

UM MODELO DE OTIMIZAÇÃO MULTI-OBJETIVO DE RESPOSTA À DEMANDA PARA GERENCIAR AS CARGAS RESIDENCIAIS

JACLASON M. VERAS*, IGOR RAFAEL S. SILVA†, RICARDO A. L. RABÊLO*, PLÁCIDO R. PINHEIRO†, JOEL J. P. C. RODRIGUES‡

*Programa de Pós-Graduação em Informática Aplicada
Universidade de Fortaleza (UNIFOR)
Fortaleza, CE, Brasil

†Departamento de Computação
Universidade Federal do Piauí (UFPI)
Teresina, PI, Brasil

‡Instituto Nacional de Telecomunicações (INATEL)
Santa Rita do Sapucaí, MG, Brasil

Emails: jaclason@gmail.com, yggori14rafa@hotmail.com, ricardoalr@ufpi.edu.br, placido@unifor.br, joelj@ieeee.org

Abstract— Demand response (DR) systems aim to balance the supply and demand of electric energy in order to maximizing the reliability and efficiency of power supply systems. Thus, this article presents a multi-objective optimization model based on real-time electricity prices to solve the problem of optimal residential load management. The proposal minimizes the cost of electricity associated with consumption and the inconvenience (dissatisfaction/discomfort) caused to consumers. The model proposed here was designed as a nonlinear programming problem subject to a set of constraints associated with the consumption of electrical energy and operational aspects related to the categories of the appliances. The proposal was solved computationally using the Non-Dominated Sorted Genetic Algorithm (NSGA-II) to determine new schedules for residential appliances over the entire time horizon. The results showed that the multi-objective DR model proposed here with the NSGA-II technique can minimize the total cost of energy consumption as well as minimize any inconvenience caused to consumers.

Keywords— Demand Response, Load Scheduling, Optimization, Smart Grid.

Resumo— A resposta à demanda (RD) visa equilibrar a oferta e a demanda de energia elétrica com o intuito de maximizar a confiabilidade e a eficiência do processo de fornecimento energético no sistema elétrico de potência (SEP). Assim, este artigo apresenta um modelo de otimização multi-objetivo baseado no preço da energia elétrica em tempo real para solucionar o problema de gerenciamento ótimo da carga residencial. O objetivo da proposta é minimizar tanto o custo da eletricidade associada ao consumo quanto a inconveniência (insatisfação/desconforto) causada aos consumidores. O modelo proposto foi formalizado como um problema de programação não-linear sujeito a um conjunto de restrições associadas ao consumo de energia elétrica e aspectos operacionais relacionados às categorias de aparelhos residenciais. A proposta foi solucionada computacionalmente por meio do *Non-Dominated Sorted Genetic Algorithm (NSGA-II)* para determinar o novo agendamento de uso dos aparelhos residenciais para todo o horizonte de tempo. Os resultados evidenciam que o modelo multi-objetivo de RD proposto usando a técnica NSGA-II consegue minimizar o custo total associado ao consumo energético bem como, minimizar a inconveniência dos consumidores.

Palavras-chave— Otimização, Programação de Carga, Redes Inteligentes, Resposta à Demanda.

1 Introdução

Resposta à Demanda (RD) ou *Demand Response (DR)* refere-se as mudanças no uso da energia elétrica por parte dos consumidores finais levando em consideração as modificações ocorridas em relação ao preço da eletricidade ao longo do tempo e, também, aos pagamentos de incentivos (como por exemplo, descontos na conta de eletricidade) oferecidos pelas concessionárias de energia elétrica (Siano, 2014). A RD tem como um dos objetivos reduzir ao menor patamar possível o uso da energia elétrica em momentos que os preços de mercado da eletricidade estão elevados ou quando a confiabilidade do sistema elétrico de potência (SEP) é comprometida com a sobrecarga do sistema (Siano, 2014; Parvania and Fotuhi-

Firuzabad, 2010). Assim, os autores em (Parvania and Fotuhi-Firuzabad, 2010) afirmam que o aumento excessivo da demanda de energia elétrica fez o uso da RD ser interessante aos consumidores e às concessionárias de energia elétrica.

No entanto, os autores em (Setlhaolo et al., 2014) afirmam que, a RD é um programa que tem tido sucesso com os consumidores comerciais e industriais devido à capacidade de reduzir significativamente o custo e o consumo de energia elétrica. Contudo, um dos empecilhos para a inserção da RD no âmbito residencial, é a necessidade de uma intervenção manual por parte do consumidor no processo de determinação do uso dos aparelhos residenciais. Por esse motivo, pela falta de tempo, de conhecimento e do consumidor não querer participar ativamente dos programas

ligados ao SEP, a implantação da RD fica afetada no cenário residencial. Assim, em (Kamyar and Peet, 2017) os autores propuseram um algoritmo que determina a configuração dos termostatos a fim de minimizar o custo da eletricidade dos consumidores finais. O problema foi formulado matematicamente como de programação dinâmica e os resultados mostram que o algoritmo permite reduzir o custo associado ao consumo de energia elétrica. No entanto, a proposta restringem-se a avaliar apenas a programação dos aparelhos térmicos sem levar consideração as outras categorias de aparelhos residenciais.

