

**UMA MODELAGEM VISANDO ECONOMIA DE
ENERGIA EM SMARTHOMES**

RAPHAEL LUCIANO DE PONTES

**UMA MODELAGEM VISANDO ECONOMIA DE
ENERGIA EM SMARTHOMES**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais – Departamento de Ciência da Computação, como requisito parcial para a obtenção do grau de Mestre em Ciência da Computação.

ORIENTADOR: DORGIVAL OLAVO GUEDES NETO

Belo Horizonte

Janeiro de 2019

© 2019, Raphael Luciano de Pontes.
Todos os direitos reservados.

Pontes, Raphael Luciano de.

P814m Uma modelagem visando economia de energia em smarthomes / Raphael Luciano de Pontes. — Belo Horizonte, 2019
xxii, 51 p. : il. ; 29cm

Dissertação (mestrado) — Universidade Federal de Minas Gerais – Departamento de Ciência da Computação.

Orientador: Dorgival Olavo Guedes Neto

1. Computação – Teses. 2. Casas inteligentes. 3. Balanceamento de carga. 4. Energia renovável. I. Orientador. II. Título.

CDU 519.6*17 (043)



UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

FOLHA DE APROVAÇÃO

UMA MODELAGEM VISANDO ECONOMIA DE ENERGIA EM
SMARTHOMES

RAPHAEL LUCIANO DE PONTES

Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:

A handwritten signature in blue ink, appearing to read "D. Guedes", positioned above the name of the first member of the examining board.

PROF. DORGIVAL OLAVO GUEDES NETO - Orientador
Departamento de Ciência da Computação - UFMG

A handwritten signature in blue ink, appearing to read "Renato", positioned above the name of the second member of the examining board.

PROF. RENATO ANTÔNIO CELSO FERREIRA
Departamento de Ciência da Computação - UFMG

A handwritten signature in blue ink, appearing to read "Ítalo", positioned above the name of the third member of the examining board.

PROF. ÍTALO FERNANDO SCOTÁ CUNHA
Departamento de Ciência da Computação - UFMG

Belo Horizonte, 22 de Fevereiro de 2019.

Dedico este trabalho à minha mãe, que é meu maior exemplo de perseverança; à minha namorada Jéssyca Guimarães, pelo apoio incondicional; ao professor Dorgival Guedes pela orientação; e à toda comunidade do curso de Ciência da Computação da UFMG.

Agradecimentos

Início meus agradecimentos pela minha mãe, Maria Cecília Luciano, que nunca mediu esforços para garantir que eu tivesse as oportunidades necessárias para concluir mais essa etapa da minha vida. Sempre acreditando em mim, e sacrificando tudo o que estava ao seu alcance para possibilitar minha ascensão na vida. Deixo meus mais sinceros agradecimentos, que certamente não podem ser medidos apenas com palavras, a essa pessoa maravilhosa a quem eu tanto devo. Obrigado minha mãe, você é, e sempre será, meu maior orgulho.

A minha namorada, Jéssyca Irene Guimarães, por ter dividido comigo mais esta etapa da minha formação, compartilhando seus conhecimentos acadêmicos e oferecendo sempre um suporte essencial para toda a minha jornada.

A todos os meus colegas de laboratório, e-SPEED do Departamento de Ciência da Computação (DCC) da UFMG, que tiveram importante papel no meu desenvolvimento como aluno e como profissional. Com eles, aprendi muito do que hoje sei, e esse conhecimento foi chave essencial para meu progresso, tanto no curso de graduação, quanto no mestrado no DCC. Obrigado a todos pelas responsabilidades que me ensinaram e cobraram.

Ao meu tio, Anor Luciano Júnior, que, como único parente na cidade de Belo Horizonte, sempre se mostrou presente nas horas de necessidade. Graças a ele tive a oportunidade de mudar para Belo Horizonte e dar início ao que, hoje, tenho orgulhosamente como minha profissão.

Ao meu orientador, Dorgival Olavo Guedes Neto, que me guiou, desde o início da graduação, nos projetos de iniciação científica, até o final do curso de mestrado. Obrigado pelas oportunidades de pesquisas e disciplinas, crescimento dentro da academia e por todo o conhecimento passado através desses anos.

Também deixo meu agradecimento aos professores Anand Seetharam (SUNY Binghamton) e Aditya Mishra (Seattle University), que me deram a oportunidade de pesquisa durante meus estudos nos Estados Unidos, e que resultou no campo de pesquisa estendido nesta dissertação de mestrado.

Agradeço, também, a todos os professores do Departamento de Ciência da Computação da UFMG, que participaram da minha jornada acadêmica. A contribuição de cada um seguirá sempre comigo em minha vida acadêmica e profissional. Juntamente com os professores, quero enfatizar minha gratidão a todos os demais funcionários do DCC, desde a secretaria, cantinas, limpeza, colegiados, e coordenação.

A Fundação Universitária Mendes Pimentel (FUMP), responsável pela assistência estudantil da UFMG, e que teve papel absolutamente fundamental em minha trajetória pela universidade. Graças a ela, tive melhores condições de trilhar minha jornada acadêmica, tendo acesso a auxílio para moradia e alimentação, cujos quais sem eles, eu provavelmente não teria conseguido.

Aos meus colegas de curso, que enfrentaram o trajeto ao meu lado e também contribuíram com o meu conhecimento. Pois toda interação com estudantes da área nos serve de oportunidade para aprendizado.

Aos amigos de convivência das moradias universitárias, que também tiveram grande importância em demais aspectos de minha passagem pela Universidade Federal de Minas Gerais. Obrigado à todos vocês pelos momentos que dividimos!

Agradeço, também, a todas as organizações de apoio a pesquisa (CAPES, CNPQ e FAPEMIG) que tiveram papel direto, ou indireto, em minha formação.

E, por fim, agradeço aos professores da minha banca examinadora, professores Ítalo Fernando Scotá Cunha e Renato Antônio Celso Ferreira, pela disponibilidade de participar de mais este procedimento dentro da minha jornada na academia. Muito obrigado a todos.

“Failure is simply the opportunity to begin again, this time more intelligently.”
(Henry Ford)

Resumo

O aumento do consumo de energia elétrica, juntamente com o conseqüente crescimento de emissão de carbono, tornam-se grande incentivo para esforços na implantação de energia renovável em estabelecimentos comerciais e industriais. Altos picos de demanda implicam em grande custo de produção de energia elétrica, juntamente com o aumento da emissão de carbono, resultando assim, no aumento do custo da energia para o usuário final. Logo, o modo como algumas companhias tarifam a venda de energia também constitui grande incentivo para modelos que priorizam, não somente a diminuição do consumo, mas a homogeneização dos picos de energia ao longo do dia. Abordagens já existentes de implantação de energia renovável (NetMetering), e de simulação com dados reais de consumo de energia (PeakCharge), foram utilizadas neste trabalho, para fins de comparação e agregação para melhoria do nosso modelo. Neste trabalho, apresentamos GreenPeaks, uma modelagem para implantar o uso de energia limpa, juntamente com uso de baterias de armazenamento em SmartHomes. Através de uma lógica reativa, GreenPeaks nos mostra tanto uma redução significativa na conta e nos picos e do consumo de energia elétrica para o usuário final, quanto uma diminuição do custo para geração da mesma para as companhias provedoras.

Palavras-chave: Economia de Energia, Casas Inteligentes, Energia Renovável, Balanceamento de Carga.

Abstract

The ascension of electricity consumption and its consequent growth of carbon footprints becomes a major incentive for implementation of renewable energy in electric utilities. High peaks demand implies great cost for electric power generation and also contributing with carbon emissions, which results in increasing the cost of energy for the final user. Therefore, the power business model adopted by some companies is also a great incentive for the models that prioritize, not only the reduction of consumption, but a homogenization of the peak demand throughout the day. Existing approaches that applies renewable energy (NetMetering) and simulation with real consumption trace (PeakCharge) were considered in this work, for comparison and improvement of our model. In this work, we introduce GreenPeaks, a modeling to deploy the use of clean energy, using storage batteries, to SmartHomes. Through a reactive work flow, GreenPeaks promotes a significant reduction of the peak demand and bill for the final user, as well as a reduction of the power cost generation for electric utilities.

Keywords: Energy Savings, Smart Home, Renewable Energy, Load Scheduling.

Lista de Figuras

| | | |
|-----|--|----|
| 1.1 | Consumo de Energia nos Estados Unidos, separado por setores (Fonte: U.S. Energy Information Administrator [2018]). | 3 |
| 2.1 | Custo marginal de produção de energia nos EUA [Commission, 2009] . . . | 8 |
| 2.2 | Geração de energia ao longo do dia, retirada do dataset Smart [2018]. . . | 17 |
| 2.3 | Consumo de energia ao longo do dia, segundo <i>Office for National Statistics</i> (Fonte: Torriti [2017]). | 17 |
| 3.1 | Demanda de um dia representativo do dataset utilizado. | 20 |
| 3.2 | Modelo de tarifação TOU. | 22 |
| 3.3 | Modelo de tarifação branca utilizado pela CEMIG. | 23 |
| 4.1 | Arquitetura de <i>GreenPeaks</i> | 26 |
| 5.1 | Consumo de um dia representativo com a aplicação de <i>NetMetering</i> | 32 |
| 5.2 | Consumo de um dia representativo com a aplicação de <i>PeakCharge</i> | 33 |
| 5.3 | Consumo de um dia representativo com a aplicação de <i>GreenPeaks</i> | 34 |
| 5.4 | Consumo original (a), após uso de <i>PeakCharge</i> (b), e após <i>GreenPeaks</i> (c), com a demanda de mais um dia representativo de nosso dataset | 35 |
| 5.5 | Demanda agregada do <i>Smart Grid</i> considerando os modelos de gerência de energia abordados. <i>NetMetering</i> não apresenta ganhos significativos em relação à demanda original nesse caso. | 36 |
| 5.6 | Economia agregada obtida pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços ToU. (<i>NetMetering</i> não utiliza baterias.) | 37 |
| 5.7 | Redução do pico máximo agregado observado pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços ToU. (<i>NetMetering</i> não utiliza baterias.) | 38 |

| | | |
|------|---|----|
| 5.8 | Economia agregada obtida em função da porcentagem de residências que adota modelos de gerência inteligente de energia, sob a política de preços ToU. | 38 |
| 5.9 | Redução do pico máximo agregado observado em função da porcentagem de residências que adota modelos de gerência inteligente de energia, sob a política de preços ToU. | 39 |
| 5.10 | Economia individual média por apartamento obtida pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços ToU. (<i>NetMetering</i> não utiliza baterias.) | 40 |
| 5.11 | Demanda agregada do <i>Smart Grid</i> considerando os modelos de gerência de energia abordados, sob a política de preços da CEMIG. <i>NetMetering</i> não apresenta ganhos significativos em relação à demanda original nesse caso. | 42 |
| 5.12 | Economia agregada obtida pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços da CEMIG. (<i>NetMetering</i> não utiliza baterias.) | 43 |
| 5.13 | Redução do pico máximo agregado observado pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços da CEMIG. (<i>NetMetering</i> não utiliza baterias.) | 43 |
| 5.14 | Economia agregada obtida em função da porcentagem de residências que adota modelos de gerência inteligente de energia, sob a política de preços da CEMIG. | 44 |
| 5.15 | Redução do pico máximo agregado observado em função da porcentagem de residências que adota modelos de gerência inteligente de energia, sob a política de preços da CEMIG. | 44 |

Lista de Tabelas

Sumário

| | |
|---|-----------|
| Agradecimentos | ix |
| Resumo | xiii |
| Abstract | xv |
| Lista de Figuras | xvii |
| Lista de Tabelas | xix |
| 1 Introdução | 1 |
| 1.1 Motivação | 2 |
| 1.2 Objetivos | 3 |
| 1.3 Contribuições do Trabalho | 4 |
| 1.4 Organização do texto | 4 |
| 2 Contextualização e Trabalhos Relacionados | 7 |
| 2.1 Tarifação por volume de demanda | 7 |
| 2.2 Smart Grid | 8 |
| 2.3 Trabalhos relacionados | 10 |
| 2.3.1 <i>PeakCharge</i> | 14 |
| 2.3.2 <i>NetMetering</i> | 16 |
| 3 Caracterização dos Dados de Entrada | 19 |
| 3.1 Caracterização de Carga Domiciliar | 19 |
| 3.2 Energia Renovável | 20 |
| 3.3 Configuração da Bateria | 21 |
| 3.4 Modelo de Tarifação <i>Time Of Use</i> | 21 |
| 3.5 Modelo de Tarifação - <i>Tarifa Branca da CEMIG</i> | 23 |
| 3.6 Penalização por Pico Máximo | 24 |

| | | |
|----------|--|-----------|
| 4 | Modelo Proposto: <i>GreenPeaks</i> | 25 |
| 4.1 | Modelo <i>Simples</i> | 27 |
| 4.2 | <i>GreenPeaks</i> | 27 |
| 5 | Avaliação | 31 |
| 5.1 | Avaliação dos modelos considerados | 32 |
| 5.1.1 | <i>NetMetering</i> | 32 |
| 5.1.2 | <i>PeakCharge</i> | 33 |
| 5.1.3 | <i>GreenPeaks</i> | 34 |
| 5.2 | Resultados com tarifação TOU (<i>Time Of Use</i>) | 35 |
| 5.3 | Resultados com a política de Tarifação Branca da CEMIG | 41 |
| 6 | Conclusão | 45 |
| | Referências Bibliográficas | 47 |

Capítulo 1

Introdução

Os problemas causados pelo alto gasto de energia geram grandes impactos na sociedade moderna e no modo de vida que levamos. De acordo com Raza et al. [2019], o consumo de energia nos Estados Unidos da América tem apresentado grande crescimento nos últimos anos. Tal aumento está diretamente relacionado com fatores como a emissão de carbono, ao ponto de tornar uma questão de incentivo público para que usuários domésticos adotem alternativas mais sustentáveis.

Juntamente com o consumo, a emissão de dióxido de carbono na atmosfera também tem sofrido aumento considerável, uma vez que a geração de eletricidade é um dos maiores contribuidores para as emissões [USEIA, 2017]. A título de exemplo, no ano de 2016, nos Estados Unidos da América, de todas as emissões de CO₂ relacionadas a energia, cerca de 35% correspondem ao setor de abastecimento de eletricidade. Adicionalmente, o ano de 2016 foi considerado o mais quente, desde o início das medições, em 1880.

Um nicho com consumo de energia de enorme impacto são estabelecimentos como: casas, prédios e lojas. Eles correspondem a uma grande parcela do gasto energético de todo um país. Como consequência desse aumento do consumo, nos próximos anos grandes estabelecimentos de países desenvolvidos necessitarão gerar, de maneira sustentável, ao menos uma parcela de sua energia consumida. Uma iniciativa do Departamento de Energia dos Estados Unidos da América (DOE) possui uma proposta de alcançar, em 2030, uma produção de energia solar de 14% do total gerado no país. Outra estimativa, ainda mais agressiva, sugere que para 2050 esse valor seja de 27% [Scarlat et al., 2015].

Tendo em mente essas demandas, casas e prédios têm sido especialmente projetadas para monitorar e reduzir o consumo de energia dos habitantes. Com a popularização das *SmartHomes*, tornou-se mais fácil a coleta de informações sobre os gastos de estabelecimentos similares a esses, para que os padrões de consumo possam

ser estudados e utilizados para o melhor entendimento dos desafios de gerência dos mesmos.

