

SMART HOME CONTROLLER: OTIMIZAÇÃO MULTI-OBJETIVO UTILIZANDO A META-HEURÍSTICA PSO

STÉPHANIE A. B. DOS SANTOS,* DANIEL K. DE A. OHI,* PEDRO U. B. DE ALBUQUERQUE,* JOSÉ R. BEZERRA,† GIOVANNI C. BARROSO*

*Universidade Federal do Ceará
Fortaleza, Ceará, Brasil

†Instituto Federal de Educação, Ciência e Tecnologia do Ceará
Fortaleza, Ceará, Brasil

Email: stephanie.abraga@gmail.com, kenji.ohi@alu.ufc.br, purbano@ifce.edu.br, jbroberto@yahoo.com.br, gcb@fisica.ufc.br

Abstract— This paper proposes a solution to the Smart Home Controller (SHC) Intelligent Load Controller model using the Particle Swarm Optimization (PSO) meta-heuristic technique. SHC has been modeled so that it can contemplate the energy cost, the comfort of the users or a combination of both. Conventional optimization techniques become very slow in relation to the convergence rate and when the number of devices is part of the demand response (DR), making them unviable for daily use. However, modern techniques based on heuristics have overcome these disadvantages. In this article we compare the results of the SHC solution with Linear Programming and PSO.

Keywords— Smart Home, Energy Efficiency, Optimization, Comfort, Demand Response

Resumo— O presente artigo propõe uma solução do modelo de um controlador de cargas inteligente, *Smart Home Controller* (SHC), utilizando a técnica de meta-heurística PSO (*Particle Swarm Optimization*). O SHC foi modelado de forma que é capaz de contemplar o custo energético, o conforto dos usuários ou uma combinação dos dois. Técnicas de otimização convencionais tornam-se muito lentas em relação à taxa de convergência e quando o número de aparelhos faz parte da resposta à demanda (DR), tornando-as inviáveis para o uso diário. Contudo, técnicas modernas baseadas em heurística superaram essas desvantagens. Neste artigo são comparados os resultados da solução do SHC com Programação Linear e PSO.

Palavras-chave— *Smart Home*, Eficiência Energética, Otimização, Conforto, Resposta à Demanda

Tabela 1: Lista de Símbolos

| Símbolo | Descrição |
|-------------|--|
| M | Número de cargas planejáveis |
| \bar{P}_m | Vetor da potência média da m -ésima carga |
| \hat{P}_m | Vetor da potência de pico da m -ésima carga |
| N_m | Duração, em número de amostras, da m -ésima carga |
| I_{Sm} | Amostra no horário mínimo de início da m -ésima carga |
| I_{Em} | Amostra no horário máximo de término da m -ésima carga |
| S | Amostra assoc. ao início do período de planejamento |
| E | Amostra assoc. ao término do período de planejamento |
| u_{mi} | i -ésima variável de decisão da m -ésima carga |
| P_k | Limite de pico no k -ésimo instante de tempo |
| C | Vetor do custo do consumo de energia elétrica no período |

1 Introdução

O consumo de energia é um dos principais indicadores do desenvolvimento econômico e do nível de qualidade de vida de uma sociedade. Esse indicador reflete o ritmo de atividade dos setores industrial, comercial e de serviços, bem como a capacidade da população de adquirir bens e serviços tecnologicamente mais avançados, como automóveis, eletrodomésticos e eletroeletrônicos (ANEEL, 2008).

O sistema de energia moderno incorporado à rede inteligente gerencia a demanda de eletricidade selecionando as prioridades do usuário por meio da comunicação nos dois sentidos. Em *Smart Grid*, o uso extensivo de comunicação e automação tornam inteligentes tanto a rede de distribuição de energia quanto a *Demand Side Management* (DSM), que consiste nos usuários da energia elétrica realizar ações afim de equilibrar a demanda, principalmente em momentos de pico (Rehman et al., 2016).

Considerando o aumento da eficiência do uso de energia elétrica e se utilizando dos conceitos de *Smart Grids*, pode-se pensar em um controlador de cargas integrado à rede inteligente de energia, que possa alocar as cargas dos clientes para momentos de tarifa reduzida como uma estratégia de diminuição do consumo de energia elétrica nos mo-

mentos de pico.

