

Algoritmo Genético para Localização de Agregadores de Dados em Redes Elétricas Inteligentes

Genetic Algorithm for Localizing Data Aggregators in Smart Grids

Gabriel da Silva Biancardi¹, Mário Mestria^{2,†}

¹Coordenadoria de Engenharia Elétrica, Campus Vitória, Instituto Federal do Espírito Santo, Brasil

²Programa de Pós-graduação em Tecnologias Sustentáveis, Campus Vitória, Instituto Federal do Espírito Santo, Brasil

† **Autor correspondente:** mmestria@ifes.edu.br, mmestria@uol.com.br

Resumo

Redes Elétricas Inteligentes são um novo paradigma para os sistemas elétricos de potência que utilizam tecnologia digital avançada, permitindo maior controle sobre a rede elétrica, transmissão de dados em tempo real e transmissão de energia com mais eficiência. O problema enfrentado é como distribuir informações dos consumidores nessa nova concepção de rede elétrica para que atenda todos os consumidores, com o menor custo para os equipamentos de comunicação. O objetivo deste trabalho é o desenvolvimento de um programa computacional para calcular soluções adequadas para o problema de alocação de agregadores de dados em uma rede elétrica inteligente, usando um Algoritmo Genético. Esse algoritmo se subdivide nas etapas de criação da população inicial, avaliação, seleção, cruzamento e mutação, emulando a evolução biológica. Na literatura, Algoritmos Genéticos são muito utilizados para encontrar soluções em problemas de otimização combinatória. Os resultados computacionais apresentaram alto desempenho com as soluções melhores do que da literatura.

Palavras-chave

Medidores Inteligentes • Agregadores de Dados • Redes Elétricas Inteligentes • Buscas Heurísticas e Otimização • Algoritmos Genéticos

Abstract

Smart grid is a new paradigm in the electric power system that uses advanced digital technology. It allows better control over the power grid, transmission of data in real-time and the transmission of energy more efficiently. The problem faced is how to distribute the information of customers in this new concept in the electrical network, in a way that reaches all consumers, with the lowest cost for communication equipment. This goal of the paper is the development of a computational program that calculates adequate solutions to the problem of allocating of the data aggregators in a smart grid, using a Genetic Algorithm. This algorithm is subdivided into the steps of creating an initial population, evaluation, selection, crossover and mutation, emulating biological evolution. In the literature, the Genetic Algorithms are commonly used to find solutions to the combinatorial optimization problems. The computational results present high performance with better solutions than literature.

Keywords

Smart Meter • Data Aggregators • Smart Grids • Heuristic Search and Optimization • Genetic Algorithms

1 Introdução

De acordo com a Ref. [1], “as Redes Elétricas Inteligentes (REI) podem ser compreendidas como a rede elétrica que utiliza tecnologia digital avançada para monitorar e gerenciar o transporte de eletricidade em tempo real com fluxo

de energia e de informações bidirecionais entre o sistema de fornecimento de energia e o cliente final.” Segundo Rolim et al. [2], isto é alcançado através do uso de medidores inteligentes, instrumentos que monitoram os dados de consumo de consumidores em uma pequena área e enviam esses dados periodicamente para um agregador de dados, que recebe os dados de vários medidores. Como Shokry et al. [3] destacam em seu artigo, dados agregados serão encaminhados para um centro de dados, para que a concessionária de energia receba o estado da rede elétrica em tempo real. Devido a comunicação bidirecional das REI, Shokry et al. [3] também citam a capacidade da REI de enviar comandos para medidores inteligentes, com o intuito de executar tarefas específicas pré-programadas.

No trabalho de Qaddoori e Ali [4] destaca-se também que a Infraestrutura de Medição Avançada (IMA) é uma parte importante das comunicações que integra a infra-estrutura de energia e de telecomunicações para coletar, monitorar e avaliar o uso de energia dos clientes. Nesse sentido, reforça-se que a IMA contém medidores inteligentes, agregadores de dados e o sistema head-end (hardware e software que recebe o fluxo de dados dos medidores inteligentes trazido de volta à concessionária por meio da IMA).

Os agregadores de dados têm custos elevados da ordem de quarenta mil dólares e custo adicional de quatro mil dólares por canal de comunicação, como citam Carniel e Mestria [5]. São capazes de receber e transmitir dados com a finalidade de verificar a qualidade de energia, medir consumo de energia e reduzir o tempo entre falhas elétricas.

Segundo Fadel et al.[6], uma REI pode ser dividida em três segmentos; redes de área doméstica ou *Home Area Networks* (HAN), redes de área local ou *Neighborhood Area Networks* (NAN), e redes de área ampla ou *Wide Area Networks* (WAN). Uma HAN é estabelecida quando é criada uma comunicação entre medidores inteligentes e eletrodomésticos, através de tecnologias de comunicação de baixa largura de banda. NAN são caminhos de comunicação entre medidores inteligentes e agregadores de dados, usando tecnologias de comunicação de curto alcance. WAN são estabelecidos entre agregadores de dados e centro de dados, com a utilização de tecnologias de banda larga. A Fig. 1 ilustra os três segmentos de uma REI.

A Ref. [1] propõe diferentes protocolos e tecnologias de comunicação, para redes de área de escalas diferentes, que atendem os requisitos essenciais de uma REI. Sendo elas divididas em sem fio (Wi-Fi, Bluetooth, ZigBee ou 5G), com fio (Fibra óptica) e por rede elétrica (*Power Line Communication*). Devido ao custo elevado de agregadores de dados, a implementação de tecnologias que atendem estes requisitos, possuem baixo custo de instalação, manutenção e modificação são sempre necessárias. Gungor et al. [7] realizam um estudo experimental das *Wireless Sensors Networks* (WSN) em redes de área em diferentes ambientes, e argumenta que as tecnologias sem fio ou WSN têm avançado considerável, e apresentam baixo custo, flexibilidade e fácil implementação.

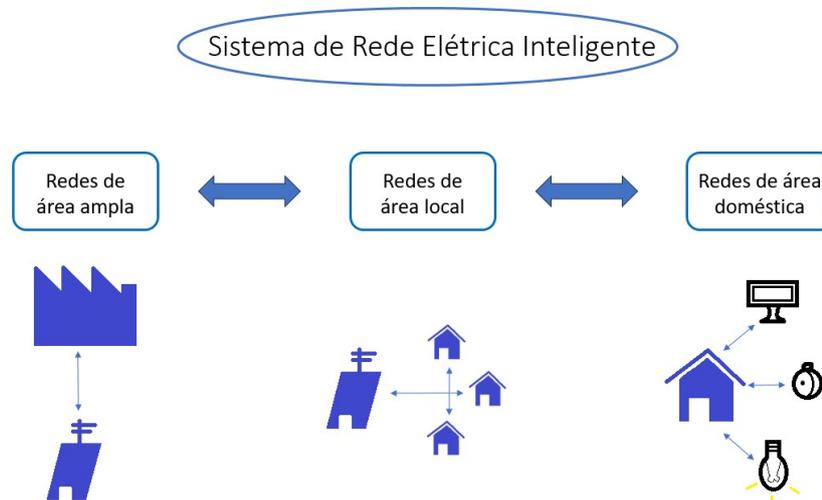


Figura 1: Divisão de uma rede elétrica inteligente em três segmentos.