Essas casas inteligentes também costumam integrar métodos alternativos de produção de energia, como turbinas eólicas e células fotovoltaicas, ao perfil de geração de energia de uma comunidade. Um novo desafio então se torna a decisão sobre como melhor utilizar esses recursos alternativos lado a lado com o modelo comercial das empresas fornecedoras de energia. Algumas propostas de modelos de operação de *SmartHomes* já foram estudadas para tentar otimizar o escalonamento das diferentes fontes de energia disponíveis, quando consumir da fornecedora, quando armazenar energia, e até mesmo quando vender energia excedente de volta para as concessionárias. Um exemplo desse tipo de solução é o modelo *PeakCharge*, desenvolvido por Mishra et al. [2013b], e usado como ponto de partida neste trabalho.

Tendo esse cenário descrito em mente, este trabalho focou em modelos para gerência de energia em *SmartHomes*, considerando a incorporação de energia renovável em modelos estudados da literatura, e que promovem a diminuição do custo de energia tanto para o usuário final quanto para as concessionárias que a geram e distribuem. Para isso, diversas técnicas já propostas foram estudadas e algumas delas selecionadas para integrarem o modelo proposto neste trabalho. Nosso algoritmo utiliza os dados de consumo de energia de apartamentos, modelo de preço variável durante o dia, produção de energia solar e também considera o uso de baterias externas para, então, tomar decisões de compra e venda de energia (mais informações sobre os modelos e dados utilizados serão explicadas posteriormente). Essas decisões a serem tomadas se constituem basicamente em alternar a fonte e o destino da energia, visando a economia, tanto para o usuário final, quanto para os fornecedores da mesma.

1.1 Motivação

Com o avanço da tecnologia, os estabelecimentos e residências passaram a contar com um perfil de demanda de energia cada vez mais agressivo. Como reportado pela organização de administração de energia oficial do governo norte americano [U.S. Energy Information Administrator, 2018], podemos ver na figura 1.1 que a demanda do país tem aumentado continuamente ao longo dos anos. Além disso, o setor residencial é o segundo mais relevante, no aspecto de consumo de energia, de todo o Estados Unidos.

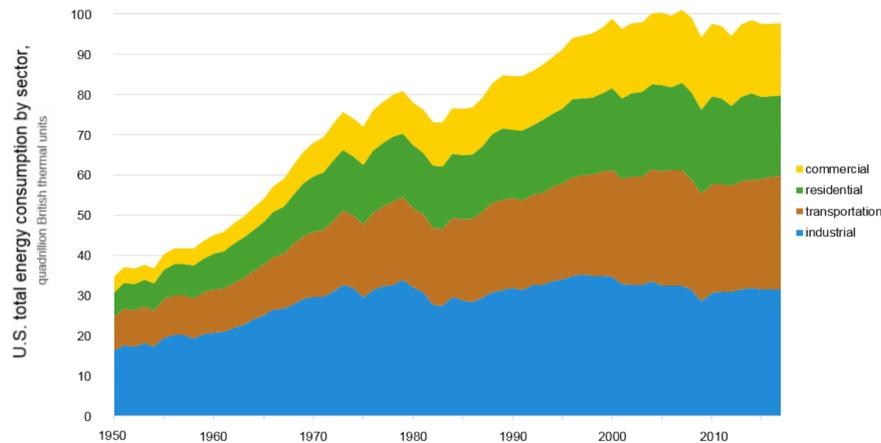


Figura 1.1: Consumo de Energia nos Estados Unidos, separado por setores (Fonte: U.S. Energy Information Administrator [2018]).

Tendo em vista esse cenário em que a demanda por energia cresce significativamente, e ainda tendo o setor residencial com grande participação, esta se torna uma área de bastante interesse para pesquisa e desenvolvimento de novas soluções, uma vez que estamos falando de um recurso escasso.

Outro fator que possibilita muitos trabalhos e pesquisas sobre essa temática é fato do avanço tecnológico passar a nos dar acesso a uma grande quantidade de dados sobre consumo de diversos estabelecimentos. Assim, torna-se possível fazer análises e propor novas soluções com base nessa informação. Trabalhos como o realizado pela University of Massachusetts Amherst [Barker et al., 2012a] são bons exemplos disso. Nele, um grande repositório de consumo de energia de diversas residências foi disponibilizado para a comunidade científica, para que novos estudos possam ser feitos nessa área.

1.2 Objetivos

Este trabalho de mestrado objetiva expandir o modelo de gerenciamento de energia em *SmartHome*, desenvolvido por Mishra et al. [2013b], chamado *PeakCharge*, e adicionar o uso de energia renovável ao problema, também acrescentando os benefícios da venda de energia excedente de volta para o *smart grid*. Ademais, também realizamos uma análise de resultados comparando com uma abordagem similar real, *NetMetering*, já implantada em diversos estabelecimentos.

Utilizando a mesma base de dados presente nos experimentos de Mishra et al. [2013b], nosso objetivo é realizar uma análise comparando os resultados obtidos pelos modelos *PeakCharge* e *NetMetering* com a nossa implementação, aqui denominada *GreenPeaks*.

É preciso ter em mente que o preço final da energia elétrica, comprada pelos moradores das residências, depende diretamente do preço da mesma sendo ofertada pelos fornecedores de energia elétrica. Dito isto, assim como realizado na análise experimental dos trabalhos anteriores, nós faremos uma bateria de experimentos que visa salientar os benefícios de *GreenPeaks* tanto para os usuários finais, quanto para a concessionária que gera e distribui energia. Logo, a economia adquirida durante a geração de energia acabará por impactar positivamente também o usuário final.

1.3 Contribuições do Trabalho

A contribuição principal deste trabalho é a implementação de um modelo de gerenciamento de energia, o *GreenPeaks*, utilizando recursos como: bateria externa, placas solares e turbinas eólicas produzindo energia limpa, e tirando vantagem de modelos de tarifação variável, a fim de promover economia de energia, tanto para o usuário final, quanto para as empresas produtoras de energia elétrica.

Como resultado deste trabalho, houve uma publicação na conferência *SMART-COMP 2018: The 4th IEEE International Conference on Smart Computing*, que abrange inovações diversas da área de Smart Computing [Pontes et al., 2018]. O código desenvolvido está disponível no repositório GitHub [GreenPeaks, 2017]. A publicação também está presente no website do projeto SMART, de onde foram retirados todos os dados utilizados.

Como contribuições secundárias, juntamente com o código desenvolvido, foram implementados e avaliados outros modelos de gerência de energia. Todos os modelos foram executados utilizando o repositório citado na seção 1.1, e foram implementados para poderem ser comparados ao novo algoritmo proposto.

Adicionalmente, também tentamos buscar dados de consumo, geração e tarifação de energia utilizados no Brasil, mais especificamente com a empresa CEMIG, de Minas Gerais. Apesar de algumas limitações, esses dados foram usados na análise da aplicação do modelo no contexto de Minas Gerais. Mais detalhes sobre os dados serão melhor descritos no capítulo 3.

1.4 Organização do texto

O restante deste trabalho esta organizado da seguinte forma: no capítulo 2 comentamos os trabalhos relacionados e fazemos uma contextualização dos temas relacionados a este trabalho; no capítulo 3 nós caracterizamos todas as cargas de entrada utilizadas pelos

nossos algoritmos; no capítulo 4 descrevemos com detalhes os modelos implementados no trabalho; no capítulo 5 realizamos uma análise dos resultados obtidos e, por fim, no capítulo 6 apresentamos nossas conclusões sobre o trabalho e discutimos possíveis continuações.

Capítulo 2

Contextualização e Trabalhos Relacionados

Neste capítulo discutimos conceitos básicos relacionados à área de modelos de gerenciamento de energia elétrica, os principais trabalhos relacionados e os modelos de gerência de energia anteriores que serviram de base para a produção deste trabalho de mestrado.

Dois conceitos básicos essenciais para o entendimento dos trabalhos nesta área são o de tarifação por volume de demanda e o de *Smart Grids*. Juntos, esses conceitos determinam a base dos modelos de gerência de energia em cidades inteligentes. Após a definição destes, abordaremos os trabalhos relacionados e daremos uma maior ênfase na modelagem *PeakCharge* e *NetMetering*, pois tiveram grande influência no nosso modelo, *GreenPeaks*, que será melhor detalhado posteriormente.

2.1 Tarifação por volume de demanda

O custo pago pelas companhias geradoras de energia para a geração de energia elétrica não segue uma tendência linear de preço conforme a demanda cresce, como podemos ver na figura 2.1. De acordo com a figura, para valores entre 20 a 30 MWh o preço da geração de energia por MWh não apresenta grandes diferenças. Porém, entre 30 e 40 MWh já vemos um salto significativo e valores maiores que 50 MWh já apresentam um crescimento exponencial no preço da geração, enfatizando o crescimento não linear do custo de geração de energia. Além disso, altos picos incorrem em perdas e ineficiências devido à transmissão da energia. Em consequência de fatores como esses, companhias de distribuição de energia têm mostrado uma tendência de migração do modelo de cobrança clássico, onde o preço por kilowatt é fixo, para modelos onde o custo varia de acordo com os picos de demanda. Com uma alta tarifação em horários de pico e baixa

tarifação em horários com menor demanda, o usuário final é incentivado a diminuir seu consumo naqueles momentos de pico. Tal medida tem como objetivo uma tendência de homogeneização da demanda para as companhias distribuidoras de energia, evitando uma necessidade de uma produção e distribuição extremamente grande em certos momentos do dia. E, como consequência, diminuindo o custo da produção da energia e resultando em uma menor tarifação da mesma para o usuário final.

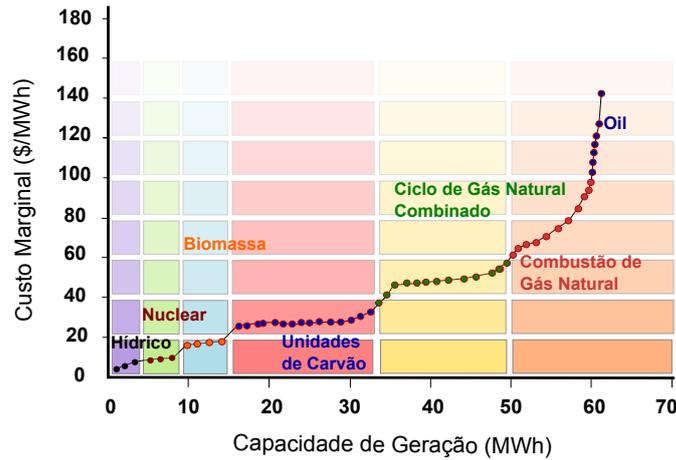


Figura 2.1: Custo marginal de produção de energia nos EUA [Commission, 2009]

Como um exemplo de tais modelos de tarifação em uso atualmente, temos o chamado *time-of-use* (TOU) oferecido pela Ontario Energy Board [OEB, 2017], onde encontramos três períodos distintos de preços diários. Nos horários de pico (*on-peak*), como horários de almoço e jantar) o valor cobrado é de 13,2 *cents*/kWh. Já os horários no decorrer do dia, exceto os *on-peak* (denominados *mid-peak*), a energia custa 9,5 *cents*/kWh. Nas demais horas, como durante a madrugada (*off-peak*), o valor é de 6,5 *cents*/kWh. Mais detalhes sobre os modelos de tarifação considerados serão apresentados nas seções 3.4 e 3.5.

2.2 Smart Grid

O termo *Smart Grid* tem sido adotado para identificar uma rede de distribuição de energia elétrica baseada na tecnologia digital, onde o sistema de geração e distribuição pode interagir com os consumidores por meio de comunicação digital bidirecional. Este sistema permite o monitoramento, análise, controle e comunicação dentro da cadeia de fornecimento para ajudar a melhorar a eficiência, reduzir o consumo e os custos de energia e maximizar a transparência e a confiabilidade. A rede inteligente foi introduzida com o objetivo de superar as deficiências das redes elétricas convencionais usando me-

didores de redes inteligentes. A bidirecionalidade do *Smart Grid*, em termos práticos, significa que também é possível a venda de energia elétrica, dos próprios consumidores, de volta para a rede. Assim, aumenta o incentivo para os consumidores finais implantarem sistemas de geração de energia limpa para que eles possam gerar sua própria energia, revendendo parte do excesso de volta para o *Smart Grid*, diminuindo suas próprias contas no fim do mês (como implementado em Energysage [2017]).

Graças ao monitoramento detalhado no *Smart Grid*, é possível identificar com mais facilidade os momentos de maiores consumos, considerando a demanda agregada de todos os estabelecimentos abastecidos pelo *Smart Grid*, pois esta alta demanda incorre em grandes custos e desafios para as concessionárias. Estes momentos de alta demanda agregada no *Smart Grid* serão, neste trabalho, chamados de momentos de pico agregado. Desta maneira, as distribuidoras de energia podem buscar por soluções para o problema mencionado acima, como propor modelos de preços variados a cada hora do dia a fim de incentivar seus clientes a adotarem um consumo mais bem distribuído. Por exemplo, em um momento de grande demanda de todo *Smart Grid*, pode-se aumentar significativamente o custo do kWh, fazendo com que os clientes optem por consumirem menos em tais momentos. Portanto, é comum estratégias neste contexto buscarem uma homogeneização do consumo, ou seja, evitar a ocorrência de grandes picos de consumo de energia. Neste trabalho serão abordados diferentes modelos de preços adotados por companhias fornecedoras de energia, e que serão detalhados posteriormente no texto.

Uma estratégia que vem sendo considerada na literatura da área e já pode ser encontrada em aplicações reais de *Smart Grid* é a utilização de baterias locais (*on-site*) onde se armazena energia elétrica para ser reutilizada posteriormente. Esta energia pode ser proveniente tanto da compra do próprio *Smart Grid*, quanto de geração de energia limpa, caso existente. O modo como estas baterias podem ser carregadas ou descarregadas vai depender da estratégia adotada pelo cliente, podendo ser feita de maneira gulosa (carregar/descarregar à taxa máxima permitida), ou respeitando alguma lógica previamente configurada. Esta solução deve, entretanto, levar em consideração o custo e a ineficiência das baterias, pois existem perdas nas conversões, tanto no armazenamento, quanto na utilização da energia armazenada. Neste trabalho também abordaremos diferentes comportamentos de carga/descarga de baterias, uma vez que esta lógica faz parte da implementação aqui proposta.

2.3 Trabalhos relacionados

Com o objetivo de buscar uma diminuição do custo de energia para o consumidor final, diversas propostas encontradas na literatura atualmente exploram os modelos de preços variáveis praticados pelas concessionárias. Daryanian et al. [1989] propuseram uma abordagem de otimização tirando vantagem do sistema de preços variados e apresentaram um estudo de caso mostrando a economia gerada para o usuário. Por outro lado, Hegde et al. [2011] modela o mesmo problema como um Processo de Decisão de Markov [Pellegrini & Wainer, 2007], com uma política que limita um montante de armazenamento de energia em bateria (*threshold*), baseado no preço instantâneo da mesma. Neste caso, a política seria ótima se a demanda se mostrasse homoganeamente distribuída ao longo do dia. Diferente da proposta deste trabalho de mestrado, que também faz uso de energia renovável, os trabalhos mencionados acima têm seu foco apenas na utilização de baterias para armazenamento e reutilização de energia.

