



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

RODRIGO TORNISIELLO

**OTIMIZAÇÃO DO BEM-ESTAR GLOBAL EM PROGRAMAS DE RESPOSTA À
DEMANDA BASEADOS EM INCENTIVOS**

FORTALEZA

2021

RODRIGO TORNISIELLO

OTIMIZAÇÃO DO BEM-ESTAR GLOBAL EM PROGRAMAS DE RESPOSTA À
DEMANDA BASEADOS EM INCENTIVOS

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia Elétrica do
Centro de Tecnologia da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Engenharia Elétrica.

Orientadora: Profa. Ph.D Ruth Pastôra
Saraiva Leão

Coorientadora: Profa. Ma. Janaína Bar-
bosa Almada

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- T638o Tornisiello, Rodrigo.
Otimização do bem-estar global em programas de resposta à demanda baseados em incentivos / Rodrigo Tornisiello. – 2021.
58 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Elétrica, Fortaleza, 2021.
Orientação: Profa. Dra. Ruth Pastôra Saraiva Leão.
Coorientação: Profa. Ma. Janaína Barbosa Almada.
1. Microrredes. 2. Resposta à demanda. 3. Geração distribuída. 4. Previsão de geração. I. Título.
CDD 621.3
-

RODRIGO TORNISIELLO

OTIMIZAÇÃO DO BEM-ESTAR GLOBAL EM PROGRAMAS DE RESPOSTA À
DEMANDA BASEADOS EM INCENTIVOS

Trabalho de Conclusão de Curso apresentado ao
Curso de Graduação em Engenharia Elétrica do
Centro de Tecnologia da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Engenharia Elétrica.

Aprovada em: de março de 2021

BANCA EXAMINADORA

Profa. Ph.D Ruth Pastôra Saraiva Leão (Orientadora)
Universidade Federal do Ceará (UFC)

Profa. Ma. Janaína Barbosa Almada (Coorientadora)
Universidade de Integração Internacional da
Lusofonia Afro-Brasileira (UNILAB)

Me. Mário Barreto de Moura Neto
Universidade Federal do Ceará (UFC)

Eng. Allan Costa Gomes
Universidade Federal do Ceará (UFC)

Aos meus pais, Nivaldo e Leni.

A minha irmã, Ligia.

A minha namorada, Thaís.

Aos meus amigos de curso e da vida.

AGRADECIMENTOS

Aos meus pais, Nivaldo e Leni, pelo apoio e cuidado em todos os momentos de minha vida.

À minha irmã, Ligia, por ser o exemplo de dedicação que me inspira e me desafia a crescer.

À minha namorada, Thaís, pelo companheirismo, cumplicidade e por ser meu suporte em qualquer condição.

Aos professores do curso de Engenharia Elétrica da Universidade Federal do Ceará, em especial aos que me orientaram ao longo da graduação: Profa. Ruth Pastôra Saraiva Leão e Prof. René Pastor. À professora Janaína Almada, que me coorientou e foi essencial para o desenvolvimento de minha pesquisa.

Ao PET, que me proporcionou amizades, conhecimentos e experiências que foram base para minha formação pessoal, acadêmica e profissional. A todos os petianos, especialmente a Bruno, Guilherme, João Vitor e Valessa, que tornaram a graduação possível, seja pelo companheirismo nos estudos ou pelos momentos de descontração necessários no cotidiano.

Aos meus amigos, Marcos e Vitor, pelos vários anos de companheirismo e empatia.

Aos meus gestores, Mário e Arthur, pela oportunidade de me desenvolver no mercado profissional e pela confiança que depositam em meu trabalho.

Ao MEC e CNPQ pelo apoio financeiro nas bolsas durante a graduação.

“Os vitoriosos são aqueles que receberam oportunidades - e que tiveram força e presença de espírito para agarrá-las.”

(Malcolm Gladwell)

RESUMO

O uso crescente da geração distribuída baseada em recursos energéticos renováveis tem desencadeado transformações nos sistemas de distribuição de energia elétrica. O crescimento da geração distribuída provoca a necessidade de um reordenamento na operação das redes de distribuição, por consequência, o desenvolvimento de microrredes. As microrredes surgem então como soluções práticas para a integração em larga escala da geração distribuída. As microrredes são sistemas elétricos de pequeno porte, que podem operar em paralelo com a rede elétrica ou desconectada desta. Devido à intermitência das fontes renováveis, é necessário fazer previsão da geração bem como gerenciar a demanda, de modo a melhor equalizar o balanço de energia da microrrede. Este projeto visa a simulação de métodos para previsão de geração e a otimização de métodos de resposta à demanda baseados em incentivo. Foram estudados diferentes métodos para previsão de curta duração de geração solar fotovoltaica, como redes neurais, séries temporais e métodos de persistência. Baseado no esforço computacional e precisão, optou-se pelas redes neurais. Para a resposta à demanda, foram avaliados programas baseados em incentivos, os quais buscam alterar a curva de demanda inicial de um conjunto de cargas para uma curva final que leve em conta os efeitos de oferta e demanda de energia. Os benefícios dos métodos de Resposta à Demanda são perceptíveis para os consumidores, que podem receber recompensas financeiras por meio da adequação aos programas, e para as operadoras, que podem ter benefícios técnico-econômicos tais como a postergação de investimentos e alívio de sobrecarga, sem perda desnecessária de receita. Por fim, otimizou-se o valor de incentivo oferecido a cada hora, gerando fronteiras de Pareto que representam pontos de custo global otimizado tanto para a distribuidora quanto para os consumidores.

Palavras-chave: Microrredes. Resposta à Demanda. Geração Distribuída. Previsão de Geração.

ABSTRACT

The increasing use of distributed resources based on renewable energy resources has triggered transformations in the electricity distribution systems. The growth of distributed resources causes the need for a reorganization in the operation of distribution networks and, consequently, the development of microgrids. The microgrids appear as practical solutions for the large-scale integration of distributed resources. Microgrids are small electrical systems that can operate in parallel with or disconnected from the power grid. Due to the intermittency of renewable sources, it is necessary to forecast generation as well as to manage demand, in order to better equalize the energy balance of the microgrid. This project aims to simulate methods for forecasting generation and to optimize incentive-based demand response methods. Different methods for short-term forecasting of photovoltaic solar generation were studied, such as neural networks, time series and persistence methods. Based on computational effort and precision, neural networks were chosen. For Demand Response, incentive-based programs were evaluated to seek to change the initial demand curve for a set of loads to a final curve that takes into account the effects of energy supply and demand. The benefits of Demand Response methods are noticeable for consumers, who can receive financial rewards for adapting to programs, and for utilities, who can have their costs reduced due to scaling the system for peak hours to be less costly if the peak demand is less. Finally, the incentive value offered every hour was optimized, generating Pareto fronts that represent points of optimized global cost for both the utility and consumers.

Keywords: Microgrids. Demand Response. Distributed Resources. Generation Forecasting.

LISTA DE FIGURAS

Figura 1 – Exemplo de topologia de microrrede	19
Figura 2 – Utilidade, custo e bem-estar para um consumidor específico.	21
Figura 3 – Painel de Geração Distribuída da Agência Nacional de Energia Elétrica (ANEEL)	22
Figura 4 – Modelo de um neurônio artificial.	23
Figura 5 – Exemplo de estrutura de RNA.	24
Figura 6 – Classificação dos métodos de RAD	26
Figura 7 – Procedimento NSGA-II	29
Figura 8 – Demanda prevista pela RNA antes da parametrização	32
Figura 9 – Diagrama de caixas a partir de erros variando a quantidade de neurônios intermediários	33
Figura 10 – Diagrama de caixas a partir de erros variando a quantidade de dados de entrada	33
Figura 11 – Diagrama de caixas a partir de erros variando a quantidade de épocas de treinamento	34
Figura 12 – Demanda prevista pela RNA após a parametrização	34
Figura 13 – Potência de geração antes e após parametrização	35
Figura 14 – Valores de utilidade para três períodos distintos	37
Figura 15 – Curva de Pareto gerada pelo PSO	38
Figura 16 – Curva de Pareto gerada pelo NSGA-II	39
Figura 17 – Topologia da microrrede de teste.	41
Figura 18 – Previsões de demanda e geração para estudo de caso I.	42
Figura 19 – Lucros do operador e do consumidor para períodos de (a) carga leve, (b) intermediária e (c) de pico.	43
Figura 20 – Curvas de elasticidade resultantes.	43
Figura 21 – Demanda antes e após programa de RAD no estudo de caso I.	44
Figura 22 – Incentivo oferecido no estudo de caso I.	44
Figura 23 – Previsões de demanda e geração para estudo de caso II.	45
Figura 24 – Demanda antes e após programa de RAD no estudo de caso II.	46
Figura 25 – Incentivo oferecido no estudo de caso II.	46

LISTA DE TABELAS

Tabela 1 – Sumário das vantagens providas pela GD	22
Tabela 2 – Programas de RAD baseados em incentivos	26
Tabela 3 – Programas de RAD baseados em preço	27
Tabela 4 – Valores de lucro obtidos no estudo de caso I.	43
Tabela 5 – Valores de lucro obtidos no estudo de caso II.	45

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
GD	Geração Distribuída
RAD	Resposta à Demanda
PSO	<i>Particle Swarm Optimization</i>
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm II</i>
RNA	Redes Neurais Artificiais
CDC	Controle Direto de Carga
I/C	Serviço de Interrupção /Corte
TDU	Tempo de Uso
PPC	Preços de pico crítico
PTR	Preços em tempo real
MSP	Método da Soma Ponderada
RMSE	<i>Root-Mean-Square Error</i>

LISTA DE SÍMBOLOS

α	Constante para cálculo da função utilidade quadrática
X	Constante para cálculo da função utilidade sigmoide
Y	Constante para cálculo da função utilidade sigmoide
Z	Constante para cálculo da função utilidade sigmoide
α_c	Constante de custo de geração
β_c	Constante de custo de geração
ω_i	Constante de inércia no PSO
c	Constante de aprendizagem no PSO
x	Demanda
d_0	Demanda inicial em kW
E	Elasticidade
\hat{y}_j	Estimador
W	Função bem-estar
C	Função custo
U	Função utilidade
i	Incentivo por kWh
L_{sist}	Lucro do sistema elétrico
G_d	Melhor posição global no PSO
P_d	Melhor posição individual de partícula no PSO
L_{oper}	Lucro do operador da rede
p	Preço da energia por kWh
L_{cons}	Lucro dos consumidores
L_{global}	Lucro global
y_j	Parâmetro estimado
w	Peso atribuído no PSO
X_d	Posição da partícula no PSO

g	Potência de geração solar fotovoltaica em kW
n	Quantidade de amostras para cálculo de erros
r	Valores aleatórios para o PSO
Δd	Varição de demanda em kW
V_d	Velocidade da partícula no PSO