Os autores em (Yan et al., 2015) apresentaram um sistema de resposta à demanda baseado no preço em tempo real da eletricidade para residências. O objetivo da proposta é modificar o comportamento de consumo energético dos consumidores nas redes inteligentes e maximizar o conforto. A proposta foi formulada matematicamente como um problema de programação linear. Contudo, a proposta não avalia as diferentes categorias de aparelhos residenciais e o nível de satisfação/conforto dos consumidores finais.

Em (Vivekananthan et al., 2015) os autores propuseram um algoritmo para gerenciar o uso da energia elétrica no âmbito residencial com o propósito de reduzir o custo da eletricidade. A proposta apresentada no trabalho usa a programação dinâmica estocástica para agendar a operação dos aparelhos. Contudo, a proposta restringe-se a avaliar somente 07 (sete) aparelhos não contemplando todas as diferentes categorias de aparelhos residenciais. Além disso, na formulação matemática não é contemplado o impacto das modificações de uso dos eletrodomésticos em relação ao nível de satisfação/conforto dos consumidores finais.

Neste sentido, o gerenciamento e o planejamento do consumo energético residencial se torna complexo devido a fatores como a falta de experiência do consumidor para lidar com a programação diária e as particularidades de operações de cada aparelho residencial. Diante disso, neste artigo é proposto um modelo de otimização multi-objetivo para gerenciar o uso das cargas residenciais com o intuito de minimizar o custo associado ao consumo de energia elétrica e também, minimizar o nível de inconveniência (insatisfação/desconforto) dos consumidores finais em relação a nova programação de uso dos aparelhos residenciais a fim de, melhorar a confiabilidade e a eficiência do sistema elétrico de potência.

Dessa forma, o modelo de otimização multi-objetivo apresentado neste trabalho foi formulado como um problema de programação não-linear que considera as várias restrições associadas ao consumo de energia elétrica tais como, limites mínimo e máximo da carga para cada intervalo de tempo, limites de rampa, consumo de eletricidade mínimo para cada horizonte de tempo e além disso, os

aspectos relacionados ao nível de inconveniência (insatisfação/desconforto) dos consumidores finais vinculados as restrições operacionais das diferentes categorias de aparelhos residenciais. Nas simulações computacionais, devido a sua eficiência com problemas de natureza combinatória (Deb et al., 2002), foi usado o *Non-Dominated Sorted Genetic Algorithm* (NSGA-II) para alcançar os resultados do problema multi-objetivo.

As contribuições relacionadas ao uso do modelo de otimização multi-objetivo proposto incluem: a) a determinação de um agendamento otimizado para operar diferentes categorias de aparelhos residenciais em horizontes de tempo com tamanho variável; b) a representação de diferentes características como localização geográfica, temperatura climática, preferências dos consumidores e o preço dinâmico (a cada hora) da energia elétrica e suas implicações no consumo energético das residências; c) a avaliação de diferentes cenários de consumo energético com e sem a otimização dos aparelhos no âmbito residencial; d) a avaliação do nível de inconveniência (insatisfação/desconforto), de modo a permitir aos consumidores finais tomarem a decisão de aderir ou não ao programa RD.

Este trabalho está disposto na seguinte forma: a Seção 2 apresenta o modelo de otimização multi-objetivo; a Seção 3 mostra um estudo de caso que exhibe os cenários de teste e os resultados numéricos alcançados na simulação computacional que aplica o modelo proposto neste trabalho; e, por fim, a Seção 4 descreve as principais contribuições deste trabalho e trabalhos futuros.