Em (de T. F. B. Filho et al., 2015), os autores apresentaram um *Smart Home Controller* (SHC) modelado como um problema de otimização utilizando programação linear inteira que é capaz de contemplar o custo energético, o conforto dos usuários ou uma combinação dos dois.

Segundo (Rehman et al., 2016), no cenário de *Smart Home*, as técnicas de otimização convencionais, por exemplo, programação linear (Yong e Choi, 2014), programação não linear (Yong e Choi, 2014), programação convexa (Richard e Pistikopoulos, 2016), são muito lentas em relação à taxa de convergência e tornam-se muito demoradas quando o número de aparelhos faz parte da resposta da demanda, do inglês *Demand Response* (DR), tornando-as inviáveis para o uso diário. Contudo, técnicas modernas baseadas em heurística, como PSO (*Particle Swarm Optimization*), ACO (*Ant Colony optimization*) (Raka et al., 2016) e GA (*Genetic Algorithm*) (et al, 2013) superaram essas desvantagens.

O presente artigo propõe uma solução do modelo do SHC proposto em (de T. F. B. Filho et al., 2015), utilizando a técnica de meta-heurística PSO, comparando o desempenho obtido com o apresentado em (de T. F. B. Filho et al., 2015).

O artigo está estruturado da seguinte forma: a Seção 2 contém uma explanação da meta-heurística PSO, na Seção 3 está descrito o modelo do SHC, a Seção 4 descreve como foi solucionado o problema de otimização, a Seção 5 descreve os cenários de referência utilizados para as simulações, na Seção 6 estão os resultados das simulações, na Seção 7 está a conclusão e trabalhos futuros e, finalmente, os agradecimentos.

2 PSO (*Particle Swarm Optimization*)

O algoritmo (PSO) é um método de otimização baseado em população que encontra a solução ideal usando uma população de partículas (Kennedy e Eberhart, 1995). Cada enxame de PSO é uma solução possível no espaço da soluções. A definição de PSO é apresentado da seguinte forma:

- Cada partícula individual i tem as seguintes propriedades: uma posição atual no espaço de busca, x_i , a velocidade atual, v_i e uma melhor posição pessoal em espaço de busca, $pbest_i$.
- A melhor posição pessoal, $pbest_i$, corresponde à posição no espaço de busca onde a partícula i apresenta o menor erro conforme determinado pela função objetivo f .
- A melhor posição global, indicada por $gbest$, representa a posição que produz o menor erro entre todos os $pbest_i$.

As equações (1) e (2) definem como o $pbest_i$ e $gbest$ são atualizados no tempo t , respectivamente. É assumido que o enxame possui s partículas, em um problema de minimização da função f .

$$pbest_i(t+1) = \begin{cases} pbest_i(t) & \text{se } f(pbest_i) \leq f(x_i(t+1)) \\ x_i(t+1) & \text{se } f(pbest_i) > f(x_i(t+1)) \end{cases} \quad (1)$$

$$gbest(t+1) = \min\{f(pbest), f(gbest)\} \quad (2)$$

$$pbest \in \{pbest_0, pbest_1, \dots, pbest_s\}$$

A velocidade e posição atual das partículas são atualizadas como apresentado nas equações (3) e (4):

$$v_i(t+1) = wv_i(t) + c_1r_1(pbest_i - x_i) + c_2r_2(gbest - x_i) \quad (3)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (4)$$

em que c_1 e c_2 são duas constantes positivas, r_1 e r_2 são dois números aleatórios dentro do intervalo $[0, 1]$, e w é o peso de inércia. A equação (3) consiste em três partes. A primeira parte é a velocidade anterior do enxame, que mostra o estado atual do enxame; a segunda parte é o termo cognitivo, que expressa a experiência individual da partícula de onde a solução está; a terceira parte é o termo social, que representa a experiência da nuvem. As três partes em conjunto determinam a capacidade do espaço de pesquisa (Esmín, 2007).