Ademais, como discutido por Carpenter et al. [2012], soluções que adotam uma taxa de carga/descarga gulosa das baterias podem promover o pico agregado para o grid distribuído, o que gera efeitos negativos no preço final da energia. A solução apresentada neste trabalho evita esse efeito colateral controlando a compra de energia de maneira a buscar sempre a média do consumo diário. Mais detalhes serão discutidos no capítulo 4. Além disso, Mishra et al. [2015] propuseram diferentes combinações de tecnologias de armazenamento de energia em múltiplos níveis de hierarquia de distribuição no grid, promovendo melhoria nos custos das concessionárias. Contrariamente, nosso trabalho se concentra na implantação de armazenamento, juntamente com energia limpa, apenas nas residências.

Outras pesquisas também investigam e propõem métodos que visam um melhor escalonamento dos utensílios domésticos para reduzir a demanda, reduzindo os picos agregados e também as contas de energia, como consequência. Uma demonstração disso pode ser vista no trabalho de Barker et al. [2012b], onde é proposto um diferente perfil de consumo de eletricidade, reescalando determinadas cargas (*background loads*), como: refrigeradores, ar-condicionado e desumidificadores. Da forma similar, Srikantha et al. [2012] definem uma noção de elasticidade no uso de utensílios domésticos, promovendo uma redução dos picos através de uma solução de programação linear.

Ainda no contexto de manipulação do perfil do usuário, os autores em Lu et al. [2010] propõe ajustar de forma inteligente a temperatura de aparelhos de ar-condicionado, a fim de reduzir o consumo excessivo durante os momentos de pico. Em nosso trabalho optamos por não incorporar metodologias similares a estas últimas, pois consideramos que estratégias que visam alterar o perfil dos usuários não seria tão

atrativas para os mesmos. Em nosso modelo, a redução de pico é obtida por uma combinação inteligente de armazenamento de energia, coleta de energia solar e tirando vantagem de um plano de preços variáveis, mantendo o processo transparente para o usuário.

Um trabalho que também aborda o uso de energia renovável em domicílios [Mishra et al., 2013a] propõe uma combinação de produção de energia solar e armazenamento para reduzir as contas de eletricidade. Esta proposta simplesmente armazena a energia coletada para um futuro reuso em momentos de alto custo. *GreenPeaks* age de maneira diferente, na medida em que seus esforços são para homogeneizar o consumo, em vez de deslocar o consumo entre períodos de baixo e alto custo. Para o uso de painéis solares como produção de energia limpa em grande escala, é importante mencionar que, como apresentado por Mishra et al. [2013a], a rentabilidade da implantação do mesmo sofre forte influência por fatores como: localização, incentivos governamentais e subsídios.

SmartCharge [Mishra et al., 2012] é um exemplo de proposta que analisa o consumo instantâneo de residências e o preço instantâneo da energia no grid. Com base nisso ele deve tomar a decisão sobre comprar energia para satisfazer a demanda e ainda para carregar a bateria e armazenar energia barata, para ser reutilizada posteriormente quando o preço da mesma estiver alto. Ou então, utilizar a energia estocada para satisfazer a demanda, não comprando energia do grid (que pode estar com preço elevado em um dado momento). Uma desvantagem dessa proposta é uma consequência, de médio a longo prazo, da adoção de muitos usuários a esse método. Se muitos domicílios adotarem essa técnica, comprando energia em horários onde o preço é baixo (majoritariamente no período da noite), passará a existir um novo período de alta demanda para a produção de energia. Logo, quando escalado o número de clientes, após determinado tempo o antigo horário de baixa demanda se transformará em um momento de alta demanda, ou pico, ocasionando um aumento no custo da energia. Isso ocasionará um ciclo de altas e baixas de preço entre tais períodos.

Em uma tentativa de diminuir este efeito cíclico, podemos ver o funcionamento de *PeakCharge* [Mishra et al., 2013b]. Ele segue os mesmos princípios de *SmartCharge*, porém a decisão não é tomada apenas com base no custo da energia, mas também em outras variáveis, como a demanda atual da casa, e em uma penalidade aplicada no máximo pico alcançado pela residência. Desta maneira, o armazenamento de energia é utilizado visando a diminuição do custo, enquanto não proporciona a desvantagem de produzir um ciclo de altas e baixas no preço para a concessionária de energia. Mais detalhes sobre o funcionamento de *PeakCharge* serão explanados na seção 2.3.1, uma vez que ele é um dos modelos utilizados como baseline para este trabalho. Uma possível

melhoria para este método é justamente a incorporação de energia sustentável ao seu fluxo de execução.

Buscando alternativas que fazem uso de energia renovável e que pudessem ser incorporadas à nossa proposta, podemos destacar o *NetMetering* [Energysage, 2017], que já é consideravelmente difundido em áreas de instalações comerciais. Esta funcionalidade tem por objetivo alternar a fonte de energia elétrica entre o grid e a produção de energia limpa *on-site*. Em alguns casos também é oferecida a funcionalidade de venda do excedente de energia, em momentos em que a geração da mesma é superior à demanda.

Considerando a importância dos dois modelos anteriores (*NetMetering* e *Peak-Charge*), eles serão discutidos em mais detalhes a seguir.

Olhando mais para o cenário atual e os esforços recentes da área, em Shahin et al. [2017] foi desenvolvido um sistema de monitoramento completo em uma *Smart Home* real. Este sistema conta com uma fonte de energia solar, e com diversos dispositivos como: interruptores, sensores de gás, sensores de fluxo hídrico, tomadas, termômetros, sensores de movimento e de segurança. Todos sendo monitorados e sua informação transmitida em tempo real, via servidor web, além de também permitir o controle de certos dispositivos remotamente.

Continuando com a ideia de apresentar os esforços atuais nas pesquisas com *Smart Homes*, outro trabalho mais recente [Abdul-Rahaim & Al-Muraab, 2018] também se concentrou em criar um sistema de controle e de automação de eletrodomésticos de uma *Smart Home*. Esse sistema tem a capacidade de detecção de movimentos, assim como de incêndios e disparos de alarmes para a conscientização dos eventos indesejados, além de um monitoramento remoto de todos os eventos.

No contexto de monitoramento de *Smart Cities*, existe um crescente esforço nas pesquisas com foco nos aspectos ambientais e de sustentabilidade. Como podemos ver em Shah & Mishra [2016], foi implementado um sistema de monitoramento de um ambiente de *IoT* (*Internet of Things*). As variáveis monitoradas por sensores foram: temperatura, umidade e emissão de CO₂. Os detalhes sobre os sensores utilizados são descritos no trabalho, e a performance do sistema é discutida. Ademais, Elma et al. [2013] detalha um projeto de *Smart Home* implementado em *Yıldız Technical University (YTU), Istanbul, Turkey*, fazendo uso de energia renovável, e então realiza uma análise do impacto da redução de emissão de carbono gerada pelo melhor gerenciamento da energia e sua integração com o *Smart Grid*.

Em uma tentativa de mitigar problemas relacionados ao funcionamento de dispositivos e eletrodomésticos, quando estes dependem dos recursos gerenciados automaticamente por uma *Smart Home*, Piloni et al. [2018] propuseram uma lógica de

escalonamento de recursos baseado no feedback de usuários de um *Smart Home*. Após a análise do comportamento de diversos perfis de usuários, os escalonadores de recursos visando redução de custo e alocação de fonte de energia, *QoE-aware*, são ativados para promover uma redução do custo e melhor experiência dos usuários. Seus experimentos demonstram uma melhoria na satisfação dos usuários, juntamente com uma redução no custo total para o mesmo.

Tomando um cenário mais amplo, [Wu et al., 2016] considera um usuário com uma *Smart Home* com armazenamento de energia local e painéis fotovoltaicos, e um veículo elétrico (*PEV - plug-in electric vehicle*) também com seu armazenamento de energia próprio. Neste trabalho é analisado um cenário com esses dois componentes, e o impacto causado para o *Smart Grid* e para o próprio usuário. Foi desenvolvido uma estratégia estocástica de gerenciamento de energia, juntamente com um preditor de demanda para a *Smart Home* e um modelo de mobilidade para o *PEV*, utilizando Cadeia de Markov. Também foi utilizado um modelo de tarifação *Time-of-Use*, similar ao utilizado nos experimentos desse trabalho de mestrado. Esse trabalho tem uma contribuição interessante de integração da geração de energia sustentável com outros elementos modernos além da *Smart Home* (nesse caso, o *PEV*), e uma análise de seu impacto.

Como já discutido nesta seção, vemos uma tendência de evolução dos *Smart Grids* de cada vez depender mais de fontes renováveis, seja solar, eólica, nuclear, etc. Uma pesquisa recente [Rehmani et al., 2018] realiza uma revisão dos recentes esforços da integração de fontes renováveis diversas com o *Smart Grid*, levando em consideração o suporte para a rede de comunicação do mesmo. Por fim, o trabalho é concluído com uma discussão sobre a direção que tais campos de pesquisa tomarão para o futuro.

Ainda considerando a interação de *Smart Homes* e veículos elétricos (*PEV - plug-in electric vehicle*), e seu impacto em um *Smart Grid*, podemos destacar o estudo realizado por Ahadi et al. [2018]. Nele, foi adotado uma estratégia estocástica de um design para uma estação de abastecimento de *PEV* através de turbinas eólicas e painéis solares. No trabalho, foram utilizados dados reais de estações de abastecimento de *PEV* da Korea, e calculado os custos para uma instalação real do modelo, considerando as demandas coletadas.

Ainda neste ano, Yang et al. [2019] realizou um estudo de um sistema híbrido de *micro-grid* sustentável, implementado no trabalho, e contando com turbinas eólicas e um sistema de armazenamento de energia. Visando a redução do custo baseado na demanda do *micro-grid*, um algoritmo modelado com de enxame de partículas objetiva minimizar o custo anual da implantação e utilização do sistema, custo de carga/descarga flexível de energia para os usuários, e problemas relacionados a eficiência de

energia renovável, após a geração *on-site*.

2.3.1 PeakCharge

Inicialmente, é interessante ressaltar que a proposta PeakCharge foi desenvolvida considerando os casos base onde os benefícios do uso de baterias para estoque de energia vinham da compra e armazenamento da mesma, nos horários de baixo custo de tarifação. Assim, a energia armazenada seria reaproveitada posteriormente em momentos de alto custo (lembrando que, para estes casos, o modelo de tarifação é variado, podendo ser alto ou baixo em diferentes momentos do dia, baseado na demanda). Desta maneira, poder-se-ia tirar vantagem dos menores preços ofertados pela concessionárias, armazenando energia elétrica barata nas baterias.

Segundo [Mishra et al., 2013b], PeakCharge leva em consideração a premissa de uma penalização por pico máximo como uma maneira efetiva de diminuir uma alta demanda concentrada em determinados momentos do dia. Isso se dá pois, considerando o consumo agregado onde diversas casas e estabelecimentos estão fazendo uso do mesmo grid, o consumo corresponderá ao montante agregado de todos os clientes. Então, uma maior necessidade de produção e distribuição de energia, do ponto de vista da concessionária, torna-se um grande desafio para a mesma, dificultando seu trabalho e aumentando o preço da energia para o usuário final.

Desta maneira, apenas o custo mais elevado da eletricidade em certos momentos do dia muitas vezes não constitui motivação suficiente para que os clientes distribuam melhor seu consumo. Outro cenário é aquele onde os clientes podem acabar passando a carregar suas baterias em capacidade máxima nos horários de baixo custo, gerando o que chamamos de *peak-rebound*, ou seja, um novo momento de pico. Tal situação continua produzindo um pico de energia para produção e distribuição [Irwin et al., 2017]. Assim como proposto pelo mesmo autor, uma penalização proporcional ao pico máximo alcançado pelo usuário, além do próprio preço da energia, aumenta o incentivo para que ele reduza o consumo da mesma, independente do horário, induzindo uma homogeneização do consumo ao longo do dia. Logo, isso acaba por ser um benefício para as concessionárias e, conseqüentemente, diminui o preço para o usuário final.

PeakCharge é uma abordagem heurística usando quatro casos simples, conforme será descrito nos parágrafos seguintes, com base no preço momentâneo da eletricidade e na demanda do estabelecimento. Para o funcionamento de PeakCharge, o preço geralmente é considerada binário, ou seja, ele será apenas baixo ou alto. Para casos reais onde o preço pode possuir diversos valores, utiliza-se a média entre eles, para decidir quando o preço está alto, e quando está baixo. Para a demanda, a mesma

lógica é aplicada. Uma vez que o objetivo do algoritmo é tentar manter sempre o consumo médio, a média será considerada na avaliação.

Primeiramente, temos que entender um princípio básico de *PeakCharge*. Ele tenta sempre avaliar se o benefício de carregar a bateria de maneira gulosa (em sua taxa máxima de carga) valerá a pena, pois tem-se, sempre, que considerar o custo da penalização, e perdas na conversão e armazenamento, citados anteriormente. Logo, para escolher se a bateria será carregada de maneira gulosa ou respeitando a média do consumo diário do estabelecimento, os autores propuseram a seguinte equação para ser avaliada:

$$X_{max} \times e_{loss} \times C_{high} \times T - X_{max} \times C_{low} \times T > X_{max} \times P \quad (2.1)$$

Onde C_{high} é o custo da energia durante o momento de alto custo (U\$/kWh); C_{low} é o custo da energia durante o momento de baixo custo (U\$/kWh); T é o período de tempo em que o preço está baixo (horas em um dia); P é o custo da penalização pelo maior pico de potência consumido no dia (kW); e_{loss} é a porcentagem de eficiência das baterias dadas as conversões de energia necessárias (na prática, girando em torno de 80%); e X_{max} é a taxa de carregamento máxima suportada pelas baterias.

Na equação 2.1, avalia-se, ao lado esquerdo, se as vantagens de carregar à taxa máxima são maiores do que os custos, representados pelo lado direito. Se esta equação for válida, a bateria será carregada de maneira gulosa no decorrer do dia. Se não, ele assumirá o comportamento *peak-centric*, onde a bateria só será carregada respeitando a média da demanda (o que será explicado a seguir).

Após a decisão da taxa de carga da bateria, *PeakCharge* vai avaliar a fonte e destino da energia a cada momento do dia. Para, por exemplo, saber se irá comprar energia do *Smart Grid* e abastecer a bateria, ou se irá retirar energia da bateria para satisfazer a demanda da casa, e assim por diante. Para isto, de maneira simplificada, *PeakCharge* possui as quatro condições descritas abaixo, que será avaliadas a cada instante. Lembrando que a demanda da casa será considerada binária, sendo alta (acima da média do consumo diário) ou baixa (abaixo da média do consumo diário). O mesmo raciocínio vale para o preço da compra de energia, que será alto (acima da média dos diversos preços possíveis existentes no dia) ou baixo (abaixo da média dos diversos preços possíveis existentes no dia).

- Se o preço da energia for baixo e a demanda estiver abaixo da média, a bateria será carregada na sua capacidade máxima se 2.1 for mantida. Caso contrário, será carregada apenas o suficiente para sustentar a demanda média diária.

- Se o preço da energia for baixo e a demanda estiver acima da média, a bateria será carregada na sua capacidade máxima se 2.1 valer. Caso contrário, será descarregada apenas o suficiente para sustentar a demanda média diária.
- Se o preço da energia for alto e a demanda estiver abaixo da média, a bateria será descarregada na sua capacidade máxima (limitado pela demanda) se 2.1 se mantiver. Caso contrário, não faz nada.
- Se o preço da energia for alto e a demanda estiver acima da média, a bateria será descarregada na sua capacidade máxima (limitada pela demanda) se 2.1 se mantiver. Caso contrário, ela será descarregada apenas o suficiente para sustentar a demanda média diária.

