

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ  
CAMPUS DE FOZ DO IGUAÇU  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E  
COMPUTAÇÃO

DISSERTAÇÃO DE MESTRADO

**GERENCIAMENTO ÓTIMO DE ENERGIA EM MICRORREDES INTELIGENTES  
EM MODO CONECTADO**

ANDRÉ QUITES ORDOVÁS SANTOS

ORIENTADOR: PROF. DR. ADRIANO BATISTA DE ALMEIDA

COORIENTADOR: PROF. DR. ROBERTO CAYETANO LOTERO

FOZ DO IGUAÇU  
2018



André Quites Ordovás Santos

## **Gerenciamento Ótimo de Energia em Microrredes Inteligentes em Modo Conectado**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Computação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica e Computação. Área de concentração: Sistemas Dinâmicos e Energéticos.

Orientador: Prof. Dr. Adriano Batista de Almeida

Coorientador: Prof. Dr. Roberto Cayetano Lotero

Foz do Iguaçu

2018

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Santos, André Quites Ordovás  
Gerenciamento Ótimo de energia em microrredes inteligentes em modo conectado / André Quites Ordovás Santos; orientador(a), Adriano Batista de Almeida; coorientador(a), Roberto Cayetano Lotero, 2018.  
112 f.

Dissertação (mestrado), Universidade Estadual do Oeste do Paraná, Centro de Engenharias e Ciências Exatas, Programa de Pós-Graduação em Engenharia Elétrica e Computação, 2018.

1. Microrredes inteligentes de energia elétrica. 2. Redes inteligentes de energia elétrica. 3. Gerenciamento de energia. 4. Geração distribuída. I. de Almeida, Adriano Batista. II. Lotero, Roberto Cayetano. III. Título.

# Gerenciamento Ótimo de Energia em Microrredes Inteligentes em Modo Conectado

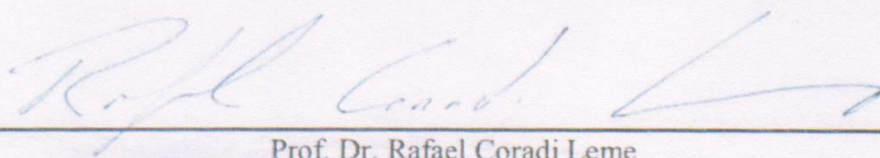
André Quites Ordovás Santos

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Computação e aprovada pela Banca Examinadora:  
Data de defesa pública: 26/07/2018



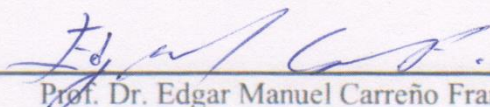
---

Prof. Dr. Adriano Batista de Almeida – (Orientador)  
Universidade Estadual do Oeste do Paraná – UNIOESTE



---

Prof. Dr. Rafael Coradi Leme  
Universidade Federal de Itajubá – UNIFEI



---

Prof. Dr. Edgar Manuel Carreño Franco  
Universidade Estadual do Oeste do Paraná – UNIOESTE



# Resumo

O esperado avanço das Redes Inteligentes de Energia Elétrica, com todos os seus benefícios em termos de segurança, disponibilidade e redução de impactos ambientais, depende em grande medida da viabilização técnico-econômica e regulatória das chamadas Microrredes inteligentes de energia elétrica. As Microrredes inteligentes são vistas como componentes essenciais para as Redes Inteligentes de Energia Elétrica que, em seu estágio avançado, serão estruturadas como grandes redes de Microrredes inteligentes interconectadas. Dentre os principais desafios para a disseminação da tecnologia das Microrredes inteligentes, a simplificação e a eficiência do gerenciamento de energia, que consiste no aproveitamento ótimo dos recursos energéticos nela inseridos, vem recebendo grande atenção dos pesquisadores, especialmente no chamado modo conectado ou “normal”, no qual as Microrredes deverão operar na quase totalidade do tempo. O investimento inicial na implantação de uma Microrrede inteligente ainda é considerado muito elevado. Neste trabalho, apresenta-se um modelo de otimização linear inteiro misto para a solução do problema do gerenciamento ótimo de energia de microrredes inteligentes de energia elétrica em modo conectado, visando a minimização de custos, em um horizonte de 24 horas, denominado *day-ahead*. Apresentam-se, também, dois modelos de otimização em tempo real em um horizonte de 5 minutos, com estratégias centralizada e descentralizada, buscando manter o balanço de potências de maneira ótima, considerando os desvios entre a demanda e a oferta previstas no *day-ahead* e o realizado. O modelo considera alguns dos principais componentes das microrredes inteligentes modernas, como fontes renováveis intermitentes, fontes não-renováveis despacháveis e sistemas de armazenamento. Considera-se que a Microrrede tem a capacidade de comprar ou vender energia para a rede da distribuidora, em um cenário de preços variáveis e demanda contratada. O modelo apresentado é aplicado, por meio de simulações, a uma arquitetura de Microrrede típica. Os resultados são então apresentados e analisados.

**Palavras-chave:** redes inteligentes de energia elétrica, microrredes inteligentes de energia elétrica, gerenciamento ótimo de energia, geração distribuída, energias renováveis.

# Abstract

The expected advance of the smart grids, with all its anticipated benefits like improved reliability and reduced environmental impacts, depends greatly on the technical-economical and regulatory viability of the so-called intelligent microgrids. Intelligent microgrids are considered as essential components of the future smart grids which, in their advanced stage, are expected to be structured as large networks of interconnected intelligent microgrids. Among the existing challenges to a wider adoption of the intelligent electrical energy microgrids technology, the efficiency and simplification of the energy management systems, responsible for the optimal operation of the energy resources available in the system, are often viewed as a primary necessity, especially in the so-called connected or normal mode, in which microgrids are expected to operate most of the time. The initial investment in deploying an intelligent microgrid is still considered very high. This paper presents a linear mixed-integer optimization model to solve the energy management problem in a microgrid in connected mode, having as objective the cost minimization, considering a 24-hour horizon, called day-ahead model. Two real-time optimization models are presented, operating in a 5-minute time horizon, with centralized and decentralized strategies, aiming at keeping the power balance optimally, considering the natural deviations of realized demand and supply, regarding the day-ahead forecast. The model presented here takes in consideration some of the most common components of the modern microgrids, such as renewable intermittent sources, non-renewable dispatchable sources, and energy storage systems. The microgrid is supposed as being able to sell and buy energy from the distribution system, in a scenario with varying energy market prices, also considering the contracted demand. The model is then applied, through computer simulations, to a typical microgrid architecture. The results are then presented and analyzed.

**Keywords:** smart grids, intelligent microgrids, energy management, distributed generation, renewable energy sources.



# Agradecimentos

Este autor gostaria de agradecer a todos os que direta ou indiretamente contribuíram para a realização deste trabalho.

Em especial, meus agradecimentos à equipe de professores do Programa de Pós-Graduação em Engenharia Elétrica e Computação da UNIOESTE, e sobretudo aos meus orientadores, professores doutores Adriano Batista de Almeida e Roberto Cayetano Lotero, pela oportunidade e orientação.

Agradeço especialmente também à minha esposa Alessandra, por todo o apoio e pelo exemplo pessoal, nesta nova etapa de vida.

Ficam também meus especiais agradecimentos à Fundação Araucária, pelo auxílio financeiro na realização desta pesquisa.



# Sumário

<b>Lista de Nomenclaturas .....</b>	<b>xi</b>
<b>Lista de Figuras.....</b>	<b>xiii</b>
<b>Lista de Tabelas .....</b>	<b>xv</b>
<b>1 Introdução .....</b>	<b>1</b>
1.1. Justificativa e motivação .....	2
1.2. Objetivo.....	3
1.2.1. Objetivos específicos.....	3
1.3. Estrutura do trabalho.....	3
<b>2 Fundamentação teórica.....</b>	<b>5</b>
2.1. Introdução.....	5
2.2. Microrredes inteligentes.....	5
2.2.1. Componentes de uma Microrrede.....	8
2.2.2. Configurações típicas .....	11
2.2.3. Tipos de Microrredes .....	11
2.3. Gerenciamento ótimo de energia em Microrredes inteligentes.....	13
2.4. Estratégias para o Gerenciamento de Energia em Microrredes.....	18
2.5. Gerenciamento de energia em Microrredes com estratégia centralizada.....	20
2.6. Gerenciamento ótimo de energia descentralizado .....	21
2.6.1. Sistemas Multiagente .....	22
2.6.2. Aplicações em Microrredes Inteligentes de Energia.....	26
2.6.3. Gerenciamento Ótimo de Energia em Microrredes modeladas como Sistemas Multiagentes.....	27
2.6.4. Teoria de leilões aplicada ao gerenciamento de energia .....	30
2.7. Conclusão .....	34
<b>3 Formulação matemática.....</b>	<b>37</b>
3.1. Introdução.....	37
3.2. Modelo centralizado.....	37
3.2.1. Modelo de programação do <i>day-ahead</i> .....	39
3.2.2. Modelo de tempo real.....	46
3.3. Modelo descentralizado .....	52
3.3.1. Gerenciamento ótimo de energia em tempo real .....	53
3.4. Conclusão .....	60

<b>4</b>	<b>Testes e resultados .....</b>	<b>63</b>
4.1.	Introdução.....	63
4.2.	Sistema Teste.....	63
4.3.	Procedimentos de testes .....	64
4.4.	Otimização de <i>day-ahead</i> .....	65
4.4.1.	Caso 1 - Microrrede com sistema fotovoltaico, sem banco de baterias e sem gerador diesel.....	68
4.4.2.	Caso 2 - Microrrede com sistema fotovoltaico, banco de baterias e gerador diesel	68
4.4.3.	Caso 3 - Microrrede com sistema fotovoltaico, sem banco de baterias e com gerador diesel. ....	69
4.4.4.	Caso 4 - Microrrede com sistema fotovoltaico, com banco de baterias e sem gerador diesel.....	70
4.5.	Otimização de tempo real.....	72
4.5.1.	Estratégia centralizada.....	75
4.5.2.	Estratégia descentralizada.....	76
4.6.	Conclusão .....	86
<b>5</b>	<b>Conclusão.....</b>	<b>87</b>
	<b>Referências Bibliográficas .....</b>	<b>91</b>
	<b>Apêndice A - Modelo de otimização do <i>day-ahead</i> no formato do <i>software</i> GAMS.....</b>	<b>99</b>
	<b>Apêndice B - Modelo de otimização em tempo real no formato do <i>software</i> GAMS.....</b>	<b>103</b>
	<b>Apêndice C - Módulo de simulação de SMA.....</b>	<b>107</b>

# Lista de Nomenclaturas

API	<i>Application Programming Interface</i> (Interface de Programação de Aplicação)
AOP	<i>Agent-Oriented Programming</i> (Programação Orientada a Agentes)
CA	Corrente Alternada
CC	Corrente Contínua
CERTS	<i>Consortium for Electric Reliability Technology Solutions</i>
CL	Controlador local de um Recurso Energético Distribuído
CSC	<i>Cold Start-up Cost</i> (Custo de partida do gerador)
GAMS	<i>General Algebraic Modeling System</i> (Sistema de Modelamento Algébrico Geral)
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IID	<i>Island Interconnection Device</i> (Dispositivo de Interconexão de Ilha)
KERI	<i>Korea Electrotechnology Research Institute</i>
MGCC	<i>Microgrid Central Controller</i> (Controlador Central da Microrrede)
MIC	<i>Monitoring, Information Exchange and Control</i> (Sistemas de Controle, Comunicação e Monitoração)
MMG	<i>Multi-Microgrids</i> (Redes de Microrredes)
MR	Microrrede de energia elétrica
OOP	<i>Object Oriented Programming</i> (Programação Orientada a Objetos)
RED	Recurso Energético Distribuído
RTDS	<i>Real-Time Digital Simulator</i> (Simulador Digital em Tempo Real)
PCC	<i>Point of Common Coupling</i> (Ponto de Acoplamento Comum)
SCADA	<i>Supervisory, Control and Data Acquisition system</i> (Sistema de monitoração, controle e aquisição de dados)
SAE	Sistema de armazenamento de energia
SMA	Sistema Multiagentes
SOC	<i>State of Charge</i> (Estado de Carga)



# Lista de Figuras

Figura 2.1. Arquitetura típica de MR inteligente. Fonte: adaptado de Lasseter (2002). .....	7
Figura 2.2: Diagrama representando um RED. Fonte: Adaptado de Katiraei <i>et al.</i> (2008).....	10
Figura 2.3: Topologias de MRs. Fonte: Adaptado de IEEE Standards Coordinating (2011). 12	
Figura 2.4. Diagrama do gerenciamento energia em uma MR. Fonte: Adaptado de Katiraei <i>et al.</i> (2008). .....	13
Figura 2.5. Arquitetura SMA típica em três níveis hierárquicos. Fonte: adaptado de Cossentino & Lodato (2011). .....	29
Figura 3.1: Curvas quadrática e linearizada por partes do custo por hora pela pot. instantânea para gerador a diesel. ....	42
Figura 3.2: Negociação entre agentes virtuais de mercado, criados por agentes físicos, fontes ou cargas. Fonte: adaptado de (Hatziargyriou, 2014). .....	54
Figura 3.3: Sequência de ações no tempo da operação de mercado da MR. Fonte: adaptado de (Dimeas & Hatziargyriou, 2005). .....	54
Figura 3.4: Blocos de energia de oferta e demanda, compondo o problema de alocação única simétrico. Fonte: Adaptado de (Hatziargyriou, 2014). .....	55
Figura 4.1. Arquitetura da planta piloto da MR do instituto KERI. Fonte: adaptado de Jeon <i>et al.</i> (2010). .....	64
Figura 4.2: Fluxograma do processo de simulação da otimização de <i>day-ahead</i> . .....	66
Figura 4.3: Fluxograma do processo de simulação da otimização de tempo real, nas estratégias centralizada e descentralizada. ....	66
Figura 4.4: Demanda e geração solar previstas para as próximas 24 horas, e demanda líquida. ....	67
Figura 4.5: Demanda prevista x contratada em cada intervalo. ....	67
Figura 4.6: Balanço de potência, na simulação sem gerador nem banco de baterias (caso 1). 68	
Figura 4.7: Estado de carga (SOC) da bateria no caso 2.....	69
Figura 4.8: Balanço de potência em cada período no caso 2. ....	69
Figura 4.9: Balanço de potência, na simulação com gerador e sem banco de baterias (caso 3). ....	70