3 Modelo do SHC

O modelo de SHC apresentado em (de T. F. B. Filho et al., 2015) baseia-se no modelo apresentado em (Giorgio e Pimpinella, 2013), cujo objetivo é escolher o momento de início de execução de cada carga em uma residência de forma que os custos de execução do conjunto de cargas seja minimizado. As decisões do SHC são tomadas baseadas nos seguintes parâmetros: custo das tarifas ao longo do dia, demanda máxima contratada, consumo de energia de cada carga, horário mínimo de início de cada carga (escolha do usuário), e horário máximo de término de cada carga (escolha do usuário).

Dado que o SHC é um sistema de tempo discreto que opera a uma certa taxa de amostragem T_s , que o dia é dividido em N amostras e que uma residência possui M cargas planejáveis, o modelo matemático do SHC, descrito como um problema de programação inteira, é apresentado a seguir. A notação dos símbolos utilizados está definida na Tabela 1.

A função-objetivo do controlador proposto por (Giorgio e Pimpinella, 2013) é definida pela

equação (5). Esta função define o custo total de execução de todas as cargas presentes no ambiente.

$$f_1(x) = \min\left\{ \sum_{m=1}^M \sum_{i=I_{sm}}^{I_{em}-N_m} \left(\sum_{n=1}^{i+(N_m-1)} \tilde{P}_m[n-i]T_s C[n] \right) u_{mi} \right\} \quad (5)$$

Sujeito às restrições:

$$\sum_{i=I_{sm}}^{I_{em}-N_m} u_{mi} = 1 \quad (6)$$

$$\sum_{m \in M_k} \left(\sum_{i=(k-(N_m-1))}^{k-(k-I_{Em}+N_m)} \tilde{P}_m[k-i] u_{mi} \right) \leq P_k \quad (7)$$

$$u_{mi} \in \{0, 1\} \quad (8)$$

A restrição definida pela equação (6) estabelece que, para cada carga, o somatório de todas as suas variáveis de decisão deve ser igual a unidade. Isto significa que para cada carga apenas uma variável de decisão poderá assumir o valor unitário enquanto as demais terão valor zero, garantindo que para cada carga a ser executada o controlador escolherá apenas um momento de início de acionamento. A restrição definida pela equação (7) estabelece que o consumo de pico em qualquer momento durante a execução de todas as cargas deve ser igual ou inferior à curva de limite de pico. E, a restrição definida pela equação (8) estabelece que as variáveis de decisão só podem assumir os valores zero e um, isto é, são variáveis de decisão binárias.

O modelo apresentado em (Giorgio e Pimpinella, 2013) é eficiente em minimizar os custos relacionados ao consumo de energia elétrica mas pode gerar um grande nível de desconforto aos usuários, se o horário de início de acionamento das cargas que estão associadas ao conforto do usuário for muito diferente do horário de início ideal definido, dado que a definição de conforto seja entendida como a distância entre o previsto acionamento da carga e o horário definido. (de T. F. B. Filho et al., 2015).

Para realizar análise sobre o nível de desconforto gerado pelo SHC, os seguintes parâmetros foram introduzidos ao problema por (de T. F. B. Filho et al., 2015).

- C_{Lm} : Nível de conforto da m-ésima carga. É definido como um valor real que varia entre 0, para cargas que não geram desconforto ao ter seu horário de início alterado, e 1 para cargas que geram grande impacto no conforto do usuário ao terem seus horários de início alterados.
- I_{Bm} : Amostra associada com o melhor horário de início da m-ésima carga. Indica ao

controlador qual o horário ideal para o início da carga.

- Pesos de controle para otimização do custo e do conforto (w_1) e (w_2).

Estas novas variáveis têm seu valor definido pelo usuário, uma vez que não é possível para o controlador determinar o nível de conforto ou o melhor horário de início de cada carga.

A função-objetivo trabalha para minimizar o deslocamento do horário de início de cada carga em relação ao horário de início ideal definido pelo usuário, maximizando o nível de conforto do usuário. Na equação (9) é definida a função-objetivo.

$$f_2(x) = \min\left\{ \sum_{m=1}^M \sum_{i=I_{sm}}^{I_{em}-N_m} (C_{Lm}|i - I_{Bm}|) u_{mi} \right\} \quad (9)$$

Com a função-objetivo que minimiza o desconforto do usuário definida, é necessário fazer o controlador minimizar a combinação das duas funções-objetivo apresentadas até aqui, isto é, o custo energético e o desconforto do usuário. Para alcançar este resultado o controlador proposto minimiza uma combinação linear das duas funções-objetivo descritas anteriormente, criando assim uma nova função-objetivo, como apresentado na equação (10). Novas restrições foram adicionadas ao problema e estão descritas nas equações (11), (12) e (13).

