando se prioriza a parcela do *CINV*, o ABH é um algoritmo que necessita de um menor número de iterações para atingir a solução mínima para o mesmo problema que o AGA e o AI. Isto ocorre devido principalmente às mudanças propostas no ABH, que possibilitaram maior agilidade no processo de convergência. Todavia, ao se comparar os tempos computacionais dos três algoritmos, enquanto o AGA e o AI apresentam tempo médio de 16ms e 35ms, respectivamente, o ABH tem o tempo médio de 39ms. Apesar de acelerar o processo de convergência, o tempo computacional é comprometido pelo elevado HMS e pelas diversas atualizações da HM.

5.2.2.2. Pesos $w_1 = 0,5$ e $w_2 = 0,5$

Para os parâmetros $w_1 = 0,5$ e $w_2 = 0,5$, foram obtidas as 3 melhores soluções apresentadas pelo ABH, exibidas na Tabela 5. Essas soluções foram obtidas com os seguintes parâmetros:

- $w_1 = 0,5$ e $w_2 = 0,5$;
- HMS = 100 (tamanho da memória harmônica);
- NI = 40 (número de iterações).

Tabela 5 – Melhores alocações para os pesos $w_1 = 0,5$ e $w_2 = 0,5$

Solução	Tempo comp. (ms)	Nº de sensores	Localização dos sensores na barra	CENS (R\$)	CINV (R\$)	FO (R\$)
1ª	38	8	6; 8; 10; 11; 12; 13; 16; 18	1046,31	1610,00	1328,16
2ª	38	8	5; 8; 10; 11; 12; 13; 16; 18	1057,01	1610,00	1333,50
3ª	38	8	6; 8; 10; 11; 12; 13; 15; 18	1057,68	1610,00	1333,84

Fonte: Elaborado pelo autor.

De acordo com a Tabela 5, a 1ª solução do algoritmo encontrada para os pesos $w_1=0,5$ e $w_2=0,5$ é a melhor obtida através de testes exaustivos do algoritmo. Na Tabela 6 são apresentados os valores das funções objetivo calculadas para cada iteração do ABH considerando a simulação para a melhor solução.


A partir da Tabela 6 nota-se que o ABH encontrou a melhor solução na 10ª geração a qual se manteve como a melhor solução até o final das iterações. Na Figura 21 são ilustrados os gráficos do comportamento do AGA, do AI e do ABH, o que possibilita uma melhor compreensão do processo de convergência.

Tabela 6 – Dados da melhor solução para os pesos $w_1=0,5$ e $w_2=0,5$

NI	FO (R\$)	Divers	HMCR
1	1570,63	1,00	1,00
2	1537,11	1,00	1,00
3	1464,39	1,00	1,00
4	1464,39	1,00	1,00
5	1430,39	1,00	1,00
6	1430,39	1,00	1,00
7	1430,39	1,00	1,00
8	1387,30	1,00	1,00
9	1387,30	1,00	1,00
10	1328,16	1,00	1,00
11	1328,16	1,00	1,00
12	1328,16	0,98	0,96
13	1328,16	0,98	0,96
14	1328,16	0,98	0,96
15	1328,16	0,97	0,94
16	1328,16	0,97	0,94
17	1328,16	0,97	0,94
18	1328,16	0,97	0,94
19	1328,16	0,97	0,94
20	1328,16	0,97	0,94
21	1328,16	0,97	0,94
22	1328,16	0,96	0,92
23	1328,16	0,96	0, 92
24	1328,16	0,96	0, 92
25	1328,16	0,96	0, 92
26	1328,16	0,96	0, 92
27	1328,16	0,96	0, 92
28	1328,16	0,96	0, 92
29	1328,16	0,96	0, 92
30	1328,16	0,96	0, 92
31	1328,16	0,96	0, 92
32	1328,16	0,95	0,90
33	1328,16	0,95	0, 90
34	1328,16	0,95	0, 90
35	1328,16	0,95	0, 90
36	1328,16	0,93	0,87
37	1328,16	0,93	0, 87
38	1328,16	0,93	0, 87
39	1328,16	0,93	0, 87
40	1328,16	0,93	0, 87

Fonte: Elaborado pelo autor.

Figura 21 – Gráfico do comportamento da função objetivo em relação ao número de iterações para os três algoritmos quando $w_1=0,5$ e $w_2=0,5$



Fonte: Elaborado pelo autor.

De acordo com a Tabela 5, é possível verificar que o ABH converge na 10ª iteração para a solução (R\$1328,16). Por outro lado, o AGA obteve a solução ótima na iteração NI=20 (OGURA; LEÃO, 2017) e para o AI, quando NI=21 (CARNIO; LEÃO, 2019). Para este caso o tempo médio computacional do AGA foi de 15ms, o AI foi de 46ms enquanto o ABH foi de 38ms. Observa-se que a convergência ocorre em menos iterações, todavia o AGA ainda apresenta menor esforço computacional.

5.2.2.3. Pesos $w_1 = 0,8$ e $w_2 = 0,2$

Para os parâmetros $w_1 = 0,8$ e $w_2 = 0,2$, foram obtidas as 3 melhores soluções apresentadas pelo ABH, exibidas na Tabela 7. Essas soluções foram obtidas com os seguintes parâmetros:

- $w_1 = 0,8$ e $w_2 = 0,2$;
- HMS = 100 (tamanho da memória harmônica);
- NI = 30 (número de iterações).

De acordo com a .