Figura 4.10: Resultados para o estado de carga (0-1), na simulação sem o gerador e com banco de baterias (caso 4).....	70
Figura 4.11: Balanço de potência, na simulação sem gerador e com banco de baterias (caso 4). .....	71
Figura 4.12: Demanda, geração solar e demanda líquida previstas para as próximas 24 horas, a partir das 11 horas da manhã. ....	72
Figura 4.13: Demandas prevista e contratada, rotacionadas em 11 horas.....	73
Figura 4.14: Demanda líquida prevista no <i>day-ahead</i> versus a demanda prevista para a próxima meia hora. ....	73
Figura 4.15: Potência média de energia comprada da macrorrede em cada intervalo, comparando a prevista para o próximo intervalo de 30 minutos com a prevista no <i>day-ahead</i> . .....	74
Figura 4.16: Comparação entre <i>SOC</i> do banco de baterias previsto no <i>day-ahead</i> e realizado para o próximo intervalo de 30 minutos.....	76
Figura 4.17: Comparação entre o <i>SOC</i> previsto no <i>day-ahead</i> e o realizado com estratégia centralizada e descentralizada com discretização de 1kW.....	80
Figura 4.18: Comparação entre o <i>SOC</i> previsto no <i>day-ahead</i> e o realizado com estratégia centralizada e descentralizada com discretização de 0,1kW. ....	81
Figura 4.19: Comparação entre o <i>SOC</i> previsto no <i>day-ahead</i> e o realizado com estratégia centralizada e descentralizada com discretização de 0,01kW. ....	82
Figura C.1: Diagrama de classe UML simplificado da plataforma SMA simulada.....	108
Figura C.2: Diagrama de sequência representando o período de mercado.....	111
Figura C.3: Diagrama de sequência mostrando exemplo de negociação entre agentes de mercado.....	112



# Lista de Tabelas

Tabela 1: Aplicabilidade das abordagens centralizadas e descentralizadas. Fonte: (Hatziargyriou, 2014).....	20
Tabela 2: exemplo de solução de problema de alocação com 3 vendedores e 3 compradores, com algoritmo de leilão simétrico. ....	59
Tabela 3: Tarifas de energia elétrica utilizadas nas simulações. Fonte: (Alvez, 2015). ....	67
Tabela 4 : Resultados da função objetivo e de custos reais. ....	71
Tabela 5: Custos reais previstos no <i>day-ahead</i> x realizados sem otimização de tempo real, para os primeiros seis intervalos de 5 minutos.....	74
Tabela 6: Custos reais previstos no <i>day-ahead</i> x realizados com otimização de tempo real com estratégia centralizada, para os primeiros seis intervalos de 5 minutos. ....	75
Tabela 7: Resultados da otimização de tempo real com estratégia multiagente, usando algoritmo de leilões, com discretização de 1 kW por Agente de Mercado.....	80
Tabela 8: Resultados da otimização de tempo real com estratégia multiagente, usando algoritmo de leilões, com discretização de 0,1 kW por Agente de Mercado. ....	81
Tabela 9: Resultados da otimização de tempo real com estratégia multiagente, usando algoritmo de leilões, com discretização de 0,01 kW por Agente de Mercado. ....	82
Tabela 10: Tempos de processamento para a solução do problema de tempo real, em diferentes estratégias, e sem o uso de escalonamento- $\epsilon$ .....	83
Tabela 11: Número de iterações, propostas e latência total estimada para a solução com estratégia SMA com resolução de 1 kW, considerando latência média da rede de 200 ms. ...	84
Tabela 12: Número de iterações, propostas e latência total estimada para a solução com estratégia SMA com resolução de 0,1 kW, considerando latência média da rede de 200 ms..	84
Tabela 13: Número de iterações, propostas e latência total estimada para a solução com estratégia SMA com resolução de 0,01 kW, considerando latência média da rede de 200 ms. ....	85
Tabela 14: Número de iterações, propostas e latência total estimada para a estratégia SMA com resolução de 0,01 kW, utilizando escalonamento- $\epsilon$ e latência média da rede de 200ms.....	86



# Capítulo 1

## Introdução

A energia elétrica se tornou um elemento essencial na vida moderna e para o desenvolvimento econômico e social. No entanto, o modelo tradicional de produção de energia elétrica, caracterizado pelo uso irrestrito de combustíveis fósseis, começa a mostrar sinais de esgotamento, sendo necessário encontrar alternativas que permitam atender à demanda crescente (Galvin *et al.*, 2009; Alvez, 2015; Hyams *et al.*, 2010; Munson, 2005).

O modelo atual das redes de energia elétrica é predominantemente centralizado, focado em grandes unidades de geração e extensas linhas de transmissão. Embora tenha funcionado bem por muitas décadas, este modelo vem demonstrando grande inércia frente aos recentes avanços tecnológicos (Falcão, 2009; Munson, 2005; Alvez, 2015).

A difusão de tecnologias de Geração Distribuída (GD) baseadas em fontes renováveis, como a solar e a eólica, vem tornando possível conceber novos modelos de negócios, com unidades geradoras distribuídas próximas aos locais de consumo, reduzindo as perdas na transmissão de energia, tornando as redes mais confiáveis e menos dependentes de grandes centrais de geração. Entretanto sua implementação também apresenta desafios e incertezas na medida em que o nível de penetração de tais Recursos Energéticos Distribuídos (REDs) aumenta, em função do maior nível de complexidade do gerenciamento de tais recursos (Alcântara, 2011; Galvin *et al.*, 2009; Montoya *et al.*, 2013; Falcão, 2009; Alves, 2016; Hatziargyriou, 2014).

O conceito de Microrrede (MR) inteligente de energia elétrica vem sendo considerado como peça fundamental para a transformação gradual das grandes redes de energia tradicionais nas avançadas Redes Inteligentes de Energia Elétrica (RIEE), ou *Smart Grids*. Na condição de sistemas elétricos de potência menores e dotados de sistemas de automação e inteligência computacional, as MRs inteligentes permitem reduzir a complexidade da integração de REDs renováveis à rede elétrica. Isto porque, ao serem integradas à grande rede de energia, geralmente no sistema de distribuição, a combinação de eletrônica de potência com sistemas de controle avançados permite às MRs comportarem-se como entidades controláveis únicas sob o ponto de vista da macrorrede, seja como uma fonte de corrente ou como uma carga, dessa forma ocultando a complexidade do gerenciamento dos REDs locais da grande rede. Espera-se que a evolução das redes elétricas atuais possa ocorrer gradualmente, com a crescente integração de MRs inteligentes, capazes de interagir de maneira efetiva com a tecnologia mais antiga das redes convencionais e com as novas tecnologias de GD (Farhangi, 2010; Amin & Schewe, 2007; Montoya *et al.*, 2013; Galvin *et al.*, 2009; Lasseter *et al.*, 2002; Olivares *et al.*, 2014).

Apesar de ser pesquisada há pelo menos duas décadas, e mesmo com todos os benefícios técnicos, econômicos, ambientais e sociais que se estima que a tecnologia das MRs possa promover, uma série de barreiras técnicas, regulatórias e econômicas ainda persistem, dificultando sua difusão, evidenciando a importância da condução de pesquisas e da implementação de protótipos (Montoya *et al.*, 2013; Borges, 2016; Katiraei *et al.*, 2008; Planas *et al.*, 2013).

Em particular, o problema do gerenciamento ótimo de energia em uma MR, que consiste no aproveitamento ótimo dos REDs nela inseridos, incluindo sistemas de armazenamento de energia, para atender a demanda local e vender eventuais excedentes, vem recebendo grande atenção dos pesquisadores. Trata-se de um problema complexo, de natureza não-linear e descontínua, e que exige solução automatizada em tempo real (Dimeas & Hatziargyriou, 2005; Katiraei *et al.*, 2008; Palma-Behnke *et al.*, 2013; Olivares *et al.*, 2014).

## 1.1. Justificativa e motivação

A tecnologia das MRs apresenta, portanto, uma série de vantagens técnicas na integração de REDs à rede de energia, sobretudo renováveis, e na manutenção de cargas críticas, sendo também considerada essencial para o futuro desenvolvimento das Redes Inteligentes de Energia Elétrica.

Embora muitas MRs já tenham sido implementadas com sucesso em diversos países, a maioria em campus universitários, com finalidades de pesquisa, o custo inicial ainda é considerado muito alto para a maioria dos consumidores, o que justifica o investimento em pesquisas na área, especialmente em sistemas de otimização, sobretudo em modo conectado (Dimeas & Hatziargyriou, 2005; Katiraei *et al.*, 2008; Palma-Behnke *et al.*, 2013; Olivares *et al.*, 2014; Planas *et al.*, 2013).

A simplificação e a eficiência dos sistemas de gerenciamento de energia, que em modo conectado têm geralmente como seu objetivo a minimização de custos, são vistas como necessidades primárias para a aceitação e a difusão das MRs no mercado (Katiraei *et al.*, 2008; Kwasinski *et al.*, 2016).

Os métodos de gerenciamento de energia são classificados em centralizados e descentralizados. A grande maioria das MRs já implementadas utilizam os primeiros que, em geral, têm se mostrado de mais fácil implementação e economicamente mais viáveis. Entretanto apresentam limitações, sobretudo em termos de sua escalabilidade, o que pode comprometer seu uso nos cenários de grande crescimento e desenvolvimento das MRs inteligentes (Planas *et al.*, 2013; Hatziargyriou, 2014; Katiraei *et al.*, 2008; Olivares *et al.*, 2014).

Diversos pesquisadores vêm demonstrando teoricamente a maior escalabilidade e flexibilidade dos métodos descentralizados. Esses, porém, em sua maioria, são ainda experimentais, sendo ainda implementados quase exclusivamente em MRs de teste ou de pesquisa. Muitas diferentes abordagens vêm sendo propostas e avaliadas. Em particular,

diversos autores vêm sugerindo a utilização das chamadas plataformas Multiagentes, desenvolvidas com base em um novo paradigma de desenvolvimento distribuído, como as mais adequadas para a implementação de soluções descentralizadas de gerenciamento, pelas suas conhecidas vantagens de flexibilidade, escalabilidade e resiliência. Simulações vêm indicando sua viabilidade e possível adequação a cenários prováveis para as próximas décadas. Esse novo paradigma de desenvolvimento, no entanto, está longe de ser considerado maduro, sendo ainda pouco utilizado em soluções comerciais reais. Pouco ainda se sabe sobre sua viabilidade prática e sua aplicabilidade e limitações em diferentes cenários, e como se comparam, em termos de eficácia e eficiência, com as estratégias centralizadas utilizadas atualmente (Planas *et al.*, 2013; Kantamneni *et al.*, 2015; McArthur *et al.*, 2007; Hatziargyriou, 2014).

Percebe-se, portanto, a importância do maior investimento na compreensão e no desenvolvimento das técnicas de gerenciamento de energia em MRs, sobretudo as descentralizadas, e na avaliação de sua eficácia, eficiência, limitações e aplicabilidade.

## **1.2. Objetivo**

O objetivo deste trabalho foi estudar modelos de gerenciamento ótimo de energia em MRs em modo conectado, com estratégias centralizadas e descentralizadas utilizando Sistemas Multiagentes (SMA).

### **1.2.1. Objetivos específicos**

Para o estudo dos modelos centralizado e descentralizado, os seguintes objetivos específicos foram estabelecidos:

1. Entender o problema de Gerenciamento Ótimo de Energia em MRs, com base nas principais propostas encontradas na literatura.
2. Avaliar a aplicação de SMAs ao problema de gerenciamento ótimo de energia em MRs.
3. Desenvolver modelos matemáticos para o gerenciamento centralizado e descentralizado de energia em uma MR típica, com base nos modelos propostos na literatura.
4. Implementar computacionalmente os modelos e avaliar sua aplicabilidade.

## **1.3. Estrutura do trabalho**

No Capítulo 2, apresenta-se a fundamentação teórica. Discute-se o conceito de MR, seus objetivos, características, aplicabilidades e desafios. Descreve-se, logo a seguir, o problema do gerenciamento ótimo de energia em MRs, e em seguida as duas estratégias de solução: centralizada e descentralizada. Em particular, apresenta-se o conceito de SMA, plataforma vista frequentemente como a mais indicada para a solução descentralizada, bem como alguns dos algoritmos de solução utilizados com a mesma. São apresentados os principais conceitos de

teoria dos leilões, e dos algoritmos fundamentados nesta teoria, os quais estão entre os mais utilizados em plataformas de SMAs, tendo sido selecionados para os testes neste trabalho.

No Capítulo 3, apresenta-se a formulação matemática desenvolvida para o problema do gerenciamento de energia em MRs. É, primeiramente, modelado como um problema de programação linear inteira-mista, utilizando-se técnicas de linearização, em dois estágios: solução preditiva, em janela deslizante, com horizonte de 24 horas (*day-ahead*); solução de tempo real, com horizonte de 5 minutos. Em seguida, apresenta-se o modelamento do problema de tempo real como um problema de alocação única, permitindo sua solução descentralizada, passível de implementação em plataforma de SMA.

No Capítulo 4, os modelos descritos no Capítulo 3 são testados por meio de simulações, aplicadas ao modelo típico de MR apresentado em Jeon *et al.* (2010). Os resultados dos testes são discutidos e analisados.

Finalmente, no Capítulo 5, apresenta-se a conclusão.

# Capítulo 2

## Fundamentação Teórica

### 2.1. Introdução

Neste capítulo, são apresentados os principais conceitos teóricos que fundamentam e justificam a pesquisa realizada.