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Motivação	16
1.2	Objetivos	17
<i>1.2.1</i>	<i>Objetivo geral</i>	<i>17</i>
<i>1.2.2</i>	<i>Objetivos específicos</i>	<i>17</i>
1.3	Estrutura do trabalho	17
2	REVISÃO BIBLIOGRÁFICA	19
2.1	Introdução	19
2.2	Microrredes	19
2.3	Consumo de energia elétrica e bem-estar	20
2.4	Geração distribuída	21
2.5	Redes neurais	23
2.6	Resposta à demanda	24
<i>2.6.1</i>	<i>Métodos baseados em incentivos</i>	<i>25</i>
<i>2.6.2</i>	<i>Métodos baseados em preço</i>	<i>26</i>
2.7	Otimização	27
<i>2.7.1</i>	<i>PSO</i>	<i>27</i>
<i>2.7.2</i>	<i>NSGA-II</i>	<i>29</i>
2.8	Considerações finais	29
3	MODELAGEM E IMPLEMENTAÇÃO	31
3.1	Introdução	31
3.2	Rede neural para previsão de geração e demanda	31
3.3	Modelo de resposta à demanda	35
3.4	Otimização do incentivo	37
3.5	Considerações finais	39
4	TESTES E ESTUDO DE CASO	41
4.1	Introdução	41
4.2	Resultados	41
<i>4.2.1</i>	<i>Estudo de caso I</i>	<i>41</i>
<i>4.2.2</i>	<i>Estudo de caso II</i>	<i>44</i>

4.3	Considerações finais	46
5	CONCLUSÃO	48
	REFERÊNCIAS	50
	APÊNDICES	52
	APÊNDICE A – CÓDIGOS-FONTES DESENVOLVIDOS	52

1 INTRODUÇÃO

O sistema de distribuição de energia elétrica vem mudando continua e rapidamente devido às necessidades dos consumidores e a preocupações ambientais, sinal disso é o surgimento de redes elétricas inteligentes, cujas principais características são a sustentabilidade, confiabilidade e a facilidade de integração de fontes renováveis. Nesse sentido, percebe-se o crescimento acelerado de conexão de sistemas de geração de pequeno porte, denominados de Geração Distribuída (GD), na maioria baseadas em recursos energéticos renováveis, nos sistemas de distribuição de energia elétrica. A inserção de GDs renováveis pode gerar benefícios técnicos, ambientais e econômicos tanto para os consumidores quanto para as concessionárias distribuidoras de energia elétrica. (COLMENAR-SANTOS *et al.*, 2016).

O crescimento da GD baseada em recursos renováveis tem contribuído para a formação de microrredes. As microrredes são uma forma de infraestrutura energética que integra com recursos de geração distribuída e cargas. Elas podem incluir também dispositivos de armazenamento de energia (BIDRAM; DAVOUDI, 2012), (IRENA, 2016). As microrredes podem operar em modo conectada à rede principal, desconectada da rede principal ou de forma autônoma.

Ademais, com o avanço das redes elétricas inteligentes os consumidores são capazes de atuarem ativamente na gestão de seu consumo de energia, de modo a se beneficiar de programas oferecidos pelas operadoras da rede principal ou microrrede. Os programas que incentivam a mudança de perfil de consumo instantâneo são chamados de programas de Resposta à Demanda (RAD). Eles propiciam redução da carga em determinados momentos definidos pela operadora em troca de benefícios financeiros para os consumidores (YOUSEFI *et al.*, 2011).

Uma questão atual é como calibrar os programas de RAD de maneira integrada com os sistemas de GDs de forma que se encontre um ótimo global beneficiando todos os envolvidos. Esse processo deve levar em conta múltiplos objetivos que podem ser inclusive conflitantes, tal como o pagamento excessivo de incentivos representar lucro para os consumidores ao mesmo que é um custo desnecessário para as operadoras.

1.1 Motivação

Tendo em vista o interesse global por parte de empresas do setor elétrico, da academia e dos consumidores de eletricidade em desenvolver e avaliar soluções alinhadas aos avanços tecnológicos de redes elétricas inteligentes, neste trabalho buscou-se justificar quais seriam as

opções de ajuste dos programas de RAD que trariam maior benefício global, para operadoras de rede bem como consumidores. Utilizando algoritmos que considerem os diferentes objetivos do problema pode-se garantir que ambas as partes possam usufruir das melhorias advindas do uso de microrredes com programas de resposta à demanda.

1.2 Objetivos

1.2.1 Objetivo geral

Este trabalho tem como objetivo apresentar um modelo de programa de RAD baseado em incentivos que considere características relevantes de microrredes, tal como a presença de sistemas de GDs renováveis. Por meio do uso de algoritmos de otimização, o modelo oferecerá sugestões de valores de incentivo que resultam em benefício para consumidores e concessionária de energia.

1.2.2 Objetivos específicos

Os seguintes objetivos específicos foram definidos para o desenvolvimento do modelo de RAD:

- Desenvolver algoritmos para previsão de geração solar e previsão de demanda para uma microrrede específica.
- Propor um modelo de RAD que represente a mudança de comportamento dos consumidores levando em conta a elasticidade para cada período do dia.
- Verificar a viabilidade financeira das sugestões de incentivos ótimos oferecidos pelo algoritmo.

1.3 Estrutura do trabalho

O trabalho está dividido em cinco capítulos. No Capítulo 1 é feita uma introdução com a motivação e os objetivos geral e específicos são definidos.

O Capítulo 2 tem a função de apresentar a base teórica para o entendimento do trabalho. É feita a conceituação de temas como sistema de distribuição de energia elétrica, bem-estar (relacionado ao consumo de energia) e geração distribuída. Além disso, são fornecidas breves explicações sobre as técnicas que foram utilizadas ao longo do estudo, tal como métodos

de resposta à demanda e algoritmos de otimização e previsão.

O Capítulo 3 desenvolve como as ferramentas expostas no Capítulo 2 foram utilizadas no trabalho. Primeiramente, apresenta como foi escolhido o método de previsão de demanda e geração. Em seguida explica os algoritmos de otimização utilizados, esclarecendo os benefícios do *Particle Swarm Optimization* (PSO) e do *Non-dominated Sorting Genetic Algorithm II* (NSGA-II). Por último, explana o desenvolvimento do modelo de resposta à demanda baseado em incentivos proposto.

No Capítulo 4 são mostrados os resultados de dois estudos de caso, os quais tratam de exemplos da aplicação do modelo de RAD em dias diferentes da semana. É feita a validação financeira do modelo proposto, além de uma discussão dos resultados alcançados.

Por fim, o Capítulo 5 expõe as conclusões adquiridas por meio dos resultados obtidos. Ademais, o capítulo sugere possíveis melhorias e propõe ideias para trabalhos futuros relacionados.

2 REVISÃO BIBLIOGRÁFICA

2.1 Introdução

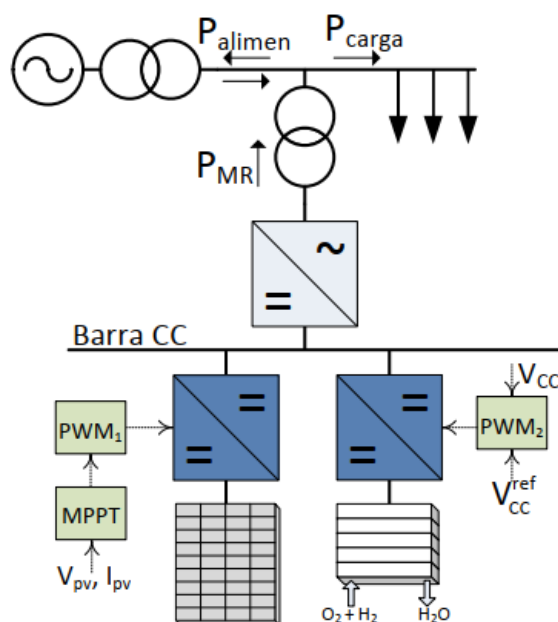
Esse capítulo apresenta a revisão bibliográfica do trabalho. Os seguintes temas são abordados: microrredes, consumo de energia elétrica e bem-estar, geração distribuída, redes neurais, RAD, PSO e, por fim, NSGA-II.

2.2 Microrredes

As microrredes podem ser entendidas como um agrupamento de microfontes, cargas e sistemas de armazenamento que, para a rede elétrica principal, é visto como uma única entidade. Além de fontes e dispositivos armazenadores, as microrredes podem incluir também medidores inteligentes e dispositivos para controle, gerenciamento e medição (ALMADA, 2013) (IRENA, 2016). As microrredes podem operar conectadas ou isoladas.

Na Figura 1, é apresentado um exemplo de uma microrrede em que as GDs, solar fotovoltaica e célula a combustível, estão conectadas ao barramento de corrente contínua, tendo um único inversor para conexão à rede principal. As cargas estão conectadas ao barramento corrente alternada, podendo ser supridas total ou parcialmente pela microrrede (Khanh *et al.*, 2010).

Figura 1 – Exemplo de topologia de microrrede



Fonte: (ALMADA, 2013).

A estrutura do sistema elétrico com microrredes descentraliza o sistema elétrico e oferece diversos benefícios, como: aumento da confiabilidade e resiliência do suprimento para os consumidores, redução da emissão de CO_2 por meio da integração com fontes de energia renováveis, redução da dependência da rede principal e suprimento de energia para áreas que não possuem uma rede elétrica pública. As microrredes conectadas à rede principal fornecem maior flexibilidade através do fluxo bidirecional de potência e com a tecnologia digital permitem uma maior integração de GDs renováveis. Diante dos claros benefícios, diversas concessionárias de energia e produtores independentes estão fazendo testes de conceito de microrrede (HIRSCH *et al.*, 2018).

2.3 Consumo de energia elétrica e bem-estar

Utilizando conceitos de microeconomia como bem-estar, utilidade e elasticidade, é possível modelar o consumo de energia elétrica de forma equivalente ao consumo de outros bens mais palpáveis. Entende-se que cada consumidor se comporta de forma independente e varia seu consumo de energia frente a mudanças em seu ambiente, tal como período do dia, alterações climáticas ou preço da energia. Essa variação no consumo buscará alcançar o ponto em que seu bem-estar é máximo (SAMADI *et al.*, 2010).

Por utilidade pode-se dizer que é a capacidade que produtos ou serviços possuem em satisfazer uma ou mais necessidades. A utilidade ou satisfação que um consumidor obtém de cada bem ou serviço é medida, pelo menos em teoria, por uma função chamada de função utilidade. Já a elasticidade é definida como a sensibilidade da demanda em relação ao preço, ou seja, quanto a demanda do produto varia mediante à variações no preço (KIRSCHEN; STRBAC, 2004). Segundo (SAMADI *et al.*, 2010), diversas funções podem ser utilizadas para modelar a utilidade do consumidor, a qual comunica o quanto o consumidor está se beneficiando do produto. A utilidade é modelada de forma que os benefícios marginais sejam decrescentes. Entende-se então que o ponto ótimo de bem-estar não necessariamente será o ponto de consumo de energia máximo, pois enquanto o custo é uma função continuamente crescente, a utilidade tende a saturar.