$$f(x) = w_1 f_1(x) + w_2 f_2(x) \quad (10)$$

onde

$$w_1 + w_2 = 1 \quad (11)$$

$$w_1 \geq 0 \quad (12)$$

$$w_2 \geq 0 \quad (13)$$

f_1 e f_2 foram definidas anteriormente nas equações (5) e (9), respectivamente. w_1 e w_2 são parâmetros de *trade-off*. O conjunto de restrições definidos pelas equações (11) a (13) estabelecem que a soma dos parâmetros w_1 e w_2 deve ser igual a unidade, e que ambos devem ser maior ou igual a zero. Ao variar w_1 e w_2 , o usuário pode alcançar economia de energia agregado a um baixo impacto no seu conforto. Por exemplo, ao fazer $w_1 = 1$, o usuário determina que o nível de conforto não é importante para a execução das cargas e o controlador minimizará apenas os custos do consumo de eletricidade. Ao fazer $w_2 = 1$, o controlador obterá a solução que melhor mantém os níveis de conforto do usuário, obedecendo às restrições impostas.

4 Otimização Multi-Objetivo


Nesta Seção é descrita a forma como o problema de otimização multi-objetivo foi modelado neste

artigo. Apesar do problema ser multi-objetivo, foi solucionado com uma técnica mono-objetivo, já que a função *Fitness* é um somatório das funções objetivo, ponderadas por parâmetros de *trade-off*. A técnica de meta-heurística PSO utiliza o conceito de população e de função *Fitness*, que estão descritos a seguir.

4.1 População de indivíduos

Como a solução ótima é um conjunto com os melhores horários de início de execução das M cargas, o indivíduo também é composto dessa forma. Na Figura 1 está ilustrado o modelo do indivíduo considerado.

Figura 1: Ilustração do indivíduo



O indivíduo é um vetor com tamanho M , em que cada posição é o horário de início de cada carga.

4.2 Função Fitness

Como o problema de otimização é um problema de minimização com restrições, fez-se necessário escolher uma função *Fitness* que leve em consideração o que se deseja minimizar e as restrições impostas.

O Modelo da função *Fitness* está na equação (14). Na primeira componente da função (f_1), pretende-se minimizar o custo total de execução de todas as cargas, obedecendo às restrições: o valor da potência de pico não exceder o limite de pico para cada amostra no tempo; e que os horários de início estejam entre o intervalo de horário selecionado pelo usuário. Já na segunda componente (f_2), pretende-se minimizar o desconforto gerado. w_1 e w_2 são parâmetros de *trade-off* entre (f_1) e (f_2) e obedecem as restrições já definidas pelas equações (11) a (13). As equações (15) e (16) descrevem como foram calculadas as parcelas f_1 e f_2 da função *Fitness*, respectivamente.

$$fitness = w_1 f_1 + w_2 f_2 + f_3 \quad (14)$$

$$f_1 = \sum_{m=1}^M \sum_{i=I_{cm}}^{I_{cm}+N_m} (P_m[i] T_s C[i]) \quad (15)$$

$$f_2 = \sum_{m=1}^M (C_{Lm} |I_{cm} - I_{Bm}|) \quad (16)$$

em que, I_{cm} é a hora de início escolhida para cada carga m . O restante dos termos já foram descritos anteriormente.

Para incorporar as restrições à função *Fitness*, criou-se a parcela f_3 , que representa a não obediência às restrições. Calculou-se f_3 como sendo a soma da quantidade de vezes que a potência de pico excede, ao longo das amostras diárias. Esse valor foi multiplicado por 100, para dar um peso na função *Fitness*.

5 Cenários de Referência

Os cenários utilizados para as simulações foram os mesmos utilizados em (de T. F. B. Filho et al., 2015), a fim de comparar os resultados obtidos. O conjunto de cargas e suas características que são utilizadas nas simulações dos cenários estão descritas na Tabela 2. O intervalo de amostragem usado foi 5 minutos e o melhor horário de início para cada carga foi 18h. Os parâmetros hora mínima e máxima de início de cada carga, foram, respectivamente, 14h e 23h59 para todas as cargas.