Tabela 7, a 1ª solução do algoritmo encontrada para os pesos $w_1=0,8$ e $w_2=0,2$ é a melhor obtida através de testes exaustivos do algoritmo. Na Tabela 8 são apresentados os valores das

funções objetivo calculadas para cada iteração do ABH considerando a simulação para a melhor solução.

Tabela 7 – Melhores alocações para os pesos $w_1 = 0,8$ e $w_2 = 0,2$

Solução	Tempo comp. (ms)	Nº de sensores	Localização dos sensores na barra	CENS (R\$)	CINV (R\$)	FO (R\$)
1ª	29	14	4; 6; 7; 8; 9; 10; 11; 12; 13; 15; 16; 17; 18; 19	413,82	2817,5	894,56
2ª	29	15	4; 6; 7; 8; 9; 10; 11; 12; 13; 14; 15; 16; 17; 18; 19	365,10	3018,75	895,83
3ª	29	13	4; 6; 7; 8; 9; 10; 11; 12; 13; 15; 16; 18; 19	466,75	2616,25	896,65

Fonte: Elaborado pelo autor.

De acordo com a Tabela 7, a 1ª solução do algoritmo encontrada para os pesos $w_1=0,8$ e $w_2=0,2$ é a melhor obtida através de testes exaustivos do algoritmo. Na Tabela 8 são apresentados os valores das funções objetivo calculadas para cada iteração do ABH considerando a simulação para a melhor solução.

A partir da Tabela 8 nota-se que o ABH encontrou a melhor solução na 12ª geração a qual se manteve como a melhor solução até o final das iterações. Na Figura 22 são ilustrados os gráficos do comportamento do AGA, do AI e do ABH, o que possibilita uma melhor compreensão do processo de convergência.


De acordo com a Tabela 8, é possível verificar que o ABH converge na 12ª iteração para a solução mínima (R\$894,56). Por outro lado, o AGA obteve a solução ótima na iteração NI=29 (OGURA; LEÃO, 2017) e para o AI, quando NI=26 (CARNIO; LEÃO, 2019). Para este caso o tempo médio computacional do AGA foi de 31ms, o AI foi de 46ms enquanto o ABH foi de 29ms. Observa-se que o ABH obtém a solução ótima com menos iterações e com o menor esforço computacional em relação aos outros métodos.

Tabela 8 – Dados da melhor solução para os pesos $w_1=0,8$ e $w_2=0,2$

NI	FO (R\$)	Divers	HMCR
1	1032,92	1,00	1,00
2	1032,92	1,00	1,00
3	970,30	1,00	1,00
4	947,54	1,00	1,00
5	947,54	0,98	0,96
6	947,54	0,98	0,96
7	944,67	0,98	0,96
8	944,67	0,98	0,96
9	944,67	0,98	0,96
10	940,97	0,98	0,96
11	928,03	0,98	0,96
12	894,56	0,98	0,96
13	894,56	0,98	0,96
14	894,56	0,97	0,94
15	894,56	0,97	0,94
16	894,56	0,97	0,94
17	894,56	0,97	0,94
18	894,56	0,97	0,94
19	894,56	0,95	0,90
20	894,56	0,95	0,90
21	894,56	0,94	0,89
22	894,56	0,94	0,89
23	894,56	0,93	0,87
24	894,56	0,93	0,87
25	894,56	0,87	0,76
26	894,56	0,85	0,73
27	894,56	0,85	0,73
28	894,56	0,85	0,73
29	894,56	0,85	0,73
30	894,56	0,85	0,73

Fonte: Elaborado pelo autor.

Figura 22 – Gráfico do comportamento da função objetivo em relação ao número de iterações para os três algoritmos quando $w_1=0,8$ e $w_2=0,2$



Fonte: Elaborado pelo autor.

5.2.3. Discussões sobre as simulações

De acordo com a Tabela 3, as melhores alocações dos sensores obtidas nas simulações para os pesos $w_1=0,2$ e $w_2=0,8$ foram nas barras 7, 10, 11, 13 e 17, com FO de R\$ 1207,39. A segunda melhor opção, com FO de R\$1207,59, possui um menor número de sensores alocados, o que proporciona um valor menor de *CINV*, mas um valor maior de *CENS*. Todavia, isso não influencia a FO de forma significativa, uma vez que a maior importância é dada ao *CINV*.

De acordo com a Tabela 5, as melhores alocações dos sensores obtidas para os pesos de $w_1=0,5$ e $w_2=0,5$, foram nas barras 6, 8, 10, 11, 12, 13, 16 e 18, com FO de R\$1328,16. Neste caso, observa-se que, para as três melhores soluções, o número de sensores alocados é o mesmo (8 no total), já que os pesos do *CINV* e do *CENS* são os mesmos. Nota-se também que, nessas soluções, o *CENS* resultou em valores bem próximos, sendo a solução com menor *CENS* a melhor dentre as três melhores. Portanto, neste caso, a melhor solução foi aquela com menor *CENS*.

De acordo com a Tabela 7, as melhores alocações dos sensores obtidas nas simulações para os pesos $w_1=0,8$ e $w_2=0,2$, foram nas barras 4, 6, 7, 8, 9, 10, 11, 12, 13, 15, 16, 17, 18 e 19, com FO de R\$ 894,56. Neste caso, devido ao menor peso adotado para o *CINV*, as três soluções apresentam números de sensores elevados e diferentes entre si.