O conceito de MR inteligente é apresentado, com um breve panorama de suas principais características, componentes, configurações típicas e aplicações.

Apresenta-se, então, o problema do gerenciamento ótimo de energia em MRs inteligentes, discutindo-se suas principais características, objetivos e fatores intervenientes. Busca-se fornecer a visão geral da relevância do problema e dos principais aspectos envolvidos no mesmo, ressaltando os mais relevantes no contexto atual.

Discute-se, a seguir, as principais estratégias de solução do problema do gerenciamento ótimo de energia. São descritas, brevemente, as principais características das estratégias centralizadas e descentralizadas, com suas vantagens e desvantagens e suas aplicabilidades, com base nas informações disponíveis na literatura.

Em seguida, descreve-se mais detalhadamente as estratégias centralizadas e descentralizadas, dando ênfase aos novos conceitos de plataformas de SMAs e suas aplicações em sistemas de potência, e em MRs inteligentes, em particular. Os algoritmos distribuídos frequentemente utilizados em plataformas de SMAs, para a solução do problema do gerenciamento de energia, são brevemente descritos e discutidos, dando-se ênfase aos algoritmos simétricos de leilão, selecionados para os testes realizados neste trabalho.

Descrevem-se os principais conceitos da Teoria dos Leilões, uma subárea da Teoria dos Jogos, que fundamenta o algoritmo simétrico de leilões utilizado neste trabalho. O algoritmo é descrito, mostrando-se sua fundamentação teórica, vantagens e limitações.

Finalmente, mostra-se como os algoritmos de leilões simétricos são aplicados ao problema do gerenciamento ótimo de energia em MRs.

### 2.2. Microrredes inteligentes

Existem diversas definições ligeiramente diferentes para o termo microrrede (MR), porém todas envolvem conjuntos de cargas, recursos de geração e armazenamento conectados para formar um pequeno sistema de energia. Segundo o DOE (Departamento de Energia dos Estados Unidos), uma MR é um grupo de cargas e Recursos Energéticos Distribuídos (REDs), interconectados dentro de fronteiras ou limites definidos, agindo como uma entidade

controlável única sob a perspectiva da rede elétrica (a macrorrede) (Montoya *et al.*, 2013; Lasseter, 2002; Lasseter *et al.*, 2002; Farhangi, 2010; Galvin *et al.*, 2009; Falcão, 2009).

A segmentação das grandes redes de distribuição em MRs inteligentes pode simplificar e tornar mais seguro o gerenciamento e controle das redes com grande penetração de GD. Além de simplificar a integração de microfones, tal segmentação também tem o potencial de facilitar a recuperação em casos de *blackouts* ou desastres, pois permite manter áreas da grande rede com recursos locais, particularmente com o uso de energias renováveis (Lasseter, 2002; Amin & Schewe, 2007; Montoya *et al.*, 2013; Kwasinski *et al.*, 2016; Falcão, 2009).

A capacidade de funcionar em modo ilhado, ou seja, desconectadas da rede de energia da empresa distribuidora local, é uma das principais características das MRs, tendo como principal motivação a garantia de fornecimento de energia a cargas críticas (Montoya *et al.*, 2013; Lasseter, 2002; Kwasinski *et al.*, 2016).

O modo ilhado pode ser intencional, planejado antecipadamente, ou consequência de falhas inesperadas na rede de energia. A automação da MR permite a desconexão de cargas não críticas quando necessário. Eliminada a condição motivadora da transição para esse modo, a MR pode ser reconectada à macrorrede, seguindo o procedimento adequado, sem maiores transtornos aos consumidores. A operação em modo ilhado é a que apresenta os maiores desafios, haja vista que as MRs atuais geralmente não são projetadas para operar muito tempo nesse modo (IEEE Standards Coordinating, 2011; Vandoorn *et al.*, 2013; Kwasinski *et al.*, 2016; Stadler *et al.*, 2015; Falcão, 2009; Hatziargyriou, 2014).

De fato, espera-se que as MRs operem, na maior parte do tempo, em modo conectado, denominado modo normal, sendo o modo ilhado denominado estado de emergência. Assim, é no modo conectado que se espera obter os principais benefícios das MR (Hatziargyriou, 2014).

Dentre os principais desafios técnicos para a difusão das MRs, podem ser citados: a integração *plug & play* de novos componentes; a escalabilidade dos sistemas de comunicação, monitoração e controle; o gerenciamento de grandes volumes de dados; e a otimização local dos REDs em tempo real em cada MR (Montoya *et al.*, 2013; Farhangi, 2010; Kwasinski *et al.*, 2016; Lasseter, 2002; Galvin *et al.*, 2009; Planas *et al.*, 2013; Falcão, 2009; IEEE Standards Coordinating, 2011; Hyams *et al.*, 2010; Borges, 2016).

O conceito de MR inteligente vem sendo pesquisado como uma alternativa para a integração de REDs de pequena escala (menos de 1MW) em sistemas de baixa tensão. Exemplos de REDs tipicamente incluem sistemas fotovoltaicos, microturbinas, células de combustível, sistemas de aproveitamento do biogás e sistemas de armazenamento de energia (SAEs) (Alvez, 2015; Montoya *et al.*, 2013; Berkeley Lab, 2016; Lasseter, 2002).

A Figura 2.1 mostra a arquitetura típica das MRs mais comuns. O controlador central, com sistema SCADA no qual é executada a aplicação do Gerenciador de Energia (*Energy Manager*), conecta-se com os Controladores Locais (CLs) dos REDs e os sistemas de proteção. Os CLs mantêm a estabilidade de tensão e frequência em tempo real de maneira autônoma, sem



a necessidade de se comunicarem entre si ou com o SCADA, com respostas na ordem de milissegundos, usando o método denominado *frequency droop*. O controlador central é o responsável pelo posterior ajuste fino dos valores de referência (*set points*), visando a otimização global do sistema, além de outras funções de gerenciamento, segurança e proteção. Sua atuação é mais relevante em modo conectado, sendo geralmente usado, no modo ilhado, apenas para coordenar a reconexão com a macrorrede (Lasseter, 2002; Lasseter *et al.*, 2002).

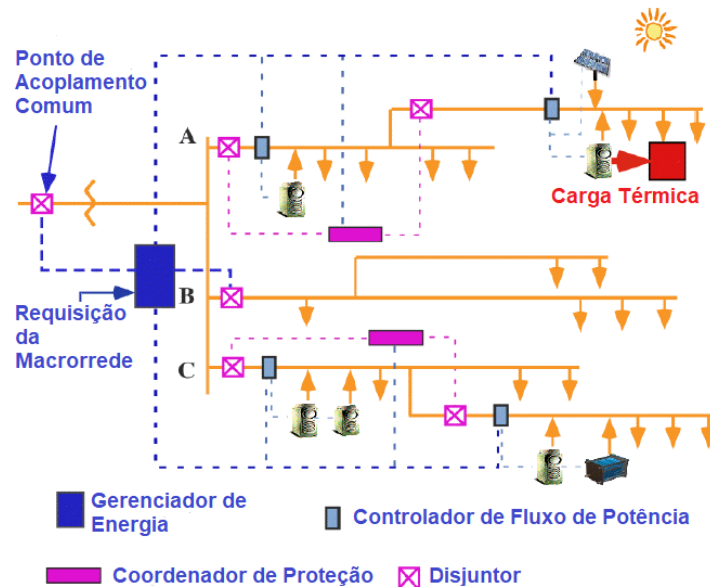


Figura 2.1. Arquitetura típica de MR inteligente. Fonte: adaptado de Lasseter (2002).

O sistema central de gerenciamento e controle assume as seguintes responsabilidades nos diferentes modos de funcionamento da MR (Vandoorn *et al.*, 2013; Kwasinski *et al.*, 2016; Lasseter, 2002; Olivares *et al.*, 2014; Katiraei *et al.*, 2008):

1. Modo conectado: minimizar custos de energia, garantindo a manutenção das reservas nos sistemas de armazenamento. Em alguns casos, observar também outros objetivos, como a minimização das emissões.
2. Modo ilhado: maximizar a segurança, a qualidade de energia e a disponibilidade do sistema, avaliando o momento adequado para a reconexão à macrorrede.
3. Modos de transição de conectado para ilhado ou ilhado para conectado: gerenciar a transição de maneira suave e segura.

As arquiteturas, configurações, dimensões, topologias e funcionalidades possíveis são extremamente diversas, podendo variar muito conforme a aplicação, custos, regulações e padronizações, que na medida em que forem evoluindo devem modificar muito os projetos de MRs, que precisarão se adaptar às novas condições (Montoya *et al.*, 2013; Hatziargyriou, 2014; Kwasinski *et al.*, 2016).

A arquitetura de controle mais centralizada, em geral, apresenta menor complexidade e menores custos. Entretanto, possui uma série de desvantagens, sobretudo no que se refere à sua escalabilidade, ou seja, capacidade de manter-se gerenciável e com bom desempenho sem custos proibitivos com o crescimento dos sistemas. Essas dificuldades tendem a se ampliar com o aumento do nível de automação dos sistemas de energia elétrica, e de dispositivos inteligentes interconectados. Nos sistemas mais descentralizados, geralmente implementados como SMAs, os CLs dos REDs e dispositivos de campo constituem agentes inteligentes, com autonomia para a tomada de decisões envolvendo seus subsistemas, e cooperando com os demais controladores na otimização global do sistema (Planas *et al.*, 2013; Kwasinski *et al.*, 2016; Kantamneni *et al.*, 2015; McArthur *et al.*, 2007; Khan *et al.*, 2016).

SMAs descentralizados, entretanto, como já referido, têm a desvantagem de apresentarem um custo computacional mais elevado, ao qual deve ser somado o fato de que ainda são considerados imaturos, implementados quase que exclusivamente em sistemas acadêmicos de testes ou emulados (Kantamneni *et al.*, 2015).

Dentre os diversos desafios apresentados para o gerenciamento e controle de MRs, o gerenciamento ótimo de energia vem recebendo maior atenção. Trata-se de problema de considerável complexidade e que exige solução automatizada de tempo real (Kantamneni *et al.*, 2015; McArthur *et al.*, 2007; Dimeas & Hatziargyriou, 2005; Katiraei *et al.*, 2008; Hatziargyriou, 2014).

### **2.2.1. Componentes de uma Microrrede**

Embora exista uma imensa variedade de tipos, arquiteturas e topologias diferentes de MRs, pode-se identificar alguns elementos comuns (Mahmoud *et al.*, 2015).

Com base na própria definição de MR, pode-se identificar como componentes essenciais a existência de REDs e cargas interconectadas. Também há a necessidade de um dispositivo de interconexão à microrrede elétrica, com sistemas de sincronização e ilhamento, permitindo à MR conectar-se e desconectar-se da rede de distribuição de energia (IEEE Standards Coordinating, 2011).

A seguir, são enumerados alguns dos elementos das MRs inteligentes (Mahmoud *et al.*, 2015; Galvin *et al.*, 2009; IEEE Standards Coordinating, 2011; Ravichandran *et al.*, 2013):

1. Interfaces de Eletrônica de Potência: permitem o controle em tempo real do fluxo de potência de fontes alternativas, como sistemas fotovoltaicos, microturbinas e geradores eólicos.
2. Medidores inteligentes: capazes de medir em tempo real e até mesmo antecipar a demanda dos consumidores, podendo enviar comandos a cargas inteligentes.
3. Sensores: permitem a monitoração contínua de todos os dispositivos críticos.

4. Dispositivos inteligentes (*Smart Devices*): dispositivos inteligentes e energeticamente eficientes são tão importantes quanto a geração e a distribuição para compor os sistemas de energia inteligentes.
5. Ponto de acoplamento comum (*Point of Common Coupling - PCC*): trata-se do ponto de acoplamento da MR à macrorrede.
6. REDs: as MRs mostram vantagens na simplificação da integração de REDs, sobretudo renováveis, às redes de energia.
7. Ponto de Acoplamento de RED: ponto onde ocorre a conexão de um RED à MR.
8. Dispositivo de interconexão de ilha (*Island Interconnection Device* ou IID): dispositivo que permite a separação da MR da macrorrede da concessionária.
9. Dispositivo de paralelização (*Paralleling Device*): dispositivo que permite conectar duas fontes de energia sob comando de uma função de sincronização (manual ou automática).
10. Sistema de Armazenamento de Energia (SAE): considerado essencial para manter a estabilidade, a confiabilidade, a disponibilidade e a qualidade da energia das MRs em modo ilhado.
11. Cargas: MRs podem alimentar diferentes tipos de cargas (residencial, industrial etc). Podem ser classificadas como cargas críticas ou despacháveis, estas últimas podendo ser controláveis ou não controláveis.
12. Sistemas de controle, comunicação e monitoração (*Monitoring, Information Exchange and Control* ou MIC): os diversos níveis hierárquicos das MRs modernas dependem de sistemas de controle e monitoração avançados.
13. Sistemas de proteção: podem assemelhar-se aos da rede da distribuidora, porém em MRs apresentam peculiaridades, representando ainda desafios tecnológicos.

As MRs permitem combinar diferentes REDs, com características diversas, buscando obter o melhor desempenho das fontes de energia locais. A seleção de quais REDs instalar em uma MR, entretanto, depende fundamentalmente da finalidade da MR a ser construída, e do contexto local (Olivares *et al.*, 2014; Alvez, 2015; Kwasinski *et al.*, 2016).

Considerando que os REDs são fontes de geração de energia elétrica, os mesmos tipicamente convertem uma fonte primária de energia em energia elétrica utilizando uma tecnologia de transformação, a qual é conectada à MR através de um dispositivo de sincronização, como mostrado na Figura 2.2. No caso de REDs acoplados eletronicamente, tem-se uma camada de conversão adicional representada pelo conversor ou inversor, que pode prover recursos adicionais de controle. Entre os REDs geralmente acoplados eletronicamente pode-se citar: microturbinas, turbinas eólicas de velocidade variável, sistemas fotovoltaicos, células de combustível e SAEs. No caso particular dos SAEs, em vez de uma fonte primária de energia, tem-se um meio de armazenamento (Katiraei *et al.*, 2008).