As Equações 2.1 e 2.2 são exemplos de modelagem do bem-estar nas quais W e U , respectivamente, bem-estar e utilidade, são funções do consumo de energia x e da elasticidade E . O custo é representado pelo produto da tarifa p e do consumo x da energia, e alfa é uma


constante pré-definida.

$$W(x, E) = U(x, E) - px \quad (2.1)$$

$$U(x, E) = \begin{cases} Ex - \frac{\alpha}{2}x^2 & \text{se } 0 \leq x \leq \frac{E}{\alpha}, \\ \frac{E^2}{2\alpha} & \text{se } x \geq \frac{E}{\alpha}, \end{cases} \quad (2.2)$$

Utilizando a função quadrática em 2.2 como modelo de função utilidade, bem como a função bem-estar em 2.1 e custo ($C = px$), obtém-se as curvas plotadas na Figura 2. Percebe-se que após a saturação da função utilidade, que ocorre em torno do consumo de 4 unidades de energia, devido à elasticidade específica desse consumidor, a função bem-estar começa a decrescer.

Figura 2 – Utilidade, custo e bem-estar para um consumidor específico.



Fonte: Adaptado de (SAMADI *et al.*, 2010).

2.4 Geração distribuída

A presença de GDs renováveis vem crescendo em ritmo acelerado devido ao interesse do consumidor em reduzir contas de energia e consumir energia de fontes que prejudicam menos o meio ambiente. Em contraste com as grandes centrais geradoras, essas fontes têm como característica estarem dispersas ao longo da rede de distribuição, sendo majoritariamente fontes

de energia renovável, tal como solar fotovoltaica, eólica ou de biomassa (COLMENAR-SANTOS *et al.*, 2016).

O gráfico da Figura 3 mostra o acelerado crescimento da quantidade de conexões de GD no Brasil ao longo dos anos de 2015 a 2020. Essa tendência pode ser explicada pela diminuição do custo dos equipamentos necessários, além das vantagens econômicas em gerar sua própria energia. A Tabela 1 resume os principais benefícios da GD agrupados por tipo: técnica, econômica e ambiental.

Figura 3 – Painel de Geração Distribuída da ANEEL



Fonte: (ANEEL, 2020)

Tabela 1 – Sumário das vantagens providas pela GD

Tipo	Vantagem	Motivo
Técnica	Redução de perdas de energia	Geração perto do consumidor, garante menores perdas de energia nas linhas de transmissão
Técnica	Melhora no perfil de tensão da rede elétrica	A conexão da GD normalmente eleva o nível de tensão, contribuindo para o perfil de tensão das redes de distribuição de média e baixa tensão
Técnica	Melhora na qualidade da energia elétrica	Em lugares onde o nível de tensão é baixo, a instalação de GD pode melhorar a qualidade do suprimento de energia
Técnica	Melhora na eficiência energética	A redução de perdas em transporte de eletricidade contribui para melhoria da eficiência energética
Econômica	Redução de custos ambientais	A redução de emissões na atmosfera ajuda a reduzir custos com taxas sob poluição ambiental
Econômica	Redução das tarifas de consumo de energia elétrica	O crescimento da inserção da GD pode trazer novos agentes para o mercado de energia, reduzindo o preço da energia por aumento de oferta
Ambiental	Redução de consumo de combustíveis fósseis	O crescimento da inserção de GD, proveniente de fontes de energia renovável, reduz a demanda por energia das centrais de geração, provenientes de combustíveis fósseis
Ambiental	Redução de emissão de gases do efeito estufa	A redução do consumo de energia proveniente da queima de combustíveis fósseis reduz a emissão de gases que contribuem para o efeito estufa

Fonte: (SAMPAIO, 2017)

Apesar das vantagens apresentadas, a inclusão de GDs traz desafios. Como a maioria das fontes renováveis utilizadas não são despacháveis, surge a necessidade de previsão


de geração dessas usinas. Existem diversos métodos que podem combinar dados ambientais, especificações dos geradores e técnicas computacionais para produzir previsões precisas para diferentes intervalos de tempo.

2.5 Redes neurais

Na busca por métodos de previsão de geração eficientes para séries históricas testa-se desde as abordagens mais simples, como métodos de persistência, nos quais se prevê que o próximo valor será igual a valor anterior a ele, até técnicas mais complexas, como Redes Neurais Artificiais (RNA). As RNAs são modelos matemáticos inspirados pelo funcionamento do cérebro humano que adquirem conhecimento através de treinamento (LOPES, 2005).

Conforme a Figura 4, o modelo de um neurônio artificial é composto por entradas de dados x_0 a x_n , pesos w_0 a w_n , o somatório das entradas multiplicadas por seus respectivos pesos e uma função de ativação. A função de ativação pode variar, sendo possível utilizar funções como degrau, linear ou sigmóides. Uma rede neural pode ser composta de diversas camadas de neurônios, sendo a primeira camada responsável pela entrada dos sinais e a última pelas saídas, como ilustrado na Figura 5.

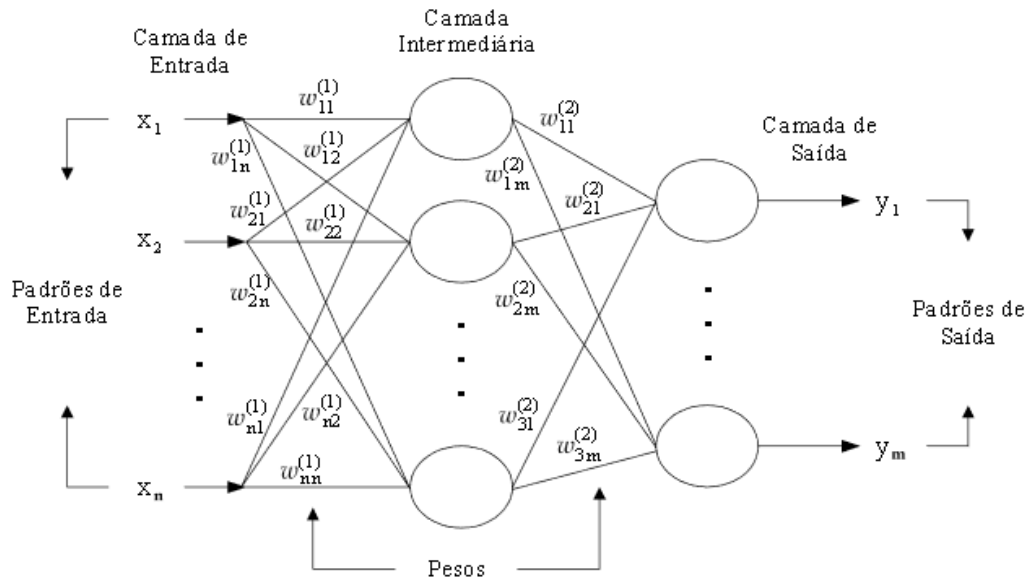
Figura 4 – Modelo de um neurônio artificial.



Fonte: (LOPES, 2005).

Segundo (LOPES, 2005), o treinamento supervisionado da RNA é feito pela exposição da rede a combinações de padrão de entrada e saída. Uma forma comum de treinamento é dividir uma base conhecida de entradas e saídas entre treinamento e teste e utilizar um algoritmo de *Backpropagation* para modificar os pesos internos de acordo com o erro gerado entre a

Figura 5 – Exemplo de estrutura de RNA.



Fonte: (LOPES, 2005).

previsão da RNA e a saída já conhecida.

Mais especificamente para previsões de séries históricas, as entradas de dados serão os dados passados e a rede deve ser treinada de forma que o erro entre a previsão que será dada pela RNA e o próximo valor da série histórica seja mínimo. Para alcançar o menor erro possível pode-se variar a quantidade de neurônios, entradas de dados passados ou o número de vezes que a rede passa pelos exemplos da base de treinamento.

2.6 Resposta à demanda

A implementação de redes elétricas inteligentes permite dentro outros benefícios a melhor comunicação entre a concessionária e os consumidores, abrindo espaço para melhorias na eficiência, confiabilidade e segurança do sistema elétrico. No que tange à eficiência, surge o conceito de RAD, que trata de quaisquer programas que têm como objetivo alterar o padrão de consumo dos consumidores, de modo que a demanda se adeque à geração, focando na inserção das fontes renováveis na matriz energética (VARDAKAS *et al.*, 2015).

Segundo Vardakas *et al.* (2015), os programas de RAD oferecem vantagens como redução do risco de falta de energia, redução de custos operacionais, diminuição da emissão de CO_2 e economia de energia reduzindo a carga elétrica durante os períodos de estresse da rede. O envolvimento dos consumidores é de extrema importância para o funcionamento adequado de um programa de RAD.

Alguns autores já estudaram como a utilização de programas de RAD altera o padrão de consumo de energia elétrica. Em (AALAMI *et al.*, 2010) é utilizada uma modelagem que busca obter o valor da demanda final a partir do produto da demanda inicial e fatores de elasticidade própria e cruzadas. Os autores especificam o teste para um programa de Serviço de Interrupção/Corte, no entanto a mesma modelagem pode ser utilizada para todos os programas baseados em incentivos.

Em (YOUSEFI *et al.*, 2011) os autores focam na fato de a elasticidade variar de acordo com o perfil do consumidor, dessa forma, ao invés de considerar apenas um padrão para a rede inteira, o programa de resposta a demanda considera uma combinação linear de fatores lineares, polinomiais, logarítmicos e exponenciais. Além disso, também é feita a distinção entre estação do ano, sendo considerados valores diferentes para inverno e verão.

Em (TAKANO *et al.*, 2018) verifica-se uma interessante alternativa para definição de valores de elasticidade. Para cada mês, os autores definem curvas sigmóides indicando a utilidade dos consumidores em função do consumo de energia. A elasticidade está então incluída em termos de fatores da curva sigmoide. Os autores descrevem matematicamente as equações para se obter os valores de incentivos pagos e demanda deslocada, sem utilizar algoritmos específicos para otimização.

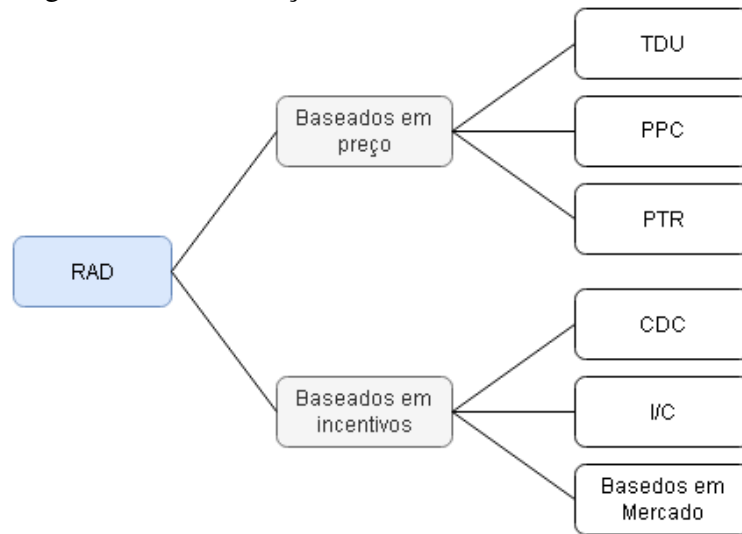
No cenário atual, pode-se classificar os programas em dois tipos: os baseados em incentivos, nos quais os consumidores recebem incentivos financeiros para participar e contribuir com a redução de carga nos momentos em que o sistema necessitar e os baseados em preço, nos quais a tarifa de energia varia ao longo do dia, incentivando ou desencorajando o consumo (VARDAKAS *et al.*, 2015).