Quanto aos tempos computacionais, comparando os resultados obtidos pelo ABH com os resultados obtidos pelo AGA e pelo AI das referências (OGURA; LEÃO, 2017; CARNIO; LEÃO, 2019), respectivamente, observou-se que, quando se deu maior prioridade ao *CINV* ($w_1=0,2$ e $w_2=0,8$) em relação ao *CENS*, o ABH obteve em média um tempo de processamento de 39ms, enquanto que o AGA obteve um tempo de 16ms e o AI um tempo de 35ms. Quando os pesos foram iguais, para o ABH, o tempo foi de 38ms, enquanto que para o AGA o tempo foi de 16ms e para o AI o tempo foi de 46ms. Por fim, quando se priorizou mais a parcela do *CENS* na FO ($w_1=0,8$ e $w_2=0,2$), o ABH obteve um tempo de processamento de 29ms, enquanto que para o AGA o tempo foi de 31ms e para o AI o tempo foi de 46ms. Logo, pode-se avaliar que, nos dois primeiros casos, o AGA foi capaz de encontrar a solução ótima com menos tempo de processamento do que o ABH, indicando uma vantagem computacional. É possível reduzir os esforços computacionais do ABH diminuindo o número de iterações, como foi feito para o caso $w_1=0,8$ e $w_2=0,2$. Todavia, ao fazer isso, pode incorrer numa diminuição da acurácia do algoritmo para alcançar a solução otimizada.

5.2.4. Discussões sobre gráficos das melhores soluções das alocações


Todos os gráficos que mostram o comportamento das funções objetivo do ABH, conforme as Figuras 20, 21 e 22, possuem uma curva característica decrescente, pois são realizados processos de improvisação de acordo com a diversidade da memória harmônica a cada iteração do algoritmo. Assim, o processo de atualização da memória harmônica elimina gradualmente as soluções de qualidade inferior, resultando em soluções de boa qualidade. Verificou-se que, caso encontre a melhor solução, o gráfico terá uma curva característica constante, como é observado a partir da 11ª iteração do gráfico da Figura 20.

Comparando o ABH com o AGA e o AI, das referências (OGURA; LEÃO, 2017; CARNIO; LEÃO, 2019), respectivamente, notou-se que, para todos os casos, o ABH necessitou de menos iterações para encontrar a melhor solução do problema. Isso só foi possível devido às mudanças realizadas no ABH original para acelerar o processo de improvisação e à utilização do HMCR dinâmico, já explicados anteriormente. Todavia, isso resultou em um aumento nos esforços computacionais, uma vez que, na maioria dos casos, o tempo médio computacional do ABH foi superior ao AGA.

5.3. Resultados para o sistema de 34 barras

Nesta seção serão apresentados os testes experimentais realizados utilizando o método implementado e o sistema teste da Figura 23.

Figura 23 – Sistema teste de 34 barras



Fonte: Adaptado de (CRUZ, 2016).

5.3.1. Considerações sobre os dados de entrada

O sistema teste possui 34 barras de carga, com uma carga total instalada de 1769 kW e 93,914 km. Os dados do sistema como as cargas nas barras e os comprimentos das linhas são apresentados no Anexo A.

Alguns dados do sistema foram extraídos de Ho et al. (2011) e incluem a seguinte informação: taxa média de falhas: 0,149 falhas/ano.km; tempo médio de reparo: 60 minutos; tempo de localização de falhas sem IF: 20 minutos (0,3333horas/km); tempo de localização de falhas com IF: 5 minutos (0,0833horas/km). Além disso, a velocidade média de deslocamento das equipes de manutenção para zonas urbanas é de 25 km/h, conforme Muniz et al. (2009).

Para a solução do sistema, as seguintes informações dos IFs remotos devem ser consideradas: preço de compra de cada sensor em três fases: R\$3628,80; custo de instalação do sensor: R\$181,44; custo de manutenção do sensor: R\$181,44; tempo médio de vida útil do sensor: 10 anos (Bjerkman, Nortroll, 2009). Além disso, o custo da energia utilizada é de R\$0,4535/kWh.

5.3.2. Resultados empregando o ABH modificado

O ABH foi utilizado no sistema teste de 34 barras, no entanto, não se obteve um desempenho satisfatório. Mesmo após a realização de diversas modificações e testes, o

algoritmo não conseguiu atingir a solução otimizada para o problema em questão. Infelizmente, o ABH modificado não se mostrou adequado para este caso específico e novas abordagens devem ser consideradas para encontrar uma solução efetiva para o problema. Diante disso, foi necessário voltar alguns passos e analisar com mais detalhes a sensibilidade do parâmetro HMCR no problema em questão.

5.3.2.1. *Análise da sensibilidade do parâmetro HMCR*

Nesta seção são apresentados os resultados obtidos a partir da implementação computacional do modelo matemático atualizado de alocação otimizada de sensores IF e da técnica de solução proposta baseada no ABH. O método proposto foi implementado em linguagem C++ na plataforma de programação Visual Studio 2019 e o computador utilizado nas simulações é um Intel(R) Core(TM) i5-7400 CPU @ 3.00 GHz e 16,0 GB de memória RAM instalada.

Os métodos foram executados em máquinas distintas, portanto, as diferenças nos tempos de execução podem ser comparadas, porém não devem ser consideradas como um critério definitivo para determinar qual método é superior nesse aspecto.

São realizados diversos testes considerando 10 valores constantes do parâmetro HMCR do ABH, sendo:


HMCR = 0,05 HMCR = 0,15 HMCR = 0,25 HMCR = 0,35 HMCR = 0,45
 HMCR = 0,55 HMCR = 0,65 HMCR = 0,75 HMCR = 0,85 HMCR = 0,95

Os dados de entrada para as simulações são os apresentados na seção 5.3.1. enquanto os demais parâmetros do algoritmo são calibrados para obter a melhor solução conforme seguem: $HMS=1000$, $NI=100$ e $w_1 = w_2 = 0,5$.

