

## **Problema de localização de facilidades em Smart Grids**

## **Facility location problem in Smart Grids**

---

**Aileen Zancanaro Carniel**

*Programa de Pós-Graduação em Tecnologias Sustentáveis – Campus Vitória  
Instituto Federal do Espírito Santo (IFES), Vitória, ES*

**Yngrith Soares da Silva**

*Coordenadoria de Engenharia Elétrica – Campus Vitória  
Instituto Federal do Espírito Santo (IFES), Vitória, ES*

**Mário Mestria**

*Coordenadoria de Engenharia Elétrica – Campus Vitória  
Programa de Pós-Graduação em Tecnologias Sustentáveis  
Instituto Federal do Espírito Santo (IFES), Vitória, ES*

DOI: 10.47573/aya.88580.2.39.1

# Resumo

---

Nas redes elétricas inteligentes tornam capazes as tecnologias como medidores inteligentes, veículos elétricos, redes de sensores, dentre outras facilidades serem importantes em escopos de pesquisas futuras. Assim, é necessário explorar a medição e a comunicação de redes inteligentes usando unidades de medição fasorial, sistemas de medição de área ampla e infraestrutura avançada de medição. Além de equipamentos como dispositivos eletrônicos inteligentes, medidores inteligentes e sensores inteligentes. Neste contexto, apresentamos modelos matemáticos de localização de facilidades com o objetivo de apoiar os tomadores de decisão nas categorias em medição avançada e infraestrutura de veículos elétricos. Para resolver esses modelos, propusemos os algoritmos baseados na metaheurística Otimização por Reação Química. Os testes foram realizados em banco de dados da literatura e em casos do mundo real. Os resultados computacionais mostraram a eficiência dos algoritmos propostos.

**Palavras-chave:** localização de facilidades. otimização combinatória. otimização por reação química. redes elétricas inteligentes. sustentabilidade.

# Abstract

---

In smart grids make able technologies as smart meters, electric vehicle, sensor networks, and other facilities, to be important in future research scopes. Thus, are necessary explored in smart grids the metering and the communication using phasor measurement units, the wide area measurement systems and the advanced metering infrastructure. Beyond equipment as intelligent electronic devices, smart meters and smart sensors. In this context, we present math models of facility location with the objective to support decision makers in the categories in advanced metering and electric vehicle infrastructure. To solve these models, we have proposed the algorithms based in the Chemical Reaction Optimization (CRO) metaheuristic. The tests were performed on the existing literature database and in real world cases. The computational results showed the efficiency of the proposed algorithms.

**Keywords:** facility location. combinatorial optimization. chemical reaction optimization. smart grids. sustainability.

Pesquisadores e engenheiros estão enfrentando o desafio de reduzir as perdas inerentes aos processos de distribuição e transmissão das redes elétricas tradicionais. A solução parece estar num novo conceito de rede, chamando de redes inteligentes (smart grids) que se baseia em novas tecnologias (CARDENAS; GEMOETS; ROSAS; SARFI, 2014), tais como: distribuição eficiente de energia com a inclusão de eletrônicos de estado sólido de última geração; utilização de recursos renováveis para gerar eletricidade; participação dos consumidores no processo pela geração e/ou conservação de energia; retorno aos consumidores e aos serviços públicos sobre o consumo em tempo real através de medidores inteligentes; uso de baterias de veículos elétricos (VE) para armazenar e distribuir energia em domicílios e distribuir recursos energéticos.

O conceito de energia inteligente abrange uma gama de questões de pesquisa, como: controle distribuído, detecção de falhas, previsão, estabilidade da rede e resposta à demanda, e assim, smart grid é uma área multidisciplinar que apresenta muitos desafios (NAAMANE e MSIRDI, 2015). Segundo IEA (2019) algumas tecnologias associadas as smart grids estão sendo efetivadas e outras em etapas de desenvolvimento.

As smart grids agregam diversas tecnologias desde a geração até a distribuição, passando pelo consumo e armazenamento da energia elétrica. Na Figura 1 mostra uma descrição das tecnologias das smart grids organizadas por categoria, equipamentos de hardware e software correspondentes. Nesse sentido, decisões de longo prazo e curto prazo devem ser entregues aos tomadores de decisões, sejam com aplicações offline ou online.

O foco desse trabalho é apresentar modelos matemáticos de otimização para problemas de localização de facilidades numa smart grids associadas às categorias: (1) infraestrutura de medição avançada e (2) infraestrutura de carregamento de VE.

Em Almeida e Fettermann (2019), destaca que o uso de medidores inteligentes ainda é muito incipiente no Brasil, resultando em altos custos para as concessionárias na realização de coleta de dados de consumo no país.

Em Santos e Silva (2019) apresenta os desafios da implantação da sustentabilidade no transporte público nos quais estão relacionados à redução dos níveis de poluição e ruídos, promoção do crescimento econômico, redução dos níveis de congestionamento, minimização dos acidentes e mortes, dentre outros.

Figura 1 - Descrição das categorias das tecnologias de uma Rede Elétrica Inteligente.

<b>Categoria</b>	<b>Hardware</b>	<b>Software</b>
Monitoramento e controle de longas áreas	Sensores	Sistemas SCADA, WAMS, WAAPCA e WASA
Integração de informação e comunicação	Equipamentos para comunicação (PLC, WIMAX, LTE, RF mesh, Celular), Roteadores, Gateways e Computadores	Sistemas ERP e CIS
Integração de geração distribuída e de fontes renováveis	Equipamentos de geração, Inversores e armazenamento de eletricidade	Sistemas EMS, DMS, SCADA e GIS
Aprimoramento da transmissão	Supercondutores, FACTS, HVDC	Sistemas de análise de estabilidade da rede e de recuperação automática
Gerenciamento da rede de distribuição	Chaves religadoras automáticas com sensores, sensores em transformadores e em cabos condutores	Sistemas GIS, DMS, OMS e WMS
Infraestrutura de medição avançada	Medidores eletrônicos inteligentes, Mostradores visuais de consumo e Computadores	Sistemas MDMS e de faturamento de energia
Infraestrutura de carregamento de veículos elétricos	Baterias, Inversores e Unidades automatizadas de abastecimento	Sistema de faturamento de energia, G2V e V2G
Gerenciamento pelo lado do consumidor	Mostradores visuais de consumo, Dispositivos portáteis e Equipamentos atuadores	Sistemas visuais de consumo, de gerenciamento de consumo doméstico e aplicações móveis

Fonte: Adaptado de IEA (2019).

Em Losqui e Souza (2019) mostra um estudo para melhorar a otimização de menor caminho em vários cenários do cotidiano das empresas de transporte, de alimentação e do setor financeiro, com intuito de reduzir custos, menor poluição e promover sustentabilidade. Já em Gassen *et al.* (2019) propõem um modelo de programação linear para a otimização do planejamento da produção com restrições de capacidade produtiva e atendimento à demanda num planejamento multiperíodo.

Os trabalhos da literatura apresentados acima procuram realizar a otimização de parâmetros para redução de custos (econômicos, sociais, dentre outros) através de modelos matemáticos. Modelos nos quais são solucionados com algoritmos de diversas técnicas, além de destacar a sustentabilidade.

O trabalho apresentado aqui tem como objetivo os modelos matemáticos para os Problemas de Localização de Facilidades em Smart Grids e sua resolução através de algoritmos baseado na metaheurística CRO. Assim, soluções ótimas ou de alta qualidade podem ser encontradas com esses algoritmos, otimizando a função objetivo proposta para cada modelo matemático de localização.

O artigo é estruturado da seguinte forma: na segunda seção são apresentadas as formulações matemáticas para os problemas de localização das facilidades e na terceira seção uma breve revisão bibliográfica é realizada. Na quarta seção é apresentada a metodologia e na quinta

seção os resultados e as discussões. Na última seção são descritas as considerações finais.

## FORMULAÇÕES MATEMÁTICAS

De forma geral existem aplicações nas áreas de engenharia que necessitam localizar facilidades com o objetivo de minimizar custos. Exemplos de facilidade são: subestações, estações de carregamento de VE, medidores inteligentes num sistema elétrico de potência, medidores de chuva, sirenes de emergência de alerta, fábricas, hospitais, creches, estações de metrô, dentre outras (CURRENT; DASKIN; SCHILLING, 2002).

Em Current, Daskin e Schilling (2002) descreve que as decisões de localização de uma facilidade envolvem vários fatores: (1) localização dos objetos que fazem parte do estudo; (2) decisões de natureza estratégica com efeitos econômicos de longo prazo; (3) atividade econômica que considera poluição, recursos naturais, desenvolvimento econômico, dentre outros; (4) não existe um modelo geral de localização de facilidade, esses são específicos com restrições e as variáveis.

Os modelos de localização são difíceis de resolverem para instâncias de grande porte devido ao custo computacional, desta forma uso de metaheurística torna-se promissora.

As smart grids necessita que o sistema elétrico seja ampliado considerando a demanda dos consumidores e nesse sentido novas facilidades deverão ser alocadas como subestações, transformadores, chaves seccionadoras, além de estações de carregamento de VE. E para monitorar as smart grids, UMF devem ser implantadas.

### Modelo para Localização das UMF

O problema de localização das UMF é um problema de recobrimento de conjuntos (PRC), conhecido na literatura por set covering problem (GROSSMAN; WOOL, 1997). O PRC foi utilizado em diversas modelagens para diversas aplicações (CONSTANTINO; CASTRO; ARAÚJO; MENDONÇA NETO, 2016).