2.3.2 NetMetering

Como mencionado anteriormente, juntamente com a lógica de *PeakCharge*, o uso energia renovável também foi considerado neste trabalho. Um modelo amplamente conhecido nesse contexto é a abordagem NetMetering [Energysage, 2017].

NetMetering é uma solução de incentivo a energia renovável a ser aplicada em estabelecimentos que possuem alguma forma de produção da mesma. <https://www.overleaf.com/project/5c3a65700b0d7a788f76b005?ws=fallbackNele>, o fluxo de energia necessária para o estabelecimento, juntamente com a quantidade sendo produzida, são gerenciadas de forma a analisar se a energia produzida será, ou não, suficiente para suprir a demanda. Portanto, se for produzido mais energia que a quantidade necessária para o estabelecimento em um determinado momento, o excesso de energia será redirecionado de volta para o *Smart Grid*, acumulando-se como crédito para compras futuras. Em caso de produção de energia insuficiente para a demanda do momento, o restante pode ser extraído do grid normalmente [Wikipedia, 2017].

Desta maneira, é possível evitar perdas, uma vez que as condições climáticas não são sincronizadas com a demanda de energia. Comumente a produção de energia fotovoltaica atinge seu máximo após as 12:00, como podemos ver na figura 2.2, quando o sol apresenta sua maior intensidade. Porém, a maior demanda das casas e estabelecimentos está nos períodos do início do dia e no final da tarde, por volta das 7:00 e das 18:00, respectivamente [Torriti, 2017], como podemos ver na figura 2.3.

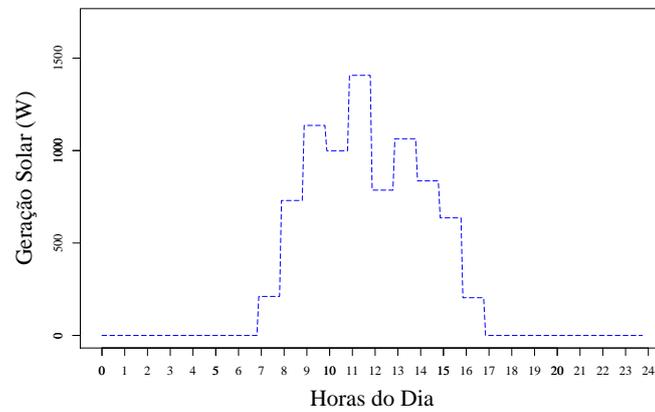


Figura 2.2: Geração de energia ao longo do dia, retirada do dataset Smart [2018].

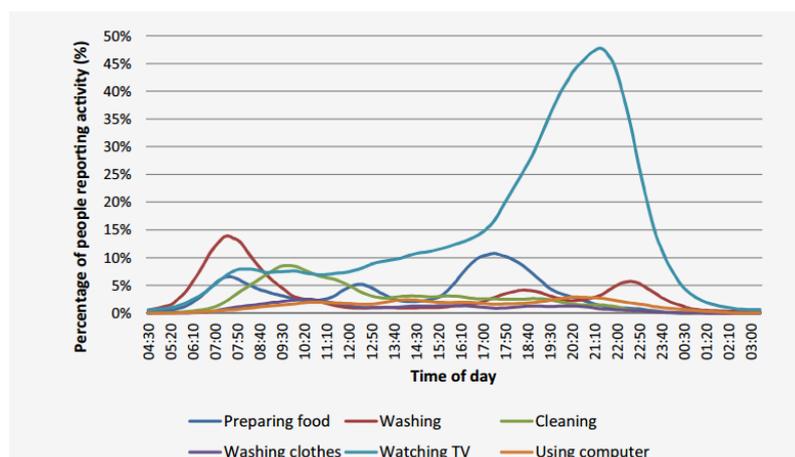


Figura 2.3: Consumo de energia ao longo do dia, segundo *Office for National Statistics* (Fonte: Torriti [2017]).

Capítulo 3

Caracterização dos Dados de Entrada

Neste capítulo, discutimos as fontes de dados e parâmetros de modelagem utilizados como entrada para as análises apresentadas posteriormente. Nosso modelo é alimentado com dados de consumo de potência de instalações reais, que já serão detalhados na seção 3.1. Juntamente com a demanda, também é necessário dados sobre o modelo de fontes de geração de energia, uma vez que o uso de energia limpa é um diferencial que incorporamos em *GreenPeaks*. Uma vez que existem diferentes modelos de tarifação aplicados no mercado, e estes podem variar significativamente um do outro, também é necessário fornecer um modelo de preço. Como diferentes tipos de baterias podem ter impactos distintos durante o processo de conversão de energia, um arquivo contendo as características da bateria (capacidade, eficiência e taxa máxima de carga/descarga) também deve ser informado. E, por fim, a seleção de qual método se deseja-se utilizar na simulação (*PeakCharge*, *NetMetering*, *Simples* ou *GreenPeaks*), pois nosso algoritmo tem opção de simular o comportamento destas várias abordagens afim de podermos comparar seus benefícios.

3.1 Caracterização de Carga Domiciliar

Para nossa análise, utilizamos o repositório *Smart**, uma base de dados coletada a partir de um conjunto de apartamentos e casas, em que foi instrumentado sensores para coleta dos perfis de consumo de energia dos mesmos [Smart, 2018; Barker et al., 2012a]. A base possui dados de 114 apartamentos, para os períodos de 2014 à 2016, e de três outras casas maiores, todas localizadas em Massachusetts.

Os apartamentos tiveram seu consumo total coletado com granularidade de um segundo. Além do consumo total, os apartamentos também possuem diversas outras medidas como: temperatura, umidade, visibilidade, pressão, velocidade do vento, co-

bertura de nuvens, intensidade de precipitação, probabilidade de precipitação e ponto de condensação da água. Já com relação às três casas, elas também possuem o consumo total a cada segundo do dia, juntamente com o monitoramento de todos os circuitos e tomadas da casa. Também foi monitorado a geração de energia solar em um sistema *on-site* de painéis fotovoltaicos, juntamente com dados climáticos de temperatura e umidade dentro das residências. Por fim, as três casas também contam com um mapeamento binário de eventos como: interruptores de luz (*on/off*), aquecedor e ar condicionado (*on/off*), abrir e fechar das portas (*on/off*) e sensores de movimento.

Para o funcionamento do nosso simulador é necessário apenas o consumo total de energia, e foram utilizados os dados de consumo dos 114 apartamentos, durante a primeira semana de fevereiro de 2016. A figura 3.1 ilustra o consumo total de uma unidade do conjunto de apartamentos em um dia representativo do período. Como podemos ver, para esse apartamento os maiores picos de demanda são alcançados nos horários da manhã/almoço e no final da tarde.

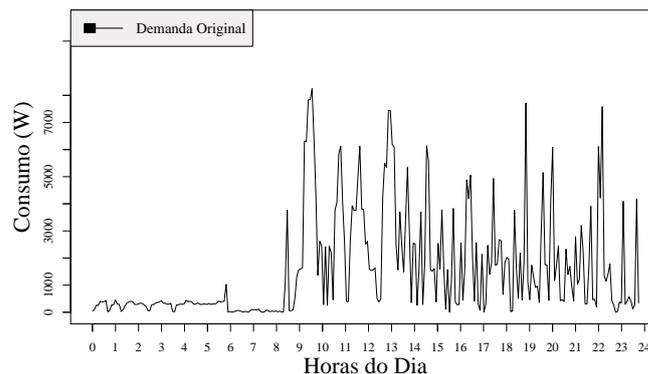


Figura 3.1: Demanda de um dia representativo do dataset utilizado.

O algoritmo aceita um arquivo contendo dados de demanda que consiste na quantidade de potência gasta (em Watts) em cada minuto do dia, uma linha para cada minuto, contendo a potência consumida pelo estabelecimento naquele instante.

3.2 Energia Renovável

Juntamente com os dados de consumo, a coleta de energia fotovoltaica também foi medida na mesma região geográfica e para o mesmo período de tempo [Smart, 2018; Barker et al., 2012a]. Nestes conjuntos de dados, existe uma vasta gama de dados de geração de energia limpa, espaçadas ao longo dos meses, tanto através de turbinas

eólicas, quanto de painéis solares. Para os experimentos deste trabalho, foram utilizados apenas os dados de energia solar, uma vez que a fonte da energia é indiferente, contanto que o formato do dado seja compatível com o algoritmo. O nosso modelo aceita um arquivo contendo dados de energia renovável que consista da quantidade de energia gerada (em Wh) em cada minuto do dia. Ou seja, uma linha para cada minuto, contendo a energia solar gerada correspondente.

Os valores de coleta de energia solar utilizados foram considerados baixos, provavelmente devido à época do ano, inverno nos Estados Unidos. O trabalho sobre *PeakCharge* sugere que valores de geração da ordem de 20% do consumo de uma residência são comuns e foram observados em outras épocas do ano no conjunto de dados utilizado. Assim, nós escalamos os dados de geração de energia solar para nossos experimentos de tal forma que a geração correspondesse à 20% da média de demanda diária dos apartamentos.

3.3 Configuração da Bateria

Os valores padrões dos parâmetros da bateria utilizado nas simulações deste trabalho são semelhante aos utilizados no trabalho de base [Mishra et al., 2013b], para manter consistência na comparação de resultados. Os autores demonstram que uma bateria com capacidade de 50% do consumo médio diário já é suficiente para maximizar a redução dos picos para estabelecimentos individuais. Então, a capacidade da bateria considerada, chamada aqui de C , é de 50% do consumo médio diário das residências, igualmente utilizada no trabalho de base. Logo, para cada dia de experimento executado, um valor diferente de capacidade de bateria foi considerado. A eficiência da bateria, taxa de conversão para carga/descarga, é de 80%, valor encontrado em baterias reais para este fim. A taxa de carregamento máxima da bateria é $C/4$ por hora, ou seja, a bateria se carrega totalmente em 4 horas.

O motivo da escolha destes parâmetros foi justamente para o alinhamento das variáveis com o trabalho base, uma vez que a ideia era estender *PeakCharge* adicionando energia renovável e comparar os resultados.

3.4 Modelo de Tarifação Time Of Use

Os experimentos realizados com o modelo *PeakCharge* utilizaram o modelo *Time of Use* (TOU) [Datchanamorthy et al., 2011], apresentado na figura 3.2. Se trata de um modelo de preço aplicado por diversas concessionárias de energia pelo mundo, onde

o preço é variado no decorrer do dia. Isto se dá pelo fato do custo da geração e distribuição da energia elétrica não crescer apenas diretamente com a quantidade de demandada agregada, sendo esperado que o custo seja maior em horários em que as concessionárias têm maior demanda do *Smart Grid*.

Este modelo já é praticado por diversas companhias no Estados Unidos, tanto para uso residencial como comercial, contando com uma alta gama de pesquisas sobre seus efeitos desde de décadas atrás [J. Aigner & Hirschberg, 1985]. Atualmente ainda vemos esforços na avaliação desse modelo, como mostrado em Harding et al. [2019], onde é analisado os efeitos da tarifação dinâmica na ocorrência do efeito de *peak-rebound*.

O modelo de preço utilizado é similar àquele utilizado, por exemplo, pelo órgão regulador do uso de energia e gás de Ontario, *Ontario Energy Board* [OEB, 2017]. Como já mencionado na seção 2, o arquivo de geração de energia solar utilizado (TOU) divide o dia em três intervalos com tarifas distintas, on-peak (11.8 *cents*/kWh), mid-peak (9.9 *cents*/kWh) e off-peak (6.3 *cents*/kWh). Modelos de tarifação similares podem também possuir diversos preços variados ao longo do dia, não restringindo a apenas três. Porém, o funcionamento de *PeakCharge* e *GreenPeaks* faz uma separação em apenas dois períodos, de alta demanda e baixa demanda, como também já mencionado anteriormente. Logo, classificamos os preços acima da média diária como altos e os demais como baixos para podermos, então, aplicar a equação (2.1).

O nosso modelo aceita um arquivo contendo os dados de tarifação (em *cents*/kWh) em cada minuto do dia. Ou seja, uma linha para cada minuto, contendo o preço, em centavos, da energia a ser comprada do *Smart Grid*. Podemos ver na figura 3.2 como a precificação varia ao decorrer do dia.

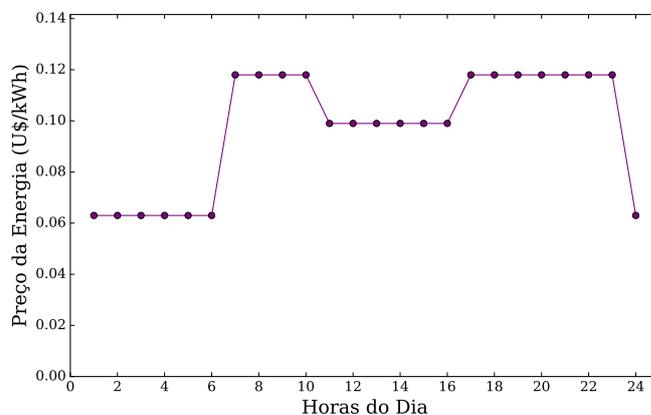


Figura 3.2: Modelo de tarifação TOU.

3.5 Modelo de Tarificação - Tarifa Branca da CEMIG

Uma vez que o intuito deste trabalho foi o de propor uma nova abordagem para comparar com os resultados de *PeakCharge*, todos os dados utilizados foram os mesmos que o do trabalho de base, coletados nos Estados Unidos. Porém, em uma tentativa de validar o nosso modelo utilizando um conjunto de dados aplicado ao Brasil, fomos em busca de alguma base análoga disponível para as empresas produtoras e distribuidoras em nosso país. Infelizmente, não foi possível encontrar dados nacionais de demanda e geração de energia para alimentar nosso algoritmo. Entretanto, foi possível utilizar um modelo de tarifação aplicado pela CEMIG [2018], que possui características semelhantes às que *PeakCharge* espera como entrada.

Tal modelo foi disponibilizado apenas neste ano, 2018, e para um perfil muito específico de usuários: aqueles com média mensal de consumo superior a 500 kWh Tarifa Branca [2018]. Em 2019, usuários com média mensal de 250 kWh também passarão a ser contemplados com esta oferta. A previsão é de que o usuário comum, sem restrições de demanda média mensal, só tenha acesso a essa opção a partir de 2020.

A tarifa branca também segrega o dia em três intervalos com tarifações distintas, ponta (1.136 R\$/kWh), intermediário (0.73 R\$/kWh) e fora de ponta (0.479 R\$/kWh). Porém, como já mencionado, *GreenPeaks* também faz a classificação dos preços em duas categorias: alto custo e baixo custo. A figura 3.3 esboça o modelo de tarifação branca utilizado pela CEMIG.

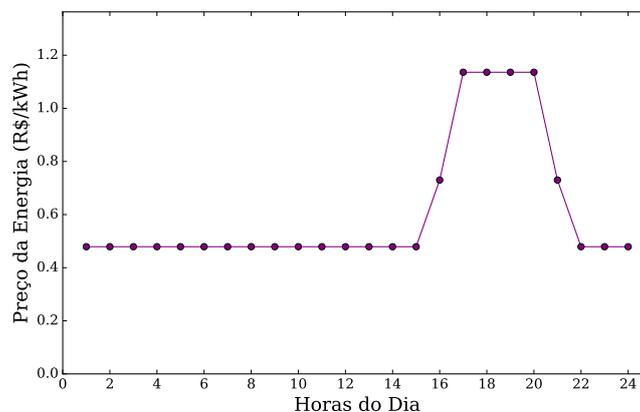


Figura 3.3: Modelo de tarifação branca utilizado pela CEMIG.