Nas Figuras 24 e 25 são ilustradas as curvas das médias dos valores da função incumbente de cada HMCR escolhido e nas Figuras 26 e 27 são exibidas as mesmas curvas mas destacando o comportamento para as primeiras 25 iterações.


Nos gráficos das Figuras 24 e 25 é possível notar que ao fim das 100 iterações apenas as soluções de $HMCR = \{ 0,05; 0,15; 0,25 \}$ não foram satisfatórias. Todavia, ao analisar os gráficos focados nas primeiras iterações, nota-se que o decaimento da função objetivo para os valores mais baixos de HMCR é maior do que em relação aos valores mais altos.

Figura 24 – Gráfico do comportamento da função objetivo em relação ao número de iterações
- Parte A




Fonte: Elaborado pelo autor.

Figura 25 – Gráfico do comportamento da função objetivo em relação ao número de iterações
- Parte B




Fonte: Elaborado pelo autor.

Figura 26 – Gráfico do comportamento da função objetivo em relação ao número de iterações ampliado para as primeiras 25 iterações - Parte A



Fonte: Elaborado pelo autor.

Figura 27 – Gráfico do comportamento da função objetivo em relação ao número de iterações ampliado para as primeiras 25 iterações - Parte B



Fonte: Elaborado pelo autor.


Com base nisso, é interessante que inicialmente o HMCR seja um valor baixo e após isso que o HMCR seja mais elevado. Todavia, foram feitos testes utilizando esta mecânica e os resultados não foram tão melhores quanto aos valores constantes. Logo, os resultados que serão analisados e comparados com o AGA da referência serão os com $\text{HMCR} = 0,55$.

5.3.2.2. Simulações considerando pesos $w_1 = 0,5$ e $w_2 = 0,5$

Os valores de w_1 e w_2 foram fixados em 0,5 para priorizar igualmente cada um dos custos conflitantes. Para os testes o ABH foi executado 100 vezes com o algoritmo calibrado, de modo que o algoritmo obtivesse a menor solução para todas as execuções, todavia, a função objetivo só foi atingida em 60 deles. Desta forma, tem-se então uma acurácia de 60%, que pode ser considerada satisfatória pelo fato de que se trata de um problema na fase de planejamento, logo poderão ser feitas várias execuções antes de instalar os sensores.

Das execuções nas quais o ABH convergiu para a solução otimizada, uma delas convergiu na 6ª iteração. Na Figura 28 é apresentado o gráfico da função objetivo do melhor resultado obtido, desconsiderando a convergência na 6ª iteração.

Figura 28 – Gráfico da função objetivo do melhor resultado



Fonte: Elaborado pelo autor.

É possível verificar que o ABH converge na 30ª iteração a qual se manteve como a melhor solução até o final das iterações. Apesar de parecer que a partir da 14ª geração já

converge, o valor da FO é o segundo melhor resultado (R\$2470,92) e o algoritmo fica estagnado por algumas iterações até atingir a solução otimizada. Além disso, o tempo computacional para esta solução foi de 2629 ms.

5.3.2.3. Comparando os resultados com o AGA

Pode-se observar nos resultados obtidos para este sistema utilizando o ABH que as configurações correspondem às encontradas pelo AGA, mas os tempos de execução são maiores (AGA 241 ms). Para convergir para as mesmas respostas, os parâmetros de tamanho da memória harmônica e o número máximo de iterações do ABH são maiores. Como resultado, os tempos de execução também são maiores.

Para analisar ainda mais a comparação do desempenho entre o ABH e o AGA, pode ser observado que o ABH converge na 30ª iteração enquanto o AGA converge na 41ª geração. Logo, podemos afirmar que apesar de demandar um esforço computacional maior, o ABH convergiu mais rápido que o AGA neste caso.

Por fim, nota-se que para o sistema de 34 barras, o algoritmo não se comportou da mesma forma em relação aos outros testes, não convergindo para a solução otimizada em todos os testes. Também, notou-se que para este método, a diversidade da população só tende a cair por conta do modo em que a memória harmônica é atualizada, por isso, fez-se necessário utilizar o parâmetro HMCR como fixo e não atrelá-lo com a diversidade proposta anteriormente.

5.3.3. Análise Multicritério dos Resultados da Alocação de IFs em Redes de Distribuição de Energia Elétrica.

Na seção anterior, os testes realizados consideraram apenas o valor de 0,5 para w_1 e w_2 , assumindo que tanto o *CENS* quanto o *CINV* possuem a mesma prioridade na classificação das configurações candidatas. Nesta seção, os pesos w_1 e w_2 serão iterativamente variados e para cada par de valores, o ABH encontrará a melhor solução, utilizando os parâmetros $HMCR=0,55$, $HMS=1000$ e $NI=100$. As melhores soluções para todos os pesos formarão a fronteira de Pareto aproximada para o problema.

A fronteira de Pareto, também conhecida como fronteira eficiente, é um conceito da teoria da otimização multicritério. Ela representa o conjunto de soluções que são consideradas ótimas ou não dominadas em relação a um conjunto de critérios ou objetivos. (BARR, 2020)

Em um problema de otimização multicritério, geralmente existem múltiplos objetivos conflitantes que precisam ser considerados simultaneamente. A fronteira de Pareto consiste nas

soluções que não podem ser melhoradas em um critério sem piorar em pelo menos um outro critério. Em outras palavras, uma solução é considerada na fronteira de Pareto se não houver outra solução que seja melhor em todos os critérios.