A modelagem para a localização das UMF considera apenas a minimização da quantidade ( $S_i$ ) de UMF com observabilidade da rede elétrica.

A observabilidade se refere que a partir de um conjunto de valores já disponíveis ou medidos é possível determinar todas as variáveis de estado do sistema elétrico de potência.

$$\min \sum_j^{Nbus} S_i, \quad \text{subject to } A.S \geq I$$

onde:


$$I = [1 \ 1 \ 1 \ \dots \ 1]_{N \times 1}^T,$$

$$S_i = \begin{cases} 1, & \text{se houver UMF instalada no barramento } i \\ 0, & \text{em caso contrário} \end{cases}$$

$$A(i, j) = \begin{cases} 1, & \text{se } i = j \\ 1, & \text{se os barramentos } i \text{ e } j \text{ forem conectados entre si} \\ 0, & \text{em caso contrário} \end{cases}$$

A matriz  $A(i,j)$  é definida como matriz de incidência. Exemplo, considere um sistema de 7 barras conforme apresentado por Xu e Abur (2004) na Figura 2, a matriz de incidência  $A(i,j)$  indica as conexões entre as barras (nós do grafo).

Figura 2 - Sistema de exemplo de 7 barramentos e respectiva matriz de incidência (A)



Fonte: Adaptado de Xu e Abur (2004).

## Modelo para Localização das Estações de Carregamento de VE

O modelo matemático, apresentado a seguir, para o problema de localização das estações de carregamento de VE visa minimizar o custo da localização das estações de carregamento e a distância percorrida pelos clientes (veículos) até uma estação (BAOUCHE *et al.*, 2014). Variáveis de decisão:

$$x_j = \{1 \text{ se a estação candidata } j \text{ foi selecionada; ou } 0, \text{ do contrário} \quad (1)$$

$$y_{ij} = \{1 \text{ se o centro de demanda } i \text{ é coberto pela estação } j; \text{ ou } 0, \text{ do contrário} \quad (2)$$

Modelo:

$$\text{Min} \sum_{j \in J} f_j \cdot x_j + \alpha \sum_{i \in I} \sum_{j \in J} d_{ij} \cdot y_{ij} \quad (3)$$

Com as seguintes restrições:

$$\sum_{j \in J} y_{ij} = 1, \forall i \in I \quad (4)$$

$$\sum_{j \in J} y_{ij} = p, \forall i \in I \quad (5)$$

$$y_{ij} - x_j \leq 0; \forall i \in I; \forall j \in J \quad (6)$$

$$x_j \in \{0,1\}; j \in J, r \geq 0 \quad (7)$$

$$y_{ij} \in \{0,1\}; i \in I, j \in J \quad (8)$$

onde:

I: Conjunto de centros de demanda

J: Conjunto de locais candidatos a estações de recarga

$f_j$ : Custo para localização da estação de recarga

$d_{ij}$ : Distância, percorrida pelo veículo, de um centro de demanda  $i$  até a estação de recarga  $j$

$\alpha$ : Custo do Kilowatt-hora

$p$ : Número de estações escolhidas (medianas)

A função objetivo (3) é a função que minimiza o custo total de instalação das estações de carregamento e a distância de cada cliente ao local da estação candidata escolhida. A restrição (4) diz que toda demanda do centro de demanda deve ser satisfeita. A restrição (5) estabelece que o número de estações escolhidas seja igual a  $p$ . A restrição (6) assegura que um centro de demanda só pode ser associado a uma estação escolhida. As restrições (7) e (8) mostram que as variáveis de decisão são inteiras binárias.

As simplificações adotadas nesse trabalho não implicam em perda de generalidade ao modelo proposto para a localização das estações de carregamento de VE: primeiro o custo ( $f_j$ ) de instalação de cada estação de carregamento  $j$  foi mantido fixo, (custo monetário de aquisição do terreno); segundo, foi considerado que as estações possuem o mesmo número de baias (pontos de recarga dos VE); e por último, foi considerado, que o custo do quilowatt-hora ( $\alpha$ ) foi igual a 1 (um), devido ser uma constante e não impactar na localização das estações de trabalho.

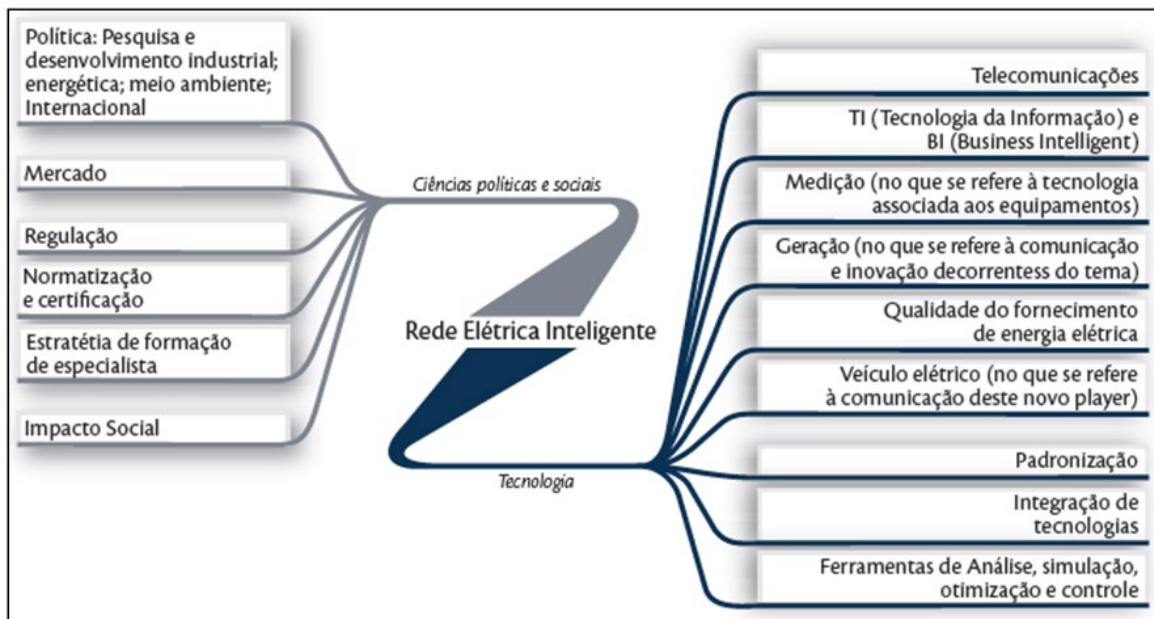
## REFERENCIAL TEÓRICO

A seguir, uma breve revisão bibliográfica relacionada às smart grids e a localização das facilidades (UMF e VE) é apresentada.

### Smart Grids

A equipe do Centro de Gestão e Estudos Estratégicos definiram linhas com foco em ações de Ciência, Tecnologia e Inovação (CT&I) associadas ao tema Smart Grids e classificaram em dois grandes blocos: as ciências humanas e a tecnologia, Figura 3 (CGEE, 2012).

Figura 3 – Blocos e classificação das áreas de pesquisa vinculadas a Smart grids.



Fonte: Adaptado de CGEE (2012).

A energia elétrica, um produto comercial, deve ser visto não só sob a ótica da continuidade, mas, também da conformidade e nesse novo ambiente o conhecimento da frequência de ocorrência das perturbações, bem como as durações das mesmas, passou a ser essencial para as concessionárias (ALMEIDA e KAGAN, 2010). Assim, Almeida e Kagan (2010) afirmam a necessidade de uma metodologia que determine o número mínimo de medidores de qualidade de energia elétrica necessários para monitorar uma rede elétrica, bem como os pontos onde os mesmos devem ser instalados.

Depuru, Wang e Devabhaktuni (2011) destacam entre outros que: a) os medidores inteligentes podem ler informações do consumo de energia em tempo real, incluindo os valores de tensão, ângulo de fase e frequência e comunicar com segurança esses dados; b) a capacidade de medidores inteligentes para a comunicação bidirecional de dados permite coletar informações sobre a eletricidade.

Boccardo *et al.* (2013) afirmam que o índice de sustentabilidade exibido no medidor inteligente não reflete a quantidade física de energia que chega ao usuário final, sendo que o medidor só fornece maneiras de incentivar a adoção de energias mais limpas para um determinado domínio.

Amin e Wollenberg (2005) destacam que um sistema de energia elétrica seja inteligente e autoconfigurável, com desafios de computar em grade (grid) e oferecer um meio eficiente para os participantes competir/cooperar no fornecimento de energia elétrica confiável, barata e sustentável. Em um lado oposto, a rede tradicional não atende com competência a demanda por fornecimento de energia de qualidade. Dessa forma a introdução de inteligência na rede, Figura 4 se faz necessária (HOSSAIN; OO; ALI, 2013).