2 Modelo de otimização multi-objetivo

O modelo multi-objetivo deste trabalho é composto por duas funções de minimização, sendo uma com o objetivo de minimizar o custo associado ao consumo da eletricidade, chamada de $f1$, e uma outra visando minimizar a inconveniência do consumidor final, chamada de $f2$. A função que visa a minimização do custo associado ao consumo de energia elétrica considera um horizonte de tempo T , que pode ser definido pelo consumidor (por exemplo, 24 horas) com discretização por hora, a potência (em kW) e o consumo energético (em kWh) de cada aparelho residencial por intervalo de tempo. Na equação (1) é apresentada a função $f1$.

$$\text{Minimize } \sum_{i=1}^N E_i \sum_{t=1}^T (Pr_t * DSA_{t,i})^2 \quad (1)$$

onde N representa o número de aparelhos residenciais; $E_i (i = 1, \dots, N)$ corresponde ao vetor com o consumo de energia elétrica dos aparelhos residenciais i quando estiver em operação; T indica

o horizonte de tempo; Pr_t corresponde ao preço da energia elétrica no intervalo de tempo t ; DSA (Configuração Diária dos Aparelhos) corresponde à matriz de programação das cargas com a seguintes configuração:

$$DSA_{t,i} = \begin{cases} 1, & \text{se aparelho } i \text{ ligado no tempo } t, \\ 0, & \text{caso contrário.} \end{cases}$$

sujeito as diversas restrições a seguir.

A restrição 1 (eq. 2) estabelece limites (mínimo e máximo) para os níveis de carga em cada intervalo de tempo onde $P_i (i = 1, \dots, N)$ é o vetor com a potência (em kW) de cada aparelho residencial.

$$d_t^{min} \leq \sum_{i=1}^N DSA_{t,i} * P_i \leq d_t^{max}, \forall t=1, \dots, T \quad (2)$$

As restrições 2 e 3 (eq. 3 e 4) definem os limites de rampa máximo/mínimo por intervalo de tempo.

$$\sum_{i=1}^N (DSA_{t,i} - DSA_{t+1,i}) * P_i \leq r^D, \forall t=1, \dots, T-1 \quad (3)$$

$$\sum_{i=1}^N (DSA_{t+1,i} - DSA_{t,i}) * P_i \leq r^U, \forall t=1, \dots, T-1 \quad (4)$$

A restrição 4 (eq. 5) estabelece um consumo mínimo (mdc) diário de energia elétrica.

$$\sum_{i=1}^N \sum_{t=1}^T DSA_{t,i} * E_i \geq mdc \quad (5)$$

As restrições 5 a 7 (eq. 6-8) estão relacionadas aos tipos de aparelhos residenciais especificados por suas particularidades operacionais (Chen et al., 2012), sendo eles: *interruptible* e *deferrable* (A_I); *uninterruptible* e *deferrable* (A_{II}); e, *uninterruptible* e *non-deferrable* (A_{III}). *Uninterruptible* significa que uma tarefa não pode ser interrompida até que seja concluída. *Non-deferrable* significa que uma tarefa deve ser iniciada no primeiro intervalo de tempo do período requerido para seu funcionamento. Com base nessas definições, pode-se especificar as restrições que lidam com as diferentes categorias de aparelhos residenciais A_I , A_{II} e A_{III} .

Assim, a restrição 5 (eq. 6) define que o início da operação dos aparelhos residenciais A_I pode variar ao longo do horizonte de tempo T desde que Req_i seja respeitado.

$$\sum_{t=1}^T DSA_{t,i} \geq Req_i, \forall i \in A_I \quad (6)$$

A restrição 6 (eq. 7) estabelece que o início da operação do aparelho residencial do tipo A_{II} pode

ser adiado no horizonte de tempo T mas, uma vez que seu funcionamento foi iniciado, não pode ser interrompido.

$$\sum_{q=1}^{T-Req_i} \prod_{t=q}^{Req_i+(q-1)} DSA_{t,i} \geq 1, \forall i \in A_{II} \quad (7)$$

Por fim, a restrição 7 (eq. 8) visa garantir que, entre o tempo definido pelos consumidores para início (ST_i) e fim (ET_i) da operação dos aparelhos residenciais do tipo A_{III} , o seu funcionamento seja ininterrupto durante o tempo requerido Req_i no horizonte de tempo T .

$$\sum_{ST_i}^{ET_i} DSA_{t,i} \geq Req_i, \forall i \in A_{III} \quad (8)$$

A função $f2$ avalia como as modificações de uso dos aparelhos residenciais podem interferir na satisfação/conforto dos consumidores finais, minimizando a inconveniência. Este cálculo compara o consumo de energia elétrica real (*Baseline*) no intervalo de tempo t para as diferentes categorias de aparelhos residenciais das famílias analisadas por meio da ferramenta *Load Profile Generator (LPG)* (Pflugradt, 2016) e o consumo (*OPT*) sugerido pelas técnicas de otimização utilizadas nas simulações computacionais. Portanto, a matriz $Baseline_{t,i}$ pode ser definida da seguinte forma:

$$Baseline_{t,i} = \begin{cases} 1, & \text{se aparelho } i \text{ ligado no tempo } t, \\ 0, & \text{caso contrário.} \end{cases}$$

O $OPT_{t,i}$ é a programação de carga sugerida pela técnica de otimização para os diversos modelos de RD.