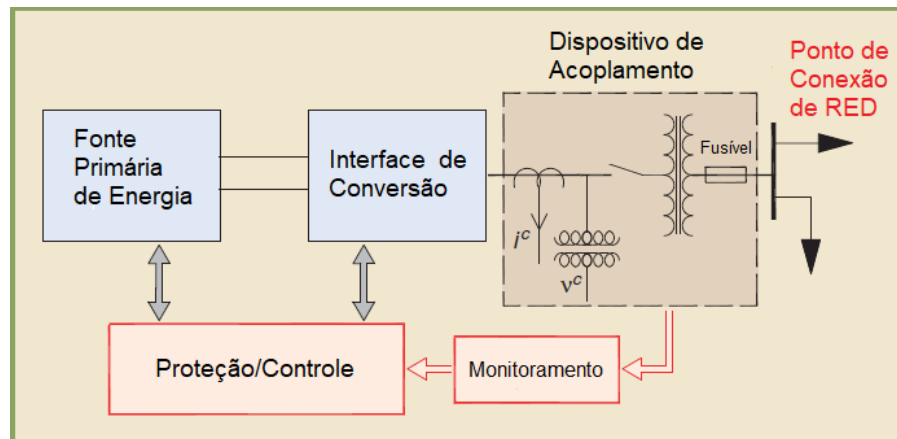


Figura 2.2: Diagrama representando um RED. Fonte: Adaptado de Katiraei *et al.* (2008).

Embora qualquer tipo de geração possa, em tese, ser utilizada em uma MR, o uso de sistemas de geração baseados em interfaces eletrônicas, como inversores inteligentes (*smart inverters*), permite maior flexibilidade e agilidade no controle de tensão e frequência, com um mínimo de equipamentos adicionais. Em particular, apresentam rápida resposta dinâmica. Entretanto, por não possuírem inércia, esses REDs não têm a tendência inerente para manter a estabilidade da frequência como as máquinas síncronas convencionais, o que, entretanto, pode ser emulado por meio das interfaces eletrônicas (Montoya *et al.*, 2013; Katiraei *et al.*, 2008).

Os REDs de uma MR podem também ser classificados em despacháveis, que podem ser plenamente controlados externamente (e.g. geradores a diesel ou microturbinas a gás), e não despacháveis, geralmente não controláveis, sendo geralmente configurados para operarem sempre em seus pontos de máxima transferência de potência, extraindo o máximo de suas fontes primárias. REDs com fontes primárias renováveis, como solar e eólica, são tipicamente não despacháveis, e naturalmente busca-se maximizar seu aproveitamento. Sua produção é geralmente intermitente, dependendo de variáveis meteorológicas, como a velocidade do vento e a irradiação solar (Olivares *et al.*, 2014; Katiraei *et al.*, 2008).

Em termos de controle do fluxo de potência, as unidades despacháveis podem ser de resposta rápida ou lenta. Pode-se também combinar diferentes fontes primárias ou unidades de armazenamento em REDs híbridos, acoplados à MR por meio de uma interface de potência única. Dessa forma, pode-se combinar, em um único RED híbrido, as potencialidades de REDs com diferentes características. Por exemplo, combinando-se células fotovoltaicas e baterias em um RED híbrido, tem-se um novo RED com fonte primária solar renovável, porém também despachável. Outro exemplo seria a combinação de uma unidade geradora de resposta lenta com um sistema de armazenamento capacitivo de resposta rápida, capaz de fornecer potência complementar de curto prazo durante a partida do gerador, ou durante a sua lenta aceleração ou desaceleração (Katiraei *et al.*, 2008).

Considera-se também como RED a resposta da demanda, que consiste basicamente no controle da demanda de maneira direta ou indireta, seja por parte dos usuários ou pela empresa distribuidora (Alvez, 2015).

### 2.2.2. Configurações típicas

A norma IEEE Std 1547.4, de 2011 (*IEEE Standards Coordinating*, 2011), representa um primeiro passo no sentido de buscar uma padronização para MRs, apresentando uma lista de recomendações de boas práticas para o projeto, a operação e a integração de MRs com o sistema elétrico local, ou seja, a macrorrede. A Figura 2.3 ilustra sete exemplos de topologias possíveis, descritas no referido documento, enumeradas a seguir:

1. Sistema Elétrico de Potência Ilhado Local: formado por recursos de geração e cargas normalmente presentes em uma instalação do consumidor. É o tipo mais simples e mais comum, atualmente. A instalação da MR do lado do consumidor, naturalmente simplifica as questões legais e regulatórias.
2. Sistema Ilhado Secundário: formado por um ou mais REDs e múltiplos consumidores conectados ao lado secundário de um transformador de distribuição.
3. Ilha Lateral: ilhas formadas de cargas normalmente servidas por um alimentador lateral.
4. Ilha de Circuito: ilha incluindo cargas normalmente servidas por um único circuito de distribuição.
5. Ilha de Barramento de Subestação: ilha incluindo cargas normalmente servidas por um único barramento da subestação, embora múltiplos barramentos possam ser usados para servir cargas de uma subestação.
6. Ilha de Subestação: ilha formada por cargas normalmente servidas por toda uma subestação.
7. Ilha de Circuito Adjacente: neste tipo de ilhamento, cargas de um circuito adjacente podem ser servidas por uma porção ilhada do circuito.

Cada uma dessas topologias tem diversas implicações econômicas e técnicas, que dependerão largamente das regras, normas, leis e regulações a serem estabelecidas para governarem as MRs (Montoya *et al.*, 2013; IEEE Standards Coordinating, 2011; Borges, 2016).

### 2.2.3. Tipos de Microrredes

As MRs geralmente são classificadas de acordo com suas funcionalidades e não quanto a seu tamanho. Há, entretanto, grande variação também no que concerne às suas dimensões, recursos e abrangência. A dificuldade em definir qual critério utilizar para classificar uma MR quanto ao seu tamanho, se é pelo número de REDs, a área abrangida, número de consumidores, potência ou outros, torna o tamanho um critério pouco útil na prática (Montoya *et al.*, 2013; Institute, 2018).

Abaixo, são enumerados alguns critérios de classificação comuns (Montoya *et al.*, 2013; Peter Lilienthal, 2013; IEEE Standards Coordinating, 2011; Guerrero *et al.*, 2013):

1. Conexão: se a MR é conectável à macrorrede, ou se funciona sempre em modo ilhado. Se possui um único ponto de acoplamento (PCC) ou mais de um.
2. Tipos de REDs: se inclui REDs despacháveis controláveis, REDs renováveis, não despacháveis, SAEs, etc.
3. Nível de tensão da rede de distribuição: nível médio ou baixo, de Corrente Alternada (CA) ou Corrente Contínua (CC), ou híbrido.
4. Fases: mono ou trifásico.
5. Medição: medição tradicional com medidores eletromecânicos, com medidores inteligentes, remotos ou não, etc.
6. Balanço de energia: se a MR tem capacidade de funcionar de maneira autossuficiente quando ilhada ou não. Se o fluxo médio de potência entre a MR e a macrorrede, em determinado período (geralmente anual), é positivo, negativo ou nulo (*net zero*), etc.
7. Topologia: as configurações típicas foram discutidas na Seção 2.2.2.
8. Inteligência: as MRs são muitas vezes classificadas em inteligentes, que fazem uso dos modernos recursos da tecnologia, e não inteligentes, com sistemas mais tradicionais, geralmente eletromecânicos e mais antigos.

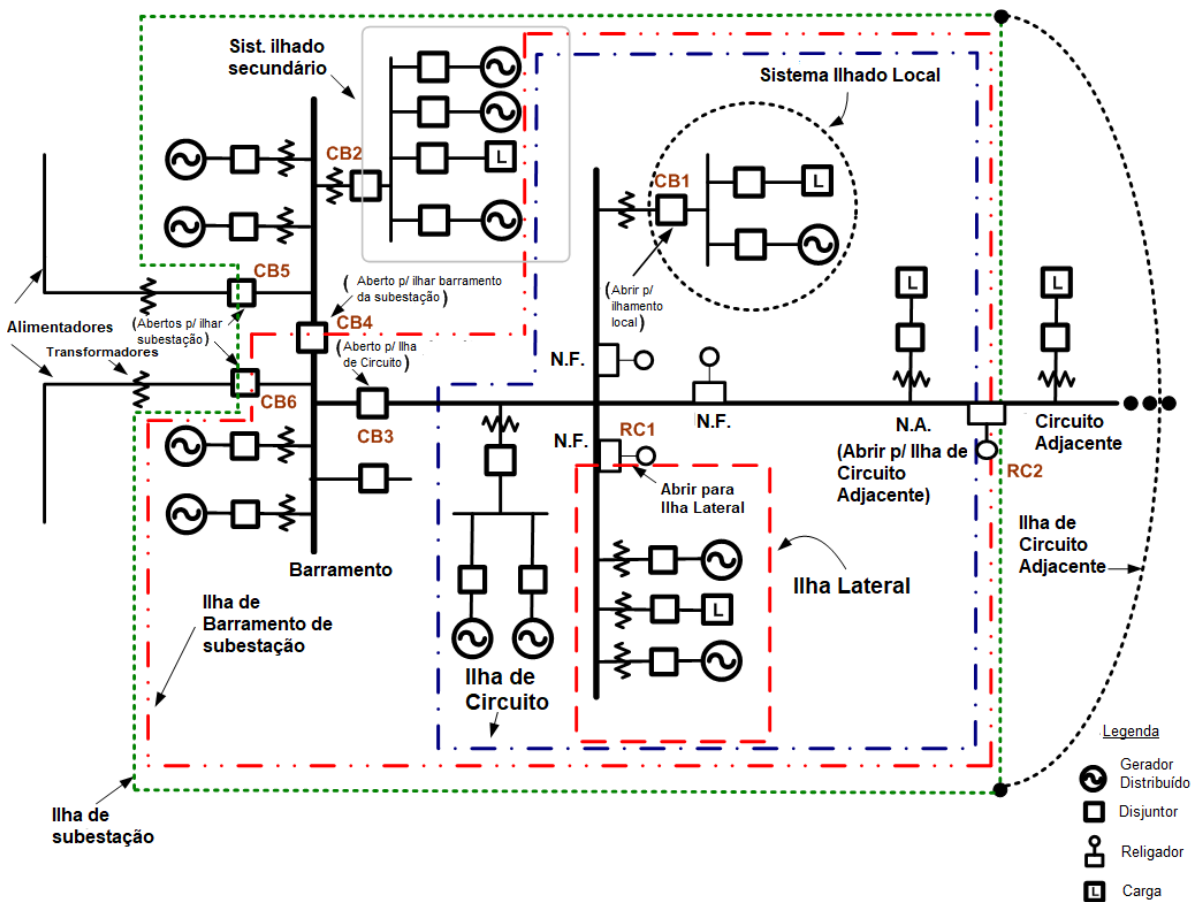


Figura 2.3: Topologias de MRs. Fonte: Adaptado de IEEE Standards Coordinating (2011).

## 2.3. Gerenciamento ótimo de energia em Microrredes inteligentes

O problema do gerenciamento ótimo de energia em uma MR consiste no aproveitamento dos REDs disponíveis e da energia importada ou exportada da macrorrede, a fim de atender à demanda local, respeitando as restrições do sistema, buscando-se a minimização dos custos. Muitos autores consideram também outros objetivos, entre os quais: a minimização das emissões de combustíveis fósseis; a redução das perdas; fornecimento de energia com qualidade diferenciada; aumento da confiabilidade e resiliência; etc. Tem-se com isso um problema de otimização multiobjetivo (Olivares *et al.*, 2014; Katiraei *et al.*, 2008; Chaouachi *et al.*, 2013).

A Figura 2.4 apresenta, de forma esquemática, o problema do gerenciamento ótimo de energia em uma MR (Cirrincione *et al.*, 2009; Kwasinski *et al.*, 2016; Bhavé, 2016; Dou *et al.*, 2016).

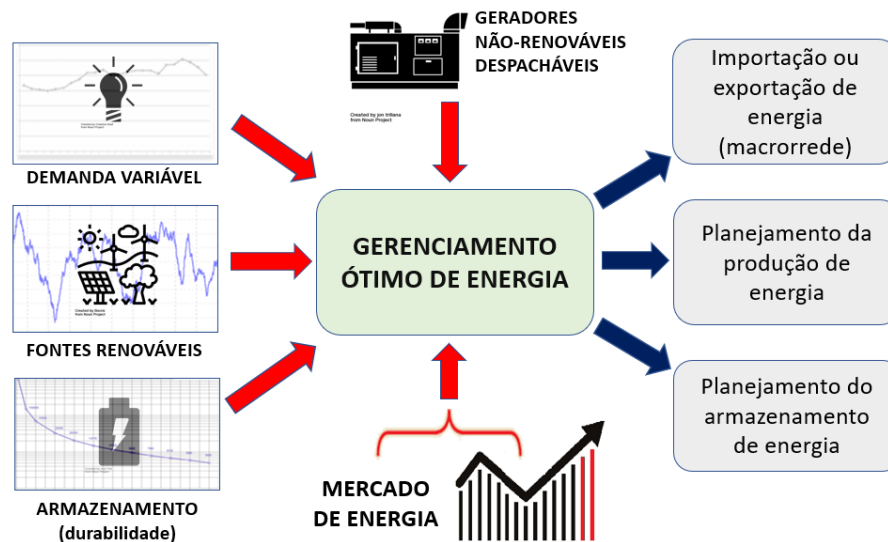


Figura 2.4. Diagrama do gerenciamento energia em uma MR. Fonte: Adaptado de Katiraei *et al.* (2008).