Portanto, observa-se que o estabelecimento de uma rede de área apropriada para trocar informações entre medidores inteligentes e agregadores de dados é necessária para alcançar o potencial das REIs como proposta por diversos autores [8, 9, 10, 11, 12, 13, 14]. Logo, o problema de localização de agregadores de dados em REIs é de extrema importância para a implementação da mesma no futuro. Através da literatura, [5, 15, 16, 17, 18] nos motivou a pesquisar na área de REIs sobre a implantação e alocação de medidores e agregadores.

O desafio enfrentado neste trabalho é realizar a distribuição de medidores inteligentes e agregadores de dados em

um caminho que atenda o máximo de consumidores possíveis nas áreas de coberturas das redes elétricas inteligentes, com o menor custo. Desta forma, para solucionar esse problema, métodos de otimização baseado em metaheurísticas serão desenvolvidos e aplicados neste artigo. Utilizamos um algoritmo genético que tem sido utilizado a várias anos, para melhorar resultados de várias instâncias da literatura.

Em resumo, as principais contribuições deste trabalho em comparação a literatura, são descritas a seguir:

1. O primeiro atributo nesse trabalho é o uso de Algoritmo Genético ponderado para localização de agregadores de dados em redes elétricas inteligentes. Esse algoritmo proposto utiliza um balanço (uma ponderação de técnicas) entre a intensificação, a diversificação, a aleatoriedade e o uso de memória, conforme prevê a literatura [19]. Esses autores [19] descrevem que o sucesso de um algoritmo necessita de componentes que usam várias técnicas de otimização.
2. No segundo atributo, o algoritmo proposto é usado para selecionar os melhores candidatos de agregadores de dados para receber informações dos medidores inteligentes. Além disso, propomos um método para determinar o número apropriado de agregadores de dados que respeitam suas distâncias máximas de alcance dos sinais recebidos pelos medidores inteligentes.
3. No terceiro atributo, são respeitados o número de canais em que cada agregador de dados pode suportar, modelando para isso um custo associado a cada agregador.
4. No quarto atributo, um novo modelo matemático é proposto baseado em parâmetros elétricos de redes inteligentes. Nesse sentido, custos mínimos de aquisição de agregadores de dados por parte das concessionárias serão otimizados.
5. Por último, o desempenho do algoritmo proposto traz benefícios para as concessionárias de energia elétrica, consumidores e para implantação das cidades inteligentes, dado que as *smart grids* se inserem dentro do contexto dessas cidades.

Este artigo está organizado de forma que: na seção 2, são descritos os modelos matemáticos utilizados neste trabalho. A seção 3 detalha a metodologia usando o algoritmo genético e seu funcionamento. A seção 4 apresenta os resultados e discussões. A sessão 5 realiza uma comparação dos resultados obtidos coma literatura. Na última seção, as conclusões e as considerações finais são delineadas.

2 Modelo Matemático

O modelo matemático proposto para a localização de agregadores foi baseado no modelo do SCP (*Set Covering Problem*) para um problema de n agregadores de dados e m medidores inteligentes. Pode ser descrito pela função objetivo na Eq. (1) e as restrições dada pelas Eqs. (2), (3), (4) e (5). Logo, a formulação matemática é descrita a seguir:

Minimizar:

$$C = \sum_{j=1}^n c_j \cdot x_j \tag{1}$$

Sujeito a:

$$\sum_{j=1}^n a_{ij} \cdot x_j \geq 1 \quad i = 1, 2, 3...m \tag{2}$$

$$d_{ij} \cdot x_j \leq d_{max} \quad i = 1, 2, 3...m \quad ; \quad j = 1, 2, 3...n \tag{3}$$

$$nc_j \cdot x_j \leq nc_{max} \quad j = 1, 2, 3...n \tag{4}$$

$$x_j \in \{0, 1\} \quad j = 1, 2, 3...n \tag{5}$$

Sendo que \mathbf{x} é o vetor solução, com $x_j = 1$, se o agregador j pertence a solução e $x_j = 0$, caso contrário. Na Eq. (2), temos $a_{ij} = 1$ se o medidor i está na área de cobertura do agregador posicionado, por exemplo, num agregador j , caso contrário, $a_{ij} = 0$. Desta forma, teremos a matriz $\mathbf{A}_{m \cdot n}$, chamada matriz de cobertura para que cada medidor i seja pelo menos alocado a um agregador j . O \mathbf{c} é chamado de vetor de custos, sendo c_j , representa o custo de um agregador j . A Eq. (3) implica que d_{ij} é a distância de um medidor i que deverá estar a uma distância menor ou igual a distância máxima d_{max} em relação ao agregador j . Em que d_{max} representa o alcance máximo de comunicação de um agregador j aos medidores i ao seu redor. A Eq. (4) mostra que número de canais nc_j designados em cada agregador j deverá respeitar ao seu número máximo de canais nc_{max} possíveis que possam alocar os sinais recebidos dos diversos medidores ao seu redor. Por fim, a Eq. (5) são as variáveis de decisão de integralidades binárias.

3 Metodologia Proposta usando Algoritmo Genético

A metodologia proposta nesse trabalho utilizou Algoritmos Genéticos por ser um método eficiente para encontrar soluções de qualidade para problemas de otimização combinatória. Nesse sentido, para a realização deste trabalho, um programa foi desenvolvido na linguagem C, na plataforma de programação LabWindows™/CVI. Os resultados do algoritmo foram obtidos utilizando um computador com as seguintes características: 8GB RAM, Processador Intel® Core™i5-8300H e clock 2,30GHz, utilizando somente um núcleo.

Outro programa, desenvolvido por Biancardi e Mestria [20], foi usado para gerar instâncias de teste para este trabalho, disponibilizado pelos autores. O programa gera instâncias em acordo a parâmetros definidos pela literatura em: [2], [12], [16], [21] e [22]. Esses dados são salvos em um arquivo de texto para que possa ser extraído para o programa desenvolvido neste artigo. Em resumo, o programa gera de forma pseudoaleatória, a posição no eixo das abscissas e ordenadas para medidores inteligentes e agregadores de dados de acordo com a região planar desejada pelo usuário. Além disso, para os agregadores de dados, gera outras características como raio de distância máxima de comunicação com os medidores, número de canais disponíveis aos medidores ao seu redor quando o agregador estiver alocado, como descrito em Carniel e Mestria [5], no qual esses autores destacam os valores de quatro mil dólares por canal, mais um custo base de quarenta mil dólares.

Nesse sentido, enfatizamos que o Algoritmo Genético utilizado é uma técnica de busca para problemas de otimização, baseando-se nos princípios da evolução biológica e seleção natural. Tem-se que a população analisada é um conjunto de indivíduos, formados e caracterizados por conjuntos de cromossomos, e os cromossomos, por sua vez, formado por um conjunto de genes. Quando aplicado ao problema de alocação de agregadores de dados em redes elétricas inteligentes, os indivíduos são uma das soluções possíveis para o problema e os cromossomos mapeados em seus genótipos representam os agregadores de dados de um indivíduo que serão escolhidos ao longo do algoritmo. Cada gene possui conexão de um agregador no indivíduo associado aos possíveis medidores selecionados.