$$OPT_{t,i} = \begin{cases} 1, & \text{se aparelho } i \text{ ligado no tempo } t, \\ 0, & \text{caso contrário.} \end{cases}$$

Partindo desse pressuposto, o cálculo da inconveniência associado a uma programação de operação dos aparelhos residenciais permite ao consumidor tomar a melhor decisão de utilização dos aparelhos residenciais no programa de RD. Assim, a formulação da função $f2$ é mostrada na equação (9) e assume-se que, tanto a $Baseline_{t,i}$ quanto o $OPT_{t,i}$ estejam na forma de uma matriz binária (composta apenas por 1's e 0's) para indicar quais os aparelhos estão em operação em cada intervalo de tempo.

$$\text{Minimize} \sum_{t=1}^T \sum_{i=1}^N (Baseline_{t,i} - OPT_{t,i})^2 \quad (9)$$

Definidas as funções $f1$ e $f2$, a função objetivo do modelo multi-objetivo deste trabalho se apresenta da seguinte maneira:

$$\begin{aligned} & \text{minimize}(f1) \\ & \text{minimize}(f2) \end{aligned} \quad (10)$$

3 Estudo de caso

Para avaliar o modelo de otimização multi-objetivo utilizou-se perfis de consumo de energia elétrica fornecidos pela ferramenta *Load Profile Generator (LPG)* (Pflugradt, 2016) para 06 (seis) famílias brasileiras residentes nas cidades de Brasília (DF), Florianópolis (SC) e João Pessoa (PB) situadas nas regiões Centro-Oeste, Sul e Nordeste do Brasil respectivamente.

Foram utilizadas nas simulações computacionais um horizonte de tempo T , com discretização por hora, que contempla os dias com maior e menor consumo de energia elétrica para cada família entre o período de 01 de janeiro a 31 de dezembro de 2016. Assumimos que todo o intervalo de tempo de agendamento consiste em 24 sub-intervalos, isto é, $T = \{1h, 2h \dots 24h\}$. Assim, o preço do consumo unitário de energia em cada sub-intervalo é baseado nos valores do *Iberian Electricity Market (OMIE)* (OMIE, 2017) de Portugal para calcular o preço da eletricidade para cada hora, já que o Brasil não utiliza um programa de RD tendo como base os preços da energia elétrica em tempo real.

Dessa forma, o modelo de otimização multi-objetivo proposto neste trabalho permite a utilização das informações de preços de diferentes análises, como estudos que utilizam previsão ou histórico de preços. Assim, a informação referente ao preço da eletricidade é considerada como uma entrada, de modo que o modelo não restringe-se ao uso do preço de países ou localidades específicas. Na Figura 1 é apresentado o preço da energia elétrica em tempo real para cada hora do horizonte de planejamento baseado nos valores diários do OMIE para um dos dias de maior consumo energético (24 de dezembro de 2016) na cidade de Florianópolis (SC).




Figura 1: Preço da energia elétrica para cada sub-intervalo de tempo.

3.1 Resultados e Discussões

Nesta seção, apresentamos os resultados das simulações computacionais para avaliar o desempenho do modelo de otimização multi-objetivo de RD proposto usando a técnica de otimização NSGA-II (Deb et al., 2002) para solucionar o problema de agendamento de uso dos aparelhos para 02 (dois) diferentes cenários residenciais de consumo de energia elétrica levando em consideração um conjunto variado de restrições. Nas análises foi considerada a solução com melhor desempenho no objetivo minimizar custo ($f1$, definido pela Equação 2), indicada com a letra **A** na Figura 2, que apresenta a fronteira de pareto ótima encontrada nas simulações computacionais. A Tabela 1 mostra os aparelhos residenciais usados nas simulações para cada cenário.




Figura 2: Fronteira de pareto ótima encontrada nas simulações computacionais.

Tabela 1: Aparelhos residenciais de cada cenário.

Cenários	Aparelhos Residenciais
1	Lâmpadas 100W, 20W e 60W, Receptor de Sinal de Satélite, TV, Carregador de Celular, Playstation, Microsoft Xbox 360, Receptor de Sinal Digital, Notebook, CD/DVD Player, Computador, Roteador, Monitor de Computador, Rádio de Cozinha, Home Theater, Adega de Vinhos, Ferro a Vapor, Secador de Cabelo, Barbear elétrico, Fogão Elétrico, Bicicleta Ergométrica, Microondas, Espregador de Fruta, Máquina de Lavar Roupas, Secadora de Roupas, Torradeira, Chaleira Elétrica, Máquina de Café Expresso, Geladeira, Ar Condicionado, Aquecedor Elétrico e Freezer.
2	Lâmpadas 100W, 20W e 60W, Receptor de Sinal de Satélite, TV, Playstation, Notebook, CD/DVD Player, Computador, Monitor de Computador, Roteador, Adega de Vinhos, Ferro a Vapor, Espregador de Fruta, Microondas, Máquina de Lavar Roupas, Chaleira Elétrica, Máquina de Café Expresso, Geladeira, Ar Condicionado, Aquecedor Elétrico e Freezer.