O limite de pico utilizado nas simulações foi de 4,5 kWh. Para simular cargas não-planejáveis, isto é, cargas existentes no ambiente mas que seus horários de execução não podem ser alterados, este limite é reduzido utilizando duas gaussianas de 0,5 kWh de pico e uma gaussiana de 1,4 kWh de pico. As gaussianas estão centradas às 06h, 13h e 20h horas, respectivamente. Os perfis de tarifas utilizadas estão mostrados na Tabela 3.

5.1 Cenário 1 - Tarifa Única

Esse cenário utiliza a tarifa constante durante todo o dia (perfil 1 da Tabela 3), situação similar a como é realizada a tarifação residencial atualmente no Brasil. Neste tipo de situação o controlador trabalha para manter as cargas dentro do intervalo desejado pelo usuário e para garantir que o limite de pico não seja ultrapassado. Não há ganhos econômicos em acionar as cargas em momentos distintos do dia. Logo, para este tipo de cenário, qualquer solução que mantenha o conjunto de cargas abaixo do limite de pico e atenda aos requisitos do usuário de tempo de início e de término do acionamento de cada carga, é uma solução ótima do ponto de vista de economia energética.

5.2 Cenário 2 - Tarifa Dupla

Neste cenário é utilizado o perfil 2 da Tabela 3, que utiliza duas tarifas ao longo do dia. Portanto, do ponto de vista de economia energética, alocar cargas entre as 08h e 19h horas é menos vantajoso.

5.3 Cenário 3 - Tarifa Dupla e DSM

Neste cenário deseja-se simular uma situação com tarifa dupla juntamente com *Demand Response*, um tipo de DSM (*Demand Side Management*). A

Tabela 2: Características das cargas

| Carga | Etapas | $\Delta t(\text{min})$ | $\bar{P}[\text{kW}]$ | $\hat{P}[\text{kW}]$ | C_{Lm} |
|-------|--------|---------------------------------|--|--|----------|
| 1 | 6 | [5, 10, 15, 5, 5, 10] | [0.02, 1.96, 0.02, 0.02, 0.02, 0.05] | [0.15, 2.10, 0.15, 0.15, 0.20, 0.55] | 1,0 |
| 2 | 1 | [105] | [2.36] | [2.70] | 0,9 |
| 3 | 7 | [5, 25, 20, 5, 10, 10, 20] | [0.04, 1.99, 0.28, 0.06, 0.06, 0.06, 0.08] | [0.20, 2.10, 2.10, 0.20, 0.30, 0.25, 0.50] | 0,8 |
| 4 | 6 | [15, 30, 10, 5, 20, 50] | [0.07, 1.40, 0.10, 0.07, 2.02, 0.01] | [0.10, 2.10, 1.20, 0.10, 2.15, 0.02] | 0,7 |
| 5 | 8 | [25, 5, 60, 20, 10, 10, 10, 20] | [0.27, 0.05, 2.10, 0.11, 0.11, 0.10, 0.10, 0.26] | [2.10, 0.30, 2.20, 0.20, 0.60, 0.80, 0.80, 1.10] | 0,6 |
| 6 | 6 | [20, 15, 35, 10, 20, 50] | [0.07, 2.00, 0.07, 0.07, 1.80, 0.01] | [0.10, 2.10, 0.10, 0.25, 2.30, 0.02] | 0,5 |
| 7 | 3 | [50, 20, 50] | [0.80, 0.50, 1.00] | [1.00, 0.80, 1.20] | 0,4 |
| 8 | 4 | [20, 20, 10, 15] | [1.40, 0.50, 0.60, 1.00] | [1.60, 0.80, 0.60, 1.00] | 0,3 |
| 9 | 3 | [30, 20, 30] | [0.60, 0.70, 1.00] | [0.60, 0.70, 1.00] | 0,2 |

Tabela 3: Preços Diários de Energia

| Tarifa | Período | Preço [cent/kwh] |
|--------|------------|---------------------------------|
| 1 | Padrão | [00h - 24h] 18,00 |
| 2 | Fora-Ponta | [00h - 08h] e [19h - 24h] 16,75 |
| | Ponta | [08h - 19h] 21,22 |
| 3 | Fora-Ponta | [00h - 08h] e [19h - 24h] 16,75 |
| | Ponta | [08h - 16h] e [18h - 19h] 21,22 |
| | DSM | [16h - 18h] 12,00 |

concessionária de energia elétrica envia uma mensagem aos seus usuários, utilizando, por exemplo, o conceito de redes inteligentes, informando sobre uma tarifa promocional. Com o controlador integrado à rede da concessionária este tipo de mensagem é recebida e pode então ser levada em consideração para os cálculos de otimização das cargas que ainda não iniciaram sua execução.