Em Seri *et al.* (2018), classifica-se os métodos de RAD conforme a Figura 6. Estes são detalhados nas Seções 2.6.1 e 2.6.2.

2.6.1 Métodos baseados em incentivos

Nessa categoria, destacam-se as variações de obrigatoriedade ou não de reduzir a carga, existência ou não de multas caso não haja diminuição de carga quando solicitado e condição do sistema elétrico quando é solicitada corte de carga. Na Tabela 2, consta um resumo dos principais programas de RAD baseados em incentivos, junto a uma descrição do seu funcionamento.

Figura 6 – Classificação dos métodos de RAD



Fonte: Adaptado de (SERI *et al.*, 2018)

Tabela 2 – Programas de RAD baseados em incentivos

Programa	Funcionamento
Controle Direto de Carga (CDC)	Normalmente aplicado a pequenos consumidores, o participante permite que a concessionária tenha controle de algumas de suas cargas, permitindo o desligamento ou ajustes, no caso das cargas térmicas, dessas cargas caso haja necessidade.
Serviço de Interrupção / Corte (I/C)	Aplicado apenas a grandes consumidores, o programa oferece descontos ou créditos para os participantes reduzirem sua carga durante as contingências do sistema. A redução é obrigatória e a não participação resulta em penalidades ou expulsão do programa.
Incentivos de Mercado	Aplicados apenas para grandes consumidores, os programas dessa categoria recompensam os participantes com base em quanta redução de carga eles podem oferecer ao sistema.

Fonte: Adaptado de (SERI *et al.*, 2018).

2.6.2 Métodos baseados em preço

Nos programas baseados em preço, espera-se observar o tarifa da energia alterar o consumo, dessa forma, quando a tarifa está mais alta os consumidores em geral provavelmente diminuirão o consumo, enquanto quando os preços estão baixos o consumo provavelmente deve aumentar. As diferenças entre os programas dessa categoria estão na regularidade em que os preços mudam e no estado da rede quando o programa é acionado. Na Tabela 3, constam as características de cada um dos programas.

Tabela 3 – Programas de RAD baseados em preço

Programa	Funcionamento
Tempo de Uso (TDU)	São definidas diferentes tarifas para períodos ao longo do dia. Os períodos e suas respectivas tarifas são fixos. As definições de preço são feitas com base nos dados históricos. A tarifa branca é um exemplo de RAD desse tipo.
Preços de pico crítico (PPC)	Os participantes têm sua tarifa base mais baixa em troca de um grande aumento de tarifa durante os momentos de pico do sistema. Dessa forma, espera-se que eles reduzam fortemente o consumo durante os picos, que normalmente são previstos e avisados com uma pequena antecedência.
Preços em tempo real (PTR)	São definidos valores máximos e mínimos para a tarifa. O preço varia entre os extremos ao longo do dia, comumente de hora em hora. Os consumidores devem então adaptar seu consumo para utilizar a energia nos momentos financeiramente mais favoráveis.

Fonte: Adaptado de (SERI *et al.*, 2018).

2.7 Otimização

Durante a implementação de métodos de RAD surgem questões relacionadas a como garantir que ambas as partes, concessionária e consumidor, estão se beneficiando do programa. Além disso, como ajustar a tarifa ou o incentivo de forma que esse benefício seja o maximizado.

Para garantir robustez ao trabalho, optou-se por otimizar o modelo de programa de RAD utilizando dois algoritmos diferentes, permitindo a comparação entre os resultados e validação se ambos apontam para soluções semelhantes. Os algoritmos escolhidos foram o PSO e o NSGA-II.

2.7.1 PSO

O PSO (*Particle Swarm Optimization*) se trata de um algoritmo meta-heurístico baseado no comportamento coletivo de algumas espécies, proposta por (KENNEDY; EBERHART, 1995). Para buscar pontos ótimos de funções, são gerados M indivíduos que possuem N dimensões. As dimensões são dados de posição, velocidade, melhor posição individual e coletiva. Junto a isso, são definidos valores de taxa de aprendizado e são gerados valores aleatórios para atualizar dados de velocidade de cada partícula a cada iteração.

Na primeira iteração, os indivíduos têm as posições inicializadas aleatoriamente. A função objetivo, que é a que se deseja otimizar, é calculada e os valores individuais de melhor posição são obtidos. Com base nos valores individuais, pode-se obter o valor de melhor posição global. Uma nova solução então é proposta por meio das equações 2.3 e 2.4 e o processo pode se repetir. Caso se obtenha valores melhores para posição individual ou global, esses valores são

atualizados. O programa segue até que um número de iterações preestabelecido seja alcançado ou até que o erro seja menor que um valor definido (BEZERRA, 2015).

$$V_d^{(i+1)} = \omega_i V_d^{(i)} + c_1 r_1 (P_d^{(i)} - X_d^{(i)}) + c_2 r_2 (G^{(i)} - X_d^{(i)}) \quad (2.3)$$

$$X_d^{(i+1)} = X_d^{(i)} + V_d^{(i)} \quad (2.4)$$

Nas quais:

- $X_d^{(i)}$ é a posição da partícula d na iteração i
- $V_d^{(i)}$ é a velocidade da partícula d na iteração i
- ω_i é o valor definido de inércia
- $P_d^{(i)}$ é a melhor posição da partícula d na iteração i
- $G^{(i)}$ é a melhor posição global na iteração i
- c_1 e c_2 são os valores de fator de aprendizagem
- r_1 e r_2 são valores aleatórios gerados a cada iteração

O PSO originalmente é um algoritmo que busca otimizar problemas de objetivo único. No entanto, é possível utilizar o método Método da Soma Ponderada (MSP) de soma ponderada, que combina múltiplas funções objetivos em uma só, permitindo a utilização do PSO. A técnica MSP consiste em atribuir pesos ω para um dos objetivos $f_m(x)$, sendo a função objetivo $F(x)$ a soma ponderada dos objetivos, como definido na Equação 2.5, em que M é o número de total objetivos originais (BEZERRA, 2015).

$$F(x) = \sum_{m=1}^M \omega f_m(x) \quad (2.5)$$

Segundo Bezerra (2015), os pesos atribuídos aos objetivos representam o grau de importância que está sendo dado para cada objetivo. No entanto, a escolha dos pesos pode ser subjetiva ou baseada em experiência. Utilizando o método MSP pode-se também gerar uma curva de Pareto e obter os pontos ótimos para diversas variações entre os pesos de cada objetivo.

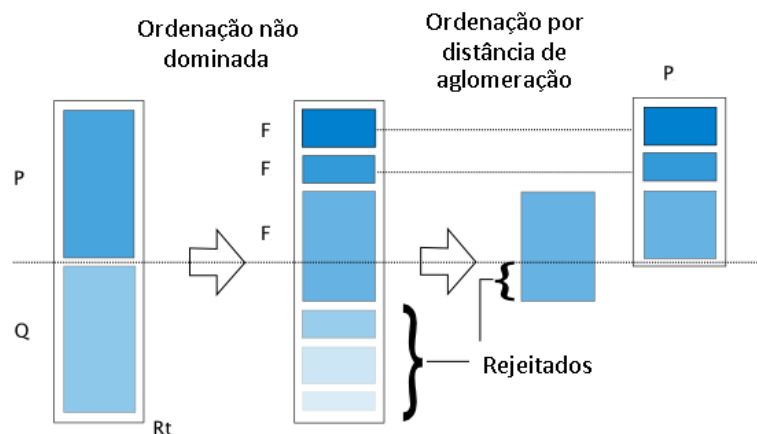
2.7.2 NSGA-II

O algoritmo NSGA-II (*Non-dominated Sorting Genetic Algorithm*) foi desenvolvido com o objetivo de realizar otimizações multiobjetivo, fornecendo como resultado uma curva de Pareto com as melhores soluções obtidas pelo NSGA-II. Partindo das bases de um algoritmo genético, foram feitas modificações nos cruzamentos e na seleção dos mais adaptados (DEB *et al.*, 2002).

Inicialmente, uma população P é aleatoriamente gerada e são aplicados os operadores de seleção, recombinação e mutação, gerando então a população de Q . Então as populações P e Q são unidas e ordenadas de acordo com o nível de adaptação nos grupos F_i . Finalmente, os indivíduos são selecionados baseados na métrica de distância de aglomeração, que se trata de uma distância de Manhattan em um espaço objetivo. Isso garante que os pontos extremos sejam mantidos a cada geração, que então farão parte da curva de Pareto obtido como resultado (DEB *et al.*, 2002).

Na Figura 7, está ilustrado o processo de seleção feito pelo NSGA-II para obter os resultados.

Figura 7 – Procedimento NSGA-II



Fonte: Adaptado de (DEB *et al.*, 2002).

2.8 Considerações finais

Este capítulo abordou as bases para entendimento desse trabalho. Partindo do conceito de microrredes, explicou-se como a GD e os métodos de RAD se relacionam com os avanços na implementação das microrredes. Especificamente quanto a métodos de RAD, os principais programas foram classificados e detalhados para esclarecer o escopo do trabalho.

Em seguida os fundamentos lógicos dos algoritmos que serão utilizados ao longo do trabalho foram apresentados e suas funções foram definidas. Conclui-se que os conceitos necessários para a clareza da proposta do trabalho, que é apresentar um modelo de programa de RAD baseado em incentivos otimizado para concessionária e consumidor, foram definidos.

3 MODELAGEM E IMPLEMENTAÇÃO

3.1 Introdução

Neste capítulo, serão apresentados aspectos do projeto e implementação do programa de RAD baseado em incentivos. Primeiramente, será abordada a estrutura e parametrização da rede neural utilizada como base para construção do programa. Em seguida, será descrito como foi construído o modelo para simular o programa de RAD, buscando entender como os consumidores se comportariam diante da oferta de incentivos monetários em troca de alterações em seu padrão consumo. Finalmente, serão descritas as estratégias de otimização utilizadas para encontrar preços ótimos de incentivo, garantindo que tanto a distribuidora quanto os consumidores se beneficiem da aplicação do programa.

3.2 Rede neural para previsão de geração e demanda

No modelo que será abordado no próximo capítulo, inclui-se duas variáveis que necessitam ser previstas: demanda e potência de geração solar. Diversos modelos preditivos foram testados, tal como modelo da persistência e modelos estatísticos de auto regressão. No entanto, o método que mais se adequou às necessidades de previsão para a janela de tempo de 24 horas, precisão das previsões e esforço computacional desse projeto foi a RNA.

Para definir os modelos preditivos foram utilizadas duas bases de dados fornecidas pela Enel Distribuição Ceará. A primeira delas contendo dados de carga de um alimentador genérico e a segunda dados de geração de uma usina solar fotovoltaica de potência nominal igual a 1 MW. Ambas possuem resolução de 15 minutos e totalizam 1 ano de medições. No caso da geração, por se tratarem de dados de potência, é dispensado o uso de modelos para conversão de informações ambientais, como temperatura e irradiação, em informações de potência, eliminando a possibilidade de erros nesse aspecto.