3.1.1 Cenário 1

Neste cenário consideramos cada família constituída por 02 adultos com 03 filhos. Os resultados das simulações computacionais apontam que a família residente na cidade de Brasília (DF) em comparação com as outras famílias reduziu o custo total da eletricidade de R\$ 799.98 para R\$ 740.14 perfazendo um total de 7.48 % proporcionando os melhores resultados relacionados a minimização de custo associado ao consumo de energia elétrica.

A Tabela 2 mostra um resumo dos resultados das simulações computacionais para o cenário 1.

Tabela 2: Redução por família em cada cidade no cenário 1.

Família	Custo sem RD (R\$)	Custo com RD (R\$)	Redução (%)
I (Brasília-DF)	799.98	740.14	7.48
II (João Pessoa-PB)	855.93	804.92	5.96
III (Florianópolis-SC)	697.30	647.09	7.20

Na análise de inconveniência e de *tradeoff* é possível observar que para cada unidade de inconveniência causada há uma redução média total de R\$ 0.44 no custo associado ao consumo de energia elétrica. Assim, a família residente na cidade de Brasília (DF) obteve o maior valor de *tradeoff* com 0.47, o que equivale a R\$ 0.47 reduzidos por unidade de inconveniência causada ao consumidor final. Na Tabela 3 é exibido um resumo dos resultados alcançados nas simulações computacionais para a inconveniência e o *tradeoff*.

Tabela 3: Análise de inconveniência e *tradeoff* no cenário 1.

Família	Inconveniência Causada	<i>Tradeoff</i>
I (Brasília-DF)	127	0.47
II (João Pessoa-PB)	117	0.44
III (Florianópolis-SC)	123	0.41
TOTAL	363	-

3.1.2 Cenário 2

No cenário 2 consideramos que cada família contém somente 1 adulto. Assim, percebe-se que a família residente na cidade de Brasília (DF) em comparação com as demais famílias, conseguiu atingir a maior redução referente ao custo total da eletricidade passando de R\$ 175.62 para R\$ 162.59 perfazendo um total de 7.42 %. Logo, atingiu os melhores resultados computacionais dentre as famílias analisadas. Na Tabela 4 são mostrados os resultados das simulações computacionais para cada família do cenário 3.

Tabela 4: Redução por família em cada cidade no cenário 2.

Família	Custo sem RD (R\$)	Custo com RD (R\$)	Redução (%)
I (Brasília-DF)	175.62	162.59	7.42
II (João Pessoa-PB)	174.24	163.46	6.19
III (Florianópolis-SC)	171.14	159.04	7.07

Analisando os valores de inconveniência e de *tradeoff* obtidos nas simulações computacionais, é visto que há uma redução média de R\$ 0.29 no custo total associado ao consumo de energia elétrica no cenário 2. Neste cenário a família residente na cidade de Florianópolis-SC alcançou o maior valor de *tradeoff* com 0.31 dentre as famílias analisadas. Na Tabela 5 é exibido um resumo dos resultados das simulações computacionais para a inconveniência e o *tradeoff*.

Tabela 5: Análise de inconveniência e *tradeoff* no cenário 2.

Família	Inconveniência Causada	<i>Tradeoff</i>
I (Brasília-DF)	43	0.30
II (João Pessoa-PB)	40	0.27
III (Florianópolis-SC)	39	0.31

3.2 Análise Estatística

Neste trabalho foram realizadas simulações computacionais usando a técnica de otimização NSGA-II e o comparamos com um algoritmo de busca aleatória (que consiste de um algoritmo genético (AG) (Holland, 1975) com um método de seleção aleatório, que não utiliza nenhum conhecimento heurístico em sua execução, chamado de AG aleatório). Utilizamos 03 métricas de desempenho (Diversity, Coverage e Hipervolume) para analisar os resultados computacionais referente ao problema de agendamento de uso dos aparelhos residenciais. A Diversity mede a variedade de soluções em uma região, geralmente ampla, dada por um algoritmo. Assim, um bom desempenho nesse aspecto melhora o número de opções no espaço de soluções.