Assim, o Algoritmo Genético, se subdivide nas etapas: (1) Criação da população inicial; (2) Avaliação, em que é avaliado o desempenho de um indivíduo através de uma função de avaliação denominada *fitness*; (3) Cruzamento, em que os indivíduos selecionados realizam uma troca de genes; (4) Mutação, em que indivíduos podem sofrer uma mudança aleatória nos genes; E por fim, (5) Seleção, em que são escolhidos os indivíduos de maior aptidão através do *fitness*. Mais ainda, um ciclo desse processo para todos os indivíduos de uma população, denominado de geração, será estabelecido. Este ciclo se repete até que o limite máximo de gerações, determinado pelo usuário do programa.

3.1 População Inicial

Utilizando-se o programa computacional para geração de instâncias, desenvolvido por Biancardi e Mestria [20], cria-se um conjunto destes dados, que serão usados para a criação da população inicial. Através de uma interface, definem-se os parâmetros do algoritmo e requisita que o usuário insira qual instância com medidores e agregadores deseja utilizar para a criação da população inicial. Em seguida, requisita a quantidade de indivíduos (soluções possíveis) nesta população e a quantidade de cromossomos que representará esses indivíduos (que é a representação dos agregadores). Por fim, o algoritmo exige o limite máximo de gerações que o programa irá executar. Após os parâmetros serem definidos, o algoritmo delega quais agregadores serão associados às quais indivíduos através de uma metodologia pseudoaleatória, garantindo que indivíduos sejam distintos mesmo com a utilização dos mesmos parâmetros. Finalmente, a população inicial é criada.

3.2 Avaliação

Na etapa de avaliação, as soluções possíveis são avaliadas através do custo total da solução, e por funções de *fitness*, que determinam a aptidão de uma solução. Consideram-se duas funções para a avaliação da solução, apresentadas nas Eqs. (6) e (7).

$$fit_{1j} = \sum_{k=1}^{n_j} p_1 \cdot \frac{1}{c_{j,k}} \quad (6)$$

$$fit_{2j} = \sum_{k=1}^{n_j} p_2 \cdot \frac{1}{d_{j,k}} \quad (7)$$

Em que:

- $c_{j,k}$ é o custo de um agregador k de certo indivíduo j
- $d_{j,k}$ é a distância entre um agregador k (de um certo indivíduo j) e o medidor associado a tal agregador k
- n_j é a quantidade de agregadores que pertencem ao indivíduo j

- p_1 um parâmetro inserido que prioriza os custos dos agregadores
- p_2 um parâmetro inserido que prioriza as distâncias entre os agregadores e os medidores

Os parâmetros $p_1 = 80$ e $p_2 = 10$ foram calibrados após dezenas de testes com um conjunto de instâncias. Além disso, foi calculado o *fitness* total F na geração, que é mostrada na Eq. (8).

$$F = \sum_{j=1}^g fit_{1_j} + fit_{2_j} \tag{8}$$

Sendo g a quantidade de indivíduos. Nota-se que valores menores para $c_{j,k}$ e $d_{j,k}$ são desejáveis, pois indicam, respectivamente, menor custo da solução, e menor distância entre agregador e consumidor. Portanto, quanto maior o valor *fitness* de uma solução, maior sua aptidão. A solução também é avaliada a partir de seu custo total dos agregadores de dados selecionados, de forma independente, sendo a maior preocupação no estabelecimento de uma REI devido ao alto custo de agregadores segundo Carniel e Mestria [5].

3.3 Cruzamento

Na etapa de Cruzamento ou Recombinação, são usados operadores de cruzamento, nos quais esses operadores reorganizam ou trocam parte dos genes entre dois indivíduos para criar duas novas soluções potenciais. Portanto, pares de soluções filhos são criados a partir de pares de soluções pais. Os alelos gerados por meio dos pontos de corte dos genes, foram escolhidos de forma pseudoaleatória. Nota-se que se o par de soluções pais for uma solução viável, o par de soluções filhos também será. A Fig. 2 demonstra este processo.

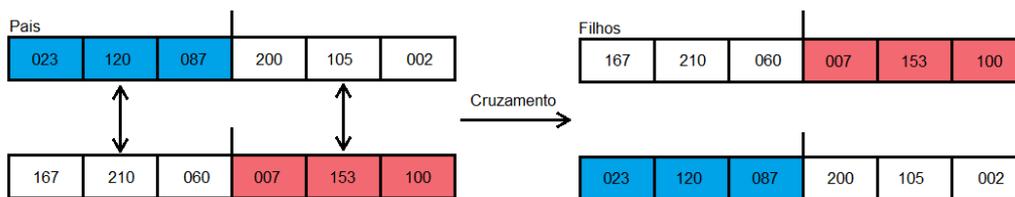


Figura 2: Criação de indivíduos filhos por indivíduos pais através do processo de Cruzamento.

3.4 Mutação

Após a etapa de cruzamento, existe uma pequena chance de que os genes dos indivíduos filhos sofram uma alteração aleatória, chamada de mutação. Esta etapa emula a evolução biológica, em que a mutação serve para introduzir diversidade na população, evitando a convergência prematura para possíveis soluções subótimas. Da mesma forma, foi introduzida uma porcentagem para que ocorra uma mutação no gene de um indivíduo. A Fig. 4 demonstra este processo.

3.5 Seleção

A seleção é feita no final da geração atual, os pares de soluções filhos são avaliadas e comparadas com os pares de soluções pais, selecionando-se os indivíduos com melhores resultados para fazerem parte da próxima geração, este processo descrito como elitismo por Gaspar-Cunha et al. [23] serve para preservar indivíduos que possuam valores de *fitness* elevados. Os resultados da melhor solução da geração atual são armazenados e impressos no arquivo de saída. A Fig. 3 mostra as etapas do Algoritmo Genético através de um fluxograma.

4 Resultados e Discussão

Os resultados do algoritmo são escritos em arquivo de texto, contendo o valor do *fitness* e o preço de cada agregador de um indivíduo, assim como o *fitness* e o custo total do indivíduo. No fim da geração, o valor do *fitness* e o valor da função objetivo naquela geração também são escritos num arquivo texto, como mostra a Fig. 5. Observa-se na Fig. 5 que nem todos os agregadores foram escolhidos.