Os códigos foram desenvolvidos em *Python*, utilizando as bibliotecas *pandas* e *numpy* para o tratamento de dados e *Keras* para modelagem da rede. Primeiramente, os dados foram divididos em duas partes, uma para treinamento da RNA sequencial e outra para validação da rede treinada. Logo após, definiu-se uma topologia de rede inicial arbitrária, para que fosse testada a precisão da RNA resultante. Os fatores escolhidos foram: 5 épocas, significando a quantidade de vezes que a rede passaria pela amostra de treino, 100 neurônios na primeira

camada, significando o total de medições passadas que seriam utilizadas como dados de entrada, e 50 neurônios na camada intermediária para processamento. A performance das redes foi medida em termos de *Root-Mean-Square Error* (RMSE), cujo cálculo é mostrado na Equação 3.1.


$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (3.1)$$

Na qual:

- y_j é a medição observada;
- \hat{y}_j é o valor previsto;
- n é a quantidade de previsões feitas.

Na topologia inicial da RNA, obteve-se o resultado mostrado na Figura 8. A amostra escolhida mostra as previsões da RNA para 96 medições, representando um dia completo. Nota-se que apesar de a rede seguir certo padrão conforme os dados medidos, ainda é possível perceber erros significativos, resultando em um RMSE de 317.

Figura 8 – Demanda prevista pela RNA antes da parametrização




Fonte: O Próprio Autor.

Por ser o treinamento da rede um processo estocástico, a fim de ajustar os hiperparâmetros mais adequados deve-se realizar uma série de treinamentos e cálculo de erros, pois o resultado de um único treinamento pode não ser representativo das verdadeiras capacidades da

rede. Dessa forma, para cada um dos testes realizados as redes foram treinadas 10 vezes e os resultados condensados utilizando diagramas de caixas.


Primeiramente buscou-se definir a quantidade de neurônios na camada intermediária. A Figura 9 mostra os resultados, nela pode-se constatar que pelo RMSE o mais adequado é parametrizar a quantidade de neurônios intermediários para 200. O mesmo processo foi feito para quantidade de dados de entrada e quantidade de épocas de treinamento, os resultados constam nas Figuras 10 e 11, respectivamente. Pelos gráficos, foram escolhidos os valores de 1000 dados passados de entrada e 30 épocas de treinamento.

Figura 9 – Diagrama de caixas a partir de erros variando a quantidade de neurônios intermediários




Fonte: O Próprio Autor.

Figura 10 – Diagrama de caixas a partir de erros variando a quantidade de dados de entrada



Fonte: O Próprio Autor.


Figura 11 – Diagrama de caixas a partir de erros variando a quantidade de épocas de treinamento



Fonte: O Próprio Autor.

A rede resultante, agora com hiper-parâmetros ajustados, se mostra então mais precisa em prever os dados de demanda para esse alimentador. A Figura 12 mostra a nova RNA prevendo a mesma amostra, dessa vez obtendo um erro RMSE de 145, significativamente inferior à rede desparametrizada.

Figura 12 – Demanda prevista pela RNA após a parametrização

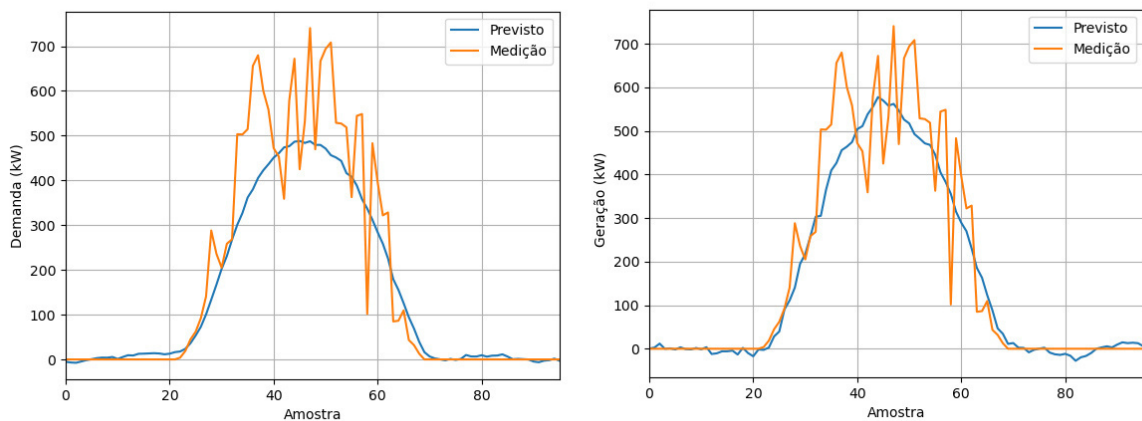


Fonte: O Próprio Autor.

Por fim, o mesmo procedimento foi aplicado para parametrização da outra rede, a de previsão de geração solar fotovoltaica. O erro RMSE calculado inicial foi de 92, enquanto após a parametrização obteve-se erro RMSE de 80. Nota-se que a melhoria foi inferior se comparada

à melhoria apresentada pela RNA referente à demanda, isso ocorre devido à curva da potência de geração ser menos comportada em virtude de fenômenos como sombreamento, que alteram drasticamente as medições. Os hiper-parâmetros definidos foram: 500 neurônios intermediários, 500 dados de entrada e 5 épocas de treinamento. Na Figura 13 consta a comparação entre a rede antes e após a adequação.

Figura 13 – Potência de geração antes e após parametrização



Fonte: O Próprio Autor.

3.3 Modelo de resposta à demanda

A modelagem do programa de RAD é dividida em duas partes. Para o operador da rede é considerado o lucro em seu entendimento habitual, sendo igual à receita com a venda de energia menos os custos de geração. Destaca-se que, como o programa modelado é baseado em incentivos, o pagamento desse incentivo é considerado um custo adicional. A equação 3.2 indica o modelo para o lucro do ponto de vista do operador. Os custos de geração são modelados como custos quadráticos, conforme (POURBABAK *et al.*, 2018), e constam na equação 3.3.

$$L_{oper} = p(d_0 - \Delta d - g) - \mathbf{f}_{custo}(d_0 - \Delta d - g) - i\Delta d \quad (3.2)$$

Na qual:

- p é o preço da energia por kWh
- d_0 é o valor de demanda previsto
- Δd é a da manda deslocada devido ao programa de RAD
- g é a da potência de geração prevista

- i é o valor de incentivo pago por kWh

$$f_{\text{custo}}(x) = \alpha_c x^2 + \beta_c x \quad (3.3)$$

A segunda parte da modelagem consiste no ponto de vista do consumidor de energia. Os consumidores não buscam apenas o lucro, mas também os benefícios trazidos pelo uso da energia elétrica. Dessa forma, é necessária uma função utilidade, cujo objetivo é converter as vantagens obtidas pelos consumidores em termos monetários.

A função utilidade engloba dois conceitos sobre o consumo de energia: a elasticidade e a tendência à saturação. Segundo (AALAMI *et al.*, 2010), algumas cargas têm maior tendência a serem deslocadas para outros horários, sendo assim elásticas, enquanto outras cargas, tal como iluminação, não possuem tanta flexibilidade. Cargas inelásticas então possuem baixa tendência a deslocamento, sendo necessários altos incentivos para que isso ocorra. Quanto à saturação, a função utilidade descrita em (SAMADI *et al.*, 2010) define que uma propriedade dessa função é que os benefícios marginais do consumo são decrescentes, portanto, cada incremento no consumo de energia tende a gerar menores incrementos de utilidade.

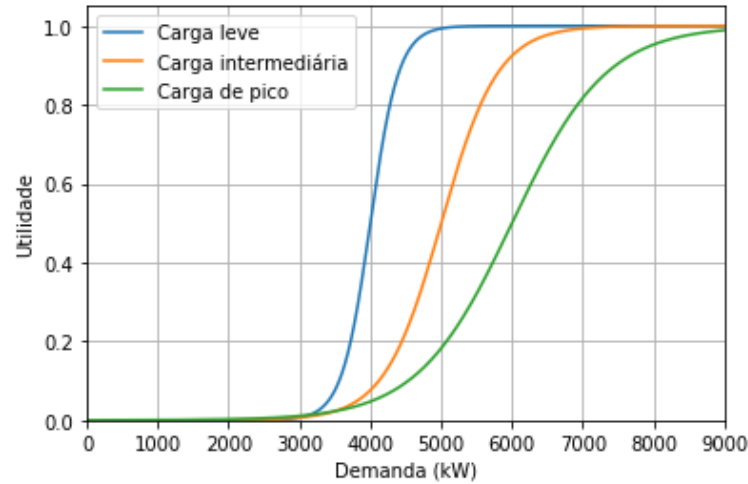
Diversas funções podem modelar a utilidade, em (SAMADI *et al.*, 2010), por exemplo, utiliza-se uma composição de uma função quadrática e uma reta, representada no capítulo 2. Nesse trabalho optou-se por utilizar a função sigmoide, conforme (TAKANO *et al.*, 2018). A função é mostrada na Equação 3.4 e sua representação normalizada para três períodos diferentes é mostrado na Figura 14. Percebe-se que nos períodos de pico a curva possui menor inclinação representando uma elasticidade maior, ademais, as três funções tendem a saturar.

$$f_{\text{utilidade}}(x) = \frac{Z}{1 + e^{-X(x-Y)}} \quad (3.4)$$

Na qual:

- x é a demanda
- X, Y e Z são parâmetros que modificam o formato da curva referentes aos hábitos dos consumidores e do alimentador

Figura 14 – Valores de utilidade para três períodos distintos



Fonte: O Próprio Autor.

Na Equação 3.5 é definido o cálculo do lucro percebido pelo consumidor de energia. Nota-se que não é possível unificar a função utilidade em um termo devido a não linearidade da função sigmoide. Além disso, percebe-se que os outros termos da equação são idênticos aos termos do lucro da operadora, exceto pelo sinal.

$$L_{cons} = \mathbf{f}_{utilidade}(d_0) - \mathbf{f}_{utilidade}(d_0 - \Delta d) - p(d_0 - \Delta d - g) + i\Delta d \quad (3.5)$$

Na qual:

- p é o preço da energia por kWh
- d_0 é o valor de demanda previsto
- Δd é a demanda deslocada devido ao programa de RAD
- g é a da potência de geração prevista
- i é o valor de incentivo pago por kWh

3.4 Otimização do incentivo

Após a definição dos modelos, enfim pode-se buscar a implementação de um programa de RAD que traga benefícios para ambos os lados: operadora e consumidores. Do ponto de vista global, o programa é modelado pela soma das equações 3.2 e 3.5, explicitado na Equação 3.6. Percebe-se que o objetivo é maximizar o lucro global, no entanto as parcelas que o compõe são conflitantes, tornando assim o problema em uma otimização multi-objetivo.

$$L_{global} = L_{oper} + L_{cons} \quad (3.6)$$

A finalidade então passa a ser equilibrar os valores das variáveis Δd e i de forma que o lucro global seja maximizado e que ambas as partes possuam lucro superiores aos que teriam caso não houvesse programa de RAD implementado.