3.6 Penalização por Pico Máximo

Como argumentado por Mishra et al. [2013b], para alcançar uma melhor homogeneização dos picos ao longo do dia seria necessário uma remodelagem dos planos de preços e algoritmos de integração. Portanto, para mantermos a consistência com o que foi feito em [Mishra et al., 2013b], a na avaliação de *GreenPeaks* também aplicamos um plano híbrido de preços, contando com o fator penalização por pico máximo ocorrido no dia. A penalização se justifica pelo fato de que apenas o preço da energia sendo maior nos horários de pico, muitas vezes não constituir motivação suficiente para os clientes abaixarem o seu consumo nos determinados horários, como mencionado no trabalho de base de *PeakCharge*. O que pode ser comprovado pelo fato de ainda existirem grandes picos em tais momentos, mesmo possuindo maior tarifação. A existência dessa maior demanda, causados por altos picos distribuídos pelo *Smart Grid*, incorre em grandes desafios para as companhia geradoras e distribuidoras de energia, encarecendo, então, o preço da energia para o usuário final.

Então, em nosso modelo os clientes são cobrados tanto pelo consumo total de energia ($\$/\text{kWh}$) gasto no dia, quanto por uma penalização do pico de potência mais alto alcançado ($\$/\text{kW}$). Nós adotamos a penalização, baseada no maior pico absoluto, com base no estudo apresentado por Irwin et al. [2017]. A penalidade adotada foi de US $\$2,0/\text{kW}$, logo o preço final gasto pelo usuário, em um determinado dia, seria o valor do pico mais alto do dia, em kW, multiplicado pelo valor da penalização, somado aos valores normais da tarifação. O motivo principal pela escolha de tal valor é o de manter a consistência com trabalhos anteriores, como [Mishra et al., 2013b], uma vez que comparamos seus resultados com os aqui apresentados.

Capítulo 4

Modelo Proposto: GreenPeaks

Nesta seção abordaremos as soluções propostas para o problema explorado neste trabalho. Porém, antes de nos aprofundarmos na modelagem, faz-se necessária uma breve descrição dos fluxos de energia, monitoramento e controle da arquitetura proposta, os quais os algoritmos utilizarão.

A figura 4.1 descreve a arquitetura utilizada pelos dois algoritmos propostos neste trabalho, incluindo os fluxos de controle e de energia. Ela nos permite entender a origem e destino da energia desde a sua compra no *Smart Grid* até o estoque e reuso, seja pela casa ou pela bateria, e contando também com a venda do excesso de volta para o *Smart Grid*. Um controlador de descarga limita programaticamente a quantidade de energia extraída da bateria para satisfazer a demanda da casa. Sem tal controle, a taxa de descarga seria ditada pelo próprio consumo instantâneo do estabelecimento, e não respeitando a lógica do algoritmo. Um servidor *gateway* monitora continuamente: 1) a demanda instantânea do estabelecimento, através do monitor de consumo; 2) o estado de carga atual na bateria; 3) o preço instantâneo da eletricidade, via internet (lembrando que este pode ser variável em múltiplas faixas durante o dia); 4) a coleta de energia solar utilizando transdutores de corrente. Baseado neste monitoramento, o papel do servidor será o de gerenciar qual a fração de energia gerada será redirecionada para o consumo instantâneo da residência e qual fração será utilizada para abastecer a bateria. Adicionalmente, ele também é incumbido de decidir qual a parcela da demanda instantânea do estabelecimento será retirada da bateria e qual será comprada do *Smart Grid*. O *Bidirectional Panel Meter* é o painel padrão utilizado na arquitetura de *NetMetering*, que tem por objetivo realizar a medição de tensão e a corrente instantâneas. Seguindo o funcionamento deste último modelo citado, qualquer energia restante, após satisfazer a demanda e carregar a bateria, será vendida novamente para o *Smart Grid*, convertendo em créditos para o usuário.

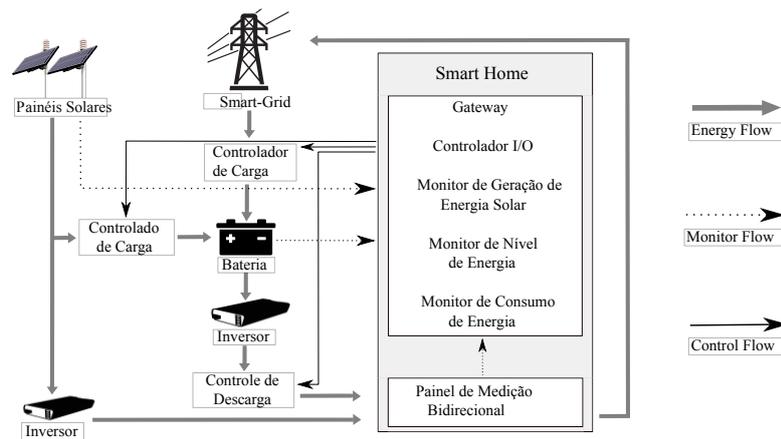


Figura 4.1: Arquitetura de *GreenPeaks*

Considerando as tecnologias presentes no nosso modelo, deixamos aqui uma abordagem dos hardwares atuais disponíveis no mercado, e que são usados em implementações do mundo real de *SmartHomes*. O preço de uma bateria para a utilização em implantações de *SmartHomes* é calculado por sua capacidade de armazenamento, e uma média de preços praticados no mercado atualmente é de U\$ 500,00 por KWh [Clean Energy Reviews, 2018]. Na base de dados utilizada em nossos experimentos, apesar da capacidade das baterias poder variar, um valor médio encontrado para o armazenamento da bateria gira em torno de 10 KWh, totalizando um valor de U\$ 5000,00 para a sua implantação. Outro hardware necessário para a conversão da energia solar em energia elétrica útil é o inversor, equipamento que tem um custo aproximado de U\$ 1.300.

Como mencionado na descrição da arquitetura de *GreenPeaks*, para a produção de energia solar é necessário o uso de painéis fotovoltaicos. Segundo Solar Installation Cost [2018], uma estimativa conservadora da capacidade de produção de energia solar através destes painéis, é de 10 Watts por *square feet* (aproximadamente 0,1 metros quadrados). De acordo com este compilado, levando em consideração uma média de disponibilidade de luz solar e a eficiência dos painéis (cerca de 12%), entre 400 a 800 *square feet* (37 a 74 metros quadrados) são suficientes para o abastecimento de uma casa com consumo médio nos Estados Unidos. Logo, uma instalação deste porte pode variar em torno de U\$ 25,000 a U\$ 35,000.

Um fator importante de ser levado em consideração, e que é citado em Solar Installation Cost [2018], é o fato de muitas companhias nos Estados Unidos promoverem um subsídio de até 50% do valor da instalação de todo o sistema. Ainda mais, companhias provedoras dessa tecnologia, como: *First Solar* [FirstSolar, 2018] e *Nanosolar* [NanoSolar, 2018] discutem uma queda agressiva no preço dos painéis nos

próximos dois anos, chegando a um custo de U\$ 10,000, para um sistema de mesmo porte do aqui discutido.

4.1 Modelo *Simples*

Como o foco durante o desenvolvimento deste trabalho era o de tentar tirar proveito dos benefícios de *PeakCharge* adicionando o uso de energia renovável, o primeiro modelo proposto objetivava apenas criar uma lógica simples para adicionar a energia limpa coletada ao funcionamento padrão de *PeakCharge*. Nele, a quantidade de energia renovável produzida é apenas encaminhada para satisfazer a demanda instantânea do estabelecimento, não tendo qualquer parcela armazenada na bateria. Lembrando que, como o funcionamento padrão de *PeakCharge* também está presente, a bateria pode ser usada por este, mas com energia somente comprada da concessionária. Uma vez que *NetMetering* já é uma solução real para estabelecimentos com produção de energia limpa, também implementamos a funcionalidade de venda do excedente de volta para o grid, caso possível. O modelo *Simples* serve, assim, como uma abordagem mais simples a ser utilizada como base, que combina a energia solar coletada, bateria local e *PeakCharge* para reduzir os picos de consumo de energia.

4.2 GreenPeaks

Após as etapas intermediárias de experimentação com o modelo *Simples*, percebemos que haviam desvantagens ao utilizar a energia renovável da maneira descrita em 4.1. Não seria interessante sempre utilizar a energia renovável para satisfazer a demanda da casa, uma vez que o preço instantâneo da energia externa poderia estar baixo, sendo mais proveitoso comprá-la. O oposto também é válido, pois nos horários de maiores picos, por volta de 20:00-22:00 segundo a figura 2.3, a energia tem preço elevado, porém não há uma fonte de energia solar para auxiliar na homogeneização do consumo. Com este cenário em vista, tirar proveito da energia limpa para também abastecer a bateria pareceu-nos algo interessante, uma vez que ela poderia ser armazenada e utilizada posteriormente, de maneira mais inteligente, com a lógica de *PeakCharge*.

Juntamente com a variação mencionada no parágrafo anterior, um outro detalhe nos chamou a atenção para ser agregado ao modelo *Simples*. Como descrito na seção 2.3.1, o benefício desejado no projeto era baixar o preço da energia, tanto para o usuário final, quanto para a sua produção e distribuição pelas concessionárias. Logo, a busca pela homogeneização do consumo agregado é um fator importante. Dito isto, a

intenção de buscar sempre uma média do consumo nos guiou a propor uma melhoria no uso das fontes renováveis para que a energia advinda dessas fontes, assim como a advinda da bateria, seguissem a mesma lógica de *PeakCharge* buscando, assim, sempre a média do consumo diário original.

Um efeito colateral bem conhecido dos modelos que compram energia no baixo custo para reutilizá-las nos momentos de alto custo, é o efeito de *peak-rebound*, como brevemente mencionado na seção 2.3.1 [Irwin et al., 2017]. Entre outros fatores, o alto custo de produção e distribuição de energia pelas concessionárias se dá pela necessidade de satisfazer os grandes picos de energia de todo o *Smart Grid*, como ilustra a figura 2.1. Tendo isso em mente, em um momento de baixo custo de energia (costumeiramente à noite), todos os integrantes do *Smart Grid* passarão a comprar sua energia de forma gulosa, e isso acarretará em desafios para a concessionárias em satisfazer a demanda neste horário. Consequentemente, a concessionárias passará a cobrar mais caro pela energia nestes momentos, e o antigo momento de baixo custo se tornará em um período de alto custo, e vice-versa (*peak-rebound*).

Tendo em vista o problema mencionado no parágrafo anterior, a lógica de buscar sempre o consumo médio diário, adotada por *GreenPeaks*, tem justamente o objetivo de mitigar o efeito *peak-rebound*. Em um *Smart Grid*, ao escalar o número de usuários de *GreenPeaks*, todos estarão sempre buscando um padrão de consumo médio, evitando picos desproporcionais ao longo do dia, e fugindo de uma variação de preços causadas pelos picos agregados no *Smart Grid*.

Adentrando agora no funcionamento de *GreenPeaks*, o modelo usa o consumo médio de energia do dia para decidir se a energia solar coletada será usada para satisfazer diretamente a demanda da casa ou alimentar a bateria. Se a demanda instantânea do estabelecimento estiver acima da média, a energia produzida é usada para reduzir tal demanda à média; qualquer montante residual é então armazenado na bateria. Em contrapartida, se a demanda estiver abaixo da média, a energia coletada é usada primeiro para carregar a bateria. No caso da mesma ficar completamente carregada, a energia residual coletada é usada para satisfazer o restante da demanda do estabelecimento (que, neste caso, já estaria na média ou abaixo dela). Nos dois cenários, depois de satisfazer a demanda da casa e o armazenamento completo da bateria, qualquer excedente de energia extraída é vendido de volta para a grid, como já proposto por *NetMetering*. Os detalhes do algoritmo *GreenPeaks* são apresentados em pseudocódigo no Algoritmo 1.

Algoritmo revisado.

Algorithm 1 *GreenPeaks*

```
1: for cada período de tempo do
2:   if demanda  $\geq$  média then
3:     if (energia solar coletada  $\geq$  demanda - média ) then
4:       nivela demanda à média
5:       if (energia solar disponível) then
6:         alimenta bateria ao seu máximo
7:         utiliza energia solar restante para satisfazer demanda da casa
8:       end if
9:     else
10:      utiliza toda energia solar para satisfazer a demanda da casa
11:    end if
12:  else
13:    carrega bateria ao máximo possível
14:    utiliza energia solar para satisfazer demanda da casa
15:  end if
16:  aplica funcionamento padrão de PeakCharge
17:  if (ainda existir energia solar restante) then
18:    vende de volta para o grid
19:  end if
20: end for
```

A análise do comportamento do modelo será apresentada no capítulo seguinte.

Capítulo 5

Avaliação

Neste capítulo apresentamos os resultados da análise do modelo de gerência *GreenPeaks* em comparação com os demais modelos abordados: *NetMetering* [Energysage, 2017], já consagrada na literatura e utilizada em aplicações reais, e *PeakCharge*, uma vez que *GreenPeaks* é sua extensão com o adicional do uso de energia limpa e revenda de excedentes.

Como detalhado no capítulo 3, os dados referentes ao modelo de tarifação provêm de duas fontes diferentes: O dataset e modelo de preço utilizado no trabalho predecessor, aplicados nos Estados Unidos da América; e o modelo de tarifação branca utilizado, ainda em pequenas proporções, pela CEMIG, no estado de Minas Gerais. Logo, dividimos os experimentos em duas seções, para analisarmos separadamente os resultados com modelos de preço distintos.

Para nossa análise, aplicamos os algoritmos que implementam cada modelo a todos os apartamentos do dataset, para cada dia do período considerado. Com isso temos uma análise do comportamento diário de cada modelo. A seção 5.1 apresenta uma análise do comportamento de cada modelo, para validar o comportamento do simulador e para ilustrar os detalhes de cada modelo. Em seguida, as seções 5.2 e 5.3 apresentam os resultados agregados para o conjunto de apartamentos durante todo o período considerado, separados pelos dois modelos de precificação obtidos. Desta maneira conseguimos analisar os benefícios encontrados para a concessionária, que tem por objetivo gerenciar todo o *Smart Grid* e sua demanda total compartilhada com todos os clientes.

Outro fator a ser mencionado é a capacidade da bateria utilizada em cada apartamento nos experimentos. Com exceção das figuras que avaliam, especificamente, o impacto da variação da capacidade de armazenamento, as baterias foram utilizadas sempre com o valor de 50% do consumo de energia diária. O motivo desta decisão

é para manter compatibilidade com os valores utilizados no trabalho de base, como melhor explicado na seção 3.3. O mesmo motivo se aplica para a penalização por pico máximo, que já foi descrito na seção 3.6

5.1 Avaliação dos modelos considerados

Para a análise a seguir, os modelos discutidos foram individualmente implementados no sistema e avaliados com a base de dados utilizada. A seguir apresentamos um resultado para cada modelo, com a exceção do modelo simples.

5.1.1 NetMetering

A figura 5.1 esboça o resultado da aplicação de *NetMetering* utilizando dados de um dia representativo do dataset Smart [2018]. Como descrito na seção 2.3.2, *NetMetering* irá utilizar a energia solar produzida no momento para suprir a demanda da casa, e isso é ilustrado, na figura 5.1, pelo consumo final reduzido (linha pontilhada verde) entre os horários aproximados de 8:00 e 15:00. Neste intervalo a energia produzida foi capaz de reduzir parcialmente o pico do consumo original da casa, o que é evidenciado pelo consumo após utilizar *NetMetering* que esta levemente inferior a demanda original (linha sólida preta). Obviamente, *NetMetering* apenas promove benefício nestes horários pois são os momentos de intensidade solar e, conseqüentemente, produção de energia solar. Nos demais intervalos a geração de energia não foi suficiente para satisfazer, mesmo que parcialmente, a demanda da casa e as linhas de *NetMetering* e demanda original se sobrepõem.