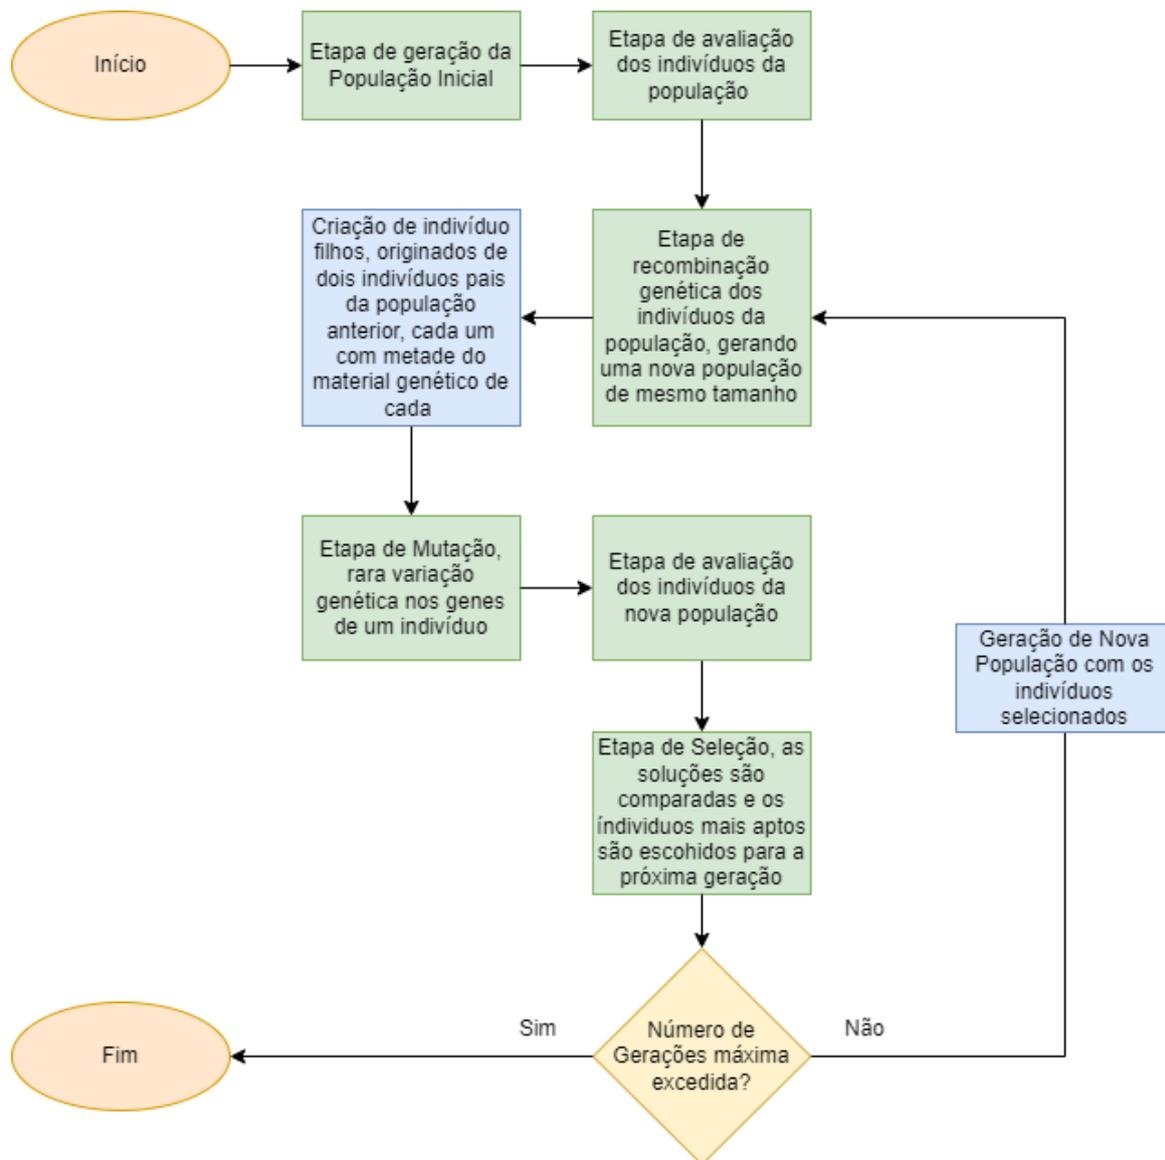


Figura 3: Fluxograma das etapas do Algoritmo Genético.

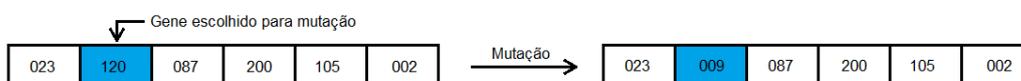


Figura 4: Mutaçao de um indivíduo.

Algoritmos Genéticos possuem natureza estocástica e nesse sentido vários experimentos foram realizados. Com isso, é possível ver o desempenho desse algoritmo desenvolvido. Para cada instância, o algoritmo foi executado 5 vezes com os mesmos parâmetros descritos anteriormente. Nesse sentido a média da função objetivo foi avaliada. O número de gerações, o tamanho da população, o cruzamento e taxa de mutação foram selecionados a partir de vários testes computacionais com algumas instâncias selecionadas de forma aleatória. No entanto, a seleção dos pais utilizou o elitismo conforme sugere o trabalho de Gaspar-Cunha et al. [23]. A população inicial alocou para cada indivíduo que os agregadores de dados sejam designados de forma pseudoaleatória aos medidores. As instâncias utilizadas para obtenção de resultados são conjuntos de instâncias utilizados por Biancardi e Mestria [20], e estão presentes nas Tabelas 1 e 2.

```

Individuo 10
Agregador 61. Custo: 68. Fitness: 0.293
Agregador 146. Custo: 76. Fitness: 0.047
Agregador 42. Custo: 68. Fitness: 0.132
Agregador 191. Custo: 72. Fitness: 0.107
Agregador 75. Custo: 68. Fitness: 0.916
Agregador 78. Custo: 72. Fitness: 0.143
Agregador 97. Custo: 68. Fitness: 0.242
Agregador 139. Custo: 76. Fitness: 3.065
Agregador 127. Custo: 80. Fitness: 0.154
Agregador 190. Custo: 80. Fitness: 0.125
Agregador 56. Custo: 80. Fitness: 0.068
Agregador 195. Custo: 68. Fitness: 0.077
Agregador 154. Custo: 76. Fitness: 0.117
Agregador 12. Custo: 64. Fitness: 0.064
Agregador 69. Custo: 64. Fitness: 0.886
Agregador 155. Custo: 68. Fitness: 0.215
Agregador 98. Custo: 76. Fitness: 0.279
Agregador 185. Custo: 72. Fitness: 0.603
Agregador 197. Custo: 68. Fitness: 0.597
Agregador 76. Custo: 68. Fitness: 0.418
Custo total do individuo 10: 1432
Fitness total do individuo 10: 8.550

Custo final da geração 1: 13192.000

Fitness final da geração 1: 69.197
    
```

Figura 5: Trecho dos resultados de saída do programa.

Tabela 1: Instâncias utilizadas para agregadores.

Nº de Agregadores
200
210
220
240
250
260
270
280

As instâncias das Tabelas 1 e 2 foram usadas para testes computacionais do Algoritmo Genético. Os testes foram realizados com as condições de parada para 10, 20, e 30 gerações e com população inicial igual a 10. Os resultados dos testes se encontram nas Tabelas 3 e 4.

Observa-se que, em geral, uma condição de parada maior resulta na diminuição do custo da solução, porém, também implica num tempo de execução maior não significativo. O tempo computacional médio de execução do Algoritmo Genético foi sempre menor do que 1 segundo. Outro parâmetro a ser avaliado é a população inicial para agregadores de 200, 210, 220, 240, 250, 260, 270 e 280. Foram realizados novamente testes computacionais com população inicial igual a 20. Os resultados destes testes se encontram nas Tabelas 5 e 6.