Para garantir robustez ao trabalho, a otimização foi feita por meio de duas meta-heurísticas. A primeira delas o PSO e a segunda uma variação do algoritmo genético, chamado NSGA-II. Segundo (BEZERRA, 2015), um dos métodos para solucionar problemas multi-objetivo é transformá-lo em um problema de objetivo único. Isso pode ser feito por meio do método MSP. Na equação 3.7 observa-se a aplicação do MSP no problema proposto.

$$\text{Objetivo}(i, \Delta d) = wL_{sist} + (1 - w)L_{cons} \quad (3.7)$$

$$\begin{aligned} \text{Objetivo}(i, \Delta d) = & w(p(d_0 - \Delta d - g) - \mathbf{f}_{custo}(d_0 - \Delta d - g) - i\Delta d) + \\ & (1 - w)(\mathbf{f}_{utilidade}(d_0) - \mathbf{f}_{utilidade}(d_0 - \Delta d) - p(d_0 - \Delta d - g)) \end{aligned} \quad (3.8)$$

Para implementar o PSO foi utilizada a biblioteca pymoo (BLANK; DEB, 2020). O fator w incluído na equação representa a importância atribuída a cada parcela na função objetivo. O procedimento utilizado foi variar o w com uma resolução de 0,005. A cada valor de w o PSO foi executado, gerando a Figura 15. Percebe-se que inicialmente w possuía valor zero, garantindo toda importância para o lucro dos consumidores e prejuízo para o operador. No entanto, conforme o valor de w aumenta a situação se inverte. Nos pontos intermediários nota-se a curva de Pareto gerada, com pontos igualmente eficientes por serem pontos não dominados.

Figura 15 – Curva de Pareto gerada pelo PSO




Fonte: O Próprio Autor.

O outro algoritmo utilizado para otimização foi o NSGA-II, também implementado via uso da biblioteca em *Python* pymoo (BLANK; DEB, 2020). Por sua vez, essa metodologia já é adaptada para uso em problemas de otimização multi-objetivo, sendo dispensado o uso de pesos.

A representação gráfica dessa otimização utilizando os mesmos parâmetros utilizados no PSO consta na Figura 16. Nessa imagem pode-se perceber que os resultados obtidos são similares aos do PSO, validando assim os procedimentos. No entanto, nota-se que o NSGA-II se mostrou mais eficiente em plotar a curva de Pareto de forma mais distribuída, enquanto as otimizações do PSO se concentraram no meio e nos extremos. Buscou-se diminuir a resolução do PSO com o objetivo de obter uma curva mais completa, no entanto isso não foi eficaz. Portanto, entende-se que a limitação é própria do PSO, que não é o algoritmo mais adequado para otimizações multi-objetivo.

Figura 16 – Curva de Pareto gerada pelo NSGA-II



Fonte: O Próprio Autor.

3.5 Considerações finais

Nesse capítulo foi abordado o procedimento para a modelagem do programa de RAD otimizado. Buscou-se explicar os passos na sequência lógica de necessidade, partindo da esclarecimento que o modelo possui variáveis previstas, apresentou-se qual foi a estratégia de previsão que se mostrou mais adequada para o trabalho e como ela foi modelada para entregar resultados mais precisos.

Em seguida, foi dada uma breve introdução sobre os conceitos utilizados na construção de modelos de lucro do ponto de vista do do operador da rede e do ponto de vista do consumidor. Abordou-se o tema utilidade e suas características de benefício marginal decrescente

e elasticidade.

Por fim, após a obtenção das variáveis previstas e a modelagem do programa de RAD serem esclarecidos, seguiu-se para explanação do método de otimização desse modelo. Primeiramente, é abordado o PSO e as adaptações necessárias para possibilitar sua utilização problema que tem objetivos conflitantes. Logo após, indica-se a solução via NSGA-II, algoritmo já apropriado para questões desse tipo. Os resultados então foram comparados e foi indicado uma hipótese para a curva gerada pelo NSGA-II em relação a do PSO.

As principais adequações propostas nesse capítulo foram:

- **Proposição de um modelo de programa de RAD baseado em incentivos:** Foi proposto um modelo que possui duas parcelas e necessita dados de entrada de previsão e demanda;
- **Proposição de uma otimização do modelo apresentado:** Uma metodologia para definir os valores de demanda deslocada e valor do incentivo pago de forma que haja benefícios para ambas partes envolvidas no programa RAD.

4 TESTES E ESTUDO DE CASO

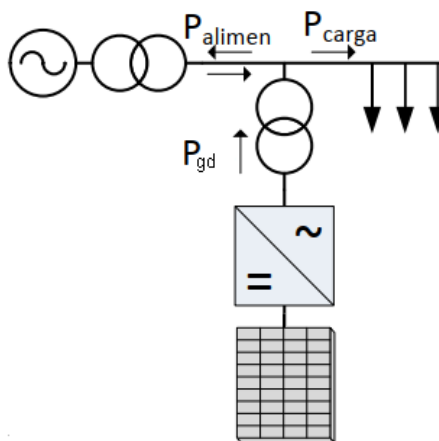
4.1 Introdução

Nesse capítulo é apresentada estrutura da microrrede utilizada como base para as simulações e validação do programa de RAD baseado em incentivos proposto. Logo após, são executados dois testes em condições de carregamento distintas a fim de verificar a capacidade de alcançar o objetivo de ser economicamente favorável para os consumidores e para o operador da rede.

4.2 Resultados

A topologia escolhida para os testes se trata de uma microrrede de pequena capacidade conectada à rede principal, cuja ilustração está representada na Figura 17. A microrrede é composta de uma usina solar fotovoltaica, cujo custo de geração é considerado nulo, e de cargas cuja demanda é suprida por ambos, microrrede e rede externa.

Figura 17 – Topologia da microrrede de teste.



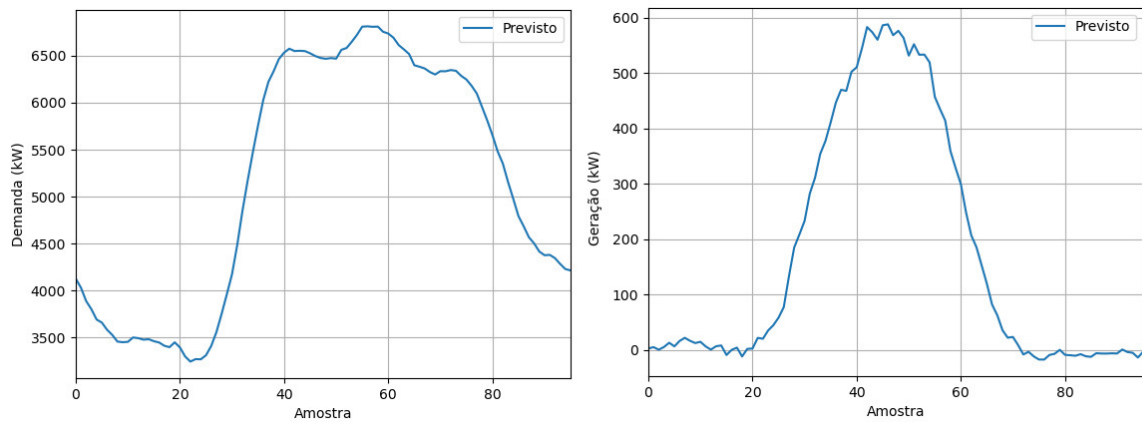
Fonte: Adaptado de (ALMADA, 2013).

4.2.1 Estudo de caso I

No estudo de caso I, foram analisadas quais seriam as soluções apresentadas pelo programa de RAD no caso de um dia útil. Com base nos dados de demanda e potência de geração, obteve-se da RNA a previsão para o dia 01/11/2018, uma quinta-feira. As previsões são apresentadas na Figura 18, são 96 amostras, representando 1 dia completo com resolução de 15

minutos.

Figura 18 – Previsões de demanda e geração para estudo de caso I.



Fonte: O Próprio Autor.


Em seguida, o dia foi dividido em três períodos de acordo com a demanda, indicando elasticidades diferentes. Os parâmetros X , Y e Z , referentes ao formato da curva de utilidade, foram ajustados de forma que haja equilíbrio entre a ordem de grandeza do lucro do operador da rede e do lucro dos consumidores. Foi considerado o valor de R\$ 0,80 por kWh de energia.

Na Figura 19, constam exemplos de fronteiras de pareto obtidas para amostras em período de carga leve, intermediária e de pico. Nota-se que existem muitos pontos mesmo sendo não dominados ainda possuem valores negativos de L_{cons} , portanto são negativos do ponto de vista dos consumidores. É possível verificar que no momento de pico os lucros tendem a ser superiores.

Já na Figura 20 é mostrada a curva de utilidade para cada intervalo, considerando os parâmetros da Equação 4.1. Observa-se que a curva de utilidade para carga de pico indica uma elasticidade superior, já que uma diminuição da demanda gera menores diminuições de utilidade em comparação com a carga intermediária ou leve. Além disso, nota-se que a saturação demora mais para ocorrer no período de carga de pico.


$$X; Y \text{ e } Z = \begin{cases} 0,0035; 3500 \text{ e } 10000 & \text{se, } x < 4500; \\ 0,0030; 4000 \text{ e } 10000 & \text{se, } 4500 \leq x \leq 6000; \\ 0,0020; 6000 \text{ e } 10000 & \text{se, } x > 6000. \end{cases} \quad (4.1)$$

Figura 19 – Lucros do operador e do consumidor para períodos de (a) carga leve, (b) intermediária e (c) de pico.



Fonte: O Próprio Autor.

Figura 20 – Curvas de elasticidade resultantes.



Fonte: O Próprio Autor.

Logo após, para cada um dos 96 intervalos de 15 minutos foi executado o algoritmo NSGA-II, dessa forma gerando as fronteiras de pareto e selecionando a solução que possui maior de lucro global. Para as soluções selecionadas, foi somado o valor de lucro dos consumidores, Equação 3.5, valor de lucro do sistema, Equação 3.2 e valor de lucro global, Equação 3.6. Essas somatórias foram comparadas com os resultados que seriam obtidos caso não houvesse programa de resposta à demanda. Os resultados foram sumarizados na Tabela 4.

Tabela 4 – Valores de lucro obtidos no estudo de caso I.

	Sem programa de RAD	Com programa de RAD
Lucro do ponto de vista dos consumidores	-409.737	196.686
Lucro do ponto de vista do operador	275.144	194.312
Lucro global	-134.593	390.999

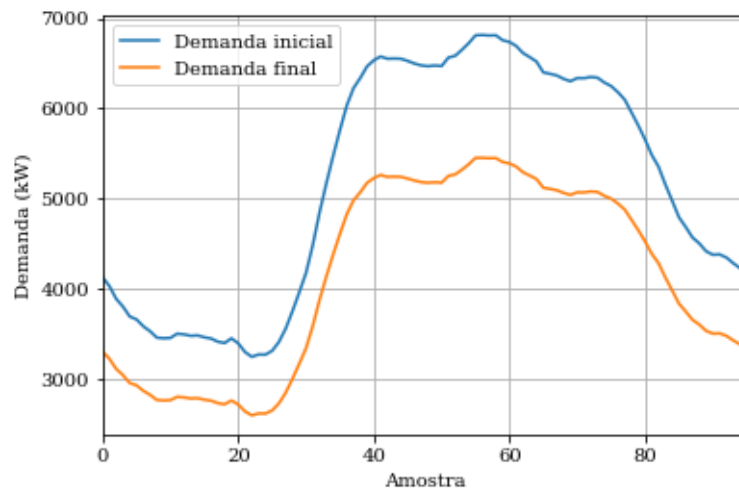
Fonte: O Próprio Autor.