Assim, a fronteira de Pareto representa um conjunto de soluções não dominadas, onde não é possível melhorar um critério sem piorar pelo menos um outro critério. Essas soluções oferecem diferentes opções para o tomador de decisão, permitindo que ele escolha a solução que melhor se ajuste às suas preferências ou necessidades, considerando o compromisso existente entre os diferentes critérios.

Com base na fronteira de Pareto aproximada, a concessionária de energia poderá escolher a solução que melhor atenda aos seus interesses, priorizando o *CENS* e/ou o *CINV*.

Como mencionado anteriormente, os valores dos pesos modificados devem obedecer às restrições:

$$w_1 + w_2 = 1 \quad w_1 \text{ e } w_2 \geq 0$$

A partir dessas restrições, os pesos podem assumir valores no intervalo de 0 a 1 para w_1 e w_2 .

Para obter uma gama de soluções e traçar a fronteira de Pareto aproximada, o valor de w_1 foi variado de 0 até 1 em passos discretos. Observou-se que se o passo é grande, poucas soluções são obtidas, o que pode não representar adequadamente o espaço de busca do problema. Por outro lado, se o passo é muito pequeno resulta em muitas soluções. Neste trabalho, o passo δw empregado é de 0,01. Portanto, os valores de w_1 e w_2 podem assumir valores entre 0 e 1 em passos de 0,01, o que representa 101 soluções para compor a fronteira de Pareto.

Pode-se observar nas Tabelas 9, 10 e 11 os valores da função objetivo mínima, bem como os valores das parcelas *CENS* e *CINV* para cada valor dos pesos, para o sistema de 34 barras. Nessa tabela, é destacada a solução obtida com ponderações iguais, que representa o melhor compromisso simultâneo para os custos conflitantes. Essa solução é a que está mais próxima dos eixos *CENS* e *CINV* simultaneamente, ou seja, a solução cujo ponto localiza-se mais próximo do "joelho" da curva da fronteira de Pareto aproximada.

Tabela 9 – Resultados para a fronteira de Pareto do sistema de 34 barras – Parte A

w1	w2	IFS	barras	F.O. (R\$/ano)	CENS (R\$/ano)	CINV (R\$/ano)	Tempo (ms)
0,00	1,00	0	0	0,00	31224,60	0,00	2560
0,01	0,99	0	0	312,25	31224,60	0,00	2425
0,02	0,98	0	0	624,49	31224,60	0,00	2442
0,03	0,97	3	1	823,75	9272,12	562,46	2425
0,04	0,96	3	1	910,85	9272,12	562,46	2437
0,05	0,95	3	1	997,95	9272,12	562,46	2470
0,06	0,94	3	1	1085,04	9272,12	562,46	2413
0,07	0,93	4	2	1159,87	6605,87	749,95	2449
0,08	0,92	4	2	1218,43	6605,87	749,95	2699
0,09	0,91	4	2	1276,98	6605,87	749,95	2518
0,10	0,90	4	2	1335,54	6605,87	749,95	2561
0,11	0,89	4	2	1394,10	6605,87	749,95	2586
0,12	0,88	4	2	1452,66	6605,87	749,95	2646
0,13	0,87	4	2	1511,22	6605,87	749,95	2628
0,14	0,86	4	2	1569,78	6605,87	749,95	2662
0,15	0,85	4	2	1628,34	6605,87	749,95	2558
0,16	0,84	4	2	1686,90	6605,87	749,95	2524
0,17	0,83	4	2	1745,46	6605,87	749,95	2576
0,18	0,82	4	2	1804,02	6605,87	749,95	2550
0,19	0,81	4	2	1862,58	6605,87	749,95	2553
0,20	0,80	4	2	1921,13	6605,87	749,95	2574
0,21	0,79	4	2	1979,69	6605,87	749,95	2724
0,22	0,78	4	2	2038,25	6605,87	749,95	2542
0,23	0,77	7	3	2087,41	4681,95	1312,42	2579
0,24	0,76	7	3	2121,10	4681,95	1312,42	2580
0,25	0,75	7	3	2154,80	4681,95	1312,42	2600
0,26	0,74	7	3	2188,49	4681,95	1312,42	2583
0,27	0,73	7	3	2222,19	4681,95	1312,42	2546
0,28	0,72	7	3	2255,88	4681,95	1312,42	2523
0,29	0,71	8	4	2287,59	4216,06	1499,90	2640
0,30	0,70	9	5	2314,10	3776,42	1687,39	2594
0,31	0,69	9	5	2334,99	3776,42	1687,39	2567
0,32	0,68	9	5	2355,88	3776,42	1687,39	2575
0,33	0,67	9	5	2376,77	3776,42	1687,39	2619
0,34	0,66	9	5	2397,66	3776,42	1687,39	2551
0,35	0,65	10	6	2415,38	3419,16	1874,88	2550
0,36	0,64	10	6	2430,82	3419,16	1874,88	2689
0,37	0,63	12	6	2442,26	2769,87	2249,86	2537
0,38	0,62	12	6	2447,46	2769,87	2249,86	2568
0,39	0,61	12	6	2452,66	2769,87	2249,86	2569

Fonte: Elaborado pelo autor.