É utilizado o perfil 3 da Tabela 3, que utiliza três tarifas ao longo do dia. Portanto é mais vantajoso, do ponto de vista de economia energética, alocar o máximo de cargas no período de 16h às 18h e em seguida após as 19h.

5.4 Cenário 4 - Tarifa Dupla e DSM com Redução de Pico

Semelhante ao cenário 3, é utilizado o perfil 2 da Tabela 3. Neste cenário também deseja-se simular uma situação com tarifa dupla juntamente com DSM (*demand side management*), porém com uma redução no limite de pico. A concessionária de energia elétrica envia uma mensagem aos seus usuários, utilizando, por exemplo, o conceito de redes inteligentes, informando sobre uma redu-

ção de 1,5 kW no limite de pico entre as 21h e 22h. Com o controlador integrado à rede da concessionária, este tipo de mensagem é recebida e pode então ser levada em consideração para os cálculos de otimização das cargas que ainda não iniciaram sua execução.

6 Resultados e Discussões

Os parâmetros de simulação para PSO foram:

- Inicialização da População: aleatoriamente, dentro do intervalo escolhido pelo usuário, para hora inicial e final de início de carga;
- Tamanho da População: 20 indivíduos;
- Peso de inércia: $w = 0,5$;
- Parâmetro cognitivo: $c_1 = 1$;
- Parâmetro social: $c_2 = 4$;
- Critério de parada: número de iterações igual a 500;

Para se escolher esses parâmetros foram feitos testes e comparações, utilizando o cenário 2 como referência. Na Tabela 4 estão os valores obtidos da função *Fitness* com os diferentes valores de c_1 e c_2 . O melhor valor de função *Fitness* encontrado foi quando utilizou-se $c_1 = 1$ e $c_2 = 4$.

Tabela 4: Relação dos Parâmetros PSO e Função *Fitness*

| c_1 | c_2 | Função <i>Fitness</i> |
|-------|-------|-----------------------|
| 1 | 4 | 180,36 |
| 2 | 2 | 193,46 |
| 4 | 1 | 214,50 |

Com o algoritmo proposto (PSO), foram realizadas 4 simulações, uma para cada cenário apresentado, com todas as respectivas características citadas na Seção 5.

Da mesma forma, foi executado o algoritmo com programação linear, a fim de comparar os resultados. O computador utilizado para execução dos ambientes simulados possui as seguintes características:

- Processador: Intel Core i3-4005U @ 1,70 GHz;
- Memória RAM: 4,00 GB;
- Disco Rígido: HD 500 GB;
- Sistema Operacional: Microsoft Windows 8.1 64bits;

Nas Tabelas 5, 6, 7 e 8 estão os resultados obtidos para cada cenário, respectivamente, em comparação com os resultados em (de T. F. B. Filho et al., 2015). Cada simulação foi executada 3 vezes, variando os parâmetros de *trade-off* entre o custo e o desconforto (w_1 e w_2) da função *Fitness*:

a) $w_1 = 0,3$ e $w_2 = 0,7$

b) $w_1 = 0,5$ e $w_2 = 0,5$

c) $w_1 = 0,7$ e $w_2 = 0,3$

O custo está medido em cent e o tempo de execução em segundos.