O objetivo do gerenciamento de energia nas MRs depende muito do propósito da MR. A motivação inicial foi o atendimento a cargas críticas e este continua a ser o principal motivador de muitas MRs, sobretudo nos Estados Unidos, embora MRs comerciais com a finalidade de prover níveis diferenciados de qualidade de energia, ou de promover maior integração de REDs renováveis com finalidades ambientais, venham despertando interesse crescente, sobretudo na União Europeia e no Japão (Kwasinski *et al.*, 2016; Lasseter, 2002).

As MRs geralmente integram diferentes REDs, o que pode lhes conferir maior autonomia, em comparação aos sistemas tradicionais de *backup* de energia. Entretanto os altos custos de implantação dos mesmos tornam extremamente relevante a gestão ótima de tais recursos para a viabilização comercial das MRs. Por este motivo, em modo conectado, no qual as MRs se

mantêm na maior parte do tempo, geralmente prioriza-se a minimização dos custos. Isto porque pode-se contar com a macrorrede, que funciona na condição de barramento infinito equilibrado (*slack bus*), absorvendo quaisquer desequilíbrios entre oferta e demanda e garantindo a estabilidade (Katiraei *et al.*, 2008; Vandoorn *et al.*, 2013; Kwasinski *et al.*, 2016; Lasseter, 2002; Jiang *et al.*, 2013).

Já no modo ilhado é preciso considerar outras prioridades, como a segurança, a qualidade da energia, a disponibilidade do sistema e a manutenção da estabilidade da tensão e da frequência, sendo a redução de custos menos prioritária. A manutenção de reservas adequadas de energia, neste modo, é de fundamental importância para a garantia da estabilidade e a prevenção do colapso (Pulcherio *et al.*, 2016; Colson & Nehrir, 2009; Lasseter, 2002; Vandoorn *et al.*, 2013; Jiang *et al.*, 2013; Kwasinski *et al.*, 2016).

O balanceamento de múltiplos geradores e cargas, a interação de componentes controláveis e não-controláveis e a natureza dinâmica das características das MRs, envolvendo restrições como a disponibilidade de combustíveis, incertezas quanto a variáveis meteorológicas, previsões de demanda e as variações de preços de energia, tornam o gerenciamento de energia um grande desafio. Os sistemas de gerenciamento de MRs, dependendo de fatores como o tipo e penetração de REDs e as características de suas cargas, podem diferir muito dos sistemas de potência convencionais. Entre os principais fatores responsáveis por essas diferenças pode-se citar (Katiraei *et al.*, 2008; Colson & Nehrir, 2009):

- As características de regime permanente e transitório dos REDs das MRs podem diferir muito das grandes máquinas síncronas dos sistemas de potência convencionais.
- MRs estão sempre sujeitas a significativos desbalanceamentos, devido à presença de cargas e/ou REDs monofásicos.
- Significativas porções da oferta de energia dentro de uma MR podem vir de fontes não-controláveis, como as fontes renováveis intermitentes (eólica, solar, etc).
- O controle e a operação de MRs geralmente dependem de maneira relevante de SAEs de curto e longo prazos.
- Fatores econômicos frequentemente requerem a rápida conexão e desconexão de REDs e cargas, com a MR sendo mantida em operação.
- MRs podem ter a necessidade de fornecer níveis mais elevados de qualidade de energia ou outros serviços diferenciados para cargas específicas.
- Além de energia elétrica, MRs podem ter a necessidade de fornecer energia térmica para algumas ou todas as suas cargas.

O gerenciamento ótimo de energia depende necessariamente das previsões de oferta e demanda de energia, em determinado horizonte de tempo. Ambas são consideravelmente mais complexas em MRs, se comparadas aos grandes sistemas de potência convencionais. A oferta de energia frequentemente envolve fontes renováveis intermitentes, cuja produção depende de variáveis meteorológicas. Por outro lado, a curva de carga em uma MR, com menor número de



cargas e delimitação geográfica, geralmente se apresenta muito menos suave, com padrões abruptos e atípicos, exigindo a aplicação de técnicas avançadas de inteligência artificial (Hernandez *et al.*, 2014; Carvalho, 2017; Hernandez *et al.*, 2013).

A suavização da curva de carga também pode ser alcançada por meio de estratégias de resposta da demanda, sobretudo nas MRs inteligentes mais automatizadas do futuro, cujas cargas inteligentes (*smart devices*) podem se comunicar com o sistema de gerenciamento, como já mencionado (Katiraei *et al.*, 2008; Falcão, 2009; Galvin *et al.*, 2009).

Em condições de ilhamento, quando a oferta de energia não for suficiente para atender com segurança a demanda local, o gerenciador de energia pode realizar o corte de cargas não críticas, estratégia necessária sobretudo com cargas não críticas e não controláveis. O corte de cargas pode também ser necessário em modo conectado para atender a contratos restritivos de importação e exportação de energia com a empresa local de energia, sendo necessário estabelecer uma hierarquia ou escala de prioridades entre as cargas do sistema (Lasseter, 2002; Katiraei *et al.*, 2008).

Tendo em vista os baixos custos operacionais de fontes renováveis como a solar e a eólica, além dos benefícios ambientais, naturalmente busca-se priorizar o atendimento da demanda por meio de tais fontes. Tratando-se de fontes não-controláveis e intermitentes, entretanto, nem sempre será possível atender a demanda local com esses REDs, sendo necessário complementá-las importando energia da macrorrede, utilizando reservas dos SAEs, acionando unidades geradoras não-renováveis, ou combinando diferentes estratégias (Katiraei *et al.*, 2008).

Da mesma forma, pode-se ter a ocorrência de excedentes de energia em determinados horários, como, por exemplo, picos de geração de energia solar ao meio-dia, em residências cujo pico de demanda ocorre no final da tarde. O excedente de energia produzida pelas fontes renováveis pode ser exportado para a distribuidora, gerando créditos ou receita, ou armazenado em um SAE, para uso posterior ou para vender à macrorrede em horário de ponta (Katiraei *et al.*, 2008).

Além de serem um recurso essencial em modo ilhado, para a manutenção da estabilidade e disponibilidade da MR, os SAEs também desempenham um papel importante na otimização de custos em modo conectado, promovendo a suavização das flutuações geradas pela intermitência das fontes renováveis, podendo, assim, melhorar a qualidade de energia. A estratégia de carregamento e descarregamento desses sistemas precisa levar em consideração os custos de oportunidade, conforme a variação de preços no mercado de energia, sendo possível armazenar energia nos horários em que esta é mais barata, ou quando houver excedente de produção das fontes renováveis não-controláveis e exportá-la ou utilizá-la nos horários de ponta, nos quais a energia é mais cara, ou ainda quando houver maior demanda ou redução da produção das fontes renováveis (Palma-Behnke *et al.*, 2013; Olivares *et al.*, 2014; Montoya *et al.*, 2013; Berrada & Loudiyi, 2016; Galvin *et al.*, 2009).

A estratégia de armazenamento de energia também deve ser planejada para maximizar a vida útil de cada dispositivo de armazenamento, considerando os altos custos de investimento exigidos na instalação de tais dispositivos (Alvez, 2015; Olivares *et al.*, 2014).

As estratégias para a maximização da vida útil dos SAEs dependem da tecnologia dos mesmos. A maximização da vida útil das baterias, por exemplo, atualmente o tipo mais comum de SAE em MRs, depende de diversos fatores, sobretudo da sua tecnologia, da profundidade do ciclo de descarga e do número de ciclos de carga e descarga. Fatores como a temperatura de operação, o nível das potências de carregamento e descarregamento, tensão e corrente têm relevância, entre outros. Trata-se de um problema não-linear e de considerável complexidade (Zhou *et al.*, 2011; Palma-Behnke *et al.*, 2013; Galvin *et al.*, 2009).

Além de depender das previsões de oferta e demanda de energia, o gerenciamento ótimo de energia em MRs depende também de conhecer a modalidade tarifária acordada com a distribuidora ou empresa local de energia, e as previsões de tarifas para as próximas 24 horas. Isto é importante sobretudo para os SAEs, tendo em vista sua natureza intertemporal (Katiraei *et al.*, 2008; Farzan *et al.*, 2013; Gu *et al.*, 2014).

Espera-se que, com o avanço das RIEEs, ocorra gradualmente uma revisão da estrutura regulatória e tarifária do mercado de energia. Com redes de energia estruturadas como grandes redes de MRs inteligentes interligadas, dotadas de capacidades avançadas de comunicação e processamento de informações, pode-se otimizar não apenas a oferta, mas também a demanda, por meio de diversas estratégias. Espera-se que as MRs do futuro possam responder em tempo real a sinais de preços de energia, solicitações de serviços ancilares e de redução de demanda da macrorrede, podendo também vender energia para ela, tornando os atuais consumidores de energia em prosumidores, capazes de consumir e produzir energia (Falcão, 2009; Jiang *et al.*, 2013).

Cabe ressaltar que a regulamentação vigente atualmente no Brasil ainda não permite aos consumidores cativos vender energia à distribuidora. Permite-se apenas a geração de créditos de energia, inovação estabelecida pela resolução normativa nº 482/2012 da Agência Nacional de Energia Elétrica. Segundo essa resolução, sempre que a energia injetada na rede for maior que a consumida, o consumidor receberá um crédito em energia (kWh) que poderá ser utilizado para abater o consumo, preferencialmente no mesmo posto horário, em um período de até 60 meses (ANEEL, 2012).

Além das fontes renováveis e dos SAEs, as MRs frequentemente incluem geradores não-renováveis despacháveis. Os geradores a combustão interna, geralmente usando combustíveis fósseis, representam ainda a tecnologia de geração distribuída mais difundida, apesar da baixa eficiência e das emissões de poluentes. Isso ocorre em função do baixo custo de investimento inicial em relação a outras tecnologias. Em MRs, geradores a combustão interna se mostram muito úteis devido à flexibilidade que proporcionam, à relativa rápida resposta dinâmica, da sua facilidade de transporte e da disponibilidade de combustível (geralmente diesel ou gás natural) (Kwasinski *et al.*, 2016).

Em modo conectado, as unidades geradoras a combustão interna podem manter a potência constante, em níveis planejados pelo Gerenciador de Energia, independente de flutuações na demanda, já que quaisquer desequilíbrios momentâneos entre oferta e demanda podem ser absorvidos pela macrorrede. Já em modo ilhado, os REDs precisam sempre participar no balanço de potências e na manutenção da estabilidade do sistema, em geral empregando o método *droop* de frequência ou tensão (Ahn *et al.*, 2009; Katiraei *et al.*, 2008).

Com custos marginais maiores que o da energia importada da macrorrede, os geradores a combustão interna são mais frequentemente utilizados como reserva para o caso de ilhamento. O uso de tais REDs em modo conectado, entretanto, pode justificar-se quando o preço de mercado da energia se mostrar muito alto em horários de ponta, ou se houver contratos muito restritivos quanto ao fluxo de energia entre a MR e a macrorrede. Podem, por exemplo, ser usados para evitar condições de ultrapassagem da demanda contratada, quando esta existir, devido aos elevados valores de multa. Isto pode ocorrer caso as reservas dos SAEs não sejam capazes de suprir o excedente de demanda sem incorrer na condição da ultrapassagem. Nesses casos, cabe ao sistema gerenciador de energia determinar os níveis de produção de energia de cada unidade geradora da MR em cada intervalo de tempo, de maneira a minimizar os custos. Esse problema de otimização, tradicionalmente conhecido como Despacho Econômico, problema de considerável complexidade, de natureza não linear e também descontínua, nas MRs vem sendo tratado como gerenciamento ótimo de energia (Ahn *et al.*, 2009; Palma-Behnke *et al.*, 2013; Jiang *et al.*, 2013; Kwasinski *et al.*, 2016).

Os geradores a combustão, por serem flexíveis e controláveis, são muito úteis em condições de ilhamento. Entretanto apresentam a desvantagem de, em situações de calamidades públicas, dependerem muitas vezes de complexa logística para o abastecimento e estoque de combustíveis. O sistema de gerenciamento de energia, particularmente nessas situações, precisa considerar as incertezas quanto à disponibilidade e variações de custos de combustíveis. Em tais situações, as MRs têm se mostrado especialmente interessantes, por integrar REDs renováveis, que geralmente não demandam logística complexa (Montoya *et al.*, 2013; Kwasinski *et al.*, 2016).

Os altos custos das MRs, uma das principais barreiras para a difusão desta tecnologia, decorrem tipicamente dos altos custos dos REDs. Por isso, a manutenção dos REDs em faixas de operação com alto rendimento é essencial. Por este mesmo motivo, em muitos casos, sobretudo em MRs com cargas térmicas, o uso de técnicas de cogeração, nas quais o calor gerado como subproduto por REDs que produzem aquecimento, como geradores a combustão ou células a combustível, são reaproveitados para abastecer cargas térmicas. Considera-se o uso da cogeração, atualmente, como mandatário para a viabilidade econômica de MRs com cargas térmicas (Gu *et al.*, 2014; Basu *et al.*, 2011; Kwasinski *et al.*, 2016).

Estudos vêm demonstrando a capacidade das MRs de participarem não apenas no mercado de energia, mas também no de serviços auxiliares, sobretudo, mas não somente, utilizando geradores com motores a combustão interna, a gás ou a diesel, devido à capacidade,

controlabilidade e responsividade desses REDs. As técnicas matemáticas para incluir a manutenção de reservas para a participação nesse mercado no cálculo de otimização de *day-ahead* são já bem conhecidas para o mercado norte-americano, por se assemelharem muito às técnicas de cootimização já utilizadas por operadores independentes (*ISO – Independent System Operators*), sendo consideradas como responsabilidade do Gerenciador de Energia da MR, quando esta fornecer tais serviços. No Brasil, em particular, os estudos sobre os possíveis impactos da participação das MRs no mercado de serviços ancilares ainda têm sido considerados incipientes, porém estima-se que as MRs tenham potencial de trazer grandes benefícios ao sistema elétrico do país provendo tais serviços (Farzan *et al.*, 2013; Basu *et al.*, 2011; Katiraei *et al.*, 2008; Gil & Joos, 2008; Kueck *et al.*, 2003; Borges, 2016; Tenfen *et al.*, 2013; Asano & Bando, 2008; Costa *et al.*, 2007).