Tabela 10 – Resultados para a fronteira de Pareto do sistema de 34 barras – Parte B

w1	w2	IFS	barras	F.O. (R\$/ano)	CENS (R\$/ano)	CINV (R\$/ano)	Tempo (ms)
0,40	0,60	12	6	2457,86	2769,87	2249,86	2533
0,41	0,59	12	6	2463,06	2769,87	2249,86	2534
0,42	0,58	12	6	2468,26	2769,87	2249,86	2515
0,43	0,57	12	6	2473,46	2769,87	2249,86	2667
0,44	0,56	12	6	2478,66	2769,87	2249,86	2524
0,45	0,55	13	7	2480,21	2532,60	2437,34	2484
0,46	0,54	13	7	2481,16	2532,60	2437,34	2513
0,47	0,53	13	7	2482,11	2532,60	2437,34	2545
0,48	0,52	15	7	2482,71	2125,64	2812,32	2544
0,49	0,51	15	7	2475,84	2125,64	2812,32	2533
0,50	0,50	15	7	2468,98	2125,64	2812,32	2629
0,51	0,49	15	7	2462,11	2125,64	2812,32	2624
0,52	0,48	15	7	2455,24	2125,64	2812,32	2555
0,53	0,47	16	8	2447,66	1958,01	2999,81	2569
0,54	0,46	16	8	2437,24	1958,01	2999,81	2528
0,55	0,45	16	8	2426,82	1958,01	2999,81	2527
0,56	0,44	16	8	2416,40	1958,01	2999,81	2578
0,57	0,43	16	8	2405,99	1958,01	2999,81	2561
0,58	0,42	16	8	2395,57	1958,01	2999,81	2537
0,59	0,41	16	8	2385,15	1958,01	2999,81	2588
0,60	0,40	17	9	2372,03	1828,52	3187,30	2553
0,61	0,39	17	9	2358,44	1828,52	3187,30	2564
0,62	0,38	17	9	2344,86	1828,52	3187,30	2586
0,63	0,37	19	9	2324,90	1598,18	3562,27	2624
0,64	0,36	19	9	2305,26	1598,18	3562,27	2526
0,65	0,35	19	9	2285,61	1598,18	3562,27	2513
0,66	0,34	20	10	2263,29	1497,53	3749,76	2508
0,67	0,33	20	10	2244,54	1503,17	3749,76	2519
0,68	0,32	20	10	2224,21	1506,31	3749,76	2506
0,69	0,31	20	10	2195,72	1497,53	3749,76	2500
0,70	0,30	20	10	2173,20	1497,53	3749,76	2560
0,71	0,29	24	12	2146,27	1185,01	4499,71	2510
0,72	0,28	23	11	2113,13	1185,01	4499,71	2579
0,73	0,27	24	12	2079,98	1185,01	4499,71	2497
0,74	0,26	24	12	2046,83	1185,01	4499,71	2614
0,75	0,25	24	12	2013,68	1185,01	4499,71	2545
0,76	0,24	24	12	1980,54	1185,01	4499,71	2626
0,77	0,23	24	12	1947,39	1185,01	4499,71	2532
0,78	0,22	26	12	1910,44	1074,37	4874,69	2511

Fonte: Elaborado pelo autor.

Tabela 11 – Resultados para a fronteira de Pareto do sistema de 34 barras – Parte C


w ₁	w ₂	IFS	barras	F.O. (R\$/ano)	CENS (R\$/ano)	CINV (R\$/ano)	Tempo (ms)
0,79	0,21	26	12	1872,44	1074,37	4874,69	2436
0,80	0,20	26	12	1834,44	1074,37	4874,69	2515
0,81	0,19	29	13	1800,40	947,33	5437,15	2500
0,82	0,18	29	13	1754,73	946,40	5437,15	2500
0,83	0,17	29	13	1702,49	937,56	5437,15	2465
0,84	0,16	29	13	1657,49	937,56	5437,15	2494
0,85	0,15	29	13	1612,49	937,56	5437,15	2494
0,86	0,14	29	13	1567,50	937,56	5437,15	2507
0,87	0,13	29	13	1522,50	937,56	5437,15	2544
0,88	0,12	32	14	1473,21	855,97	5999,62	2523
0,89	0,11	32	14	1421,77	855,97	5999,62	2578
0,90	0,10	32	14	1370,34	855,97	5999,62	2484
0,91	0,09	32	14	1318,90	855,97	5999,62	2480
0,92	0,08	32	14	1267,47	855,97	5999,62	2480
0,93	0,07	32	14	1216,03	855,97	5999,62	2507
0,94	0,06	32	14	1164,59	855,97	5999,62	2482
0,95	0,05	36	16	1108,93	812,06	6749,57	2483
0,96	0,04	36	16	1049,56	812,06	6749,57	2510
0,97	0,03	42	18	982,89	769,74	7874,50	2479
0,98	0,02	42	18	911,84	769,74	7874,50	2594
0,99	0,01	46	20	838,28	759,63	8624,45	2725
1,00	0,00	86	34	750,45	750,45	12186,70	2716

Fonte: Elaborado pelo autor.

Analisando as Tabelas 9, 10 e 11, é relevante notar que valores pequenos de w_1 correspondem a valores grandes de w_2 . Isso significa que a função objetivo é fortemente influenciada pelo *CINV*, e o método tende a alocar um menor número de IFs. O oposto ocorre com valores grandes de w_1 , onde a função objetivo é dominada pelo *CENS*. Nesse caso, o método tende a alocar uma maior quantidade de IFs, aumentando o valor do *CINV*, mas reduzindo o valor do *CENS*.