Tabela 2: Instâncias utilizadas para medidores.

Nº de Medidores
600
700

Tabela 3: Custo da solução, em milhares de dólares, para a instância de 600 medidores.

Instância agregadores	Função objetivo com 10 gerações	Função objetivo com 20 gerações	Função objetivo com 30 gerações
200	12973,60	12816,00	12849,20
210	12987,20	12920,60	12896,80
220	12956,80	12956,80	12924,00
240	13728,80	13649,20	13635,20
250	14527,80	14484,20	14452,60
260	15243,20	15210,40	15092,00
270	15524,00	15512,60	15473,40
280	15996,80	15971,20	15955,20

Tabela 4: Custo da solução, em milhares de dólares, para a instância de 700 medidores.

Instância agregadores	Função objetivo com 10 gerações	Função objetivo com 20 gerações	Função objetivo com 30 gerações
200	13160,00	13019,20	12997,60
210	13260,20	13142,8	13018,4
220	14142,40	14072,80	14044,00
240	14934,40	14892,00	14887,20
250	15098,20	15020,40	14964,00
260	16040,80	15879,60	15764,7
270	16124,60	15959,20	15723,20
280	16352,80	16308,60	16244,80

Percebe-se que comparando os custos das soluções das Tabelas 5 e 6 com as Tabelas 3 e 4, os resultados dos testes com população inicial igual a 20 tendem a ser maiores, com algumas exceções (em que uma população inicial maior diminuiu o custo da solução). Uma das hipóteses levantada como consequências do aumento dos custos na função objetivo após aumentar a população inicial, é uma quantidade maior de indivíduos que sofreram mutações. Desta forma, as gerações sofreram maior diversificação entre os indivíduos, em vez de intensificação.

Os dados das Tabelas 3, 4, 5 e 6 foram usados nas Figs. 6, 7, 8 e 9 respectivamente, que demonstram uma comparação entre os resultados das diferentes gerações utilizando o gráfico BloxPlot.

Observa-se, nas Figs. 6 e 7, com as instâncias de 600 e 700 medidores juntos aos agregadores de dados que variam entre 200 e 280 unidades, para o algoritmo com população inicial igual a 10 e número de gerações com valor 30, os resultados computacionais foram melhores. Isso se explica por haver maior número de intensificação nas diversas soluções geradas pelo algoritmo.

No entanto, quando aumenta o número da população inicial de 10 para 20 e variando o número de gerações

Tabela 5: Custo da solução, em milhares de dólares, para a instância de 600 medidores, população inicial igual a 20.

Instância agregadores	Função objetivo com 10 gerações	Função objetivo com 20 gerações	Função objetivo com 30 gerações
200	13017,60	12987,20	12968,00
210	13008,20	12954,60	12912,80
220	12988,00	12946,20	12918,80
240	13835,20	13747,20	13732,00
250	14584,40	14538,20	14520,60
260	15726,80	15682,40	15360,00
270	15784,60	15554,00	15436,20
280	16057,60	16009,20	16002,20

Tabela 6: Custo da solução, em milhares de dólares, para a instância de 700 medidores, população inicial igual a 20.

Instância agregadores	Função objetivo com 10 gerações	Função objetivo com 20 gerações	Função objetivo com 30 gerações
200	13146,40	13097,60	13093,60
210	13486,20	13428,20	13378,40
220	14558,40	14520,00	14426,80
240	14980,80	14932,80	14886,40
250	15064,20	15024,60	14986,20
260	16154,60	16028,40	15928,00
270	15640,00	15480,20	15276,40
280	16477,60	16340,00	16313,40

entre 10 e 30, o algoritmo tende a ter mais diversificação nos cromossomos. Isso implica que o algoritmo tenha comportamento diferenciado, como pode ser visto nas Figs. 8 e 9 para as instâncias com 600 e 700 medidores (com agregadores entre 200 e 280).

De acordo com os trabalhos de Blum e Roli [24] e Blum et al. [25], um método metaheurístico necessita de um equilíbrio entre intensificação, diversificação, aleatoriedade e uso de memória. Ressalta-se que o Algoritmo Genético desenvolvido por esse trabalho: (1) usou da intensificação, por ser executado o algoritmo por várias gerações escolhendo os melhores indivíduos; (2) da diversificação por meio da população inicial e da mutação; (3) de elementos aleatórios por meio da população inicial, cruzamento e mutação; (4) por último, do uso de memória, em que os indivíduos passam de uma geração para outra seus alelos, e assim carrega parte do cromossomo na solução; por fim, destaca-se que os **tempos computacionais médios de execução do Algoritmo Genético para todas as instâncias são menores do que 1 segundo**. Assim, esses tempos não foram dispostos nas tabelas nos resultados computacionais pode serem muito pequenos.

5 Comparação com a Literatura

Para verificar o desempenho do Algoritmo Genético com a base de dados das instâncias avaliadas nesse trabalho foi utilizado um algoritmo desenvolvido recentemente [20]. Assim, é possível fazer uma comparação com a mesma base de dados e avaliar a robustez do algoritmo proposto. Compara-se os resultados obtidos por Biancardi e Mestria [20] nas Tabelas 7 e 8 e percebe-se que houve uma redução no custo das soluções. Porém, o tempo computacional médio do Algoritmo kNN de Biancardi e Mestria [20] é próximo de 0,01 segundos

Para uma maior análise comparativa entre os resultados, a Fig. 10 demonstra o melhor resultado obtido das

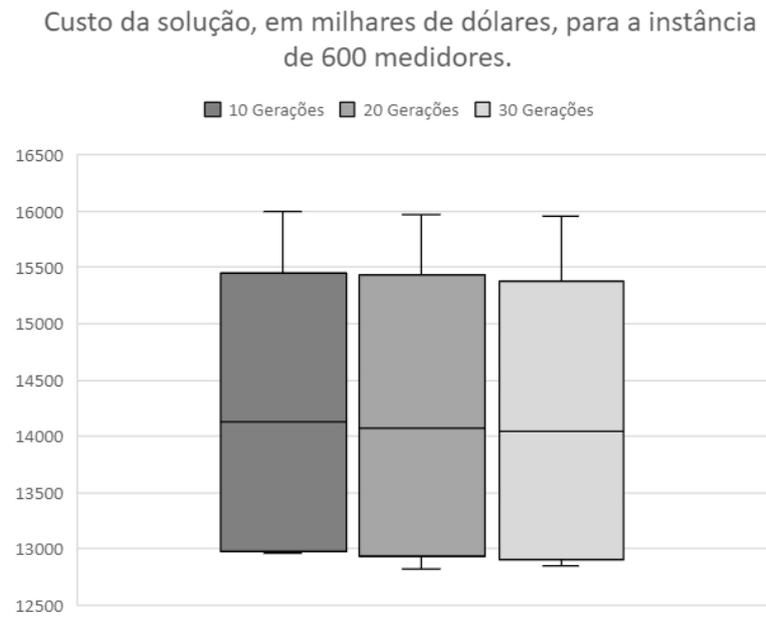


Figura 6: Gráfico BloxPlot, demonstrando a diferença entre custos de soluções de 600 medidores.