A Coverage (métrica C) é utilizada para avaliar a capacidade de aproximação ótima das soluções. Assim, a Coverage assegura um espaço de soluções mais adequado para solucionar o problema de RD apresentado neste trabalho. Logo, a métrica C (Zitzler and Thiele, 1999) foi usada para avaliar qual dos algoritmos (NSGA-II ou AG aleatório) apresentam a melhor cobertura. Além disso, a métrica de Hipervolume (HV) (Zitzler and Thiele, 1999) (Zitzler et al., 2003) foi usada para avaliar de forma mais abrangente o desempenho geral dos algoritmos multi-objetivos. Ambas as técnicas analisadas (NSGA-II e AG aleatório) foram executadas 1000 vezes para a obtenção dos valores utilizados nas análises estatísticas, para reduzir o impacto da natureza estocástica das mesmas.

3.2.1 Diversity

A métrica *spacing* (Schott, 1995) foi usada para calcular a Diversity, que é dada pelo valor de s :

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{d} - d_i)^2} \quad (11)$$

onde $d_i = \min_j \sum_{a=1}^M (|f_a^i(x) - f_a^j(x)|)$, $i, j = 1, 2, 3, \dots, n$, $i \neq j$. $\bar{d}$ representa a média dos valores de d_i , M é o número de objetivos do problema e n é o número de soluções.

Neste sentido, quando o valor de s for mais próximo de zero, maior será a proximidade das soluções dentro do conjunto analisado. Assim, menor a diversidade (Schott, 1995).

3.2.2 Coverage

A métrica C é usada para comparar a relação de cobertura entre dois conjuntos de soluções. Assim, $C(A, B)$ representa a proporção do número de pontos no conjunto B dominado pelo conjunto A sobre o número total de pontos no conjunto B . Na Equation 12 é apresentada a métrica C .

$$C(A, B) = \frac{|\{x \in B \mid \exists y \in A : y \text{ domina } x\}|}{|B|} \quad (12)$$

O valor $C(A, B) = 1$ significa que todos os pontos em B são dominados por A ou iguais aos pontos contidos em A . Em contrapartida, se $C(A, B) = 0$, indica que nenhum dos pontos em B são dominados pelo conjunto A . Assim, deve se observar que $C(A, B)$ e $C(B, A)$ devem ser considerados porque $C(A, B) \neq 1 - C(B, A)$ (Zitzler and Thiele, 1999). Nas simulações computacionais, o A será considerado como o modelo multi-objetivo de RD proposto neste trabalho usando o NSGA-II e B o algoritmo de busca aleatória (AG aleatório).

3.2.3 Hipervolume

Para analisar o desempenho dos resultados alcançados nas simulações computacionais pelo modelo de RD proposto neste trabalho, foi calculado o Hipervolume (HV) que é uma métrica de performance que calcula o volume do espaço objetivo entre o conjunto de soluções encontradas e um ponto referencial, e quanto maior o valor do HV, melhor o desempenho em termos de convergência, extensão e uniformidade (Zitzler and Thiele, 1999). Nas simulações computacionais, foi utilizado o ponto de nadir (vetor que tem como elementos os piores valores de cada critério do problema multi-objetivo) (Zitzler et al., 2007) (Lu and Anderson-Cook, 2013) como ponto referencial para analisar a performance dos resultados.

Zitzler et al. (Zitzler et al., 2003) afirma que o HV é a única métrica unária a qual é capaz de avaliar que um conjunto de soluções S não é pior do

que outro S' . Dessa forma, um conjunto de soluções é *Pareto Optima* apenas quando o HV é maximizado e vice-versa (Fleischer, 2003). Assim, uma característica principal do HV é que ele é compatível com a dominância de Pareto - se uma população de Pareto domina outra, então esta possui um HV maior que a dominada - além de não necessitar da fronteira de pareto real do problema no seu cálculo (Zitzler and Thiele, 1999) (Zitzler et al., 2003).

3.2.4 Resultados Estatísticos

Os resultados das simulações computacionais alcançados por meio da técnica de otimização NSGA-II foram comparados com os valores produzidos pelo AG aleatório com o intuito de validar a corretude do algoritmo (*sanity check*). Assim, os resultados estatísticos apresentam que o NSGA-II obteve um hypervolume mínimo de 0.57 e máximo de 0.65 enquanto o AG aleatório obteve um hypervolume mínimo e máximo de 0.29 e 0.35 respectivamente. Em média, os valores de hypervolume do modelo proposto neste trabalho usando a técnica NSGA-II são maiores e melhores que os associados ao AG aleatória.

Adicionalmente, foi verificada a variedade de soluções em uma região (*diversity*). Logo, pode-se observar na diversity que o NSGA-II obteve na métrica *spacing* um valor mínimo e máximo de 14.56 e 18.19 respectivamente. Já o AG aleatório alcançou os valores para mínimo de 10.12 e para máximo 15.38.