Tabela 5: Resultados - Cenário 1

| Cenário 1 | | Custo | Desconforto | Tempo de Execução |
|--------------|---|-------|-------------|-------------------|
| Prog. Linear | a | 248,7 | 6,18 | 254,17 |
| | b | 248,7 | 6,18 | 251,48 |
| | c | 248,7 | 6,18 | 270,96 |
| PSO | a | 248,7 | 8,44 | 6,71 |
| | b | 248,7 | 11,00 | 5,25 |
| | c | 248,7 | 9,46 | 5,23 |

Tabela 6: Resultados - Cenário 2

| Cenário 2 | | Custo | Desconforto | Tempo de Execução |
|--------------|---|--------|-------------|-------------------|
| Prog. Linear | a | 241,07 | 9,99 | 465,37 |
| | b | 237,03 | 13,52 | 60,84 |
| | c | 237,03 | 13,52 | 26,04 |
| PSO | a | 260,56 | 10,22 | 5,05 |
| | b | 258,36 | 9,24 | 5,19 |
| | c | 257,00 | 11,00 | 5,04 |

No cenário 1, a tarifa é constante ao longo do dia, então não há economia em mover as cargas ao longo do dia. Logo, o custo nas duas técnicas foram os mesmos, porém na otimização com PSO houve um incremento do valor de desconforto. Em relação ao tempo de execução, o algoritmo com programação linear tem um tempo

Tabela 7: Resultados - Cenário 3

| Cenário 3 | | Custo | Desconforto | Tempo de Execução |
|--------------|---|--------|-------------|-------------------|
| Prog. Linear | a | 201,28 | 7,09 | 69,26 |
| | b | 201,28 | 7,09 | 13,79 |
| | c | 199,79 | 9,99 | 4,62 |
| PSO | a | 222,9 | 10,66 | 5,17 |
| | b | 215,92 | 8,84 | 5,05 |
| | c | 217,20 | 9,94 | 5,09 |

Tabela 8: Resultados - Cenário 4

| Cenário 4 | | Custo | Desconforto | Tempo de Execução |
|--------------|---|--------|-------------|-------------------|
| Prog. Linear | a | 244,10 | 9,66 | 155,06 |
| | b | 247,36 | 9,54 | 85,59 |
| | c | 243,08 | 10,8 | 279,61 |
| PSO | a | 260,58 | 10,60 | 5,17 |
| | b | 260,50 | 10,76 | 4,95 |
| | c | 256,38 | 11,88 | 5,13 |

aproximadamente 50 vezes maior do que o algoritmo com PSO.

No cenário 2, os custos na otimização com PSO tiveram um incremento em média de 8,4%, porém o nível de conforto foi melhor, tendo um decréscimo de, em média, 13,3% no desconforto. Em relação ao tempo de execução, o algoritmo com programação linear apresenta um tempo de execução menor, se comparado ao cenário 1, porém o algoritmo com PSO mantém a mesma média de tempo de execução, continuando com o tempo de execução consideravelmente menor do que com programação linear.

Nos cenário 3, os custos tiveram um aumento de 8,9% na otimização com PSO e o nível de desconforto teve um aumento de 24,8%, em média. Já no cenário 4, os custos tiveram um aumento de 5,8% na otimização com PSO e o nível de desconforto teve um aumento de 10,8%, em média. Apesar do custo e nível de desconforto serem um pouco maiores no caso do PSO, o tempo de execução com PSO foi consideravelmente menor na maioria dos casos. Isso mostra que, apesar de não apresentar a solução ótima, PSO apresenta uma solução boa, com um menor tempo de execução.

Nas Figuras (2, 3, 4, 5) estão os gráficos da distribuição das cargas, ao longo do dia, para cada cenário. Foram considerados os valores de pesos de controle de $w_1 = 0,5$ e $w_2 = 0,5$.

7 Conclusões e Trabalhos Futuros

Neste artigo foi solucionado um problema de otimização do SHC proposto por (de T. F. B. Filho et al., 2015), utilizando a técnica de meta-heurísticas PSO, comparando os desempenhos