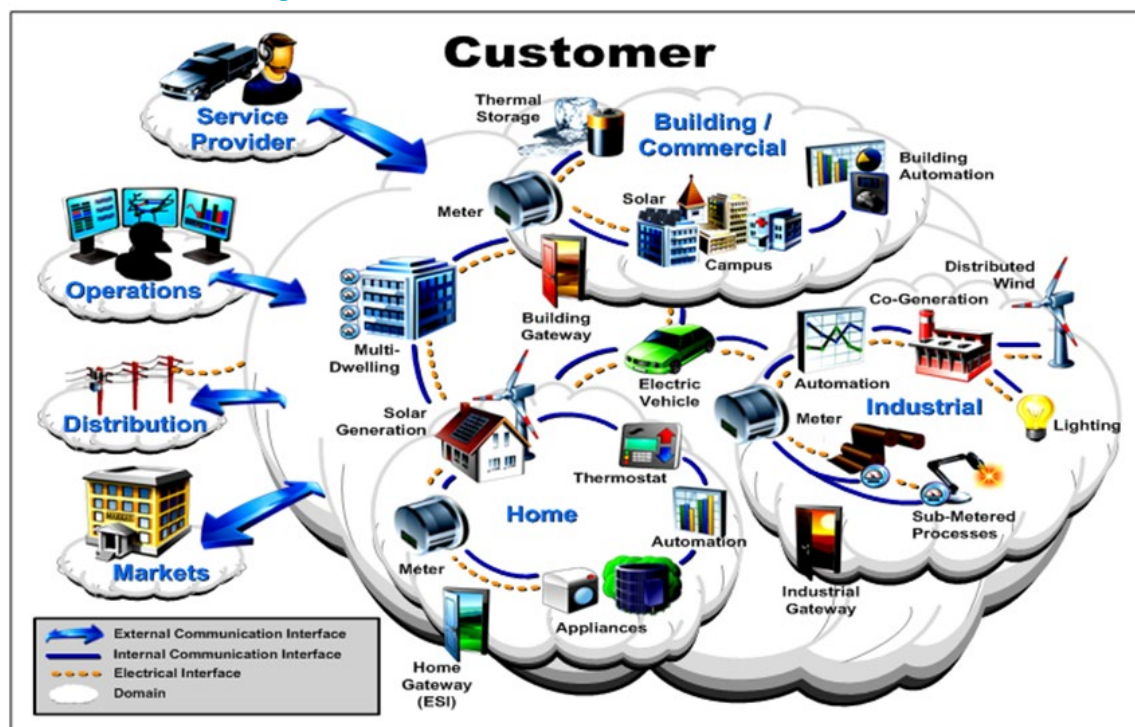
Figura 4 - Comparação entre a Rede Tradicional e a Rede Inteligente

Rede Tradicional	Rede Inteligente (Smart Grid)
Eletromecânico, estado sólido	Digital/Microprocessador
Comunicação local em duas vias e em via única	Global/Comunicação em duas vias integradas
Geração centralizada	Geração distribuída que se acomoda
Sistema de controle e monitoramento, proteção limitada	Monitoramento de área ampla, proteção e controle, proteção adaptativa
“Rede cega”	Auto-monitoramento
Restauração manual	Automatizado, “auto-cura”
Verifica o equipamento manualmente	Monitora o equipamento remotamente
Contingências limitadas do sistema de controle	Sistema de controle penetrante
Confiabilidade estimada	Confiabilidade preditiva

Fonte: Adaptado de Hossain, Oo e Ali (2013).

A implantação das redes elétricas inteligentes pode ser estendida para outros serviços públicos, tais como água, gás, segurança e trânsito, evoluindo para o conceito de cidades inteligentes (RIVERA, ESPOSITO e TEIXEIRA, 2013). Isto irá trazer um novo paradigma aos clientes de redes inteligentes através de um modelo conceitual denominado de Domínio do Consumidor (Customer Domain), Figura 5.

Figura 5 – Uma visão do Domínio do Consumidor



Fonte: Adaptado de EPRI (2017).



tos (2013) para alocação de UMF no sistema elétrico com modificações nos operadores genéticos de crossover e mutação, assim como na formação da subpopulação.

Nazari-Heris e Mohammadi-Ivatloo (2015) apresentaram um algoritmo denominado de UBHS (Upgraded Binary Harmony Search), uma adaptação da meta-heurística HSA (Harmony Search Algorithm), para resolver o problema de alocação UMF em um sistema de energia alcançando um sistema observável por completo.

No trabalho de Souza, Angelim e Affonso (2016), a proposta foi identificar o número mínimo de UMF e alocá-las nas barras mais adequadas do sistema de potência. A escolha das melhores barras é realizada por meio de análise modal.

Mouwafi, El-Sehiemy, El-Ela e Kinawy (2016) apresentaram um método multi-estágio eficiente baseado no Algoritmo ACO (Ant Colony Optimization) e propuseram regras RS (Reduction Strategy) para encontrar a alocação ótima de UMF, considerando o número mínimo de canais de medições com completa observabilidade topológica da rede.

## Estações de Carregamento de VE

A evolução da eletro-mobilidade é impulsionada por potenciais benefícios ambientais que os VE e induz a busca por soluções alternativas no sentido de quebrar a dependência dos combustíveis fósseis (BAOUCHE; BILLOT; EL FAOUZI; TRIGUI, 2014).


Estes autores, no entanto, ressaltam que um desenvolvimento da eletro-mobilidade de larga escala trará novos desafios e várias questões de pesquisa, tal como a localização ótima de estações de carregamento.

Vários países desenvolvidos têm financiado subsídios para aquisição diretamente financiados pelos impostos para promover a indústria de VE local, muitas vezes, um pagamento direto, crédito fiscal ou isenção fiscal para cada comprador dos VE (YANNICK; MARC; WILLET, 2013).

Os autores Yannick, Marc e Willet (2013) afirmam que os números de veículos plug-in (EV+PHEV - Electric Vehicles + Plug-in Hybrid Electric Vehicles) projetados em 2020 serão impressionantes, considerando a combinação dos objetivos de vendas dos VE estabelecidos em diferentes países e o custo do subsídio por veículo.

Desta forma, na projeção para 2020, ver Figura 7, sete milhões de veículos plug-in estará circulando. Com isto vimos é vantajoso implantar uma rede que proporciona o carregamento das baterias dos VE para a viabilização deste tipo de veículo, principalmente numa área urbana.

Figura 7 - Metas nacionais: EV (Electric Vehicles) e híbridos recarregáveis (PHEV) em 2020.



Fonte: IEA (2019), adaptado de Yannick, Marc e Willet (2013).

## METODOLOGIA

Nesta seção serão apresentadas as etapas da metodologia para solucionar a localização de facilidades em smart grids, seguida a metaheurística CRO (Chemical Reaction Optimization) e por fim os algoritmos.

### Etapas da Metodologia

As etapas da metodologia desenvolvidas são mostradas na Figura 8.

Figura 8 – Etapas da metodologia.

Etapa 1: Levantar e revisar a bibliografia.
Etapa 2: Entender conceitos fundamentais como: otimização, facilidades, eficiência de veículos elétricos, sistemas elétricos de potência, impactos ambientais para implantação das facilidades, eficiência em energia elétrica, medidores inteligentes, metaheurísticas, algoritmos e projetos eficientes para os sistemas de engenharia elétrica.
Etapa 3: Pesquisar os problemas de sistemas de engenharia elétrica envolvendo facilidades.
Etapa 4: Procurar modelos matemáticos de otimização de custos de implantação das facilidades.
Etapa 5: Pesquisar os algoritmos que tratam de cada problema específico abordando: problemas de localização ótima de estações de carregamento de veículo elétrico e problemas de localização de medidores.
Etapa 6: Desenvolver os algoritmos baseados nas metaheurísticas CRO para os problemas descritos na Etapa 5.
Etapa 7: Realizar testes computacionais.
Etapa 8: Aprimorar a metodologia desenvolvida.
Etapa 9: Realizar novos testes computacionais.
Etapa 10: Propor melhorias para os sistemas de engenharia elétrica envolvendo facilidades.

Fonte: Elaborado pelos autores (2021).

O problema de localização de facilidades em smart grids (PLFSG) é um problema de otimização combinatória. Para solucionar o PLFSG foram utilizados algoritmos baseados na metaheurística CRO, no qual obteve desempenho superior em termos de qualidade da solução, para problemas de otimização combinatória, quando comparado com algoritmos da literatura (YU, LAM e LI, 2014).

## Chemical Reaction Optimization

O CRO é inspirado na natureza das reações químicas. Uma reação química é um processo natural de transformar substâncias instáveis para substâncias estáveis (LAM; LI, 2012). Na visão microscópica, uma reação química começa com algumas moléculas instáveis com energia excessiva. As moléculas interagem umas com as outras através de uma sequência de reações elementares. No final, elas são convertidas para aquelas com energia mínima para suportar sua existência. Esta propriedade da reação química está embutida na metaheurística CRO (Chemical Reaction Optimization) para resolver problemas de otimização.

O CRO foi explorado com sucesso para resolver o problema de designação quadrática, treinamento em redes neurais, problema de escalonamento de projeto com restrição de recursos, problema de atribuição de canais em redes de malha sem fio, problema de otimização de codificação em rede, dentre outros.

De acordo Lam e Li (2012) as vantagens de CRO são: um framework que permite a implantação de operadores diferentes para atender a diferentes problemas; o tamanho da população variável permite que o sistema adaptar-se automaticamente aos problemas.

CRO tem outros atributos que podem ser facilmente incorporados dando flexibilidade para projetar diferentes operadores; CRO desfruta das vantagens de ambos, Simulated Annealing (KIRKPATRICK; GELATT JR.; VECCHI, 1983) e Algoritmos Genéticos (GOLDBERG, 1989); CRO pode ser facilmente programado em linguagem de programação orientada a objetos, onde uma classe define a molécula e os métodos definem os tipos de reação elementar.