Por fim, a métrica C foi utilizada para avaliar a coverage dos resultados obtidos nas simulações computacionais pelo NSGA-II e AG aleatório. Assim, os valores mínimos e máximos que o NSGA-II e o AG aleatório alcançaram para $C(A, B)$ e $C(B, A)$ foram 1, 1 e 0, 0 respectivamente. Portanto, é possível observar nos resultados estatísticos mostrados na Tabela 6, que o modelo de RD proposto neste trabalho usando a técnica NSGA-II obteve os melhores valores do que o AG aleatório para todas as métricas consideradas nas simulações computacionais.

Tabela 6: Análise estatística.

Algoritmo	Métrica	Min	Max	Média	Desvio Padrão
NSGA-II	Spacing	14.56	18.19	16.08	1.14
AG aleatório		10.12	15.38	14.35	1.06
NSGA-II	C (A,B)	1	1	1	0
AG aleatório					
NSGA-II	C (B,A)	0	0	0	0
AG aleatório					
NSGA-II	HV	0.57	0.65	0.61	0.01
AG aleatório		0.29	0.35	0.32	0.01

Também foram feitas análises para verificar se a diferença entre os algoritmos (NSGA-II e AG aleatório) é estatisticamente significativa. Para isso, foram utilizados dois testes não-

paramétricos, que não requerem que os dados analisados possuam uma distribuição normal. Primeiramente, foi usado o teste de Kolmogorov-Smirnov (Rumsey, 2007) (KS test), que verifica se os conjuntos de resultados possuem a mesma distribuição (normal). Pode-se observar, por meio dos resultados das simulações computacionais que os conjuntos não seguem a mesma distribuição (nível de significância = 0.01, todos os p -values < 0.001).

Em seguida, foi utilizado o teste de Wilcoxon-Mann-Whitney (Rumsey, 2007) (Rank-Sum test), para verificar se os conjuntos de resultados possuem a mesma mediana. Os resultados obtidos mostram que as medianas são diferentes, logo, os testes indicam que há uma diferença estatisticamente significativa entre os conjuntos de resultados analisados. (nível de significância = 0.01, todos os p -values < 0.001).

Adicionalmente, foi utilizada a medida A de Vargha-Delaney (Rumsey, 2007) (VDA), que é uma medida padrão de *effect size* para validar que o modelo multi-objetivo proposto possui um melhor desempenho que o AG aleatório. A medida A de Vargha-Delaney é um valor entre 0 e 1, no qual valores próximos a 0.5 indicam que as duas técnicas possuem performance similar. Valores entre 0 e 0.5 indicam que o AG aleatório tem performance melhor e valores entre 0.5 e 1 indicam que o AG aleatório tem comportamento inferior ao NSGA-II. Portanto, na avaliação dos valores das métricas de Hipervolume e Spacing utilizando o VDA, a técnica de otimização NSGA-II obtém resultados significativamente melhores que o AG aleatório. A Tabela 7 mostra um resumo dos valores da medida VDA para as métricas analisadas.

Tabela 7: Valor da Medida A de Vargha-Delaney

Métrica	VDA
Spacing	0.999
Hipervolume	0.999

4 Conclusão

Neste trabalho é proposto um modelo de otimização multi-objetivo formulado matematicamente como um problema de programação não-linear para gerenciar a operação dos aparelhos residenciais considerando um conjunto de restrições associadas ao consumo energético e as particularidades existentes em cada categoria de aparelhos. Além disso, a proposta apresentada leva em consideração o impacto do agendamento otimizado de uso dos aparelhos residenciais no nível de inconveniência (insatisfação/desconforto) dos consumidores. Neste sentido, os objetivos principais da proposta é minimizar o custo associado ao consumo energético e também, reduzir os níveis de inconveniência dos consumidores finais.

Adicionalmente, ao levarmos em consideração o melhor desempenho do modelo de otimização multi-objetivo de RD usando a técnica de otimização NSGA-II, conforme mostrado na Seção 3, é possível observar que há uma redução significativa no custo total associado ao consumo de energia elétrica para os 2 cenários analisados neste trabalho. Dessa forma, a família que obteve os melhores valores foi a residente na cidade de Brasília (DF) onde o resultado alcançado relacionado ao custo total da eletricidade foi de R\$ 799.98 para R\$ 740.14 e de R\$ 175.62 para R\$ 162.59 para os cenários 1 e 2, respectivamente. Isso se deve à localização geográfica, que apresenta altas temperaturas, o que causa alto consumo de energia elétrica ao longo do horizonte de tempo e, consequentemente, maiores reduções.