Figura 7: Gráfico BloxPlot, demonstrando a diferença entre custos de soluções de 700 medidores.

Tabelas 3, 5 e 7, para o número de medidores igual a 600. Enquanto que, a Fig. 11 demonstra uma comparação do melhor resultado obtido das Tabelas 4, 6 e 8, para número de medidores igual a 700.

Na comparação com a literatura, as Figs. 10 e 11 mostram que os resultados computacionais obtidos pelo algoritmo desenvolvido nesse trabalho foram melhores com os seguintes parâmetros: população inicial igual a 10 e número de gerações com valor 30. Fica claro que o equilíbrio entre a intensificação e a diversificação deva ser calibrada para que algoritmos possam gerar soluções de boa qualidade.

Novamente, destaca-se que o Algoritmo Genético desenvolvido apresenta tempos computacionais para encontrar a melhor solução sempre menor do que 1 segundo. Os testes com o algoritmo kNN foram executados nas mesmas

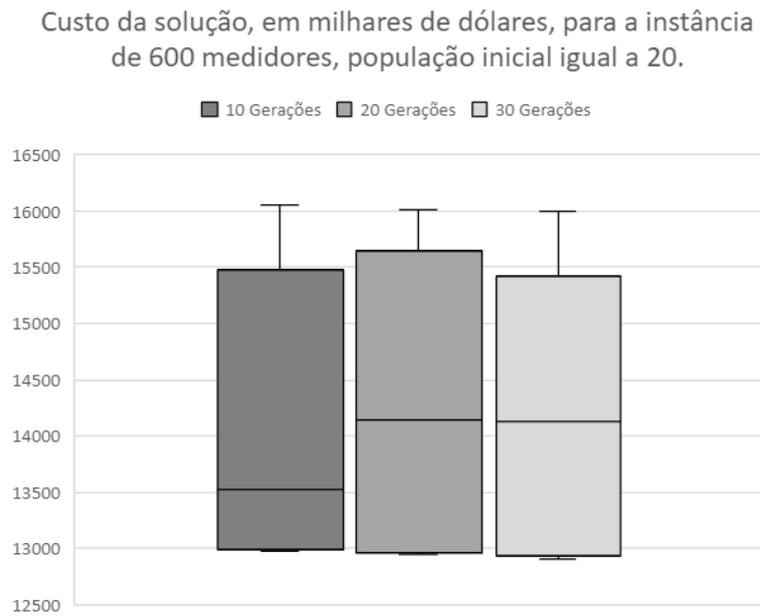


Figura 8: Gráfico BloxPlot, demonstrando a diferença entre custos de soluções de 600 medidores, população inicial igual a 20.

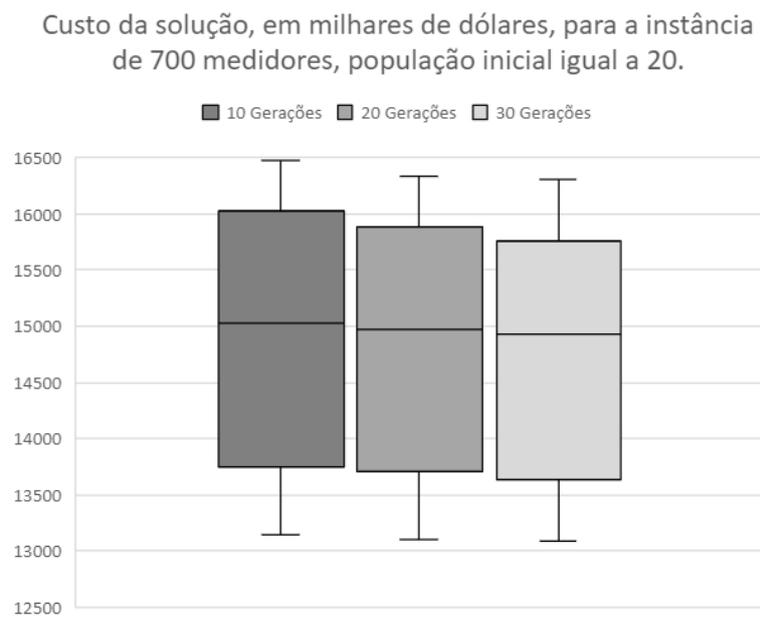


Figura 9: Gráfico BloxPlot, demonstrando a diferença entre custos de soluções de 700 medidores, população inicial igual a 20.

condições computacionais que Algoritmo Genético, um computador com os atributos: 8GB RAM, Processador Intel® Core™i5-8300H e clock 2,30GHz, com uso de um único núcleo.

Tabela 7: Custo da solução, em milhares de dólares, para a instância de 600 medidores para diversos valores de k [20].

Instância agregadores	k igual a 4	k igual a 5	k igual a 6	k igual a 7	k igual a 8	k igual a 9	k igual a 10
200	13496*	13064	12996	12932	12932	12932	12932
210	14100*	13888*	13516*	13444*	13444*	13444	13444
220	14084*	13688*	13688*	13116	12972	12972	12972
240	14464*	14104	13976	13660	13660	13660	13660
250	15268	14920	14848	14640	14560	14560	14560
260	16104	15672	15472	15396	15320	15320	15320
270	16180*	15824*	15616	15616	15544	15544	15544
280	16392	16132	16132	16060	16060	16060	16060

Tabela 8: Custo da solução, em milhares de dólares, para a instância de 700 medidores para diversos valores de k [20].

Instância agregadores	k igual a 4	k igual a 5	k igual a 6	k igual a 7	k igual a 8	k igual a 9	k igual a 10
200	14092*	13680	13256	13256	13176	13176	13176
210	14516*	14004*	13780*	13480*	13480*	13404*	13404*
220	15088*	14500*	14148	14148	14148	14072	14072
240	15908*	15408	14976	14900	14900	14900	14900
250	16356	15484	15340	15104	15104	15104	15104
260	17328	16564	16268	16120	16120	16120	16120
270	15968*	15968*	15900	15900	15900	15900	15900
280	17144*	16704	16420	16420	16348	16284	16284

6 Conclusão e Considerações Finais

Os resultados computacionais alcançados nesse trabalho demonstraram que o Algoritmo Genético para o problema de alocação de agregadores de dados em redes elétricas inteligentes apresenta boas soluções quando é comparado com os resultados da literatura. O uso do Algoritmo Genético se demonstrou adequado para problemas de diferentes portes através do aumento da condição de parada, permitindo que o Algoritmo Genético se aproxime de uma solução ótima à medida que o número de gerações aumenta.

Logo, o Algoritmo Genético apresenta maior escalabilidade, sendo indicado para a implementação de comunicações em uma REI [6]. O trabalho também colabora para implantação das cidades inteligentes dentro do contexto das *smart grids* [13]. Além disso, esse trabalho tem como objetivo, incorporar infraestruturas modernas utilizando a IMA como suporte nas redes elétricas convencionais na geração, na distribuição e no consumo de energia. Nesse sentido, as redes elétricas convencionais caminha para as redes elétricas inteligentes.