A partir dos dados das Tabelas 9, 10 e 11 pode-se traçar a fronteira de Pareto aproximada ilustrada na, que relaciona a variação do *CENS* com o valor correspondente de *CINV*. Pode-se observar que a relação entre os custos é inversa ou conflitante. Uma ampliação do joelho da curva da fronteira de Pareto com os eixos em escala adequada é apresentada na Figura 30.

Figura 29 – Fronteira de Pareto para sistema de 34 barras



Fonte: Elaborado pelo autor.

Figura 30 – Fronteira de Pareto para sistema de 34 barras (ampliado)



Fonte: Elaborado pelo autor.

É importante notar que nos casos em que $w_1=0$, ou seja, quando toda a importância da função objetivo estava no *CINV* ($FO = CINV$), o algoritmo não alocou IFs na solução do problema. Gradualmente, à medida que o valor de w_1 aumenta em passos $\delta w=0,01$, o algoritmo tende a alocar mais IFs progressivamente. Ao final, quando $w_1=1$ e $w_2=0$, significa que toda a importância do critério de avaliação é minimizar o *CENS* e o algoritmo aloca IFs em todas as barras do sistema, não considerando o custo de investimento.

6. Conclusões

Neste trabalho, é realizada a modelagem matemática da alocação de sensores indicadores de faltas em sistemas de distribuição de energia elétrica, como um problema de otimização combinatória. O modelo matemático consiste em dois objetivos conflitantes: a minimização do Custo da Energia Não Suprida (*CENS*) e a minimização do Custo de Investimento na alocação dos sensores (*CINV*). Assim, foram realizadas análises com o modelo matemático para concluir quais soluções geram os melhores locais da rede para alocação de sensores e quais parâmetros possuem maior influência na função da ponderação dos termos da função objetivo.

A implementação do ABH na primeira etapa do trabalho possibilitou analisar a sensibilidade do algoritmo em relação à variação do parâmetro HMCR. Os resultados mostram que o HMCR é um parâmetro interessante de estudo, e portanto deve ser considerado na elaboração de um método de variação dinâmica do HMCR no processo de improvisação, a fim de favorecer a busca global nas primeiras iterações e posteriormente favorecer a busca local da solução otimizada. Dessa forma, é possível apresentar um bom desempenho e compará-lo aos resultados obtidos na literatura. Observa-se, através dos resultados, que as funções objetivo das melhores soluções possuem uma curva característica decrescente, pois trata-se de um algoritmo metaheurístico de otimização, em que o ABH, por meio da exploração de ótimos locais, busca a melhor solução global do sistemas testes.

Foi constatado que o tempo de processamento do ABH é maior do que o do AGA, porém menor do que o do AI, o que demanda mais esforço computacional e o torna menos eficiente para solucionar o problema estudado. Contudo, o principal ponto forte do ABH foi sua rapidez na convergência. A partir dos resultados e tempos computacionais obtidos, conclui-se que o algoritmo de alocação de sensores indicadores de falta é robusto e eficiente, dependendo da aplicação, e é menos indicado se necessita de um tempo de processamento menor. Ademais, o ABH mostrou-se uma ferramenta mais promissora do que o AGA e o AI em termos de velocidade de decaimento.

Por fim, a partir da fronteira de Pareto traçada, dependendo dos interesses da concessionária, ela pode escolher a solução que melhor descreve sua priorização de custos, buscando a minimização do *CENS* ou a minimização do *CINV* em sensores.

7. Referências

- BARR, N. Economics of the welfare state. Oxford University Press, USA, 2020.
- CARNIO, G. A.; LEÃO, F. B. Alocação Otimizada de Sensores Indicadores de Falta em Sistemas de Distribuição de Energia Elétrica utilizando Algoritmo Imune. In: XXXI CONGRESSO DE INICIAÇÃO CIENTÍFICA - UNESP 2019, Anais... [s.l: s.n.]
- CRUZ, H. O. Alocação otimizada de sensores indicadores de falta em redes de distribuição de energia elétrica. 2016. Universidade Estadual Paulista - UNESP - Campus de Ilha Solteira, Mestrado, [s. l.], 2016.
- DE ALMEIDA, M. C.; COSTA, F. F.; XAVIER-DE-SOUZA, S.; SANTANA, F. Optimal placement of faulted circuit indicators in power distribution systems. Electric Power Systems Research, [s. l.], v. 81, n. 2, p. 699–706, fev. 2011.
- GEEM, Z. W.; KIM, J. H.; LOGANATHAN, G. V. A New Heuristic Optimization Optimization Algorithm: Harmony Search. SIMULATION, [s. l.], v. 76, n. 2, p. 60–68, 2001.
- HO, C.-Y.; LEE, T.-E.; LIN, C.-H. Optimal Placement of Fault Indicators Using the Immune Algorithm. IEEE Transactions on Power Systems, [s. l.], v. 26, n. 1, p. 38–45, fev. 2011.
- HORSTMANN GERMANY CATALOGUE. [Online]. Available: https://www.horstmanngmbh.com/fileadmin/products/Katalog_englisch_101101-0000_Einzelseiten_web.pdf. [Accessed: 16-Maio-2023].
- INCON-POWER REABILITY SYSTEMS. GridSense™ Line IQ Data Sheet. [s. l.], p. 1–2, 2017.
- KONG, X.; GAO, L.; OUYANG, H.; LI, S. A simplified binary harmony search algorithm for large scale 01 knapsack problems. Expert Systems with Applications, [s. l.], v. 42, n. 12, p. 5337–5355, 2015.
- LUAN, S.; TENG, J.; CHEN, C. Development of a Novel Fault Indicator for Distribution Automation. International Journal of Information and Electronics Engineering, [s. l.], v. 1, n. 2, p. 105–109, 2011.
- MUENCH, F.; WRIGHT, G. Fault indicators: types, strengths & applications. IEEE Transactions on Power Apparatus and Systems, [s. l.], v. PAS-103, n. 12, p. 3688–3693, 1984.