Além disso, ao analisar o nível de inconveniência e o *tradeoff* após a otimização do uso dos aparelhos residenciais, pode-se observar que a família moradora na cidade de Brasília (DF) atingiu os melhores valores em relação ao *tradeoff* sendo 0.47 no cenário 1 e a família residente na cidade de Florianópolis (SC) obteve 0.31 para o cenário 2, obtendo o melhor valor nesse caso. É importante mencionar, que todos os conjuntos de restrições do modelo de RD proposto estão sendo respeitadas e também, foi levado em consideração as características como a localização geográfica, as temperaturas climáticas e suas respectivas implicações de cada cidade analisada e as preferências do consumidor em relação ao uso das diferentes categorias de aparelhos residenciais.

Portanto, pode-se concluir que a proposta apresentada neste trabalho usando a técnica de otimização NSGA-II para solucionar computacionalmente o problema de otimização multi-objetivo pode ser usada como uma ferramenta de suporte auxiliar de tomada de decisão para ajudar os consumidores a melhorar o agendamento de uso dos aparelhos residenciais. Além disto, permite minimizar o custo associado ao consumo de energia elétrica e o nível de inconveniência dos consumidores.

Como trabalhos futuros deste estudo, pretendemos aperfeiçoar o modelo com o intuito de acrescentar novas características na sua formulação como por exemplo, a capacidade e o regime de carga/descarga do sistema de armazenamento energético contidos nos veículos elétricos, a potência do sistema de geração renovável de energia elétrica levando em consideração as particularidades dos recursos fotovoltaicos e eólicos.

Referências

Chen, Z., Wu, L. and Fu, Y. (2012). Real-time price-based demand response management for residential appliances via stochastic

- optimization and robust optimization, *IEEE Transactions on Smart Grid* **3**(4): 1822–1831.
- Deb, K., Pratap, A., Agarwal, S. and Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: Nsga-ii, *IEEE Transactions on Evolutionary Computation* **6**(2): 182–197.
- Fleischer, M. (2003). The measure of pareto optima applications to multi-objective metaheuristics, *Evolutionary multi-criterion optimization*, Springer, pp. 74–74.
- Holland, J. H. (1975). Adaptation in natural and artificial systems. an introductory analysis with applications to biology, control and artificial intelligence, *Ann Arbor: University of Michigan Press*, 1975 **1**.
- Kamyar, R. and Peet, M. M. (2017). Optimal thermostat programming for time-of-use and demand charges with thermal energy storage and optimal pricing for regulated utilities, *IEEE Transactions on Power Systems* **32**(4): 2714–2723.
- Lu, L. and Anderson-Cook, C. M. (2013). Adapting the hypervolume quality indicator to quantify trade-offs and search efficiency for multiple criteria decision making using pareto fronts, *Quality and Reliability Engineering International* **29**(8): 1117–1133.
- OMIE (2017). Electricity market price. <http://www.omie.es/files/flash/ResultadosMercado.swf>.
- Parvania, M. and Fotuhi-Firuzabad, M. (2010). Demand response scheduling by stochastic scuc, *IEEE Transactions on Smart Grid* **1**(1): 89–98.
- Pflugradt, N. D. (2016). *Modellierung von wasser und energieverbräuchen in haushalten*, Master’s thesis, Technische Universität Chemnitz, Chemnitz.
- Rumsey, D. J. (2007). *Intermediate statistics for dummies*, John Wiley & Sons.
- Schott, J. R. (1995). Fault tolerant design using single and multicriteria genetic algorithm optimization., *Technical report*, AIR FORCE INST OF TECH WRIGHT-PATTERSON AFB OH.
- Setlhaolo, D., Xia, X. and Zhang, J. (2014). Optimal scheduling of household appliances for demand response, *Electric Power Systems Research* **116**: 24–28.
- Siano, P. (2014). Demand response and smart grids – a survey, *Renewable and Sustainable Energy Reviews* **30**: 461–478.
- Vivekananthan, C., Mishra, Y. and Li, F. (2015). Real-time price based home energy management scheduler, *IEEE Transactions on Power Systems* **30**(4): 2149–2159.
- Yan, X., Wright, D., Kumar, S., Lee, G. and Ozturk, Y. (2015). Enabling consumer behavior modification through real time energy pricing, *Pervasive Computing and Communication Workshops (PerCom Workshops), 2015 IEEE International Conference on*, IEEE, pp. 311–316.
- Zitzler, E., Brockhoff, D. and Thiele, L. (2007). The hypervolume indicator revisited: On the design of pareto-compliant indicators via weighted integration, *Evolutionary Multi-Criterion Optimization*, Springer, pp. 862–876.
- Zitzler, E. and Thiele, L. (1999). Multiobjective evolutionary algorithms: a comparative case study and the strength pareto approach, *IEEE Transactions on Evolutionary Computation* **3**(4): 257–271.
- Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C. M. and Da Fonseca, V. G. (2003). Performance assessment of multiobjective optimizers: An analysis and review, *IEEE Transactions on Evolutionary Computation* **7**(2): 117–132.