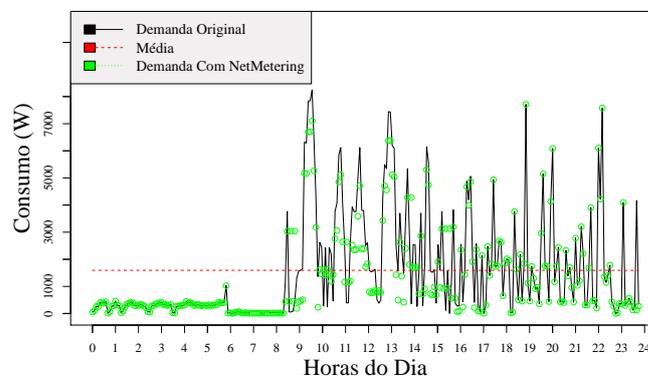


Figura 5.1: Consumo de um dia representativo com a aplicação de NetMetering

5.1.2 PeakCharge

Neste trabalho implementamos o modelo *PeakCharge* exatamente como descrito na seção 2.3.1. A figura 5.2 esboça o comportamento do modelo com a demanda do mesmo dia representativo utilizado em 5.1.1, segundo o modelo de tarifação ToU (seção 3.4). Podemos ver que entre 00:00 e 6:00, como a demanda está abaixo da média diária (linha preta abaixo da linha pontilhada vermelha) e o preço da energia está baixo, *PeakCharge* compra mais energia do *Smart Grid* que a demanda exige para poder, assim, abastecer a bateria e armazenar energia para o futuro. Entre 6:00 e 9:00 o preço da energia segundo o ToU é mais elevado, logo *PeakCharge* não compra o excesso de energia, apenas o suficiente para satisfazer a demanda momentânea do estabelecimento, já que essa é inferior à média. Entre 9:00 e 13:00 a demanda está majoritariamente acima da média, logo *PeakCharge* utiliza a energia armazenada na bateria para satisfazer a demanda diária (reduzindo-a até a média do dia, sendo que o restante continua sendo comprado do *Smart Grid*, como descrito nas condições do modelo, em 2.3.1). Por volta das 13:00 a carga da bateria se esgota. Nos momentos em que a demanda cai abaixo da média, o modelo compra energia até o nível do consumo médio, satisfazendo a demanda e alimentando a bateria. Como esses períodos são pouco frequentes, a carga armazenada na bateria não é capaz de evitar todos os picos de consumo seguintes, mas a linha verde mostra que a bateria permite ao menos reduzi-los até por volta das 16:00.

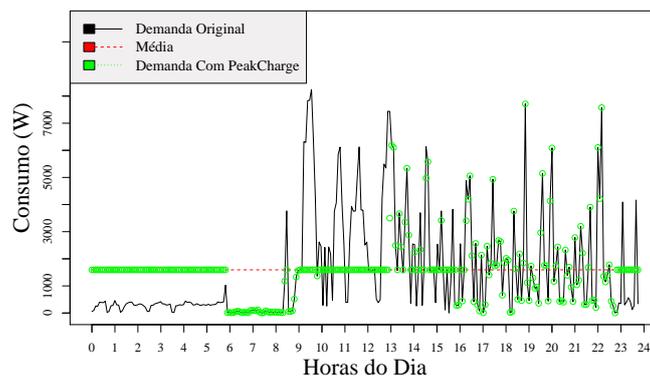


Figura 5.2: Consumo de um dia representativo com a aplicação de *PeakCharge*.

Após as 16:00 a bateria se esgota e o alto custo da energia no *Smart Grid* após esse período impede que a bateria seja carregada (quando o consumo estiver abaixo da média). Logo, o consumo de *PeakCharge* fica igual ao original (a linha verde segue sobreposta à linha preta, que corresponde à demanda original). Após as 22:00 o custo da energia no ToU cai novamente e *PeakCharge* recomeça a carregar a bateria, por isso

vemos a linha verde voltar para a média, mesmo a demanda da casa estando abaixo dela.

5.1.3 GreenPeaks

A figura 5.3 mostra o resultado da execução de *GreenPeaks* com dados do mesmo dia utilizado para gerar a figura 5.2, com *PeakCharge*. É possível notar uma grande eficácia do *GreenPeaks* ao homogeneizar todo o consumo no decorrer do dia e não somente do pico máximo ocorrido em torno das 8:00. *PeakCharge*, entretanto, só consegue efetivamente reduzir os maiores picos à média diária, gerando apenas uma pequena redução dos demais picos ao longo do dia. O armazenamento da energia solar produzida, por *GreenPeaks*, durante os momentos de intensidade solar tornaram possível uma maior disponibilidade de energia na bateria para ser utilizada futuramente no dia, quando a energia estiver cara ou a sua produção escassa (período da noite). A título de comparação, os picos ocorridos às 13:00, 19:00 e 22:00 não foram satisfeitos por *PeakCharge*, enquanto *GreenPeaks* foi capaz de reduzi-los à média, graças ao maior estoque de energia que a produção solar proporcionou. Esse é o principal benefício que *GreenPeaks* ofereceu em comparação ao modelo de base.

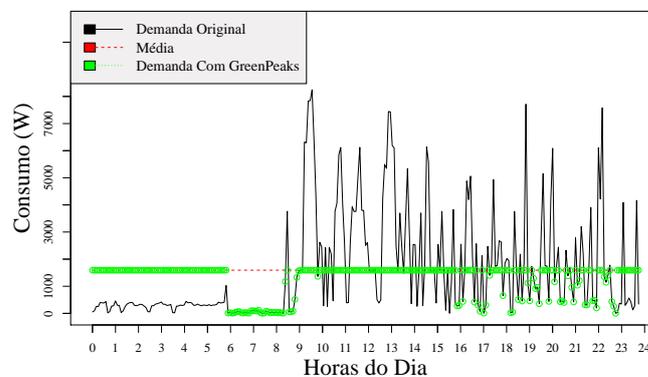


Figura 5.3: Consumo de um dia representativo com a aplicação de *GreenPeaks*

Outra curiosidade interessante na figura 5.3 é o comportamento de *GreenPeaks* no intervalo entre 16:00 e 23:00. Nesse período, quando a demanda instantânea estiver acima da média diária, a energia da bateria será utilizada para reduzir a demanda até a média, e o restante será comprado do *Smart Grid* normalmente. Porém, quando a demanda estiver abaixo da média, como a energia está com preço elevado, não será comprada energia do *Smart Grid* para também carregar a bateria. Isto pode ser entendido analisando atentamente o funcionamento do modelo em tais condições, no algoritmo 1

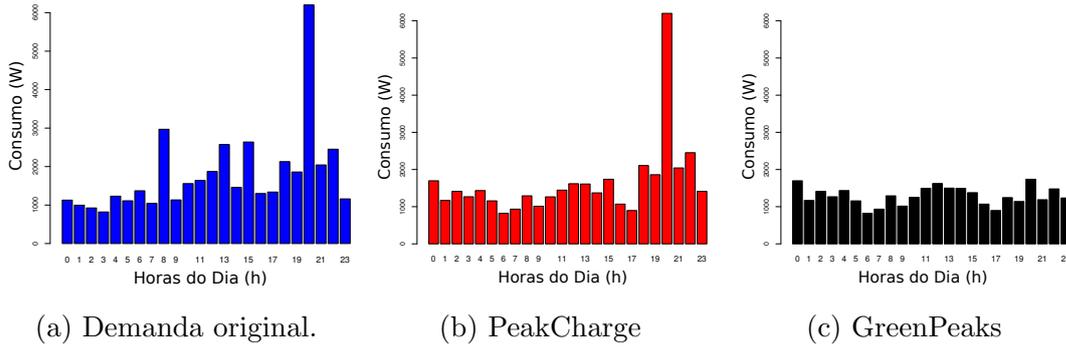


Figura 5.4: Consumo original (a), após uso de *PeakCharge* (b), e após *GreenPeaks* (c), com a demanda de mais um dia representativo de nosso dataset

(linha 16). E um outro ponto muito importante que podemos concluir é que a bateria finalizou o dia ainda com alguma carga, uma vez que até o último pico foi satisfeito completamente pela energia armazenada na bateria (lembrando que a bateria descarregou por volta de 16:00, em *PeakCharge*). Com a funcionalidade de venda de energia excedente de volta para o *Smart Grid*, *GreenPeaks* oferece ainda mais esse benefício para o usuário final.

Uma vez validados os comportamentos dos modelos de gerência, as seções a seguir resumizam os resultados obtidos nos dois métodos de tarifação considerados.

5.2 Resultados com tarifação TOU (Time Of Use)

Para avaliar a melhoria que *GreenPeaks* promove ao adicionar energia limpa, em relação ao consumo original e ao *PeakCharge*, podemos analisar o consumo original e o consumo de todos os apartamentos após a aplicação dos algoritmos em um mesmo dia representativo de nosso dataset (fig. 5.4). É possível ver, na figura 5.4b, uma redução parcial que *PeakCharge* promoveu em alguns picos ao longo do dia, mais especificamente nos períodos de 8:00, 13:00 e 15:00 horas. Porém, não houve energia suficiente armazenada na bateria para que *PeakCharge* pudesse dar conta do maior pico ocorrido no dia, por volta das 20:00 horas. Em contra partida, ao olharmos para o resultado de *GreenPeaks*, na figura 5.4c, não apenas o maior pico foi reduzido, mas o algoritmo também foi capaz de trazer todos os demais picos para próximo da média do consumo diário, o que é a proposta principal do modelo. É importante ressaltar que alguns pontos que estavam abaixo da média no consumo original acabam subindo para próximo da média com *GreenPeaks*, Isso se justifica pelo funcionamento do algoritmo que respeita o preço instantâneo da energia, que é variável ao longo do dia, conforme a equação 2.1.

Para as demais avaliações, decidimos também incluir a comparação com o modelo

Simples proposto, descrito na seção 4.1, e também *NetMetering*. Fizemos, então, uma comparação entre *GreenPeaks*, *PeakCharge*, *Simples* e *NetMetering*. Lembrando que todas as configurações dos experimentos são detalhadamente descritas na seção 3 e também complementadas no início deste capítulo.

Temos, na figura 5.5, a comparação entre a demanda agregada para todos os apartamentos, considerando a média de toda uma semana, tanto para o consumo original quanto para *PeakCharge* e *GreenPeaks* (*NetMetering* não apresentou grande redução em relação à demanda original, por isso não é apresentado nesta figura). A figura fornece uma série de informações. Primeiramente, é possível ver que o maior pico de consumo alcançado por *GreenPeaks* é menor do que o maior pico alcançado por *PeakCharge*, que por sua vez é menor que o máximo da demanda original. Além disso, é possível notar uma eficiente homogeneização da demanda promovida por *GreenPeaks*, justamente por ele objetivar sempre a média do consumo diário. Os períodos entre 10:00 e 16:00 evidenciam as vantagens de *GreenPeaks*, onde a média diária da demanda é priorizada. Isso faz com que uma maior quantidade de energia esteja disponível na bateria para ser utilizada em momentos de pico, onde a energia tem alto custo, como entre 17:00 e 22:00 horas. Ademais, a figura mostra que *GreenPeaks* pode reduzir a demanda de pico agregado para toda a rede e não apenas para uma casa individual, promovendo a diminuição dos custos de geração e, conseqüentemente, mais vantagens para o consumidor final.

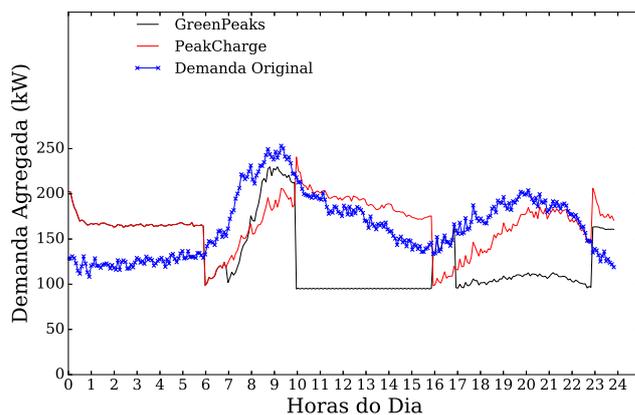


Figura 5.5: Demanda agregada do *Smart Grid* considerando os modelos de gerência de energia abordados. *NetMetering* não apresenta ganhos significativos em relação à demanda original nesse caso.

Nas figuras 5.6 e 5.7, investigamos a redução de custos na geração de energia e a redução de pico, respectivamente, conforme a capacidade da armazenamento de energia na bateria aumenta. Ambas as figuras consideram o consumo agregado, ou seja,

todos os 114 apartamentos, e a média de uma semana de experimentação. Nelas, a porcentagem indicada no eixo x a capacidade de armazenamento de energia em bateria disponível para as residências individualmente. Essa capacidade é variada de 0% a 100% do consumo médio diário de energia de cada apartamento. *NetMetering* não utiliza armazenamento em baterias, por este motivo seus resultados mostram apenas uma linha horizontal. Esse modelo foi incluído nesta análise para identificar a partir de que ponto o uso de baterias se justifica em comparação com o modelo que apenas aproveita a energia renovável diretamente. Observamos que a redução de custos de geração, juntamente com a redução de pico máximo alcançado, aumentam acentuadamente para, em seguida, desacelerar a partir de quando a capacidade da bateria alcança aproximadamente 50% ou 60%. A partir dos valores citados, onde se tem energia suficiente na bateria para satisfazer as necessidades do estabelecimento, adicionar mais capacidade de armazenamento não promove nenhuma melhoria.

As figuras 5.6 e 5.7 apresentam os resultados quando consideramos a demanda compartilhada. Nesse caso, também, *GreenPeaks* tem desempenho superior aos demais modelos. Isso se dá pois os altos picos observados no *Smart Grid* estão diretamente relacionados ao custo da geração de energia. Considerando os resultados observados, *GreenPeaks* pode fornecer redução de custos quatro vezes maior que *NetMetering*.

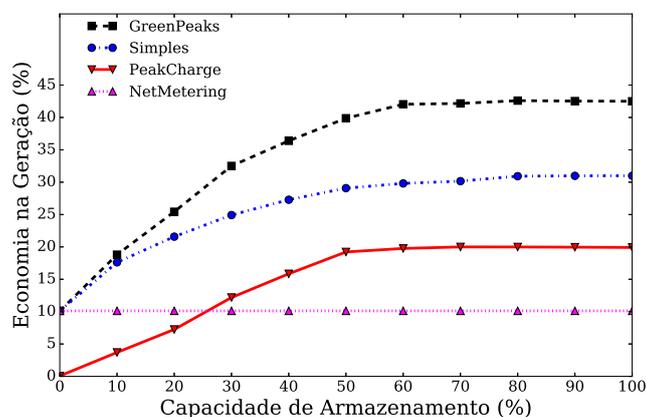


Figura 5.6: Economia agregada obtida pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços ToU. (*NetMetering* não utiliza baterias.)