Figura 2: Cenário 1 - PSO

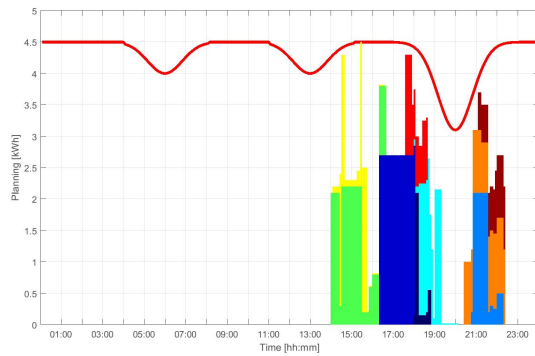


Figura 3: Cenário 2 - PSO




Figura 4: Cenário 3 - PSO


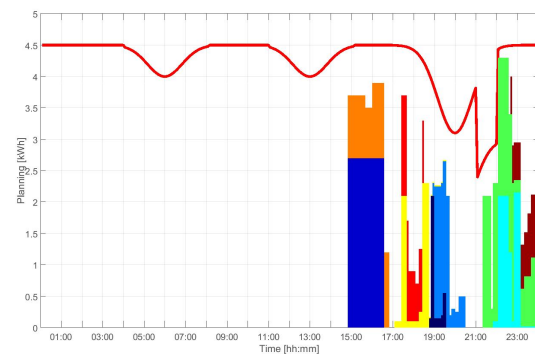


Figura 5: Cenário 4 - PSO



com a técnica utilizada no artigo referência (Programação Linear).

Pelos resultados obtidos, pôde-se observar que, em relação ao custo total de execução de todas cargas, o desempenho da otimização com PSO foi um pouco inferior ao artigo referência, com um aumento de aproximadamente 8,5%. Já em relação ao nível de desconforto, em alguns casos isolados a otimização aqui proposta (PSO) torna-se melhor, apresentando um desconforto menor, porém de forma geral, apresenta um desconforto, aproximadamente, 12% maior que o artigo referência. Porém, pelos resultados apresentados, em relação ao tempo de execução do algoritmo, o PSO é consideravelmente mais rápido do que a programação Linear.

Dessa forma, apesar da programação linear obter a resposta ótima, seu tempo de execução é bem maior do que o PSO, tornando-se inviável quando o número de cargas aumentar. No caso apresentado (com apenas 9 cargas), o algoritmo com PSO demora menos de 10 segundos, enquanto que com programação linear demora em média 3 minutos. A medida que o número de cargas aumentar, o tempo de execução também aumenta, dessa forma usar uma técnica de otimização com um tempo de execução grande, inviabiliza a ideia de embarcar a solução.

Como trabalhos futuros, pretende-se testar o algoritmo PSO em condomínio de residências e com múltiplos acionamentos das cargas, levando em consideração as diferentes etapas de cada uma.

Agradecimentos

Os autores agradecem a Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) pelo apoio financeiro.

Referências

ANEEL (2008). Atlas de energia elétrica no Brasil 3a edição, http://www2.aneel.gov.br/arquivos/pdf/atlas_par1_cap2.pdf.

de T. F. B. Filho, P., de Albuquerque, P. U. B. e Bruno de A. Prata, G. C. B. (2015). Proposição de um controlador de cargas inteligente considerando custo energético e conforto baseado em programação linear inteira, *Simpósio Brasileiro de Autimação Inteligente*.

Esmin, A. A. A. (2007). Generating fuzzy rules from examples using the particle swarm optimization algorithm, *Seventh International Conference on Hybrid Intelligent Systems*.

et al, Z. Z. (2013). An optimal power scheduling method for demand response in home energy management system., *Smart Grid, IEEE Transactions*.

- Giorgio, A. D. e Pimpinella, L. (2013). An event driven smart home controller enabling consumer economic saving and automated demand-side management, *Elsevier Applied Energy* .
- Kennedy, J. e Eberhart, R. (1995). Particle swarm optimization, *IEEE International Conference on Neural Networks* .
- Raka, J., Tuba, M. e Voss, S. (2016). An ant colony optimization algorithm for partitioning graphs with supply and demand., *Applied Soft Computing* .
- Rehman, N. U., Rahim, H., Ahmad, A., Khan, Z. A., Qasim, U. e Javaid, N. (2016). Heuristic algorithm based energy management system in smart grid, *10th International Conference on Complex, Intelligent, and Software Intensive Systems* .
- Richard, O. e Pistikopoulos, E. N. (2016). Multi-objective optimization with convex quadratic cost functions: A multi-parametric programming approach., *Computers Chemical Engineering* .
- Yong, L. J. e Choi, S. G. (2014). "linear programming based hourly peak load shaving method at home area." advanced communication technology (icact), *16th International Conference on. IEEE* .