## **2.4. Estratégias para o Gerenciamento de Energia em Microrredes**

As estratégias para tratar o problema do gerenciamento de energia de uma MR podem ser classificadas como centralizadas e descentralizadas (Hatziargyriou, 2014; Olivares *et al.*, 2014).

A escolha da melhor abordagem para uma MR específica depende de diversos fatores, sobretudo da finalidade ou função da MR, suas características, suas dimensões e da disponibilidade de recursos (Hatziargyriou, 2014).

Em um sistema de gerenciamento totalmente centralizado, toda a informação relevante para a solução do problema precisa ser fornecida a uma unidade de controle central da MR, o MGCC (*Microgrid Central Controller*), onde roda o SCADA central, que determina a solução ótima e responde a cada unidade do sistema com comandos detalhados das ações a serem tomadas. Com isso, pode-se determinar a solução ótima com mais facilidade e precisão. A estratégia centralizada é geralmente mais simples e mais barata de ser implementada em sistemas de menor porte, por não exigir redundâncias, sendo atualmente a mais utilizada (Lasseter, 2002; Olivares *et al.*, 2014; Kwasinski *et al.*, 2016).

A estratégia centralizada, entretanto, exige a construção de sistema de comunicação com grande capacidade e confiabilidade, cujo mau funcionamento pode inviabilizar a gestão da MR. Cabe ressaltar que o próprio MGCC representará também um ponto único de falha, exigindo-se do mesmo uma confiabilidade também maior, o que implica geralmente em maiores custos. Isso pode inviabilizá-la em MRs de grandes dimensões, que se estendam por grandes áreas, e incluam um grande número de REDs. Além disso, na medida em que o número de recursos distribuídos cresce em uma MR, exige-se cada vez mais capacidade computacional do MGCC, o qual pode se tornar um gargalo, não conseguindo prover as soluções e comandos necessários em tempo hábil, além dos altos investimentos exigidos (Hatziargyriou, 2014; Kwasinski *et al.*, 2016).

Outro aspecto a ser considerado é que os sistemas centralizados exigem o conhecimento completo e antecipado de toda a arquitetura da MR, sendo mais difíceis de implementar e manter no caso de MRs com grande número de componentes e diferentes consumidores e que crescem com base em seus interesses diversos, sem um planejamento centralizado. As modificações nos sistemas centralizados tipicamente exigem mão de obra qualificada para a reconfiguração do sistema a cada modificação, o que aumenta também seus custos (Hatziaargyriou, 2014; Kantamneni *et al.*, 2015).

As estratégias centralizadas também são mais recomendadas em MRs com um único proprietário, ou com vários proprietários com objetivos muito bem definidos e estáveis, sobretudo quando a determinação do ótimo global for relevante, como ocorre, por exemplo, em instalações industriais, onde há maior ênfase na redução de custos. Além disso, tornam mais simples a implementação de algoritmos de otimização mais complexos e sofisticados, buscando obter o máximo proveito do contexto local e de regras e condições específicas de mercado (Hatziaargyriou, 2014).

As soluções centralizadas se mostram mais complexas quando não há um objetivo único e bem definido, o que pode ocorrer em MRs com muitos proprietários com características e interesses diversos, eventualmente conflitantes e mutáveis. É o caso, por exemplo, de MRs com grande número de consumidores domésticos. A necessidade de contemplar muitos objetivos aumenta os custos computacionais da solução centralizada, além de aumentar a complexidade do modelo, podendo inviabilizar a determinação da solução ótima global por um controlador único centralizado. Nesses contextos, as vantagens em termos de custos e flexibilidade podem justificar soluções descentralizadas, mesmo que não seja possível garantir a solução ótima, nos casos em que seja suficiente a obtenção de soluções sub ótimas (Hatziaargyriou, 2014).

Nos sistemas totalmente descentralizados a otimização ocorre por meio da negociação entre os diferentes agentes do sistema, representados pelos CLs dos diversos REDs. Cada controlador tem acesso apenas às informações relativas a seus sistemas locais, sem o conhecimento completo do estado das demais variáveis do sistema ou dos demais controladores. Não há uma unidade central fornecendo ordens detalhadas a todos os componentes do sistema. Soluções intermediárias de compromisso, não totalmente centralizadas nem descentralizadas, são possíveis por intermédio de sistemas hierárquicos (Olivares *et al.*, 2014; Katiraei *et al.*, 2008; Kantamneni *et al.*, 2015).

Outro aspecto a considerar é a abertura a diferentes fornecedores de tecnologias. Em uma solução centralizada, todos os elementos da MR precisarão ser compatíveis com a tecnologia adotada pelo fornecedor do MGCC, com quaisquer inclusões ou exclusões de componentes exigindo sua reconfiguração por pessoal especializado. No caso das soluções descentralizadas, entretanto, pode-se ter componentes *plug-and-play*, com os fornecedores de componentes seguindo regras claras padronizadas, implementando agentes inteligentes, ou seja, CLs com inteligência computacional em seus componentes, que se integrem com facilidade à MR pré-

existente, reduzindo-se assim a necessidade de equipes técnicas especializadas para essas atividades (Hatziargyriou, 2014; McArthur *et al.*, 2007).

Portanto, com o esperado crescimento do número de MRs inteligentes interligadas no mercado, com o advento das RIEE avançadas, os pesados investimentos exigidos para a instalação de sistemas dedicados de comunicação, com grande confiabilidade e banda disponível, bem como de equipes especializadas e dedicadas, provavelmente as soluções centralizadas se tornarão menos atrativas. Assim, espera-se que as soluções descentralizadas ganhem espaço, podendo ser integradas gradualmente, convivendo com as soluções mais antigas e aproveitando a infraestrutura pré-existente (Hatziargyriou, 2014).

A Tabela 1 sintetiza os principais aspectos a avaliar, ao selecionar uma das duas abordagens.

Tabela 1: Aplicabilidade das abordagens centralizadas e descentralizadas. Fonte: (Hatziargyriou, 2014).

	<b>Solução Centralizada</b>	<b>Solução Descentralizada</b>
Propriedade	Proprietário único	Múltiplos proprietários
Objetivos	Objetivo único (e.g. minimizar custos)	Objetivos múltiplos, incertos e potencialmente mutáveis a cada momento
Equipes técnicas de operação especializadas	Disponíveis	Não disponíveis
Participação de mercado	Implementação de algoritmos complexos de otimização	Proprietários com pouco interesse em algoritmos de otimização muito complexos
Instalação de novos componentes	Exigência de técnicos especializados	Componentes <i>plug-and-play</i>
Otimalidade	Exigência de soluções ótimas	Soluções sub ótimas geralmente aceitáveis
Exigências de requisitos dos sistemas de comunicação	Grandes	Modestas

## 2.5. Gerenciamento de energia em Microrredes com estratégia centralizada

Nas arquiteturas hierárquicas centralizadas o gerenciamento ótimo de energia é feito pelo controlador central, utilizando diferentes níveis ou camadas, geralmente incluindo as três descritas a seguir (Lasseter, 2002; Stadler *et al.*, 2015; Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M. Khambadkone, 2012):

1. Nível de campo: emprega-se geralmente o método *droop* para o compartilhamento da carga em tempo real entre os CLs dos REDs, de maneira autônoma. Os CLs obedecem a comandos do controlador central, visando sua otimização (Planas *et al.*, 2013; Kwasinski *et al.*, 2016; Lasseter, 2002; Lasseter *et al.*, 2002).
2. Nível de gerenciamento: o controlador central faz a otimização do uso dos REDs, que tipicamente ocorre em dois níveis: curto prazo (minutos ou horas) e longo prazo (dias ou semanas) (Stadler *et al.*, 2015; Lasseter, 2002; Lasseter *et al.*, 2002; Planas *et al.*, 2013).
3. Nível analítico ou de rede: esse nível é responsável pela interação e coordenação das ações da MR com a macrorrede e seu operador ou operadores de mercado. Espera-se que, nas futuras RIEEs, este nível permita o gerenciamento de múltiplas MRs interconectadas (Stadler *et al.*, 2015; Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M. Khambadkone, 2012; Palma-Behnke *et al.*, 2013).

Usualmente, tem-se o sistema SCADA no controlador central (nível de gerenciamento) como o responsável pelo gerenciamento ótimo de energia. Esse sistema lê periodicamente, fazendo uma varredura ou *scan*, todas as variáveis relevantes de todos os REDs e demais componentes do sistema, determinando um planejamento ótimo de alocação dos REDs da MR e a quantidade de energia a ser importada ou exportada para a macrorrede. Esse plano se constitui em valores de referência ou ponto de operação (*set points*) que são a seguir enviados aos REDs, que passam a executar o plano, geralmente para as próximas 24 horas, sendo por isso chamado de *day-ahead*. Frequentemente utiliza-se uma janela deslizante, com o gerenciador de energia rodando o algoritmo de otimização a cada intervalo específico de alguns minutos e realizando em seguida o ajuste dos *set points* dos REDs (Lasseter, 2002; Katiraei *et al.*, 2008; Planas *et al.*, 2013; Stadler *et al.*, 2015; Palma-Behnke *et al.*, 2013; Olivares *et al.*, 2014).

A camada de rede permite a interação com a macrorrede e recursos analíticos, fornecendo as sinalizações de preços do operador de mercado para a MR, bem como requisições do sistema da macrorrede, como de serviços ancilares, ilhamentos sob demanda e outros (Planas *et al.*, 2013; Montoya *et al.*, 2013; Falcão, 2009; Stadler *et al.*, 2015).

## 2.6. Gerenciamento ótimo de energia descentralizado

Diversos autores vêm destacando as estratégias de gerenciamento utilizando SMAs em MRs como a melhor abordagem para o gerenciamento descentralizado de energia (Planas *et al.*, 2013; Kantamneni *et al.*, 2015; Dimeas & Hatziaargyriou, 2005; McArthur *et al.*, 2007).

Várias alternativas de estratégias SMA foram propostas e testadas em ambientes de simulação, porém pouco se sabe sobre a sua escalabilidade e confiabilidade em sistemas reais. A seguir, será apresentada uma breve introdução ao conceito de SMAs e sua aplicação aos sistemas de monitoração e controle de MRs (Kantamneni *et al.*, 2015; McArthur *et al.*, 2007; Bhawe, 2016; Dou *et al.*, 2016; Khan *et al.*, 2016).

### 2.6.1. Sistemas Multiagente

Sistemas Multiagente (SMAs) são sistemas desenvolvidos com base em um novo paradigma de desenvolvimento distribuído de sistemas, chamado de Programação Orientada a Agentes (em inglês, *Agent-Oriented Programming* ou AOP). Nesse novo paradigma, as aplicações são modeladas pela interação de coleções de componentes chamados “agentes”, componentes estes caracterizados por uma série de atributos, dos quais se destacam a autonomia flexível, proatividade e a capacidade de se comunicar, cooperar e competir com outros agentes (Bellifemine *et al.*, 2007; McArthur *et al.*, 2007).

Não há ainda consenso na literatura sobre como definir um SMA, assim como não há consenso para o que seria um agente. Entretanto, é possível perceber aspectos em comum entre as principais definições encontradas na ciência da computação, que envolvem quase sempre entidades de *software* ou *hardware* inseridas em um ambiente, com autonomia para reagir ao mesmo. De acordo com Shoham & Leyton-Brown (2009):

sistemas multiagentes são aqueles que incluem múltiplas entidades autônomas com informações ou interesses divergentes, ou ambos (Shoham & Leyton-Brown, 2009; McArthur *et al.*, 2007; Dimeas & Hatziargyriou, 2005).

Em SMAs não há um objetivo definido explícito, do sistema como um todo. As intenções dos projetistas ou arquitetos do sistema só podem ser inferidas avaliando-se os objetivos locais de cada agente, objetivos que correspondem a fragmentos ou componentes dessa intenção maior (McArthur *et al.*, 2007).

O estudo de SMAs é frequentemente associado à ciência da computação, envolvendo o interesse em agentes artificiais inteligentes, implementados tanto em *hardware* como em *software*. Entretanto trata-se de uma área multidisciplinar, bastante abrangente, cujos conceitos geralmente se aplicam às interações entre agentes humanos e instituições, sendo, muitas vezes, até mesmo derivados dessas. Entre as disciplinas frequentemente associadas ao estudo de SMA, pode-se citar, além da ciência da computação, áreas tão diversas como economia (sobretudo a microeconomia), filosofia analítica, pesquisa operacional, linguística, lógica, teoria de probabilidades, teoria de jogos e otimização (Shoham & Leyton-Brown, 2009).

Diversos pesquisadores vêm investigando a aplicação de SMAs em MRs, reconhecendo o potencial desse tipo de metodologias para esse fim, devido a seus benefícios inerentes como flexibilidade, escalabilidade, autonomia, manutenibilidade, entre outros (Logenthiran *et al.*, 2010; Kantamneni *et al.*, 2015; Cossentino & Lodato, 2011; Planas *et al.*, 2013).

Como destaca Shoham & Leyton-Brown (2009), a área de SMA é frequentemente confundida com teoria dos jogos. Embora não sejam sinônimos, a teoria dos jogos se constitui realmente em parte essencial dessa área, o que resulta do fato de nenhum agente ter a representação completa do sistema, precisando negociar com outros agentes.



As estratégias de controle de MRs com base em SMA maximizam a autonomia dos CLs dos REDs, dotando-os de certo grau de inteligência. Os CLs comunicam-se entre si, criando em conjunto uma entidade inteligente maior (Planas *et al.*, 2013).

## Agentes Inteligentes

A seguir, são citadas algumas das características comuns aos agentes (Planas *et al.*, 2013; Dimeas & Hatziargyriou, 2005):

1. Os agentes podem ser físicos ou virtuais;
2. Podem atuar em seu ambiente;
3. Podem se comunicar entre si, coordenando ações;
4. Certo nível de autonomia, podendo tomar decisões sem depender de um controle central;
5. Representação parcial ou inexistente do ambiente;
6. Objetivos divergentes.
7. O ambiente pode ser físico (e.g. um sistema de potência), observável através de sensores, ou computacional (e.g. recursos computacionais, bancos de dados etc.), observável através de chamadas de sistema, trocas de mensagens ou invocação de programas. A separação existente entre os agentes e seus ambientes implica na capacidade inerente de distributividade dos agentes (McArthur *et al.*, 2007).