Pelos resultados expostos, percebe-se que o lucro global e o lucro do ponto de vista dos consumidores aumentaram. No entanto o lucro do ponto de vista do operador sofreu uma

queda de aproximadamente 30%. Quanto ao lucro negativo do ponto de vista dos consumidores, esse valor indica que o bem-estar está negativo, não significando que houve prejuízo financeiro, mas que houve custos de energia não compensados pela utilidade trazida por esse consumo.


Na Figura 21, é representado o valor da demanda deslocada a cada intervalo de tempo. Já na Figura 22 constam os valores de incentivos oferecidos, a fim de facilitar a participação dos consumidores, também é plotado o gráfico com médias horárias de incentivo.

Figura 21 – Demanda antes e após programa de RAD no estudo de caso I.



Fonte: O Próprio Autor.

Figura 22 – Incentivo oferecido no estudo de caso I.




Fonte: O Próprio Autor.

4.2.2 Estudo de caso II

No estudo de caso II, foi analisado quais seriam as soluções apresentadas pelo programa de RAD no caso de um dia no final de semana, visto que o comportamento de demanda

diverge dos dias úteis. Com base nos dados de demanda e potência de geração, obteve-se com a RNA a previsão para o dia 07/10/2018, um domingo. As previsões foram feitas utilizando a mesma parametrização do estudo de caso I e são apresentadas na Figura 23, da mesma forma, são 96 amostras, representando 1 dia completo com resolução de 15 minutos.

Figura 23 – Previsões de demanda e geração para estudo de caso II.



Fonte: O Próprio Autor.

A definição dos parâmetros de utilidade empregados no estudo de caso II foram idênticos aos do caso I. Dessa forma, é possível partir para o cálculo dos valores de lucro. O procedimento se repete, para cada um dos 96 valores previstos de demanda foi feita a otimização via NSGA-II. Os pontos escolhidos foram os que possuem lucro global máximo, os valores de lucro do ponto de vista dos consumidores e operador são armazenados e comparados com os valores obtidos caso não houvesse programa de RAD. Os resultados estão resumidos na Tabela 5.

Tabela 5 – Valores de lucro obtidos no estudo de caso II.

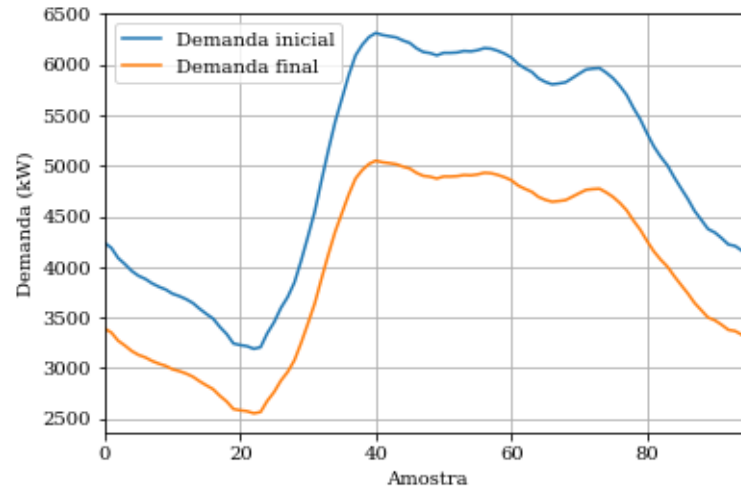
	Sem programa de RAD	Com programa de RAD
Lucro do ponto de vista dos consumidores	-361.628	131.875
Lucro do ponto de vista do operador	254.265	174.705
Lucro global	-107.362	306.580

Fonte: O Próprio Autor.

Da mesma forma que ocorreu no estudo de caso I, os valores de lucro dos consumidores e lucro global aumentaram significativamente, enquanto o valor de lucro do ponto de vista do operador sofreu queda de 32%.


Na Figura 24 é representado o valor da demanda deslocada a cada intervalo de tempo, enquanto na Figura 25 constam os valores de incentivos oferecidos.

Figura 24 – Demanda antes e após programa de RAD no estudo de caso II.



Fonte: O Próprio Autor.

Figura 25 – Incentivo oferecido no estudo de caso II.



Fonte: O Próprio Autor.

4.3 Considerações finais

A finalidade do capítulo foi apresentar os resultados obtidos aplicando a previsão de demanda e geração e a modelagem do programa de RAD em dois casos. Foram descritos dois estudos de caso, o primeiro considerando um dia útil e o segundo um dia do final de semana, cujas curvas de demanda comumente divergem.

Primeiramente, as curvas de previsão foram geradas. Com base nessas curvas definiu-se os parâmetros do cálculo da função utilidade de forma que haja um equilíbrio entre os lucros percebidos por ambas as partes.

Por fim, foram feitas as otimizações. Em ambos os casos notou-se, em comparação com a ausência de qualquer programa de RAD, que os lucros dos consumidores e o lucro global foram substancialmente ampliados, enquanto o lucro percebido do ponto de vista do operador

sofreu quedas em torno de 30%.

Os gráficos de demanda deslocada se mostraram fortemente influenciados pela curva inicial de demanda, no entanto não foi observada saturação. Finalmente, os valores otimizados de incentivo a ser oferecido foram plotados e, como forma de facilitar a adesão dos consumidores, é apresentada uma curva com valores médios horários, evitando que haja necessidade de readequação de consumo dentro de intervalos curtos de 15 minutos.

5 CONCLUSÃO

Nesse trabalho foi apresentada uma proposta de modelagem de programa de resposta à demanda baseado em incentivos, cujos efeitos resultariam em benefícios para ambos os participantes: consumidores e operador da rede elétrica. A finalidade do programa é estimular o consumidor a utilizar a energia elétrica em momentos oportunos do ponto de vista da rede elétrica, que por sua vez sofrerá menos com perdas e qualidade de energia e poderá ter os reforços ou ampliações da rede postergados.

Para alcançar tal objetivo, o modelo teve de considerar diversas variáveis, dentre as quais duas necessitaram ser previstas. Inclui-se nessa lista a própria demanda dos clientes e a geração solar fotovoltaica, comumente utilizada em estruturas de microrredes como a topologia simulada. As RNAs foram desenvolvidas e treinadas de modo que os erros nas previsões fossem reduzidos, permitindo maior confiabilidade nos dados de entrada da otimizações.

Por fim, foram desenvolvidos dois algoritmos para otimizar o modelo, o PSO modificado utilizando a lógica de pesos, uma vez que em sua versão comum ele não é adequado para problemas multi-objetivo e o NSGA-II. O emprego de dois métodos distintos foi importante para validar o processo, pois verificou-se que os resultados obtidos foram similares, no entanto, por ser capaz de plotar uma fronteira de pareto de forma mais completa, optou-se pelo uso do NSGA-II.

Nos estudos de caso buscou-se aplicar o modelo otimizado proposto para duas situações diferentes, o consumo de energia em dias úteis e nos finais de semana, pois sabidamente as curvas de carga costumam variar em formato e amplitude dentre esses momentos. Notou-se que, apesar de ter aumentado com sucesso o lucro percebido pelos consumidores e o lucro global, o lucro do ponto de vista da operador da rede foi reduzido em ambos casos de teste na perspectiva de melhorar a operação da rede elétrica.

Conclui-se que o modelo atingiu seu objetivos, resultando em benefícios para ambas partes. O consumidor manteve seu nível de satisfação medido pelo bem-estar e foi compensado pela mudança de consumo. O operador, apesar de ter seu lucro reduzido, alcançou o objetivo de alteração no carregamento da rede em horários críticos, resultando numa melhor prestação de serviço e melhor qualidade da energia suprida. Vale ressaltar que a ANEEL possui critérios de menor custo global para alguns casos, tal como obras de conexão de clientes, portanto não é inviável se pensar em um critério de maior lucro global para o caso de aplicação de programas de RAD.

Visando melhorias do presente trabalho, seguem sugestões de trabalhos futuros:

- Inclusão de mais fontes características de microrredes como eólica, turbinas a gás e baterias;
- Implementação de outras modalidades de programa de RAD, incluindo programas baseados em preço;
- Inclusão na modelagem de aspectos que trazem benefícios financeiros do ponto de vista da concessionária, tal como a postergação de reforços de rede, mas que não foram incluídos nesse modelo;
- Implementação de critérios que suavizem a curva de incentivos, facilitando a adesão aos programas de RAD.

REFERÊNCIAS

- AALAMI, H.; MOGHADDAM, M. P.; YOUSEFI, G. Demand response modeling considering interruptible/curtailable loads and capacity market programs. *Applied Energy*, v. 87, p. 243–250, 2010.
- ALMADA, J. B. **MODELAGEM, CONTROLE E GERENCIAMENTO DA OPERAÇÃO DE MICRORREDES COM FONTES RENOVÁVEIS**. 216 f. Dissertação (Mestrado em Engenharia Elétrica) – Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica: Sistemas de Energia Elétrica, Universidade Federal do Ceará, Fortaleza, 2013.
- ANEEL. **Painel de Geração Distribuída**. 2020. Disponível em: <https://www.aneel.gov.br/>. Acesso em: 28 dez. 2020.
- BEZERRA, J. R. **Contribuições para Posicionamento Ótimo de Chaves e Restauração Automática de Redes de Distribuição de Energia Elétrica**. 114 f. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2015.
- BIDRAM, A.; DAVOUDI, A. Hierarchical structure of microgrids control system. *IEEE TRANSACTIONS ON SMART GRID*, VOL. 3, NO. 4, p. 1963-1976, 2012.
- BLANK, J.; DEB, K. Pymoo: Multi-objective optimization in python. *IEEE Access*, v. 8, p. 89497–89509, 2020.
- COLMENAR-SANTOS, A.; REINO-RIO, C.; BORGE-DIEZ, D.; COLLADO-FERNÁNDEZ, E. Distributed generation: A review of factors that can contribute most to achieve a scenario of dg units embedded in the new distribution networks. *Renewable and Sustainable Energy Reviews*, v. 59, p. 1130–1148, 2016.
- DEB, K.; PRATAP, A.; AGARWAL, S.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE TRANSACTIONS ON EVOLUTIONARY COMPUTATION*, VOL. 6, NO. 2, p. 182-197, 2002.
- HIRSCH, A.; PARAG, Y.; GUERRERO, J. Microgrids: A review of technologies, key drivers, and outstanding issues. *Renewable and Sustainable Energy Reviews*, v. 90, p. 402–411, 2018.
- IRENA. *Innovation outlook: Renewable mini-grids, international renewable energy agency*. Abu Dhabi, 2016.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. *IEEE International Conference on [S.l.: s.n.]*, 1995. v. 4, p. 1942–1948, 1995.
- Khanh, L. N.; Seo, J.; Kim, Y.; Won, D. Power-management strategies for a grid-connected pv-fc hybrid system. *IEEE Transactions on Power Delivery*, v. 25, n. 3, p. 1874–1882, 2010.
- KIRSCHEN, D.; STRBAC, G. **Fundamentals of power system economics**. [S. l.: s. n.], 2004. v. 1a ed.
- LOPES, M. L. M. **Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica**. 2005. 169 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Estadual Paulista, Ilha Solteira, 2005.