Conforme afirma Lam e Li (2012), embora CRO seja uma metaheurística de propósito geral, esta também deve adaptar-se a cada problema. CRO consiste em três etapas: (1) a inicialização (das configurações do algoritmo e dos valores aos parâmetros, incluindo PopSize, KELossRate, MoleColl, buffer, InitialKE,  $\alpha$  e  $\beta$ , ver Algoritmo 1), (2) o conjunto de iterações e (3) a fase final (é utilizado um critério de parada no qual poderá ser a quantidade máxima de tempo de CPU ou um número máximo de iterações realizadas sem melhorias).

Na fase de inicialização do CRO uma molécula define os valores dos parâmetros e constrói uma população inicial de moléculas. O CRO tem uma classe “Molécula” com atributos e cinco métodos, incluindo o construtor da classe e as quatro reações elementares. Como normalmente geramos um conjunto inicial de soluções aleatoriamente no espaço de solução, iremos atribuir uma solução aleatória para  $\omega$  no construtor. O pseudocódigo da classe “Molécula” é dado no Algoritmo 1. Criamos um número PopSize de moléculas para formar uma população inicial de moléculas.

```

Algoritmo 1 - classe "Molécula"
1: class Molécula
2:   Atributos:
3:      $\omega$ , PE, KE, NumHit, MinStruct, MinPE, MinHit
4:   Métodos:
5:     Molécula () // construtor
6:     {
7:       Gera aleatoriamente  $\omega$  no espaço de solução
8:       PE  $\leftarrow f(\omega)$ 
9:       KE  $\leftarrow InitialKE$ 
10:      NumHit  $\leftarrow 0$ 
11:      MinStruct  $\leftarrow \omega$ 
12:      MinPE  $\leftarrow PE$ 
13:      MinHit  $\leftarrow 0$ 
14:    }
15:    Onwall IneffectiveCollision()
16:    Decomposition()
17:    IntermolecularIneffectiveCollision()
18:    Synthesis()
19: end class

```

Fonte: adaptado de Lam e Li (2012).

Para Lam e Li (2012), no conjunto de iterações, as moléculas tem movimento de energia e colisões de gatilho. Uma molécula pode "bater na parede do recipiente" ou colidir umas com as outras. Isto é decidido pela geração de um número aleatório  $b$  no intervalo  $[0, 1]$ . Se  $b > MoleColl$ , o sistema tem apenas uma molécula ou temos uma colisão uni-molecular. Caso contrário, uma colisão intermolecular se seguirá.

Para uma colisão uni-molecular, selecionamos aleatoriamente uma molécula da população e decidimos se resulta em uma colisão ineficaz na parede (método Onwall IneffectiveCollision do Algoritmo 1) ou uma decomposição (método Decomposition do Algoritmo 1), verificando o critério de decomposição na molécula escolhida. Da mesma forma, para uma colisão intermolecular, podemos selecionar aleatoriamente a partir de duas moléculas da população e determinar se vai haver uma colisão ineficaz intermolecular (método IntermolecularIneffectiveCollision do Algoritmo 1) ou uma síntese (método Synthesis do Algoritmo 1), através da verificação do critério de síntese sobre as moléculas escolhidas.

## Algoritmos para determinar a localização das facilidades

Na Figura 9, apresentamos um pseudocódigo do CRO para localização das UMF e na Figura 10 o fluxograma para determinar a localização de estações de carregamento de VE.

Figura 9 - Pseudo-algoritmo do CRO.

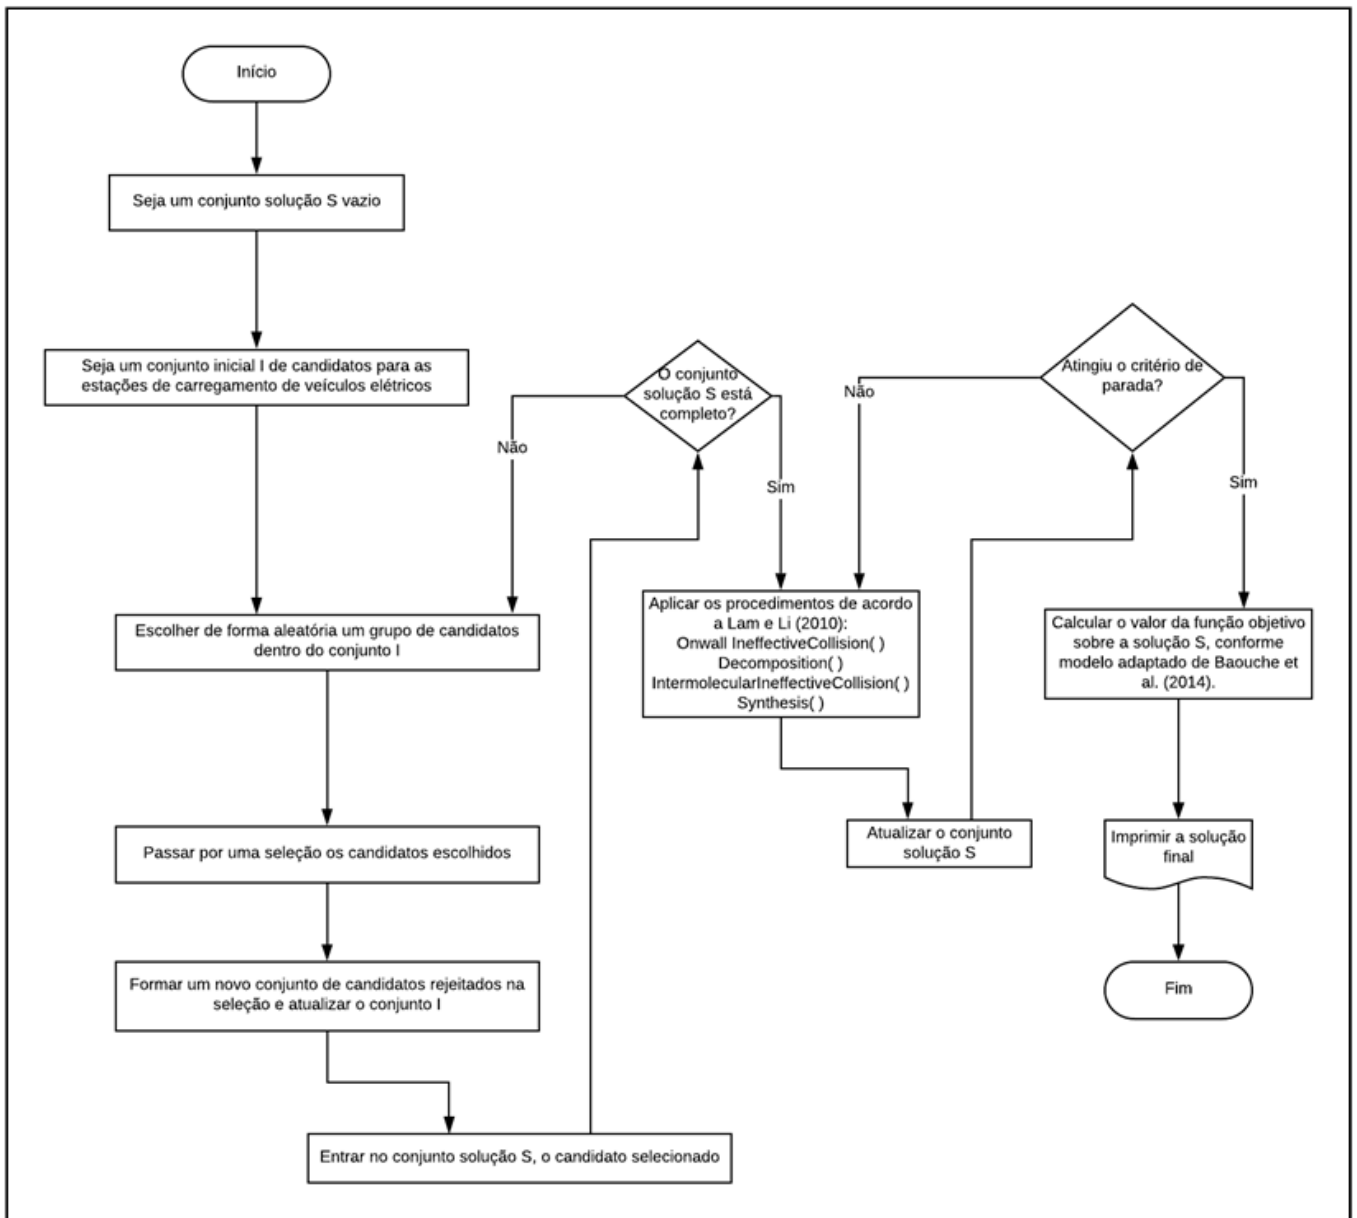
Algoritmo - CRO	
1:	Input: função objetivo $f()$ e valores de parâmetros
2:	Initialization:
3:	Inicializa PopSize, KELossRate, MoleColl, buffer, InitialKE, $\alpha$ , e $\beta$ .
4:	Cria a quantidade definida em PopSize de moléculas
5:	Iterações:
6:	<b>while</b> critério de parada não atingido <b>do</b>
7:	Gera $b \in [0, 1]$
8:	<b>if</b> ( $b > \text{MoleColl}$ ) <b>then</b>
9:	Seleciona randomicamente molécula $M_\omega$
10:	<b>if</b> (Critério de Decomposição é atingido) <b>then</b>
11:	Executa Decomposição() <b>else</b>
12:	Executa ConlisaolnefetivaNaParede()
13:	<b>end if</b>
14:	<b>else</b>
15:	Seleciona randomicamente $M_{\omega 1}$ and $M_{\omega 2}$
16:	<b>if</b> (Critério de Síntese é atingido) <b>then</b>
17:	Executa Síntese() <b>else</b>
18:	Executa ColisãolnefetivaIntermolecular()
19:	<b>end if</b>
20:	<b>end if</b>
21:	Checa se há alguma nova solução mínima
22:	<b>end while</b>
23:	Saída:
24:	Define como saída a melhor solução encontrada e seu valor de função objetivo

Fonte: Adaptado de Lam e Li (2012).