A autonomia, nas definições mais simples, refere-se à capacidade de os agentes exercerem controle sobre suas próprias ações, o que significa que podem iniciar ou agendar ações. Müller *et al.* (1997) vão ainda mais longe, exigindo que o agendamento de ações ocorra sempre em resposta a alterações no ambiente e não devido a programações pré-definidas pelo projetista ou programador. Pode-se, portanto, definir autonomia como a capacidade de o agente agendar ações com base em observações do seu ambiente. Esta definição, entretanto, pode ser aplicada a diversos sistemas antigos, que precedem o conceito de SMA, como serviços de sistemas operacionais, *daemons* do Unix, e mesmo relés de proteção antigos, que reagem a alterações de tensão e corrente do ambiente (McArthur *et al.*, 2007).

Para McArthur *et al.* (2007) a definição de autonomia flexível, apresentada originalmente por Wooldridge, diferencia a proposta de SMA de sistemas antigos como os citados. Um agente inteligente que possua autonomia flexível apresentaria três características (Franklin & Graesser, 1997):

- Reatividade: capacidade de reagir a mudanças no ambiente, buscando cumprir suas funções;
- Proatividade: comportamento orientado a objetivos. Ou seja, toma iniciativas e pode mudar o comportamento com base em seus objetivos, adaptando-se ao ambiente;

- Habilidade social: capacidade de interagir com outros agentes inteligentes. Não se trata apenas de trocar dados, mas realmente conversar, negociando e cooperando.

As duas últimas diferenciam os agentes inteligentes de diversos sistemas antigos que já apresentavam reatividade e, em conjunto, tornam possíveis os benefícios que compõem os diferenciais dessa nova estratégia de desenvolvimento (McArthur *et al.*, 2007).

## Benefícios dos SMAs

SMAs geralmente são propostos com dois objetivos básicos: construir sistemas flexíveis e extensíveis de software ou hardware; e como ferramenta de modelagem (McArthur *et al.*, 2007).

A flexibilidade está relacionada ao conceito de autonomia, de adaptação a diferentes condições do ambiente, tomando a ação mais apropriada quando algo não sai como planejado. Exemplos seriam sistemas de proteção passíveis de serem conectados a qualquer alimentador e de detectar imediatamente a conexão de REDs, modificando suas configurações imediatamente.

A extensibilidade é a capacidade de adicionar novas funcionalidades ao sistema com facilidade, sem necessidade de reimplementá-lo. SMAs permitem a fácil integração de novos agentes, agregando novas funcionalidades.

Em sistemas modulares mais tradicionais, ao receber uma requisição de um módulo externo, o módulo receptor tipicamente não tem escolha a não ser executar a requisição. Em SMAs, entretanto, os agentes podem agendar a execução para outro momento, ou mesmo recusar a demanda, enquanto o agente requerente tem liberdade de procurar outro agente que ofereça o mesmo serviço. Sistemas orientados a objetos tradicionais foram aclamados no passado pela capacidade de modelar computacionalmente elementos do mundo real. SMAs ampliam essa capacidade ao encapsular, além dos dados, também os métodos, acessíveis apenas indiretamente, por meio de uma linguagem comum (McArthur *et al.*, 2007).

Cabe ressaltar, entretanto, que o novo paradigma de SMAs não exatamente compete com o antigo paradigma de orientação a objetos (*Object Oriented Programming* ou OOP), apenas o estende, sendo as plataformas de SMAs geralmente implementadas com base nesse paradigma antigo e já bem consolidado (Müller *et al.*, 1997).

Os diferentes agentes não precisam ser implementados usando uma mesma linguagem de programação, desde que falem a mesma linguagem. Isto é, desde que a linguagem de mensagens utilizada seja entendida por todos, não há a necessidade de restringir a linguagem de programação ou mesmo *framework* utilizado para desenvolver cada agente. Isso é possível utilizando-se arquiteturas abertas de SMA, implementadas seguindo padrões pré-estabelecidos, como os definidos pela *Foundation for Intelligent Physical Agents* (FIPA). O modelo de referência criado por essa organização fornece padrões para a plataforma de agentes, que seria o ambiente onde os agentes FIPA existem. Ou, mais apropriadamente, seriam a parte do

ambiente de um agente que forneceria recursos para a criação e remoção de agentes, bem como a localização de um agente por outros (McArthur *et al.*, 2007; Kantamneni *et al.*, 2015; Bellifemine *et al.*, 2010).

Os agentes também não precisam rodar na mesma máquina física. Desde que duas máquinas rodem instâncias de uma mesma plataforma, agentes rodando nessas máquinas distintas podem se localizar e cooperar. Outra vantagem de SMAs é a facilidade de criar sistemas redundantes. Contanto que se utilize uma arquitetura aberta de agentes, pode-se adicionar facilmente redundâncias ao sistema pela simples adição de novos agentes (McArthur *et al.*, 2007; Bellifemine *et al.*, 2010).

O modelo de referência da FIPA prevê os seguintes elementos essenciais para plataformas de agentes (Planas *et al.*, 2013; Kantamneni *et al.*, 2015):

1. Sistemas de gerenciamento de agentes: *framework* que gerencia serviços básicos como a criação e deleção, registro e descoberta de agentes.
2. Canal de comunicação de agentes: fornece serviços de comunicação intra e entre plataformas, frequentemente usando a internet.
3. *Directory Facilitator*: funcionando como um quadro de mensagens ou anúncios, permitindo aos agentes descobrir outros agentes e os serviços oferecidos por eles, nessa ou mesmo em outras plataformas.

É importante também distinguir a tecnologia de SMA de outras tecnologias de sistemas distribuídos, como *grid computing* e *web services*. O que diferencia a tecnologia das plataformas de SMAs é justamente a característica de autonomia flexível dos agentes, como, por exemplo, o suporte nativo a habilidades sociais como a capacidade de negociação (McArthur *et al.*, 2007).

Também é comum a confusão com o conceito de Inteligência Artificial (IA). Embora SMAs e técnicas de IA, como redes neurais, venham sendo frequentemente utilizados na solução de problemas similares, muitas vezes combinadas, a tecnologia SMA não pode ser definida como uma tecnologia de IA, mas sim como uma plataforma de sistemas híbridos, que permite, inclusive, combinar diferentes técnicas de IA (McArthur *et al.*, 2007).

## **Aplicações em Sistemas de Potência**

A automação dos sistemas de potência tradicionalmente usa sistemas SCADA centralizados, organizados hierarquicamente. Tais sistemas possuem baixa capacidade de interpretação de dados, lidando com um grande volume de dados coletados em campo. Em tais sistemas, qualquer falha de rede pode, rapidamente, em questão de poucas horas, gerar milhares de registros de falhas, dificultando muito a análise. A utilização de SMAs permitiria descentralizar a atuação e a análise, realizada por múltiplos agentes inteligentes distribuídos, reduzindo a troca de informações, já que apenas dados significativos precisariam ser trocados (Kantamneni *et al.*, 2015; Planas *et al.*, 2013).

Por outro lado, cabe ressaltar que, em SMAs distribuídos, os CLs dos diferentes REDs, na condição de agentes, precisam se comunicar com seus vizinhos e não apenas com o controlador central, o que geralmente implica em custos mais elevados de infraestrutura. (Planas *et al.*, 2013; Dimeas & Hatziargyriou, 2005).

Desde o final da década de noventa diversos trabalhos vêm sendo publicados analisando a aplicação de SMAs em sistemas elétricos de potência, com iniciativas que podem ser classificadas em quatro grandes áreas (McArthur *et al.*, 2007):

1. Proteção: essa é até o momento a área menos explorada na literatura;
2. Modelamento e simulação: as redes complexas são compostas de grande número de entidades mais simples, cujos comportamentos individuais podem ser modelados com mais facilidade utilizando SMAs.
3. Controle distribuído: área que mais vem recebendo a atenção dos pesquisadores. O uso de SMAs permite separar o problema em um conjunto de problemas menores.
4. Monitoramento e diagnóstico: área com muitos trabalhos, em geral explorando as vantagens do processamento distribuído dos SMAs e a consequente redução da necessidade de trocas de mensagens, para gerenciar e interpretar grandes volumes de dados.

Diversos pesquisadores vêm se dedicando ao estudo da coordenação de redes de múltiplas MRs inteligentes (*Multiple Microgrids* ou MMG), e a abordagem de SMAs vêm sendo proposta como solução promissora (Ravichandran *et al.*, 2013; Amin & Schewe, 2007; Ng & El-Shatshat, 2010).

### 2.6.2. Aplicações em Microrredes Inteligentes de Energia

SMAs permitem o controle distribuído de MRs, sendo especialmente interessantes em domínios nos quais a complexidade do sistema torne inviável o conhecimento a priori sobre a inter-relação de subproblemas (Kantamneni *et al.*, 2015).

Um exemplo é o gerenciamento de energia em MRs conectadas à rede da distribuidora, contendo múltiplas unidades produtoras e consumidoras, com proprietários diversos. Cada unidade possui seus objetivos de maximização dos lucros ou redução de custos, enquanto o sistema possui um objetivo global de manutenção do balanço de potências. A solução desse tipo de problema em tempo real torna-se muito difícil em sistemas centralizados, na medida em que o número de unidades aumenta muito. Utilizando-se SMA, entretanto, cada unidade passa a ser um agente, buscando seus objetivos, tentando maximizar sua utilidade (Kantamneni *et al.*, 2015; Hatziargyriou, 2014).

Pode-se distinguir duas categorias básicas de funcionalidades das MRs passíveis de serem abordadas usando SMAs (Dimeas & Hatziargyriou, 2005):

- Funcionalidades referentes ao gerenciamento de energia: realizada, como mencionado, com a negociação entre diversos agentes;

- Ações de controle: pode-se citar, como exemplo, o processo suave de transição entre os modos ilhado e conectado. Esse tipo de funcionalidade requer a cooperação de diversos agentes, exigindo a implementação de algoritmos de coordenação em cada um.

Diferentes arquiteturas de SMAs para MRs vêm sendo propostas, sendo a mais comum a estrutura com três níveis hierárquicos (Kantamneni *et al.*, 2015).

## **Desafios para SMAs em Microrredes Inteligentes de Energia**

Como todo novo paradigma, SMAs apresentam ainda limitações que impedem seu uso em maior escala, representando oportunidades de pesquisa. Abaixo, são enumerados alguns desses desafios (Kantamneni *et al.*, 2015):

- Comportamento emergente: risco de resultados inesperados devido à autonomia dos agentes;
- Portabilidade: a grande maioria dos sistemas testes com SMAs utilizam emulações por *software*. A implementação de SMAs em *hardware* de MRs reais ainda é um desafio;
- Escalabilidade: a capacidade de escalabilidade dos agentes em sistemas de grande porte, com diferentes plataformas e grande diversidade de agentes, apesar de parecer promissora, ainda é pouco compreendida;
- Segurança: o uso crescente de infraestrutura inteligente aumenta os riscos de segurança e violações de privacidade provocados por atores externos.

Embora, de acordo com simulações, a evolução da capacidade computacional dos sistemas de *hardware* venha gradualmente tornando SMAs cada vez mais atrativos para as MRs, sobretudo quando compostas de grande número de REDs diversificados e de proprietários diversos, as incertezas inerentes à crescente complexidade de *software*, incompatibilidades de *hardware* e riscos de segurança gerados por agentes maliciosos limitam sua adoção mais ampla. Somente testes rigorosos em protótipos de *hardware* envolvendo sistemas de múltiplos fornecedores poderão demonstrar a viabilidade e maturidade da nova abordagem (Kantamneni *et al.*, 2015; Planas *et al.*, 2013).

### **2.6.3. Gerenciamento Ótimo de Energia em Microrredes modeladas como Sistemas Multiagentes**

Os SMAs para o gerenciamento e controle de MRs propostos na literatura, ou testados em sistemas protótipos, geralmente utilizam arquitetura hierárquica análoga aos sistemas tradicionais, sendo essa a solução a ser avaliada neste trabalho. Embora a descentralização completa seja possível com SMAs, o que poderia maximizar a resiliência do sistema, com os agentes dos CLs dos REDs plenamente autônomos, tal abordagem implica em custos computacionais e de comunicação elevados, com todos os agentes precisando comunicar-se

diretamente com todos os seus vizinhos. As arquiteturas multiagente distribuídas hierárquicas vêm sendo propostas como solução de compromisso entre a descentralização total, de custo excessivo embora mais resiliente, e as arquiteturas mais centralizadas tradicionais (Kantamneni *et al.*, 2015; Zheng & Li, 2010; Khan *et al.*, 2016).

Nas arquiteturas SMA em três níveis, cabe ao agente supervisor central a coordenação do processo de otimização global de energia entre os CLs dos REDs, de maneira análoga às abordagens mais tradicionais centralizadas, porém com o agente supervisor apenas intermediando ou facilitando as negociações entre os REDs. A Figura 2.5 ilustra uma arquitetura típica em três níveis de um SMA, onde cada nível hierárquico consiste em uma sociedade de agentes que atua como um agente único. No nível mais elevado da hierarquia se encontra a Sociedade ou Agente Supervisor, da qual fazem parte o Agente Mediador e o Agente Regulador. No nível intermediário tem-se a Sociedade ou Agente de Transporte, que gerencia a minimização das perdas na transmissão de energia e coordena ações de proteção, além de coordenar ações durante os dois modos de transição da MR. Já na camada inferior da hierarquia, encontram-se os agentes CLs dos REDs, divididos em sociedades de cargas, fontes e SAEs, esses últimos podendo se comportar como cargas ou fontes, dependendo da estratégia de otimização adotada, ou seja, se o SAE está sendo carregado ou descarregado, sendo por isso representados na figura na intersecção entre os retângulos das sociedades de fontes e cargas (Kantamneni *et al.*, 2015; Cossentino & Lodato, 2011; Farag *et al.*, 2011).