POURBABAK, H.; LUO, J.; CHEN, T.; SU, W. A novel consensus-based distributed algorithm for economic dispatch based on local estimation of power mismatch. *IEEE TRANSACTIONS ON SMART GRID*, VOL. 9, NO. 6, p. 5930-5942, 2018.

SAMADI, P.; MOHSENIAN-RAD, A.-H.; SCHOBER, R.; WONG, V. W.; JATSKEVICH, J. Optimal real-time pricing algorithm based on utility maximization for smart grid. *First IEEE International Conference on Smart Grid Communications*, p. 415-420, 2010.

SAMPAIO, F. C. **SISTEMA MULTIAGENTE DE PROTEÇÃO ADAPTATIVA**. 2017. 74 f. Dissertação (Graduação em Engenharia Elétrica) – Centro de Tecnologia, Curso de Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, 2017.

SERI, F.; LISSA, P.; KEANE, M. Integrated demand response solution towards energy positive neighbourhoods. *RESPOND DEMANDA RESPONSE FOR ALL*, p. 1-69, 2018.

TAKANO, H.; TANONAKA, N.; KIKUDA, S.; OHARA, A. A design method for incentive-based demand response programs based on a framework of social welfare maximization. *IFAC PapersOnLine*, v. 51-28, p. 374–379, 2018.

VARDAKAS, J. S.; ZORBA, N.; VERIKOUKIS, C. V. A survey on demand response programs in smart grids: Pricing methods and optimization algorithms. *IEEE COMMUNICATION SURVEYS & TUTORIALS*, VOL. 17, NO. 1, p. 152-178, 2015.

YOUSEFI, S.; MOGHADDAM, M. P.; MAJD, V. J. Optimal real time pricing in an agent-based retail market using a comprehensive demand response model. *Energy*, v. 36, p. 5716-5727, 2011.

APÊNDICE A – CÓDIGOS-FONTES DESENVOLVIDOS

Código-fonte 1 – Treinamento e previsão de demanda/geração fotovoltaica utilizando redes neurais.

```
1 from numpy import array
2 from keras.models import Sequential
3 from keras.layers import Dense
4 from pandas import read_csv
5 from pandas import datetime
6 import pandas as pd
7 from matplotlib import pyplot
8 from math import sqrt
9 from sklearn.metrics import mean_squared_error
10
11 def parser(x):
12     return datetime.strptime(x, '%d/%m/%Y %H:%M ')
13
14 series = pd.read_csv(r C:\Users\rodrigo\Desktop\dados.csv ,
15                     header=0, parse_dates=[0], index_col=0, squeeze=True,
16                     date_parser=parser)
17
18 train = series[0:364*96]
19 test = series[364*96:]
20
21 def split_sequence(sequence, n_steps_in, n_steps_out):
22     X, y = list(), list()
23     for i in range(len(sequence)):
24         end_ix = i + n_steps_in
25         out_end_ix = end_ix + n_steps_out
26         if out_end_ix > len(sequence):
27             break
```

```

26     seq_x, seq_y = sequence[i:end_ix], sequence[end_ix:
        out_end_ix]
27     X.append(seq_x)
28     y.append(seq_y)
29     return array(X), array(y)
30
31 raw_seq = train
32 n_steps_in, n_steps_out = 100, 96
33 X, y = split_sequence(raw_seq, n_steps_in, n_steps_out)
34 model = Sequential()
35 model.add(Dense(100, activation= relu , input_dim=
        n_steps_in))
36 model.add(Dense(n_steps_out))
37 model.compile(optimizer= adam , loss= mse )
38 model.fit(X, y, epochs=5, verbose=0)
39 x_input = array([train[-100:]])
40 x_input = x_input.reshape((1, n_steps_in))
41 yhat = model.predict(x_input, verbose=0)
42
43 RMSE = sqrt(mean_squared_error(yhat, test))

```

Código-fonte 2 – Otimização via PSO.

```

1 import numpy as np
2 from pymoo.algorithms.so_pso import PSO
3 import matplotlib.pyplot as plt
4 from pymoo.optimize import minimize
5 from pymoo.model.problem import Problem
6
7 def utilidade(d):
8     return (10000/(1+ np.exp(-0.0050*(d - 6000))))
9

```

```
10 def lucro_dist(deltad, incentivo):
11     return (6809 - deltax - 561)*0.8 - (0.0031*(6809 -
12         deltax - 561 )**2 + 8.71*( 6809 - deltax - 561 ))
13         *0.01 - deltax*incentivo
14
15 def lucro_cons(deltad, incentivo):
16     return utilidade(6809) - utilidade(6809 - deltax) -
17         (6809 - deltax - 561)*0.8 + deltax*incentivo
18
19 class MyProblem(Problem):
20
21     def __init__(self, w=0.5):
22         super().__init__(n_var=2,
23             n_obj=1,
24             n_constr=0,
25             xl=np.array([0,0]),
26             xu=np.array([3400, 1]))
27
28         self.w = w
29
30     def _evaluate(self, x, out, *args, **kwargs):
31
32         def lucro_dist(deltad, incentivo):
33             return (6809 - deltax - 561)*0.8 -
34                 (0.0031*(6809 - deltax - 561 )**2 + 8.71*(
35                     6809 - deltax - 561 ))*0.01 - deltax*
36                     incentivo
37
38         def lucro_cons(deltad, incentivo):
39             return utilidade(6809) - utilidade(6809 -
40                 deltax) - (6809 - deltax - 561)*0.8 + deltax
41                 *incentivo
```

```

34     def utilidade(d):
35         return (10000/(1+ np.exp(-0.0050*(d - 6000))))
36
37     x_ = x[:, 0]
38     y_ = x[:, 1]
39
40     lucro_dist = (lucro_dist(x_, y_))
41     lucro_cons = (lucro_cons(x_, y_))
42
43     out["F"] = -(self.w*(lucro_dist) + (1-self.w)*
44                 lucro_cons)
45
46     def _calc_pareto_front(self):
47         return 0
48
49     def _calc_pareto_set(self):
50         return anp.full(self.n_var, 0)
51
52 algorithm = PSO()
53
54 for i in [x * 0.005 for x in range(0, 201)]:
55     problem = MyProblem(w = i)
56     res = minimize(problem,
57                   algorithm,
58                   seed=1,
59                   save_history=True,
60                   verbose=True)

```

Código-fonte 3 – Otimização via NSGA-II.

```

1 import numpy as np
2 from pymoo.util.misc import stack

```



```
3 from pymoo.model.problem import Problem
4 from pymoo.algorithms.nsga2 import NSGA2
5 from pymoo.factory import get_sampling, get_crossover,
   get_mutation
6 from pymoo.optimize import minimize
7 from pymoo.factory import get_termination
8 from pymoo.visualization.scatter import Scatter
9
10 prev_demanda = [Valores previstos de demanda]
11 prev_solar = [Valores previstos de geracao]
12
13 param1 = [Valores de X definidos para funcao utilidade]
14 param2 = [Valores de Y definidos para funcao utilidade]
15
16 class MyProblem(Problem):
17
18     def __init__(self, prev_dem=0, prev_sol=0,
19                 param_utilidade_1=0, param_utilidade_2 = 0):
20         self.prev_dem = prev_dem
21         self.prev_sol = prev_sol
22         self.param_utilidade_1 = param_utilidade_1
23         self.param_utilidade_2 = param_utilidade_2
24         super().__init__(n_var=2,
25                          n_obj=2,
26                          n_constr=0,
27                          xl=np.array([0,0]),
28                          xu=np.array([3400, 1]))
29
30     def _evaluate(self, x, out, *args, **kwargs):
31
32         def lucro_dist(deltad, incentivo):
33             return (self.prev_dem - deltad - self.prev_sol)
```

```

        *0.8 - (0.0031*(self.prev_dem - deltad -
        self.prev_sol )**2 + 8.71*( self.prev_dem -
        deltad - self.prev_sol ))*0.01 - deltad*
        incentivo

33
34     def lucro_cons(deltad, incentivo):
35         return utilidade(self.prev_dem) - utilidade(
        self.prev_dem - deltad) - (self.prev_dem -
        deltad - self.prev_sol)*0.8 + deltad*
        incentivo

36
37     def utilidade(d):
38         return (10000/(1+ np.exp(-self.
        param_utilidade_1*(d - self.
        param_utilidade_2))))

39
40     x_ = x[:, 0]
41     y_ = x[:, 1]
42
43     lucro_dist = -(lucro_dist(x_, y_))
44     lucro_cons = -(lucro_cons(x_, y_))
45
46     out["F"] = np.column_stack([lucro_cons, lucro_dist
        ])

47
48     def _calc_pareto_front(self, flatten=True, **kwargs):
49         f1_a = np.linspace(0.1**2, 0.4**2, 100)
50         f2_a = (np.sqrt(f1_a) - 1)**2
51
52         f1_b = np.linspace(0.6**2, 0.9**2, 100)
53         f2_b = (np.sqrt(f1_b) - 1)**2
54

```

```
55     a, b = np.column_stack([f1_a, f2_a]), np.  
56         column_stack([f1_b, f2_b])  
57     return stack(a, b, flatten=flatten)  
58  
59 def _calc_pareto_set(self, flatten=True, **kwargs):  
60     x1_a = np.linspace(0.1, 0.4, 50)  
61     x1_b = np.linspace(0.6, 0.9, 50)  
62     x2 = np.zeros(50)  
63  
64     a, b = np.column_stack([x1_a, x2]), np.column_stack  
65         ([x1_b, x2])  
66     return stack(a,b, flatten=flatten)  
67  
68 for i in range(0,96):  
69     problem = MyProblem(prev_dem = prev_demanda[i],  
70         prev_sol = prev_solar[i], param_utilidade_1 = param1  
71         [i], param_utilidade_2=param2[i])  
72  
73     algorithm = NSGA2(  
74         pop_size=40,  
75         n_offsprings=10,  
76         sampling=get_sampling("real_random"),  
77         crossover=get_crossover("real_sbx", prob=0.9, eta  
78             =15),  
79         mutation=get_mutation("real_pm", eta=20),  
80         eliminate_duplicates=True  
81     )  
82  
83     termination = get_termination("n_gen", 40)  
84  
85     res = minimize(problem,
```

```
82         algorithm ,
83         termination ,
84         seed=1 ,
85         pf=problem.pareto_front(use_cache=False)
86         ,
87         save_history=True ,
88         verbose=False)
89
90 ps = problem.pareto_set(use_cache=False, flatten=False)
91 pf = problem.pareto_front(use_cache=False, flatten=
92     False)
93
94 res_lucro_c = -res.F[:, 0]
95 res_lucro_d = -res.F[:, 1]
```