## RESULTADOS E DISCUSSÕES

A seguir serão mostrados os resultados computacionais. O algoritmo CRO para o problema de localização da UMF (PLUMF) utilizou um computador de 64 bits, processador Intel i7, 16GB memória RAM, Windows 10 e Java SE and NetBeans Cobundle (JDK 8u171 and NB 8.2). No entanto, o algoritmo CRO para solucionar o problema de localização de estações de carregamento de VE (PLECVE) foi desenvolvido em Linguagem em C++, com máquina de 64 bits, processador Intel Core i5 de 2,4GHz, 8GB de memória RAM e Windows 10.

Figura 10 – Fluxograma para determinar a localização das estações de carregamento de VE.



Fonte: Elaborado pelos autores (2021).

## Parâmetros do CRO

### PLUMF e a biblioteca OR-Library (PRC)

A fim de realizar a parametrização do CRO, definiram-se valores para cada parâmetro do CRO com todas as combinações possíveis entre os parâmetros para o Modelo MLU aplicado UMF. Na Tabela 1 são apresentados os valores combinados do CRO para PLUMF. Os parâmetros escolhidos estão na Tabela 6.



**Tabela 1 - Valores testes para os parâmetros do Algoritmo CRO (PLUMF).**

Parâmetro	Valores
PopSize	1, 10, 100
MAX_ITER	100*(Número de nós do sistema de testes - NN) 500*(NN) 1000 (NN)
iniBuffer	3000, 5000, 10000
initialKE	PE inicial da molécula, ou seja, o mesmo valor de sua da função objetivo.
KELossRate	0.3, 0.5, 0.8
MoleColl	0.2, 0.3, 0.5, 0.8, 0.9
Alpha	10*(NN) 100*(NN) 200*(NN)
Beta	200*(NN) 500*(NN) 800*(NN)

Fonte: Elaborado pelos autores (2021).

Dado as diversas combinações dos parâmetros do CRO para a biblioteca OR-Library (PRC) e ao número de instâncias, restringiu-se a parametrização a um conjunto de instâncias (classe scp\*). A Tabela 2 mostra os parâmetros para o PRC. Para o PRC utilizou a mesma parametrização do PLUMF com os mesmos valores combinados conforme a Tabela 1.

**Tabela 2 - Valores dos parâmetros do Algoritmo CRO para a biblioteca OR-Library (PRC).**

Parâmetro	Valores
PopSize	10
MAX_ITER	15*(Número de colunas do problema de cobertura - NC)
iniBuffer	10000
initialKE	50000
KELossRate	0.3
MoleColl	0.3
Alpha	0.5*(NC)
Beta	1*(NC)

Fonte: Elaborado pelos autores (2021).

Para cada teste realizado executa-se 15 vezes o CRO, computando-se a melhor solução encontrada, o valor médio das soluções, o erro médio e o tempo médio dispendido em cada execução do algoritmo. A fim de melhorar os resultados encontrados, empregou-se uma busca local em cada solução encontrada após a execução do CRO, em que executamos 10 vezes a rotina ExhaustiveChange sobre o novo resultado encontrado. A rotina altera exaustivamente um bit por vez da solução de entrada e retorna a solução com o menor valor da função objetivo.

Foram utilizadas as variáveis correspondentes aos parâmetros PopSize, KELossRate, MoleColl, buffer, InitialKE,  $\alpha$  (alfa) e  $\beta$  (beta) e para a classe “Molécula” com seus atributos  $\omega$ , PE, KE, NumHit, MinStruct, MinPE e MinHit, e os quatro métodos correspondentes às reações elementares.

Como ponto de partida para o algoritmo CRO ao PLECVE, utilizamos os valores dos parâmetros mostrados em Lam, Leung e Chu (2014) e foram modificados a partir da alteração de um único parâmetro de cada vez e visualização dos resultados obtidos com valores ótimos da base OR-Library. O primeiro valor alterado foi KELossRate e por último, o valor de beta.

Os parâmetros calibrados foram: (1) no estudo de caso (Região Grande-Vitória) temos KELossRate= 0,5; MoleColl= 0,5; InitialKE= 1000; buffer= 0; alfa= 500; beta= 1000 e PopSize= 10; (2) na biblioteca OR-Library temos KELossRate= 0,9; MoleColl= 0,3; InitialKE= 10000; buffer= 0; alfa= 50; beta= 1000 e PopSize= 10. Os critérios de parada foram: número de iterações sem melhoria igual a 300 ou quando o número de total de iterações for igual a 5000.

### Instâncias

Para avaliar os algoritmos ao PLUMF e PLECVE, em casos práticos, foram utilizados dados reais de sistemas elétricos de potência IEEE (2020) e o estudo de caso. E para validar esses algoritmos foram utilizados conjuntos de dados da biblioteca OR-Library disponível em Beasley (2021). A seguir, mostraremos as instâncias para um caso real na alocação de estações de carregamento de VE. Para a resolução do caso real, foi escolhida a região metropolitana de Vitória-ES, pois é a que possui o maior número de automóveis em circulação do Estado do ES, segundo DENATRAN (2020). Primeiramente, definimos a localização dos locais candidatos a estações e dos clientes. Foram selecionados 8 locais candidatos a estações de carregamento (que são as medianas) e 16 clientes na região de Vitória-ES.

Os locais candidatos escolhidos são locais de grande circulação de automóveis na cidade, como centros comerciais, instituições de ensino e áreas de lazer. Além de serem espaços nos quais, geralmente, ocorre um tempo de permanência mínima superior a 15 minutos. Estes locais estão listados na Tabela 3.

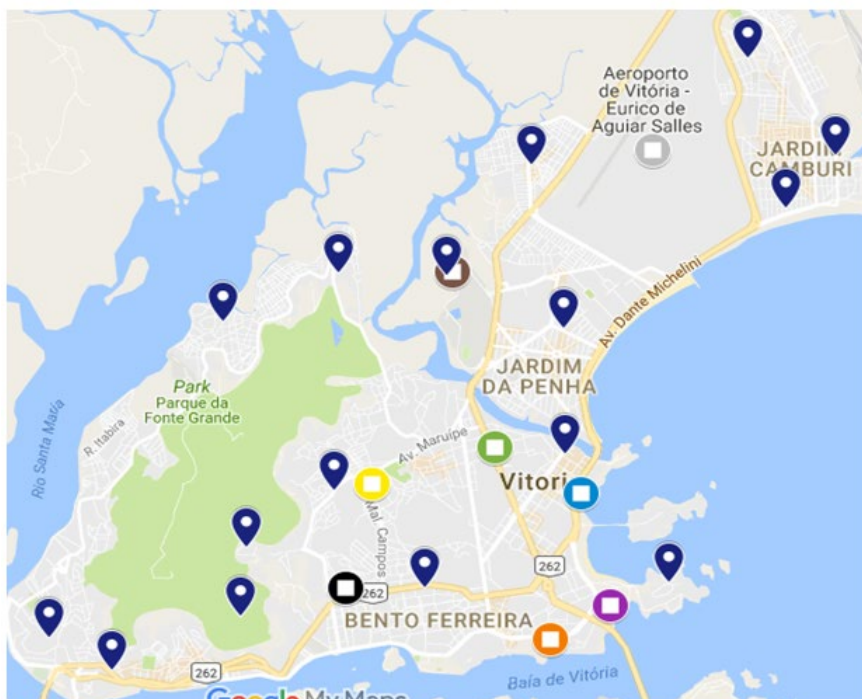
**Tabela 3 - Locais candidatos a estações de carregamento em Vitória**

Número	Local	Cor do ícone*
1	OK Hipermercado	Verde
2	Shopping Vitória	Roxo
3	Aeroporto de Vitória	Cinza
4	UFES Goiabeiras	Marrom
5	UFES Maruípe	Amarelo
6	IFES Vitória	Preto
7	Praça dos Namorados	Azul
8	Praça do Papa	Laranja

Fonte: Elaborado pelos autores (2021). \* Ver detalhes na Figura 11.

Dado que os clientes podem estar em qualquer região da cidade de Vitória, estes foram selecionados de forma aleatória, mas cobrindo a maior área possível da região, como mostra a Figura 11.

**Figura 11 – Locais candidatos a estações e os clientes escolhidos em Vitória**



**Fonte: Elaborado pelos autores (2021).**

Os mapas foram plotados no Google My Maps (Google Maps, 2020), para melhor visualização. Na Figura 11, os ícones em azul são os clientes e os ícones quadrados, são os locais candidatos, como descrito na Tabela 3.

Para a região de Vitória foram realizados dois tipos de testes. O primeiro com distâncias em linha reta (normalmente utilizado pela literatura) e o segundo, com distâncias reais. Para o teste com distâncias em linha reta, utilizou-se as coordenadas geográficas encontradas no Google My Maps, mostradas nas tabelas 4 e 5.