Vemos que só quando a capacidade da bateria ultrapassa 30% da demanda diária ele consegue oferecer economia superior ao *NetMetering*. Isso se justifica porque para todos os métodos que utilizam energia renovável, ao ter capacidade de armazenamento igual a zero, toda energia renovável disponível será direcionada para satisfazer a demanda do estabelecimento, e *PeakCharge* não conta com energia renovável. Já

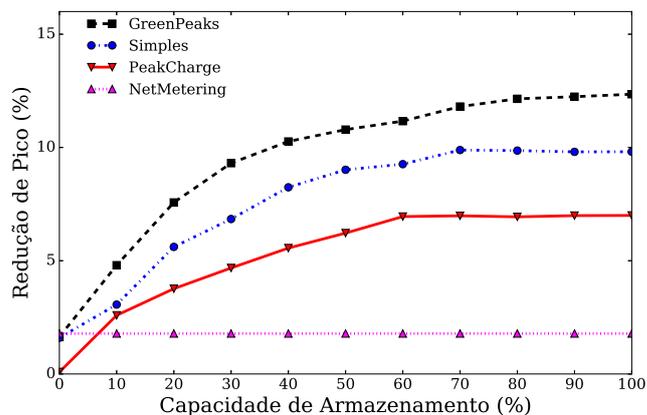


Figura 5.7: Redução do pico máximo agregado observado pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços ToU. (*NetMetering* não utiliza baterias.)

os modelos propostos nesse trabalho, como estendem este último, sempre têm resultados ao menos equivalentes a ele.

Já as figuras 5.8 e 5.9 apresentam o efeito da aplicação do modelo em função da fração das casas que efetivamente usam gerência de energia. Nelas, a porcentagem indicada no eixo x indica a parcela de apartamentos que utilizam as políticas implementadas em relação ao total de residências. Nesse caso, com base nos resultados anteriores, consideramos que cada apartamento que usa um algoritmo de gerência de energia (exceto o *NetMetering*) tem baterias que podem armazenar 50% do valor de seu consumo diário.

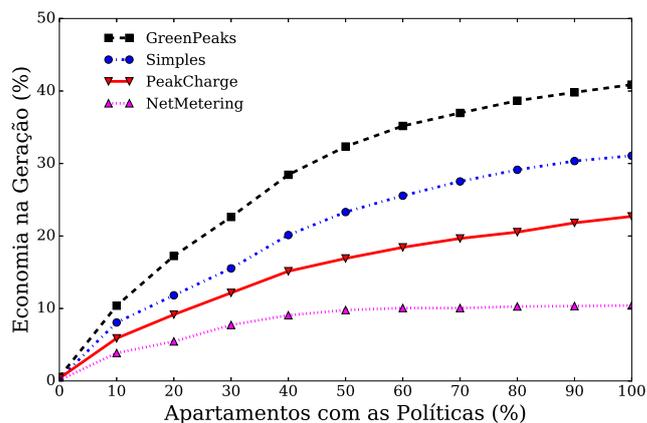


Figura 5.8: Economia agregada obtida em função da porcentagem de residências que adota modelos de gerência inteligente de energia, sob a política de preços ToU.

Os resultados demonstram que quanto mais casas adotam um modelo, maior a

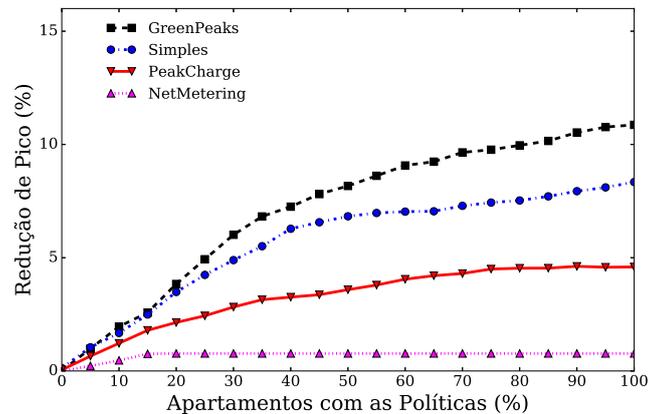


Figura 5.9: Redução do pico máximo agregado observado em função da porcentagem de residências que adota modelos de gestão inteligente de energia, sob a política de preços ToU.

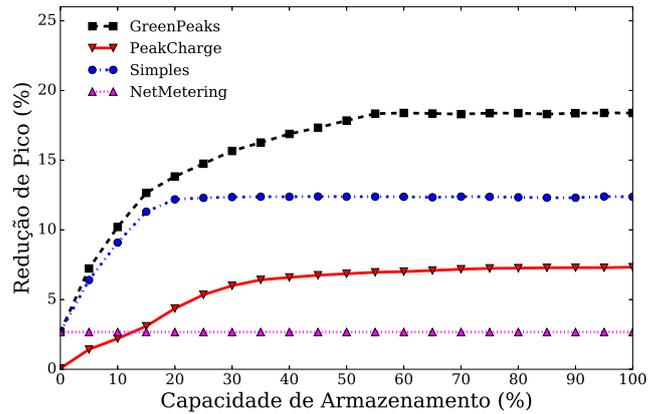
economia agregada de energia e também maior a redução de picos em toda a rede. Analogamente às figuras 5.6 e 5.7, aqui *GreenPeaks* também obtém resultados significativamente melhores em comparação com as outras abordagens. A título de exemplo, *GreenPeaks* aumenta a redução do pico agregado em mais de nove vezes (ou seja, diminui o pico em mais de nove vezes), com relação ao *NetMetering*. Além disso, a grande economia de custos alcançada com a geração de energia também demonstra ser um bom incentivo para que as empresas de serviços públicos encorajem seus clientes à produção local de energia limpa.

O intuito da maioria dos resultados apresentados até aqui foi o de esboçar os potenciais benefícios para as empresas de produção e distribuição de energia. Na figura 5.10 mostramos a redução de pico e as economias, percentual e efetiva, da perspectiva do cliente, em função da capacidade da bateria utilizada. A figura 5.10a mostra a redução média de pico para residências individuais, enquanto as figuras 5.10b e 5.10c mostram a economia, em termos de redução percentual da energia e em dólares, por dia, para os clientes (como o custo da energia varia ao longo do dia, os dois valores não são necessariamente iguais).

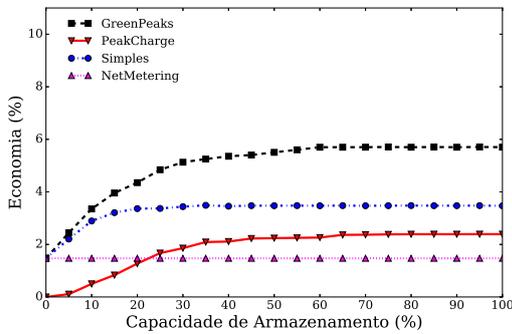
Observamos que os resultados de *GreenPeaks* promovem a maior redução dos picos e, conseqüentemente, a maior economia diária em dólares. Apesar da economia financeira do usuário final ter um valor de magnitude baixa, ele representa apenas o ganho para um único dia, fazendo com que o montante em um mês possa ser expressivo. Em comparação com *NetMetering*, por exemplo, *GreenPeaks* apresenta um ganho aproximado de quatro vezes. Assim, nossos experimentos demonstram que *GreenPeaks* beneficia tanto as empresas concessionárias quanto os clientes individuais, diminuindo

o custo de geração de energia e, conseqüentemente, o preço final da mesma.

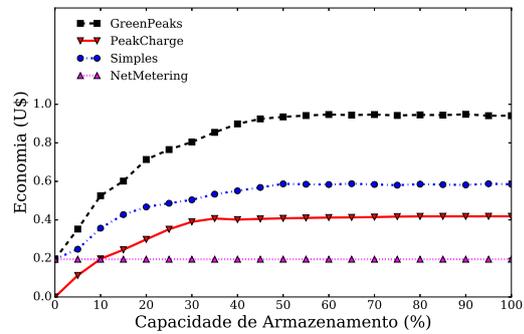
Um ponto interessante na análise da fig. 5.10 é que, para baterias de pequena capacidade, *GreenPeaks* não tem grande diferença em relação ao modelo simples proposto. É apenas para capacidades de bateria acima de 20% que os ganhos na forma como o algoritmo gerencia a energia armazenada se tornam visíveis. Nossos resultados também indicam que para *PeakCharge*, baterias acima de 30% não têm ganhos significativos, indicando que o algoritmo não é capaz de aproveitar a capacidade extra.



(a) Redução de pico.



(b) Redução do consumo de energia.



(c) Redução de custos.

Figura 5.10: Economia individual média por apartamento obtida pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços ToU. (*NetMetering* não utiliza baterias.)

5.3 Resultados com a política de Tarifação Branca da CEMIG

Nesta seção avaliamos os modelos utilizar a política de preços aplicada pela companhia brasileira CEMIG, no estado de Minas Gerais. Infelizmente, não encontramos dados de consumo de residências na região com o mesmo nível de detalhe do *dataset Smart*; sendo assim, mantivemos os perfis de consumo daquele conjunto de dados. A metodologia utilizada foi a mesma aplicada aos experimentos anteriores, considerando a média dos valores somados para dados de uma semana de experimentação. É importante destacar que nosso modelo não foi proposto originalmente tendo a tarifação branca como foco, logo é natural esperar uma diferença nos resultados, se comparados com os experimentos utilizando a tarifação *Time of Use*. Podemos considerar que a tarifação branca ainda é um modelo de política de preços muito simples, considerando-se as tendências de *Smart Grids* observadas em outros países.

A figura 5.11 mostra a comparação entre consumo original, *PeakCharge* e *GreenPeaks*, considerando a demanda agregada. A diferença no modelo de preço, como visto nas figuras 3.2 e 3.3, tem forte impacto no valor agregado de consumo do *Smart Grid*. Como os momentos de alto e baixo custo da energia foram alterados, assim como os respectivos preços, o comportamento de *PeakCharge* e *GreenPeaks* apresentam diferentes tendências. Os longos períodos de preços elevados para compra de energia, utilizando o modelo de preço americano, entre 10:00 e 16:00, e entre 17:00 e 22:00 (apresentado na figura 5.5) não ocorrem quando utilizamos a tarifa branca da CEMIG. Porém, o comportamento básico dos algoritmos, baseados na lógica de *PeakCharge*, permanece pois quando o preço da energia elétrica está alto, nós conseguimos ver uma diminuição no consumo agregado no *Smart Grid*. Além disso, a ordem de eficácia na capacidade de diminuir os picos agregados se manteve, mostrando que as abordagens avaliadas continuam funcionando para diferentes modelos de preços.

Avaliando-se a capacidade de armazenamento disponível para baterias, a redução de custos para a geração de energia é avaliada na figura 5.12 e a redução nos picos, considerando o *Smart Grid* agregado, é avaliada na figura 5.13.

Como há apenas um período curto de taxaçoão mais elevada, os ganhos com o aumento da capacidade de armazenamento seguem curvas mais uniformes, sem pontos de estabilização mais claros, como os que ocorreram com a política *Time Of Use*. Ainda podemos afirmar que redução de custos de geração aumenta linearmente a princípio para, em seguida, desacelerar aproximadamente quando a capacidade da bateria alcança 50%. A partir dos valores citados, onde se tem energia suficiente na bateria para

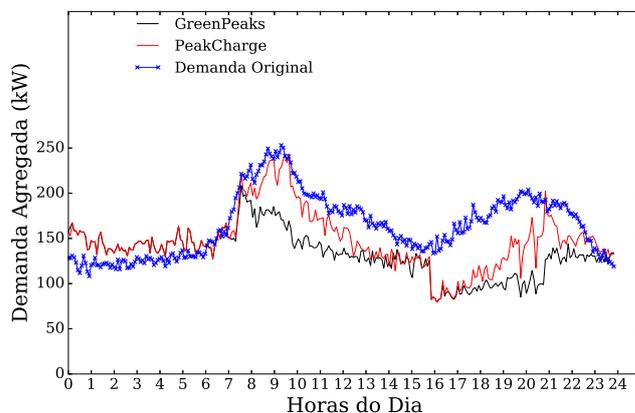


Figura 5.11: Demanda agregada do *Smart Grid* considerando os modelos de gestão de energia abordados, sob a política de preços da CEMIG. *NetMetering* não apresenta ganhos significativos em relação à demanda original nesse caso.

satisfazer as necessidades do estabelecimento, adicionar mais capacidade de armazenamento não promove mais tanta melhoria. Também para a redução de pico máximo agregado, o resultado é análogo à figura utilizando o preço *Time Of Use*, porém a tendência de estagnação na curva é menor e os valores atingidos são maiores. Isto provavelmente se deve ao fato de que nosso algoritmo foi projetado para outro modelo de preço, produzindo resultados diferentes com uma precificação diferente. Em políticas como a *Time Of Use*, onde os períodos de preço mais baixo alternam com períodos de preço alto, o aproveitamento da carga armazenada tem um impacto maior.

Novamente podemos perceber que os resultados de redução de pico dos apartamentos individuais também se refletem nas figuras 5.12 e 5.13, quando consideramos a demanda compartilhada à medida que mais residências adotam um modelo de gestão de energia, uma vez que os picos ocorridos no *Smart Grid* estão diretamente relacionados ao custo da geração de energia. Como na seção anterior, consideramos baterias com capacidade de armazenamento de 50% da demanda.

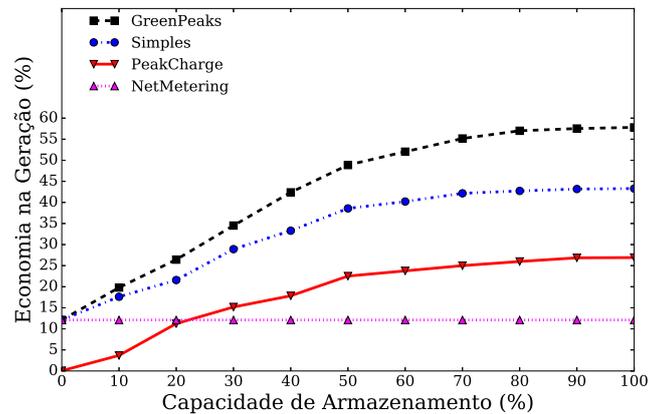


Figura 5.12: Economia agregada obtida pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços da CEMIG. (*NetMetering* não utiliza baterias.)

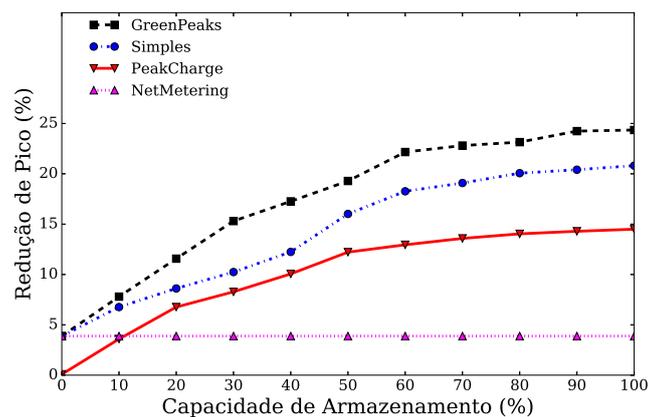


Figura 5.13: Redução do pico máximo agregado observado pelos modelos em função da capacidade das baterias utilizadas, sob a política de preços da CEMIG. (*NetMetering* não utiliza baterias.)

Também podemos ver as mesmas tendências de diminuição dos picos e, conseqüentemente, do custo de geração para as concessionárias, à medida que cresce o número de estabelecimentos que adotam *GreenPeaks* (e as demais abordagens que adotam a lógica de *PeakCharge*). Analogamente aos resultados com tarifação *Time of Use*, para a tarifa Branca, as figuras 5.14 e 5.15 mostram que *GreenPeaks* também obtém resultados significativamente melhores em comparação com as outras abordagens. A ordem das abordagens também permaneceu, sendo *GreenPeaks* o que mostra as maiores reduções de pico e economia de geração de energia, seguidas por *Simples*, *PeakCharge* e *NetMetering*, respectivamente.