OGURA, G. H.; LEÃO, F. B. Alocação Otimizada de Sensores Indicadores de Falta em Sistemas de Distribuição de Energia Elétrica utilizando Algoritmo Genético Adaptativo. In: XXIX CONGRESSO DE INICIAÇÃO CIENTÍFICA - UNESP 2017, Anais... [s.l: s.n.]

RAISON, B.; ROGNON, J.-P.; BONNOIT, S.; MANJAL, B. Optimization of fault indicators placement with dispersed generation insertion. IEEE Power Engineering Society General Meeting, 2005, [s. l.], p. 1530–1537, 2005.

SCHWEITZER ENGINEERING LABORATORIES. [Online]. Available: <https://selinc.com/products/FT50/>. [Accessed: 16-Maio-2023].

SOUZA, D. De; SILVA, I. Da; ZIOLKOWSKI, V.; FLAUZINO, R. Efficient allocation of fault indicators in distribution circuits using fuzzy logic. In: IEEE POWER & ENERGY SOCIETY GENERAL MEETING 2009, Anais... [s.l: s.n.]

TENG, J.-H.; HUANG, W.-H.; LUAN, S.-W. Automatic and Fast Faulted Line-Section Location Method for Distribution Systems Based on Fault Indicators. IEEE Transactions on Power Systems, v. 29, n. 4, p. 1653-1662, jul. 2014.

TENG, J.-H.; LUAN, S.-W.; HUANG, W.-H.; LEE, D.-J.; HUANG, Y.-F. A cost-effective fault management system for distribution systems with distributed generators. International Journal of Electrical Power and Energy Systems, [s. l.], v. 65, p. 357–366, 2015.

USIDA, W.; COURY, D. Efficient placement of fault indicators in an actual distribution system using evolutionary computing. IEEE Transactions on Power Systems, [s. l.], v. 27, n. 4, p. 1841–1849, 2012.

VILELA, L. B.; SOUZA, E. S.; LEÃO, F. B. Alocação Ótima De Indicadores De Falta Em Redes De Distribuição De Energia Elétrica Utilizando Modelagem Matemática. In: PROCEEDINGS XXII CONGRESSO BRASILEIRO DE AUTOMÁTICA 2018a, Anais... [s.l: s.n.]

VILELA, L. B.; SOUZA, E. S.; LEÃO, F. B. Proposta de um modelo matemático para alocação de indicadores de falta em redes de distribuição de energia elétrica radiais. In: 50o SBPO – SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL 2018b, Anais... [s.l: s.n.]

WANG, L.; YANG, R.; XU, Y.; NIU, Q.; PARDALOS, P. M.; FEI, M. An improved adaptive binary Harmony Search algorithm. Information Sciences, [s. l.], v. 232, p. 58–87, 2013.

ZOU, D.; GAO, L.; LI, S.; WU, J. Solving 0-1 knapsack problem by a novel global harmony search algorithm. *Applied Soft Computing Journal*, [s. l.], v. 11, n. 2, p. 1556–1564, 2011.

Anexo A – Sistemas teste de 19 e 34 barras

Foram utilizados os sistemas teste de 19 barras e de 34 barras (CRUZ, 2016). Eles estão tabelados a seguir.

Tabela 12 – Dados de entrada do sistema teste de 19 barras.

Barra Final	Barra Inicial	Carga (kW)	Comprimento (m)	Quantidade de fases
1	SE	70	1000	3
2	1	143	1000	3
3	2	168	1000	3
4	3	113	1000	3
5	4	100	1000	3
6	5	265	1000	3
7	6	251	1000	3
8	7	331	1000	3
9	8	188	1000	3
10	9	1205	1000	3
11	10	210	1000	3
12	11	989	1000	3
13	12	43	1000	3
14	13	96	1000	3
15	14	129	1000	3
16	15	44	1000	3
17	16	80	1000	3
18	17	75	1000	3
19	18	115	1000	3

SE: Subestação

Fonte: Elaborado pelo autor.

Tabela 13 – Dados de entrada do sistema teste de 34 barras.

Barra Final	Barra Inicial	Carga (kW)	Comprimento (m)	Quantidade de fases
1	SE	0	0	3
2	1	0	786	3
3	2	55	527	3
4	3	0	9823	3
5	4	16	1769	1
6	4	0	11430	3
7	6	0	9061	3
8	7	0	3	3
9	8	0	94	3
10	9	0	521	1
11	10	34	14676	1
12	11	135	4188	1
13	9	5	3112	3
14	13	40	923	1
15	13	4	256	3
16	15	52	6230	3
17	16	0	158	3
18	17	0	11225	3
19	17	4	7111	1
20	18	0	3	3
21	20	15	1493	3
22	20	0	0	3
23	22	450	3218	3
24	21	32	1777	3
25	21	2	493	1
26	24	206	615	3
27	26	82	816	3
28	27	67	262	3
29	27	0	85	3
30	29	28	1481	1
31	24	0	85	3
32	3	414	411	3
33	32	45	1109	3
34	33	23	161	3

SE: Subestação

Fonte: Elaborado pelo autor.