**Tabela 4 – Longitude e latitude dos locais candidatos (facilidades) mostrados no Google Maps.**

<b>Locais candidatos</b>	<b>Latitude</b>	<b>Longitude</b>
Ok Hipermercado	-20,29359	-40,30146
Shopping Vitória	-20,31242	-40,28781
Aeroporto	-20,25802	-40,28297
Ufes Goiabeiras	-20,27252	-40,30641
Ufes Maruípe	-20,29784	-40,31586
IFES Vitória	-20,31019	-40,31891
Praça dos Namorados	-20,29892	-40,29140
Praça do Papa	-20,31638	-40,29495

**Fonte: Elaborado pelos autores (2021).**

**Tabela 5 – Longitude e latitude dos clientes mostrados no Google Maps**

<b>Locais candidatos</b>	<b>Latitude</b>	<b>Longitude</b>
Cliente 1	-20,31377	-40,33135
Cliente 2	-20,24724	-40,27173
Cliente 3	-20,27869	-40,33330
Cliente 4	-20,27310	-40,30708
Cliente 5	-20,31031	-40,30961
Cliente 6	-20,27945	-40,29338
Cliente 7	-20,29881	-40,32027
Cliente 8	-20,30548	-40,33060
Cliente 9	-20,32008	-40,34638
Cliente 10	-20,31625	-40,35377
Cliente 11	-20,30976	-40,28100
Cliente 12	-20,26503	-40,26727
Cliente 13	-20,25988	-40,29720
Cliente 14	-20,29447	-40,29317
Cliente 15	-20,27286	-40,31978
Cliente 16	-20,25873	-40,26143

**Fonte: Elaborado pelos autores (2021).**

Os valores da latitude e longitude fornecidos pelo Google My Maps estão em graus decimais. Assim, há necessidade de conversão dos valores de latitude e longitude em graus decimais para graus, minutos e segundos. Então, calcula-se a distância latitudinal (DLA) e a distância longitudinal (DLO).

Os resultados das distâncias latitudinal e longitudinal são multiplicados por uma milha náutica. Por convenção, milha náutica equivale a 1852 metros.

Após, é feito o cálculo de distância euclidiana. A distância euclidiana (DE) entre dois pontos A e B quaisquer é dada por:

$$DE_{AB} = [(DLA_b - DLA_a)^2 + (DLO_b - DLO_a)^2]^{1/2}$$

A partir destes cálculos, foi implementada uma rotina para conversão destes valores e o preenchimento da matriz de distâncias. O Google My Maps fornece a distância em linha reta entre os locais, mas se torna inviável coletar estas informações para grandes instâncias.

No teste com distâncias reais, a matriz de distâncias foi preenchida com a menor distância percorrida de automóvel pelas ruas da cidade de todos os clientes até os locais candidatos. Essa distância é mostrada pelo Google Maps.

O CRO realizou 15 execuções para cada valor de mediana, para distâncias em linha reta e para as distâncias reais. Adotamos o valor de p entre 1 a 4. Assim, foram realizados 60 testes no total. A quantidade de 15 execuções foi definida empiricamente e com base em execuções utilizadas na literatura.

### Unidades de medição fasorial

Durante a parametrização do algoritmo de CRO, definiram-se valores de seus parâmetros conforme descrito acima na Tabela 1. Executou-se 15 vezes o algoritmo para cada combinação, computando o melhor valor encontrado, o valor médio das melhores soluções, o erro médio e o desvio padrão.

Os melhores resultados dos testes com combinações de parâmetros para a para a modelagem proposta na seção (Modelo para Localização das UMF -MLU), e para modelagem baseada em Xu *et al.* (2013), (denominando Xu) são demonstrados na Tabela 6.

As células de “MS” indica a melhor solução encontrada por todas as configurações da tabela, ou seja, o número de UMF a serem instaladas para cada instância do sistema de testes IEEE. “EM(%) Modelo MLU” corresponde ao erro médio percentual com a modelagem proposta por MLU, enquanto “EM(%) Modelo Xu” corresponde ao erro médio percentual atingido com a modelagem de Xu *et al.* (2013).

Para fins de comparação, para o sistema de 118 barras com a modelagem de penalização o menor tempo computacional obtido neste trabalho foi de 376ms. Xu *et al.* (2013) encontra os valores ótimos em 3,1s com o CRO canônico e 1,1s com o SCRO.

Com a modelagem proposta em MLU, atingimos o tempo de 991ms. Em nossa pesquisa focamos na qualidade da solução encontrada ao invés do tempo computacional do algoritmo, que neste caso foi irrelevante.

Os primeiros resultados demonstrados possuem parâmetro MoleColl nulo, o que impede a realização de reações elementares intermoleculares. Para estes casos, notamos que valores baixos de Beta são aceitos, isso se deve ao fato do critério de síntese nunca ser testado, pois apenas se executam reações unimoleculares.

Os melhores resultados são encontrados para os maiores valores de KELossRate, o que indica que o algoritmo aceita piores soluções.

O modelo proposto chega à solução ótima com menor erro percentual que a modelagem de penalização. Entretanto, os melhores resultados ainda foram encontrados com maior incidência de reações de busca local (colisões inefetivas na parede e intermolecular), havendo baixa incidência de decomposição e síntese.

Tabela 6 - Melhores resultados encontrados para o CRO.

Parâmetros							Sistema IEEE 14 Barras		Sistema IEEE 30 Barras		Sistema IEEE 57 Barras		Sistema IEEE 118 Barras	
							MS: 4 UMF		MS: 10 UMF		MS: 17 UMF		MS: 32 UMF	
Tamanho da População	Número de Iterações	Alpha	Beta	KELoss Rate	MoleColl	Buffer	EM (%) Modelo Xu	EM (%) Modelo MLU	EM (%) Modelo Xu	EM (%) Modelo MLU	EM (%) Modelo Xu	EM (%) Modelo MLU	EM (%) Modelo Xu	EM (%) Modelo MLU
1	500	200	20	0,9	0,0	1000	0,00	0,00	20,00	0,00	9,02	0,00	9,17	0,63
1	700	150	50	0,8	0,0	0	3,33	0,00	30,00	0,00	4,31	0,00	9,79	0,42
10	700	150	2	0,7	0,0	1000	3,33	0,00	15,33	0,00	8,24	0,00	11,25	1,04
10	700	150	500	0,8	0,0	1000	0,00	0,00	25,33	0,00	6,67	0,00	9,38	2,29
10	700	500	2	0,9	0,0	0	6,67	0,00	22,67	0,00	7,84	0,00	9,17	2,29
10	700	500	50	0,9	0,0	1000	10,00	0,00	23,33	0,00	6,67	0,00	9,58	1,67
1	100	100	500	0,8	0,2	10000	21,67	0,00	7,33	0,00	13,33	0,00	14,17	4,38
1	100	200	800	0,8	0,3	5000	18,33	0,00	9,33	0,00	11,76	1,18	14,58	3,33
1	500	200	500	0,8	0,3	3000	26,67	1,67	18,67	0,00	14,90	0,78	19,58	1,04
10	500	100	200	0,8	0,5	5000	18,33	26,67	7,33	0,67	12,94	1,18	17,92	1,46
100	1000	100	800	0,8	0,2	10000	15,00	36,67	7,33	0,67	10,20	2,35	15,00	1,04
100	1000	200	200	0,8	0,5	5000	13,33	1,67	6,00	0,00	12,55	0,78	15,83	0,83

Fonte: Elaborado pelos autores (2021).

Na Tabela 6 verificamos que sempre encontramos valores ótimos, rearranjando os parâmetros do CRO, para todos os sistemas de barras IEEE, exceto a barra 118 no qual o CRO teve gap mínimo de 0,42%. Assim, essa tabela mostra a qualidade do algoritmo CRO em encontrar, na maioria, valores ótimos na alocação de UMF.

### Estações de carregamento

Nas Tabelas 7 e 8 são mostrados os testes realizados para a cidade de Vitória com o algoritmo baseado no CRO, com os melhores valores obtidos para a função objetivo nas 15 execuções realizadas para cada mediana (número de estações de carregamento) e o tempo médio. Nessas tabelas foram considerados 16 clientes (usuários de VE) e número de estações.

Tabela 7 - Resultados da metaheurística CRO para 16 clientes e linha reta em Vitória

Número de estações	Estações escolhidas	Função objetivo (melhor)(Km)	Tempo médio (s)
1	5	221,9	4
2	1 e 5	178,4	6
3	1, 4 e 5	107,0	9
4	1, 4, 5 e 7	27,40	11

Fonte: Elaborado pelos autores (2021).

Tabela 8 - Resultados da metaheurística CRO para 16 clientes e distâncias reais em Vitória

Número de estações	Estações escolhidas	Função objetivo (melhor)(Km)	Tempo médio (s)
1	5	366,08	3
2	5 e 6	243,4	6
3	1, 5 e 6	168,0	6
4	1, 4,5 e 6	56,70	9

Fonte: Elaborado pelos autores (2021).

Observamos que há uma diferença nas escolhas das estações de carregamento quando considera as distâncias em linha reta e as distâncias reais. A Figura 12 mostra os resultados obtidos com a metaheurística CRO para  $p=4$ , na configuração de distância em linha reta, com ícones em azul que mostram os clientes, ícones quadradas em laranja as estações não escolhidas e ícones em verde que são as medianas escolhidas.

Figura 12 – Configuração de 4 estações escolhida com metaheurística CRO.



Fonte: Elaborado pelos autores (2021).

## Testes com dados da literatura

O problema de localização de UMF é modelado por um problema de recobrimento de conjuntos. Assim, foram realizados testes com instâncias disponíveis na biblioteca OR-Library associadas a problemas de cobertura de conjuntos (CC) para validar o algoritmo CRO. Os resultados desses testes estão dispostos na Tabela 9.