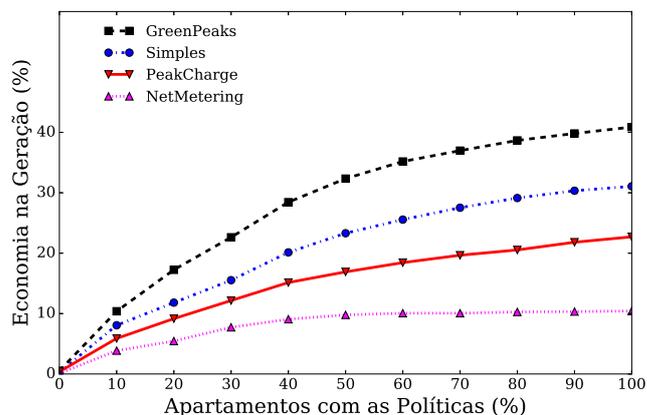


Figura 5.14: Economia agregada obtida em função da porcentagem de residências que adota modelos de gestão inteligente de energia, sob a política de preços da CEMIG.

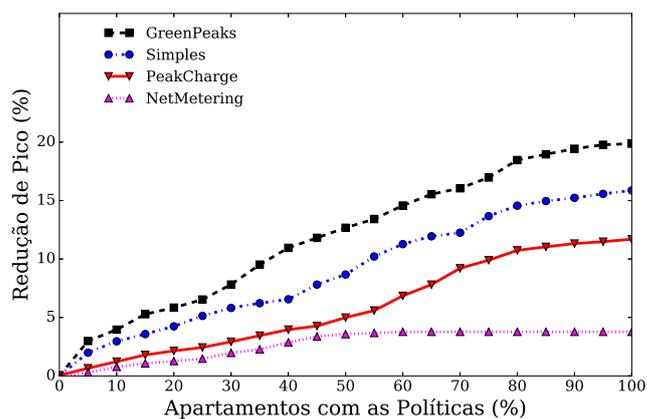


Figura 5.15: Redução do pico máximo agregado observado em função da porcentagem de residências que adota modelos de gestão inteligente de energia, sob a política de preços da CEMIG.

Capítulo 6

Conclusão

Neste trabalho nosso objetivo foi o de estender um algoritmo já conhecido na literatura relacionada à economia de energia em *SmartHomes*, adicionando energia renovável ao seu funcionamento. Algumas tentativas de combinar o método base com a utilização de energia limpa foram feitas, até se encontrar um bom equilíbrio entre todas as variáveis presentes. Isso nos fez passar por um método intermediário, *Simple*, e incluímos adaptações de aplicações reais, como *NetMetering*, até finalmente chegarmos a uma abordagem híbrida, que conta com pontos positivos dos principais métodos estudados. Por fim, neste trabalho apresentamos *GreenPeaks*, um modelo que incorpora o uso de energia renovável e um inteligente armazenamento de energia, que efetivamente reduz: 1) os picos alcançados, 2) o custo de geração de energia pela concessionária, 3) as contas de eletricidade dos clientes, e contribui com uma maior integração de energia renovável com o *Smart Grid*.

GreenPeaks não só foi capaz de promover redução dos picos máximos alcançados, como produziu resultado consideravelmente superiores às demais abordagens consideradas. Nossos resultados mostram uma redução de 39% do pico máximo alcançado em todo grid.

Com relação aos benefícios de barateamento da produção de energia, mostramos que quanto mais estabelecimentos aderem à estratégia, maior é a economia durante a geração e distribuição de energia, repercutindo assim em um barateamento da mesma para o usuário final. *GreenPeaks* alcança uma redução do custo de geração de energia de cerca de 42%, considerando o montante agregado no grid.

Considerando as vantagens promovidas para o usuário final ao adotar nosso modelo, podemos destacar os resultados mostrados na figura 5.10. As mesmas conclusões se aplicam, também, para o usuário individual, onde uma capacidade de armazenamento de 50% do consumo médio já promove um benefício máximo de redução de pico

e economia financeira. Além do fato de que *GreenPeaks* também se mostra superior aos demais métodos comparados, seguindo a ordem de eficiência: *GreenPeaks*, *Simple*, *PeakCharge* e *NetMetering*. Lembrando que, apesar da economia financeira do usuário final ter um valor de magnitude baixa, ele é apenas para um único dia, fazendo com que o montante em um mês possa ser expressivo. Também é importante ressaltar que diferentes apartamentos e casa apresentam diferentes perfis de consumo, fazendo com que ocasionem diferentes perfis de economia. Nossos resultados mostram que, para o usuário individual, foi possível economizar em média 80 centavos de dólar em um único dia, com adoção de *GreenPeaks*.

Por fim, a funcionalidade de venda de excedente de geração de energia de volta para o *Smart Grid*, inspirada em *NetMetering*, também é uma contribuição considerável no sentido de integralização de estabelecimentos com o grid. A ideia de fazer de um estabelecimento parte de um *Smart Grid*, consumindo e gerando energia de forma distribuída, é um dos esforços presentes nas áreas de pesquisa em *Smart Grid*.

Até o momento, nós avaliamos o comportamento de *GreenPeaks* apenas para estabelecimentos residenciais. No futuro, pretendemos estendê-lo também para estabelecimentos comerciais, que apresentam diferentes padrões de consumo e diferentes necessidades em termos de energia renovável e capacidade de armazenamento de baterias para aplicação de *GreenPeaks*. Outro aspecto interessante de ser abordado futuramente é a aplicação de nosso modelo a um perfil de demanda e produção de energia coletados no Brasil. Além disso, o estudo de economia de eletricidade apresentado neste trabalho não leva em conta custos de equipamentos como baterias e painéis solares. Um trabalho futuro nesse sentido seria conduzir um estudo de retorno de investimentos de longo prazo para *GreenPeaks* que leve em conta esses fatores.

Referências Bibliográficas

- Abdul-Rahaim, L. & Al-Muraab, S. (2018). Monitoring and controlling home automation system based on gsm/gprs technique. *Journal of Engineering and Applied Sciences*, 13:7545–7554.
- Ahadi, A.; Sarma, S.; Moon, J. S.; Kang, S. & Lee, J.-H. (2018). A robust optimization for designing a charging station based on solar and wind energy for electric vehicles of a smart home in small villages. *Energies*, 11(7). ISSN 1996-1073.
- Barker, S.; Mishra, A.; Irwin, D.; Cecchet, E.; Shenoy, P. & Albrecht, J. (2012a). Smart*: An open data set and tools for enabling research in sustainable homes. *Knowledge Discovery and Data Mining in Sustainability, August*, 111(112):108.
- Barker, S. K.; Mishra, A. K.; Irwin, D. E.; Shenoy, P. J. & Albrecht, J. R. (2012b). Smartcap: Flattening peak electricity demand in smart homes. *2012 IEEE International Conference on Pervasive Computing and Communications*, pp. 67–75.
- Carpenter, T.; Singla, S.; Azimzadeh, P. & Keshav, S. (2012). The impact of electricity pricing schemes on storage adoption in Ontario. Em *Future Energy Systems: Where Energy, Computing and Communication Meet (e-Energy)*, 2012 Third International Conference on, pp. 1–10.
- CEMIG (2018). Cemig. <http://www.cemig.com.br/en-us/Pages/default.aspx>. Acessado em: 27-05-2018.
- Clean Energy Reviews (2018). Hybrid solar battery energy storage system review. <https://www.cleanenergyreviews.info/hybrid-solar-battery-energy-storage-system-review>. Acessado em: 10-03-2019.
- Commission, F. E. R. (2009). State of the markets report 2008. Relatório técnico, Technical Report. Federal Energy Regulatory Commission. Acessado em: 26-05-2018.

- Daryanian, B.; Bohn, R. & Tabors, R. (1989). Optimal demand-side response to electricity spot prices for storage-type customers. *IEEE Transactions on Power Systems*, 4(3):897–903.
- Datchanamoorthy, S.; Kumar, S.; Ozturk, Y. & Lee, G. (2011). Optimal time-of-use pricing for residential load control. Em *Smart Grid Communications (SmartGridComm)*, 2011 *IEEE International Conference on*, pp. 375–380. IEEE.
- Elma, O.; Selamogullari, U. S.; Uzunoglu, M. & Ugur, E. (2013). Carbon emission savings with a renewable energy supplied smart home operation. Em *2013 International Conference on Renewable Energy Research and Applications (ICRERA)*, pp. 1129–1132. ISSN .
- Energysage (2017). How does net metering work with solar. <https://www.energysage.com/solar/101/net-metering-for-home-solar-panels/>. Acessado em: 25-05-2018.
- FirstSolar (2018). Leading the world’s sustainable energy future. <http://www.firstsolar.com/>. Acessado em: 12-03-2019.
- GreenPeaks (2017). Greenpeaks repository. <https://github.com/raphael-luciano/Smart-Project>. Acessado em: 01-08-2018.
- Harding, M.; Kettler, K. & Lamarche, C. (2019). Environmental and social benefits of time of use electricity pricing.
- Hegde, N.; Massoulié, L.; Salonidis, T. et al. (2011). Optimal control of residential energy storage under price fluctuations. Em *ENERGY*.
- Irwin, D.; Iyengar, S.; Lee, S.; Mishra, A.; Shenoy, P. & Xu, Y. (2017). Enabling distributed energy storage by incentivizing small load shifts. *ACM Transactions on Cyber-Physical Systems*, 1(2):10.
- J. Aigner, D. & Hirschberg, J. (1985). Commercial/industrial customer response to time-of-use electricity prices: Some experimental results. *RAND Journal of Economics*, 16:341–355.
- Lu, J.; Sookoor, T.; Srinivasan, V.; Gao, G.; Holben, B.; Stankovic, J.; Field, E. & Whitehouse, K. (2010). The smart thermostat: using occupancy sensors to save energy in homes. Em *Proceedings of the 8th ACM Conference on Embedded Networked Sensor Systems*, pp. 211–224. ACM.

- Mishra, A.; Irwin, D.; Shenoy, P.; Kurose, J. & Zhu, T. (2012). Smartcharge: Cutting the electricity bill in smart homes with energy storage. Em *Proceedings of the 3rd International Conference on Future Energy Systems: Where Energy, Computing and Communication Meet*, p. 29. ACM.
- Mishra, A.; Irwin, D.; Shenoy, P.; Kurose, J. & Zhu, T. (2013a). Greencharge: Managing renewable energy in smart buildings. *IEEE Journal on Selected Areas in Communications*, 31(7):1281–1293.
- Mishra, A.; Irwin, D.; Shenoy, P. & Zhu, T. (2013b). Scaling distributed energy storage for grid peak reduction. Em *Proceedings of the fourth international conference on Future energy systems*, pp. 3–14. ACM.
- Mishra, A.; Sitaraman, R.; Irwin, D.; Zhu, T.; Shenoy, P.; Dalvi, B. & Lee, S. (2015). Integrating energy storage in electricity distribution networks. Em *Proceedings of the 2015 ACM Sixth International Conference on Future Energy Systems*, pp. 37–46. ACM.
- NanoSolar (2018). What if you could print solar energy? <http://www.nanosolar.com/>. Acessado em: 1-03-2019.
- OEB (2017). Ontario energy board: Electricity prices. <http://www.ontarioenergyboard.ca/OEB/Consumers>. Acessado em: 27-05-2018.
- Pellegrini, J. & Wainer, J. (2007). Processos de decisão de markov: um tutorial. *Revista de Informática Teórica e Aplicada*, 14(2):133–179.
- Pilloni, V.; Floris, A.; Meloni, A. & Atzori, L. (2018). Smart home energy management including renewable sources: A qoe-driven approach. *IEEE Transactions on Smart Grid*, 9(3):2006–2018. ISSN 1949-3053.
- Pontes, R. L.; Mishra, A.; Seetharam, A.; Shekhar, M. & Ramesh, A. (2018). Greenpeaks: Employing renewables to effectively cut load in electric grids. Em *2018 IEEE International Conference on Smart Computing (SMARTCOMP)*, pp. 123–130. IEEE.
- Raza, S. A.; Shah, N. & Sharif, A. (2019). Time frequency relationship between energy consumption, economic growth and environmental degradation in the united states: Evidence from transportation sector. *Energy*.
- Rehmani, M. H.; Reisslein, M.; Rachedi, A.; Erol-Kantarci, M. & Radenkovic, M. (2018). Integrating renewable energy resources into the smart grid: Recent deve-

- lopments in information and communication technologies. *IEEE Transactions on Industrial Informatics*, 14(7):2814–2825. ISSN 1551-3203.
- Scarlat, N.; Dallemand, J.-F.; Monforti-Ferrario, F.; Banja, M. & Motola, V. (2015). Renewable energy policy framework and bioenergy contribution in the European Union - An overview from national renewable energy action plans and progress reports. *Renewable and Sustainable Energy Reviews*, 51:969–985.
- Shah, J. & Mishra, B. (2016). Iot enabled environmental monitoring system for smart cities. Em *2016 International Conference on Internet of Things and Applications (IOTA)*, pp. 383–388. ISSN .
- Shahin, F.; Tawheed, P.; Haque, M.; Hasan, M. & Khan, M. N. (2017). Smart home solutions with sun tracking solar panel. pp. 766–769.
- Smart (2018). Smart project. <http://lass.cs.umass.edu/projects/smart/>. Acessado em: 27-05-2018.
- Solar Installation Cost (2018). How much does it cost to install solar on an average us house? <https://www.solarpowerauthority.com/how-much-does-it-cost-to-install-solar-on-an-average-us-house/>. Acessado em: 8-03-2019.
- Srikantha, P.; Rosenberg, C. & Keshav, S. (2012). An analysis of peak demand reductions due to elasticity of domestic appliances. Em *Proceedings of the 3rd International Conference on Future Energy Systems: Where Energy, Computing and Communication Meet*, p. 28. ACM.
- Tarifa Branca (2018). Bandeiras tarifárias. http://www.cemig.com.br/pt-br/atendimento/Paginas/FAQ_Tarifa.aspx. Acessado em: 22-07-2018.
- Torriti, J. (2017). Understanding the timing of energy demand through time use data: Time of the day dependence of social practices. *Energy research & social science*, 25:37–47.
- U.S. Energy Information Administrator (2018). https://www.eia.gov/energyexplained/?page=us_energy_use. Acessado em: 20-03-2019.
- USEIA (2017). How much of U.S. carbon dioxide emissions are associated with electricity generation? U.S. Energy Information Administration (EIA). <https://www.eia.gov/tools/faqs/faq.php?id=77&t=11>. Acessado em: 25-05-2018.

- Wikipedia (2017). Net metering. <https://en.wikipedia.org/wiki/Netmetering>. Acessado em: 27-05-2018.
- Wu, X.; Hu, X.; Moura, S.; Yin, X. & Pickert, V. (2016). Stochastic control of smart home energy management with plug-in electric vehicle battery energy storage and photovoltaic array. *Journal of Power Sources*, 333:203 – 212. ISSN 0378-7753.
- Yang, L.; Huang, K.; Kong, X.; Luo, Q. & Guo, H. (2019). Size optimization of a stand-alone micro-grid integrated with flexible load and the complementary of solar and wind. *Journal of Renewable and Sustainable Energy*, 11(2):025502.