O trabalho assessora na integração de novas tecnologias, na inserção de recursos energéticos renováveis principalmente na área residencial com uso de energia fotovoltaica e na implantação de dispositivos de armazenamento de energia ao nível da rede. Tudo isso necessita de coletar informações dos parâmetros elétricos das redes. A inserção de veículos elétricos e a interligação com microrredes e prossumidores, também afetam as redes elétricas com utilização de dispositivos eletrônicos de potência em diferentes fases. Isso também necessita de coleta de informações por medidores inteligentes.

Destaca-se ainda, que o Algoritmo Genético para o problema de alocação de agregadores de dados em redes elétricas inteligentes obteve bom desempenho para diferentes instâncias de vários portes. Nesse sentido, os resultados computacionais se aproximam das soluções ótimas quando vários testes são realizados com condições diferentes de

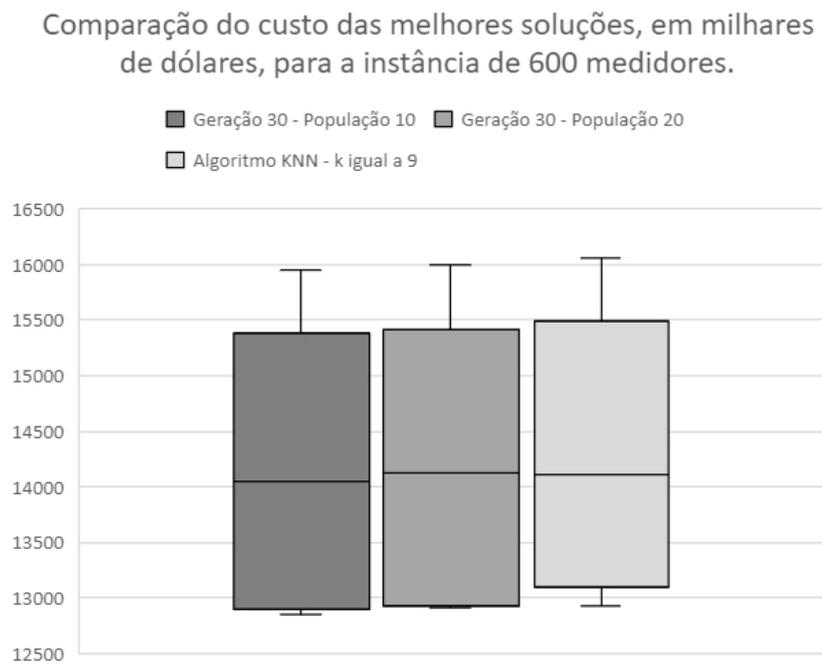


Figura 10: Gráfico BloxPlot, Comparação do custo das melhores soluções, em milhares de dólares, para a instância de 600 medidores.

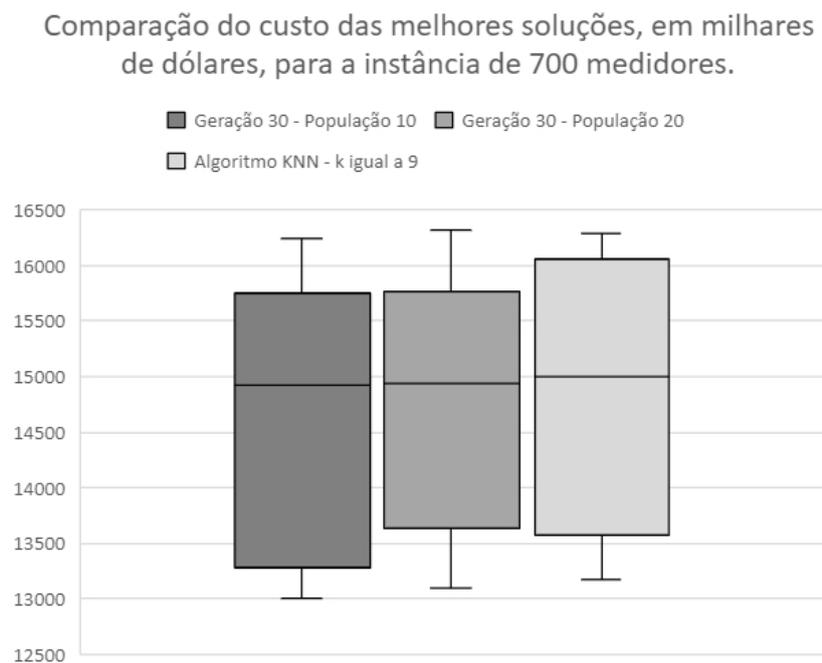


Figura 11: Gráfico BloxPlot, Comparação do custo das melhores soluções, em milhares de dólares, para a instância de 700 medidores.

parada (números de gerações).

As limitações impostas nesse trabalho considerou não haver obstáculos entre os dispositivos medidores e agregadores, comum em ambientes urbanos. Outra limitação foi considerar que os agregadores de dados estarão funcionado

24 horas por dia em sete dias na semana. Havendo pane em um dos agregadores poderá afetar a comunicação entre os medidores inteligentes e as concessionárias de energia elétrica.

Como trabalho futuro, um algoritmo a ser desenvolvido deverá incorporar mais funcionalidades para sanar as limitações descritas anteriores. No caso da primeira limitação, pode o algoritmo impor uma penalização entre a distância Euclidiana dos medidores aos agregadores mais próximo. Isso impõem uma situação de obstáculo entre esses dispositivos. Na situação de pane, o algoritmo pode incorporar programação dinâmica utilizando como dado de entrada os agregadores disponíveis na hora de execução. O algoritmo mantém parte da solução encontrada previamente em memória, de forma a evitar recálculo. Nesse caso, o algoritmo considerará no recálculo em encontrar a nova solução, somente com os medidores operantes na rede elétrica inteligente que foram afetados nessa pane .

Agradecimentos

Esse trabalho teve o apoio institucional do Ifes por meio do editais do Programa Institucional de Bolsas de Iniciação em Desenvolvimento Tecnológico e Inovação (Pibiti - 2022 e 2024), projeto PJ 5526 e plano de trabalho PT 10694 e por meio de bolsa promovida pelo edital FAPES nº10/2022 - PIBICES 2022.