A Tabela 9 mostra os resultados de 31 instâncias (primeira coluna), seguido do tempo de processamento médio computacional do CRO dado em segundos, as dimensões (linhas e colu-

nas) e na quinta coluna os valores ótimos da função objetivo. Nas últimas quatro colunas têm: o melhor valor da função objetivo encontrado pelo CRO, o gap, o valor médio encontrado do CRO, e o erro médio, respectivamente. O CRO encontrou 19 valores com gap máximo igual a 10%, o que mostra a qualidade média do algoritmo considerando os valores para a função objetivo.

**Tabela 9 - Resultados encontrados para instâncias PRC da biblioteca OR-Library.**

Instância	Tempo Processamento (s)	Linhas	Colunas	Valor Ótimo	Melhor Solução Encontrada	GAP (%)	Média Soluções	Erro Médio (%)
41	167	200	1000	429	432	0,70%	449,60	4,80%
42	168	200	1000	512	525	2,54%	555,40	8,48%
43	160	200	1000	516	531	2,91%	546,53	5,92%
44	175	200	1000	494	530	7,29%	543,93	10,11%
45	176	200	1000	512	522	1,95%	548,40	7,11%
46	169	200	1000	560	568	1,43%	592,33	5,77%
410	161	200	1000	514	548	6,61%	563,33	9,60%
51	1077	200	2000	253	271	7,11%	278,27	9,99%
55	1085	200	2000	211	221	4,74%	225,53	6,89%
510	1054	200	2000	265	270	1,89%	276,07	4,18%
61	299	200	1000	138	144	4,35%	150,47	9,03%
65	286	200	1000	161	171	6,21%	176,93	9,90%
a4	4296	300	3000	234	246	5,13%	254,40	8,72%
a5	4268	300	3000	236	240	1,69%	247,20	4,75%
b1	5466	300	3000	69	77	11,59%	81,73	18,45%
b5	5444	300	3000	72	75	4,17%	80,93	12,41%
c1	10108	400	4000	227	232	2,20%	242,73	6,93%
c5	10475	400	4000	215	224	4,19%	233,20	8,47%
clr10	29	511	210	25	30	20,00%	31,73	26,93%
clr11	132	1023	330	23	31	34,78%	32,33	40,58%
clr12	614	2047	495	23	33	43,48%	34,40	49,57%
clr13	2735	4095	715	23	35	52,17%	35,87	55,94%
d1	13158	400	4000	60	65	8,33%	69,73	16,22%
d5	12564	400	4000	61	66	8,20%	71,73	17,60%
e1	34	50	500	5	6	20,00%	6,87	37,33%
e2	35	50	500	5	6	20,00%	6,87	37,33%
e3	36	50	500	5	6	20,00%	6,53	30,67%
e5	36	50	500	5	6	20,00%	6,80	36,00%
nre4	31434	500	5000	28	31	10,71%	33,53	19,76%
nre5	31369	500	5000	28	31	10,71%	32,93	17,62%
nrf1	45501	500	5000	14	16	14,29%	17,87	27,62%

Fonte: Elaborado pelos autores (2021).



Para validar o algoritmo CRO que resolve o problema de localização de estações de carregamento de VE utilizamos os dados da literatura da biblioteca OR-Library, dado que conhecemos os valores ótimos de cada instância. A Tabela 10 mostra os resultados para 40 instâncias (primeira coluna) com valores da função objetivo (FO) ótimos na segunda coluna, seguido de suas dimensões (tamanho do número de vértices e número de medianas (p)).

Nas últimas quatro colunas têm: o valor da função objetivo do CRO, o gap, desvio padrão e tempo médio computacional dado em segundos, respectivamente. O CRO encontrou 31 valores ótimos e o máximo gap no valor de 0,07%, o que mostra a qualidade do algoritmo em termos dos valores encontrados para a função objetivo.

**Tabela 10 - Resultados da resolução de 40 instâncias da OR-Library**

OR Library				CRO			
Nome do arquivo	FO (valor ótimo)	Tamanho	p	FO	Gap (%)	Desvio médio (%)	Tempo médio (s)
pmed1	5819	100	5	5819	0,00	0,00	0,98
pmed2	4093	100	10	4093	0,00	0,03	0,97
pmed3	4250	100	10	4253	0,07	0,07	0,98
pmed4	3034	100	20	3033	0,03	0,03	0,99
pmed5	1355	100	33	1355	0,00	0,11	1,10
pmed6	7824	200	5	7824	0,00	0,00	1,78
pmed7	5631	200	10	5631	0,00	0,00	1,37
pmed8	4445	200	20	4445	0,00	0,39	3,46
pmed9	2734	200	40	2734	0,00	0,13	6,74
pmed10	1255	200	67	1255	0,00	0,00	7,23
pmed11	7696	300	5	7696	0,00	0,04	4,91
pmed12	6634	300	10	6634	0,00	0,02	5,37
pmed13	4374	300	30	4374	0,00	0,06	13,78
pmed14	2968	300	60	2969	0,03	0,00	32,45
pmed15	1729	300	100	1730	0,06	0,09	33,56
pmed16	8162	400	5	8162	0,00	0,01	7,89
pmed17	6999	400	10	6999	0,00	0,00	9,54
pmed18	4809	400	40	4809	0,00	0,00	31,93
pmed19	2845	400	80	2845	0,00	0,24	57,40
pmed20	1789	400	133	1790	0,06	0,11	83,27
pmed21	9138	500	5	9138	0,00	0,03	10,36
pmed22	8579	500	10	8579	0,00	0,03	19,18
pmed23	4619	500	50	4619	0,00	0,00	81,88
pmed24	2961	500	100	2962	0,03	0,06	125,02
pmed25	1828	500	167	1829	0,05	0,00	142,86
pmed26	9917	600	5	9917	0,00	0,00	26,14
pmed27	8307	600	10	8307	0,00	0,07	51,08
pmed28	4498	600	60	4498	0,00	0,00	154,09
pmed29	3033	600	120	3033	0,00	0,11	238,34
pmed30	1989	600	200	1989	0,00	0,45	244,67
pmed31	10086	700	5	10086	0,00	0,07	26,98
pmed32	9297	700	10	9297	0,00	0,00	31,96
pmed33	4700	700	70	4701	0,02	0,02	217,71

pmed34	3013	700	140	3013	0,00	0,00	358,54
pmed35	10400	800	5	10400	0,00	0,09	33,10
pmed36	9934	800	10	9934	0,00	0,12	55,27
pmed37	5057	800	80	5057	0,00	0,02	372,69
pmed38	11060	900	5	11060	0,00	0,00	47,37
pmed39	9423	900	10	9423	0,00	0,00	60,02
pmed40	5128	900	90	5130	0,04	0,04	501,57

Fonte: Elaborado pelos autores (2021).

## Discussões

Um grande desafio para as smart grids são monitorar a qualidade da energia da rede elétrica e para isso necessita de uma infraestrutura de medição avançada. Além disso, novos serviços especializados advindo do uso das smart grids, como por exemplo, os VE, necessitarão de uma infraestrutura adequada em prover fornecimento de energia elétrica sustentável e a instalação para as estações de carregamento de VE.

Os resultados computacionais apresentados para as modelagens aos problemas de localização de facilidades em smart grids foram promissores quando utilizaram algoritmos baseados no CRO.

Além disso, temos os desafios relacionados às smart grids como os listados em CGEE (2012), e destacamos alguns:

- Desenvolver um modelo para o mercado que o torna viável;
- Desenvolvimento de novos equipamentos elétricos, sistemas de comunicação e aplicações de software para suporte às funcionalidades requeridas;
- Ganhar experiência com projetos de tecnologia de informações e comunicação em larga escala;
- Promover, de forma prioritária, a interação e o envolvimento dos consumidores, com o objetivo de construir consciência e consenso sobre a importância da smart grids;
- Promover uma política industrial que garanta a sustentabilidade da cadeia produtiva.

## CONSIDERAÇÕES FINAIS

Além dos desafios destacados anteriormente incluímos a necessidade de modelagem de problemas de localização de facilidades nas smart grids com intuito de otimizar recursos, promover sustentabilidade e torna as redes elétricas inteligentes e otimizadas. Desta forma, as smart grids permite implantar medidores eletrônicos inteligentes (que são capazes de transmitir seus dados com a finalidade de verificar a qualidade de energia, medir consumo de energia, minimizar as perdas elétricas, reduzir o tempo entre falhas elétricas e comunicar de forma bidirecional).

As smart grids permitem ainda a implantação de fontes eólicas, solar ou armazenamento de energia com o uso dos carros elétricos.

Nesse trabalho os modelos matemáticos para os problemas de localização de facilidades em smart grids foram resolvidos por algoritmos baseados em CRO. Eles foram aplicados à infraestrutura de medição avançada e para as instalações de estações de carregamento de VE. Os resultados apresentados mostram a eficiência dos algoritmos propostos.

Como trabalhos futuros para a localização de estações de carregamento de VE, podemos realizar a análise de sensibilidade efetuada para diferentes taxas de penetração (aumento no número de VE) na frota. Para a medição avançada, um estudo futuro da implantação nos domicílios residenciais de medidores inteligentes e seus impactos na rede elétrica, tornam-se promissor com intuito de cada cliente implantar sua própria geração de energia fotovoltaica em suas residências.