Referências

- [1] CGEE, *Redes Elétricas Inteligentes: Contexto Nacional*. Centro de Gestão e Estudos Estratégicos, CGEE, 2012, vol. 16, cap. 1, 172 p. Disponível em: https://www.cgee.org.br/documents/10195/11009594/Redes_Eletricas_Inteligentes__22mar13_9539.pdf/36f87ff1-43ed-4f33-9b53-5c869ace9023?version=1.6
- [2] G. Rolim, D. Passos, C. Albuquerque, e I. Moraes, “Moskou: A heuristic for data aggregator positioning in smart grids,” *IEEE Transactions on Smart Grid*, vol. 9, no. 6, pp. 6206–6213, 2018. Disponível em: <https://doi.org/10.1109/TSG.2017.2706962>
- [3] M. Shokry, A. I. Awad, M. K. Abd-Ellah, e A. A. Khalaf, “Systematic survey of advanced metering infrastructure security: Vulnerabilities, attacks, countermeasures, and future vision,” *Future Generation Computer Systems*, vol. 136, pp. 358–377, 2022. Disponível em: <https://doi.org/10.1016/j.future.2022.06.013>
- [4] S. L. Qaddoori e Q. I. Ali, “An embedded and intelligent anomaly power consumption detection system based on smart metering,” *IET Wireless Sensor Systems*, vol. 13, no. 2, pp. 75–90, 2023. Disponível em: <https://doi.org/10.1049/wss2.12054>
- [5] A. Z. Carniel e M. Mestria, “Um algoritmo de otimização por reações químicas para alocação de unidades de medição fasorial,” em *XXI Encontro Nacional de Modelagem Computacional e IX Encontro de Ciência e Tecnologia de Materiais*, 2018. Disponível em: <https://editoraessentia.iff.edu.br/index.php/enmcectm/article/view/12173/9610>
- [6] E. Fadel, V. Gungor, L. Nassef, N. Akkari, M. A. Malik, S. Almasri, e I. F. Akyildiz, “A survey on wireless sensor networks for smart grid,” *Computer Communications*, vol. 71, pp. 22–33, 2015. Disponível em: <https://doi.org/10.1016/j.comcom.2015.09.006>
- [7] V. C. Gungor, B. Lu, e G. P. Hancke, “Opportunities and challenges of wireless sensor networks in smart grid,” *IEEE Transactions on Industrial Electronics*, vol. 57, no. 10, pp. 3557–3564, 2010. Disponível em: <https://doi.org/10.1109/TIE.2009.2039455>
- [8] M. R. Hossain, A. M. T. Oo, e A. B. M. S. Ali, *Smart Grid*. London: Springer London, 2013, pp. 23–44. Disponível em: https://doi.org/10.1007/978-1-4471-5210-1_2
- [9] A. Naamane e N. Msirdi, “Towards a smart grid communication,” *Energy Procedia*, vol. 83, pp. 428–433, 2015, sustainability in Energy and Buildings: Proceedings of the 7th International Conference SEB-15. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1876610215028271>
- [10] T. Zhen, T. Elgindy, S. M. S. Alam, B. Hodge, e C. D. Laird, “Optimal placement of data concentrators for expansion of the smart grid communications network,” *IET Smart Grid*, vol. 2, no. 4, 8 2019. Disponível em: <https://www.osti.gov/biblio/1742051>
- [11] B. O. Palate, T. P. Guedes, A. Grilo-Pavani, A. Padilha-Feltrin, e J. D. Melo, “Aggregator units allocation in low voltage distribution networks with penetration of photovoltaic systems,” *International Journal of Electrical Power & Energy Systems*, vol. 130, p. 107003, 2021. Disponível em: <https://doi.org/10.1016/j.ijepes.2021.107003>

- [12] H.-C. Hsu, S.-R. Zhuang, e Y.-F. Huang, “Cost-effective data aggregation method for smart grid,” *Electronics*, vol. 10, no. 23, 2021. Disponível em: <https://www.mdpi.com/2079-9292/10/23/2911>
- [13] M. M. Jaber, M. H. Ali, S. CB, R. R. Asaad, R. Agrawal, B. Bizu, e I. Sanz-Prieto, “Future smart grids creation and dimensionality reduction with signal handling on smart grid using targeted projection,” *Sustainable Computing: Informatics and Systems*, vol. 39, p. 100897, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2210537923000525>
- [14] J. P. Astudillo León, C. L. Duenas Santos, A. M. Mezher, J. Cárdenas Barrera, J. Meng, e E. Castillo Guerra, “Exploring the potential, limitations, and future directions of wireless technologies in smart grid networks: A comparative analysis,” *Computer Networks*, vol. 235, p. 109956, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1389128623004012>
- [15] G. R. Breda e M. Mestria, “Expansão otimizada e sustentável de uma rede de distribuição elétrica utilizando métodos heurísticos,” em *Anais Do Encontro Nacional de Engenharia de Produção*, 2020. Disponível em: https://doi.org/10.14488/enegep2020_tn_sto_344_1765_39484
- [16] S. N. Lumar, T. R. de Oliveira, e M. Mestria, “Problema de alocação de agregador de dados em redes elétricas inteligentes,” *Revista SODEBRAS*, vol. 15, no. 179, pp. 98–104, 2020. Disponível em: <https://doi.org/10.29367/issn.1809-3957.15.2020.179.98>
- [17] J. Yang, Y. Zhang, Y. Yuan, K. Ma, e J. Li, “Energy trading and power allocation strategies for relay-assisted smart grid communications: A three-stage game approach,” *IEEE Transactions on Mobile Computing*, vol. 22, no. 12, pp. 7438–7450, 2023. Disponível em: <https://doi.org/10.1109/TMC.2022.3211408>
- [18] S. Ramisetty, D. Anand, Kavita, S. Verma, N. Z. Jhanjhi, M. Masud, e M. Baz, “Energy efficient unequal fault tolerance clustering approach,” *Computer Systems Science and Engineering*, vol. 45, no. 2, pp. 1971–1983, 2023. Disponível em: <https://doi.org/10.32604/csse.2022.021924>
- [19] C. Blum e A. Roli, *Hybrid Metaheuristics: An Introduction*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008, pp. 1–30. Disponível em: https://doi.org/10.1007/978-3-540-78295-7_1
- [20] G. Biancardi e M. Mestria, “Um algoritmo de otimização para alocar medidores inteligentes e agregadores de dados em redes elétricas inteligentes,” *Revista SODEBRAS*, vol. 17, no. 204, pp. 1241–1251, 2022. Disponível em: <https://doi.org/10.29367/issn.1809-3957.17.2022.204.58>
- [21] F. Aalamifar, G. N. Shirazi, M. Noori, e L. Lampe, “Cost-efficient data aggregation point placement for advanced metering infrastructure,” em *2014 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 2014, pp. 344–349. Disponível em: <https://doi.org/10.1109/SmartGridComm.2014.7007670>
- [22] T. Alquthami, A. Alamoudi, A. Alsubaie, A. Jaber, N. Alshlwan, M. Anwar, e S. Husaien, “Analytics framework for optimal smart meters data processing,” *Electrical Engineering*, vol. 102, 09 2020. Disponível em: <https://doi.org/10.1007/s00202-020-00949-0>
- [23] A. Gaspar-Cunha, R. Takahashi, e C. Antunes, *Manual de computação evolutiva e metaheurística*, ser. Ensino. Imprensa da Universidade de Coimbra / Coimbra University Press, 2012. Disponível em: <https://books.google.com.br/books?id=9Di5CwAAQBAJ>
- [24] C. Blum e A. Roli, “Metaheuristics in combinatorial optimization: Overview and conceptual comparison,” *ACM Comput. Surv.*, vol. 35, no. 3, p. 268–308, sep 2003. Disponível em: <https://doi.org/10.1145/937503.937505>
- [25] C. Blum, J. Puchinger, G. R. Raidl, e A. Roli, “Hybrid metaheuristics in combinatorial optimization: A survey,” *Applied Soft Computing*, vol. 11, no. 6, pp. 4135–4151, 2011. Disponível em: <https://doi.org/10.1016/j.asoc.2011.02.032>