## AGRADECIMENTOS

Os autores agradecem a Fundação de Amparo à Pesquisa e Inovação do Espírito Santo (FAPES) pelo apoio, dentro do Projeto PIBIC-IFES, Edital PIBIC/PIBITI/2016, Resolução nº 143/2016, Nível I. Agradece também ao Instituto Federal do Espírito Santo, projeto nº PJ00002933 e plano de trabalho nº PT00004475. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) no Programa de Pós-Graduação em Tecnologias Sustentáveis.

## REFERÊNCIAS

- ALMEIDA, C. F. M.; KAGAN, N. Aplicação de algoritmos genéticos e teoria dos conjuntos Fuzzy no dimensionamento de sistemas de monitoração para redes de transmissão de energia elétrica. *SBA Controle & Automação*, Campinas, v. 21, n. 4, p. 363-378, 2010. <http://dx.doi.org/10.1590/S0103-17592010000400004>.
- ALMEIDA, T. D.; FETTERMANN, D. C. Consumo residencial: uma proposta de modelo de negócio para medidores inteligentes. *Revista Produção Online*, Florianópolis, v. 19, n. 3, p. 1094-1117, 2019. <https://doi.org/10.14488/1676-1901.v19i3.3617>.
- AMIN, M. M.; MOUSSA, H. B.; MOHAMMED, O. A. Wide area measurement system for smart grid applications involving hybrid energy sources. *Energy Systems*, vol. 3, n. 1, p. 3-21, 2012. <https://doi.org/10.1007/s12667-011-0047-4>.
- AMIN, S. M.; WOLLENBERG, B. F. Toward a smart grid: power delivery for the 21st century. *IEEE Power and Energy Magazine*, vol. 3, n. 5, p. 34-41, 2005. <https://doi.org/10.1109/MPAE.2005.1507024>.
- BAOUCHE, F., BILLOT, R., EI FAOUZI, N.-E e TRIGU. Efficient Allocation of Electric Vehicles Charging Stations: Optimization Model and Application to a Dense Urban Network. *IEEE Intelligent Transportation Systems*, p. 33-43, Paris, 2014. <http://dx.doi.org/10.1109/MITS.2014.2324023>
- BEASLEY, J. E. OR-Library: Set covering. Disponível em: <http://people.brunel.ac.uk/~mastjjb/jeb/orlib/scpinfo.html>. Acesso em: 26 jan. 2021.
- BOCCARDO, D. *et al.*, Energy footprint framework: A pathway toward smart grid sustainability. *IEEE Communications Magazine*, vol. 51, n. 1, p. 50-56, 2013.

<http://doi.org/10.1109/MCOM.2013.6400438>

CARDENAS, J. A.; GEMOETS, L.; ROSAS, J. H. A.; SARFI, R. A literature survey on Smart Grid distribution: an analytical approach. *Journal of Cleaner Production*, vol. 65, p. 202-216, 2014. <https://doi.org/10.1016/j.jclepro.2013.09.019>

CGEE. *Redes elétricas inteligentes: contexto nacional*. Centro de Gestão e Estudos Estratégicos, Brasília, 2012.

CONSTANTINO, A. A.; CASTRO, E. C.; ARAÚJO, S. A.; MENDONÇA NETO, C. F. X. Pré-processamento do problema de cobertura de conjunto aplicado ao escalonamento de condutores. *Revista Brasileira de Computação Aplicada*, Passo Fundo, vol. 8, n. 2, p. 28-43, 2016. <https://doi.org/10.5335/rbca.v8i2.5131>

DENATRAN – Departamento Nacional de Trânsito. Disponível em: <http://www.denatran.gov.br/estatistica/257-frota-2015>. Acesso 29 nov 2020.

DEPURU, S. S. S. R.; WANG, L.; DEVABHAKTUNI, V. Smart meters for power grid: Challenges, issues, advantages and status. *Renewable and Sustainable Energy Reviews*, vol. 15, n. 6, p. 2736-2742, 2011. <http://doi.org/10.1109/PSCE.2011.5772451>

EPRI. Electric Power Research Institute. Report to NIST on the Smart Grid Interoperability Standards Roadmap, 2009. Disponível em <https://www.nist.gov/sites/default/files/documents/smartgrid/InterimSmartGridRoadmapNISTRestructure.pdf>. Acesso em 26 nov. 2019.

GASSEN, G. *et al.* Proposta de um modelo de programação linear para otimização do planejamento agregado de produção de brocas para empresa multinacional. *Revista Produção Online*, Florianópolis, v. 19, n. 1, p. 21-43, 2019. <https://doi.org/10.14488/1676-1901.v19i1.3013>.

GOOGLE MAPS. Disponível em: <https://www.google.com.br/maps>. Acesso 29 nov 2020.

GROSSMAN, T; WOOL, A. Computational Experience with Approximation Algorithms for the Set Covering Problem. *European Journal of Operational Research*, vol. 101, n. 1, p. 81-92, 1997. [https://doi.org/10.1016/S0377-2217\(96\)00161-0](https://doi.org/10.1016/S0377-2217(96)00161-0)

HOSSAIN, M. R.; OO, A. M. T.; ALI, A. B. M. S. Smart Grid. In *Smart Grids: Opportunities, Developments, and Trends*. A. B. M. Shawkat Ali ed., Springer-Verlag London, 2013.

IEA (INTERNATIONAL ENERGY AGENCY). *Technology roadmaps smart grids*. Disponível em: <https://webstore.iea.org/technology-roadmap-smart-grids>. Acesso em: 25 nov. 2019.

IEEE. *Power Flow Test Cases*. Disponível em: <https://www2.ee.washington.edu/research/pstca/>. Acesso em 29/11/2020.

LOSQUI, H. V. F.; SOUZA, F. H. B. Análise de pontos de aleatoriedade como estratégia para melhoria de ótimos locais em uma heurística construtiva. *Revista Produção Online*, Florianópolis, v. 19, n. 3, p. 923-951, 2019. <https://doi.org/10.14488/1676-1901.v19i3.3336>.

NAAMANE, A.; MSIRDI, N. K. Towards a Smart Grid Communication, *Energy Procedia*, vol. 83, p. 428-433, 2015. <https://doi.org/10.1016/j.egypro.2015.12.162>

NAZARI-HERIS, M.; MOHAMMADI-IVATLOO, B. Optimal placement of phasor measurement units

to attain power system observability utilizing an upgraded binary harmony search algorithm. *Energy Systems*, vol. 6, n. 2, p. 201-220, 2015. <https://doi.org/10.1007/s12667-014-0135-3>

MOUWAFI, M. T.; EL-SEHIEMY, R. A.; EL-ELA, A. A. A.; KINAWY, A. M. Optimal placement of phasor measurement units with minimum availability of measuring channels in smart power systems, *Electric Power Systems Research*, vol. 141, p. 421-431, 2016. <https://doi.org/10.1016/j.epsr.2016.07.029>

RIVERA, R.; ESPOSITO, A. S.; TEIXEIRA, I. Redes elétricas inteligentes (smart grid): oportunidade para adensamento produtivo e tecnológico local. *Revista do BNDES*, Rio de Janeiro, n. 40, p. 43-83, dez. 2013.

SANTOS, T. F.; SILVA, M. A. V. Transporte público e sustentabilidade: uma análise das publicações à luz da bibliometria. *Revista Produção Online*, Florianópolis, v. 19, n. 1, p. 44-71, 2019. <https://doi.org/10.14488/1676-1901.v19i1.3068>

SOUZA, Z. A. F.; ANGELIM, J. H.; AFFONSO, C. M. Identificação do Número Mínimo de Unidades de Medição Fasorial Sincronizada (PMU) para o Monitoramento em Tempo Real da Margem de Estabilidade de Tensão. VI Simpósio Brasileiro de Sistemas Elétricos, ISSN 2177-6164, 6 pp., 2016.

TAVASOLI, M.; YAGHMAEE, M. H.; MOHAJERZADEH, A. H. Optimal placement of data aggregators in smart grid on hybrid wireless and wired communication. 2016 IEEE Smart Energy Grid Engineering (SEGE), Oshawa, Canadá, p. 332-336, 2016. <http://doi.org/10.1109/SEGE.2016.7589547>

WEN, H. F. M.; XU, J.; LI, V. O. K. Optimal multistage PMU placement for wide-area monitoring. *IEEE Transactions on Power Systems*, vol. 28, n. 4, p. 4134-4143, 2013. <http://doi.org/10.1109/TPWRS.2013.2277741>

XU, B.; ABUR, A. Observability analysis and measurement placement for systems with PMUs, *IEEE PES Power Systems Conference and Exposition*, v. 2, p. 943-946, 2004. <http://doi.org/10.1109/PSCE.2004.1397683>

XU, J.; WEN, M. H. F.; LI, V. O. K.; LEUNG, K. C. Optimal PMU placement for wide-area monitoring using chemical reaction optimization. 2013 IEEE PES Innovative Smart Grid Technologies Conference (ISGT), Washington, DC, p. 1-6, 2013. <http://doi.org/10.1109/ISGT.2013.6497845>

YANNICK, P.; MARC, P.; WILLET, K. A Public Policy Strategies for Electrical Vehicles and for Vehicle to Grid Power. *Electric Vehicle Symposium and Exhibition (EVS27)*, 2013 World, Barcelona, p. 1-10, 2013. <http://doi.org/10.1109/EVS.2013.6914856>

YU, J. J. Q.; LAM, A. Y. S.; Li, V. O. K. Chemical reaction optimization for the set covering problem. 2014 IEEE Congress on Evolutionary Computation (CEC), Beijing, p. 512-519, 2014. <http://doi.org/10.1109/CEC.2014.6900233>