Uma vantagem do uso de SMA hierárquico, em relação às estruturas hierárquicas mais centralizadas, é que os agentes locais inteligentes contam com a capacidade de modelar e simular os dispositivos físicos (cargas, fontes, baterias etc.) que representam, além de poderem aprender com o tempo, melhorando constantemente seus modelos. Com isso, tais agentes só terão necessidade de comunicar ao agente supervisor as informações relevantes para a negociação com outros agentes, visando à otimização global. Não existe ainda consenso na literatura a respeito do grau de distribuição de responsabilidades entre as camadas hierárquicas, que pode ser mais distribuído, com menos exigência de processamento do agente supervisor central, ou mais centralizado, com maior exigência de esforço computacional por parte do agente central (Planas *et al.*, 2013; Kantamneni *et al.*, 2015).

Diversas propostas de modelos e estratégias de otimização de energia com arquiteturas multiagentes já foram avaliadas na literatura, usando diferentes tipos de algoritmos distribuídos, como, por exemplo, algoritmos de leilões diversos (sobretudo leilão inglês, leilão holandês e designação única), como os propostos por Dimeas & Hatziaargyriou (2005) e Cirrincione *et al.* (2009), algoritmos de inteligência artificial (sobretudo *reinforcement learning*), algoritmos heurísticos diversos, como variações de algoritmos genéticos apresentados por Logenthiran *et al.* (2011), e lógica *Fuzzy* utilizada por Chaouachi *et al.* (2013), além de diferentes algoritmos baseados em abordagens da teoria de jogos, como a estratégia apresentada por Khan *et al.* (2016). Em especial, destaca-se o caráter mais ou menos distribuído das diferentes propostas,

com maior ou menor exigência computacional por parte do agente central supervisor ou facilitador (Faqiry *et al.*, 2014; Saad *et al.*, 2012; Hatziargyriou, 2014).

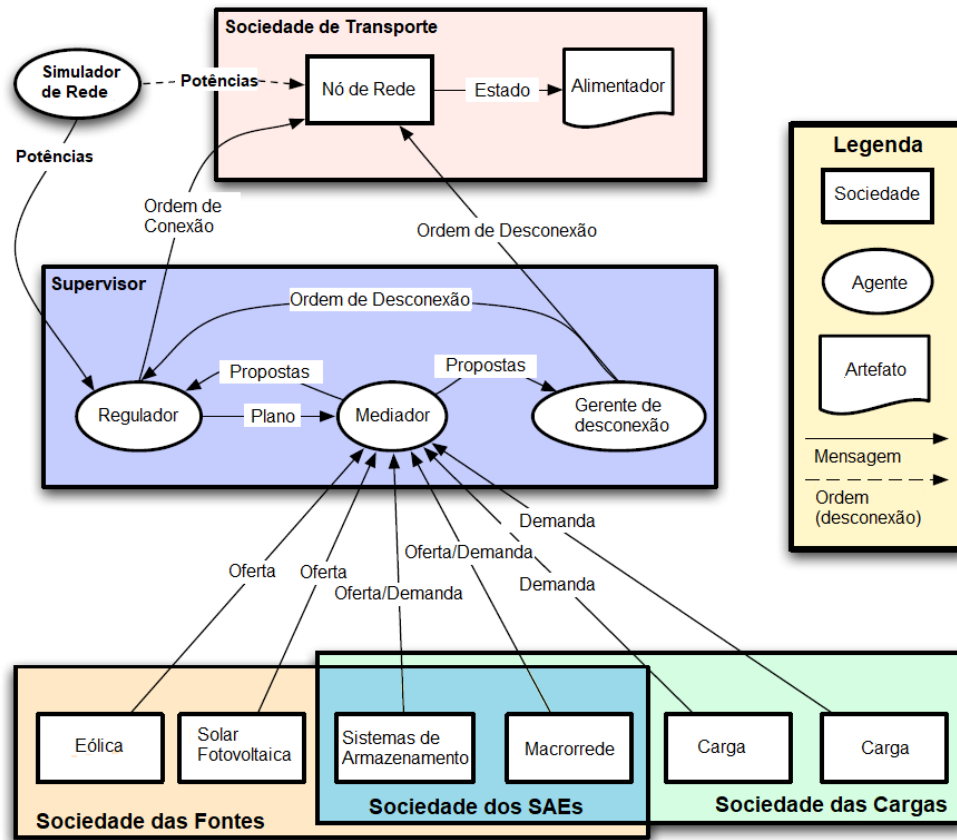


Figura 2.5. Arquitetura SMA típica em três níveis hierárquicos. Fonte: adaptado de Cossentino & Lodato (2011).

Os algoritmos de leilões vêm sendo usados há décadas para resolver problemas de otimização combinatória de alocação de recursos, permitindo convergir para o ótimo global com margem de erro definida, em um número finito de iterações. Mostram-se eficientes, apesar de sua relativa simplicidade, possibilitando a implementação de estratégias de otimização multiagentes totalmente descentralizadas (Dimeas & Hatziargyriou, 2005; Katiraei *et al.*, 2008; Bertsekas, 1990).

Tendo em vista a eficiência dos algoritmos de leilões no gerenciamento de energia em MRs modeladas como SMAs, decidiu-se por explorar as possibilidades dessa classe de algoritmos no modelo analisado (Kantamneni *et al.*, 2015; Katiraei *et al.*, 2008; Olivares *et al.*, 2014; Hatziargyriou, 2014; Dimeas & Hatziargyriou, 2005).

A seguir, é realizada uma breve introdução à teoria de leilões e aos algoritmos de otimização propostos com base na mesma, e é detalhado o modelo a ser avaliado neste trabalho.

### 2.6.4. Teoria de leilões aplicada ao gerenciamento de energia

A Teoria dos Jogos é definida como o estudo de modelos matemáticos de conflito e cooperação entre tomadores de decisões inteligentes. As técnicas matemáticas desta teoria permitem analisar situações nas quais dois ou mais indivíduos (chamados jogadores ou *players*) tomam decisões de maneira independente, cujas consequências, em termos do seu sucesso ou fracasso relativo, dependem também das decisões dos demais indivíduos ou jogadores (Myerson, 1991; Easley & Kleinberg, 2010).

Estratégias de como atuar em leilões são muito estudadas na teoria dos jogos, sendo uma de suas aplicações clássicas a solução dos problemas de designação. Os problemas de designação, também chamados problemas de alocação (*assignment problems* em inglês), são problemas de programação linear nos quais é preciso associar  $n$  itens de origem a  $n$  itens de destino de maneira ótima, como, por exemplo, a alocação de vendedores a localidades, ou funcionários a tarefas, em que cada alocação tem um benefício específico que deve ser maximizado. O problema do gerenciamento ótimo de energia em MRs pode ser visto como um problema de designação, no qual é preciso alocar a energia gerada pelas fontes disponíveis às cargas existentes dentro da MR, de maneira ótima, como será visto mais adiante, com cada possível associação implicando em diferentes benefícios (ou custos) (Myerson, 1991; Easley & Kleinberg, 2010; Bertsekas, 1990; Burkard *et al.*, 2012; Dimeas & Hatziargyriou, 2005).

Em sua forma clássica, o problema de alocação ou designação é simétrico, com o número  $n$  de pessoas (agentes compradores) igual ao número  $n$  de objetos (agentes vendedores) em leilão. Nele, existe um benefício ou valor intrínseco  $a_{ij}$  associado à alocação da pessoa  $i$  com o objeto  $j$ , e cada comprador pode comprar um único objeto. Deseja-se maximizar o benefício total ou social, representado pela soma dos benefícios de todas as alocações. Em notação matemática, diz-se que se deseja encontrar uma alocação de um para um que corresponda a um benefício total  $\sum_{i=1}^n a_{ij_i}$  máximo, onde  $j_i$  é o índice do objeto alocado à pessoa  $i$  (Bertsekas, 1990; Dimeas & Hatziargyriou, 2005; Bertsekas & Castañon, 1992).

Como exemplo, considere um leilão de preços com  $n$  compradores dispostos a comprar um entre  $n$  objetos, em que cada comprador pode comprar apenas um único objeto, sendo as pessoas, ou compradores, agentes racionais buscando maximizar seus lucros pessoais. Suponha que cada objeto  $j$  tem um preço inicial  $p_j$ , preço que a pessoa que o comprar deve desembolsar. Pode-se dizer, então, que o lucro, valor real ou benefício real do objeto  $j$  para uma determinada pessoa  $i$  é dado pelo benefício intrínseco deste objeto para esta pessoa menos o seu preço, ou seja, é igual a  $a_{ij} - p_j$ . Logicamente, a pessoa  $i$  irá preferir dar lances sempre para o objeto  $j_i$  que pode lhe prover o maior lucro ou benefício real, como ilustra a equação (2.1) (Bertsekas, 1990).

$$a_{ij_i} - p_{j_i} = \max_{j=1, \dots, n} \{ a_{ij} - p_j \} \quad (2.1)$$



Diz-se que a pessoa  $i$  está satisfeita ou feliz se observada tal condição, e se diz, também, que uma alocação, com seu conjunto de preços, estará em equilíbrio se todas as pessoas estiverem satisfeitas ou felizes. Pode ser observado que, na condição de equilíbrio de preços, a alocação alcança o máximo benefício social  $\sum_{i=1}^n a_{ij}$ . Esta seria então a solução ótima do problema de alocação, com o conjunto de preços obtido representando a solução do problema dual associado, o que é garantido pelo teorema da dualidade da programação linear, em que o nível de felicidade relativa de cada comprador é medido pela condição de folga complementar, como será detalhado mais adiante nesta seção (Bertsekas, 1990; Easley & Kleinberg, 2010).

A técnica da folga complementar (*complementary slackness*) é utilizada para contornar falhas de convergência observadas na forma mais simples do algoritmo de leilões, o chamado algoritmo de leilão ingênuo (*naive auction algorithm*). A seguir, descreve-se o algoritmo ingênuo, identificando suas falhas e então mostra-se como o acréscimo da folga complementar é realizado para torná-lo efetivo (Bertsekas, 1990).

O algoritmo de leilão ingênuo é iterativo, realizado em diversas rodadas (iterações), podendo iniciar com quaisquer combinações de conjuntos de preços e alocações. Se todas as pessoas/compradores estiverem felizes com a combinação de preços e alocações no início de uma rodada, o algoritmo alcança sua condição de término e o processo é concluído. Caso contrário, a nova rodada inicia com a seleção de uma pessoa  $i$  que não esteja feliz (não esteja alocada ao objeto preferido, com base nos valores intrínsecos e preços na rodada em questão), dando à mesma a chance de oferecer novo lance. Essa pessoa deve então selecionar o seu objeto preferido  $j_i$ , que ofereça máximo valor real ou lucro para ela (valor intrínseco menos preço), como mostrado na equação (2.2) (Bertsekas, 1990).

$$j_i = \arg \max_{j=1,\dots,n} \{ a_{ij} - p_j \} \quad (2.2)$$

O algoritmo segue com a pessoa  $i$  oferecendo novo lance para o objeto  $j_i$ . O novo lance deve ser agressivo para que o processo possa ser acelerado, como se observa em leilões reais, com a pessoa  $i$  oferecendo o preço máximo que pagaria pelo segundo melhor objeto disponível para a mesma, tornando o objeto preferido pouco interessante a possíveis concorrentes que o valorem da mesma maneira. Ou seja, a pessoa deve oferecer o novo preço  $p_{ji}$  (equação (2.3)), com um incremento  $\gamma_i$  (equação (2.4)), dado pela diferença do valor real do melhor objeto  $v_i$  para o valor real do segundo melhor objeto  $\omega_i$ , definidos respectivamente nas equações (2.5) e (2.6).

$$p_{ji} = p_{j_i} + \gamma_i \quad (2.3)$$

$$\gamma_i = v_i - \omega_i \quad (2.4)$$

$$v_i = \max_{j=1,\dots,n} \{ a_{ij} - p_j \} \quad (2.5)$$

$$\omega_i = \max_{j \neq j_i} \{ a_{ij} - p_j \} \quad (2.6)$$

Note que  $\gamma_i$  representa o maior incremento de preço possível para o objeto preferido  $j_i$  que ainda o mantenha como o melhor objeto para a pessoa  $i$ . O objeto  $j_i$  é então alocado à pessoa  $i$ , e se o mesmo já estava alocado para outra pessoa, esta passa a ficar sem objeto designado e disposta a novos lances.

Esse processo é repetido em uma sequência de rodadas até que todas as pessoas estejam felizes, ou seja, estejam alocadas ou designadas para seus melhores objetos, considerando os valores intrínsecos para cada pessoa e os preços vigentes no início da última rodada.

Esse algoritmo simples estimula a competição em condições de igualdade entre os agentes compradores, como em um leilão real, atingindo, assim, o ótimo global ou máximo benefício social, e em geral funciona bem. Porém, infelizmente, possui uma falha que ocorre nos casos em que o incremento de preço  $\gamma_i$  é nulo, ou seja, em que existe mais de um objeto oferecendo máximo valor real para o próximo licitante  $i$ . Com isso, pode-se criar uma interminável competição, na qual diversas pessoas competem sempre pelos mesmos objetos preferidos, sem nunca incrementar seus preços (Bertsekas, 1990).

Para quebrar esse *loop* do algoritmo em sua forma ingênua, insere-se uma perturbação, também inspirada em estratégias de leilões reais: obriga-se os compradores a assumir um pequeno nível de risco, incrementando sempre um pouco mais os seus preços. Isso é feito definindo-se um incremento positivo mínimo de preços, representado por um escalar positivo  $\epsilon$ . Diz-se então que, em cada rodada, a pessoa  $i$  estará quase feliz se o valor real do objeto designado a ela estiver a uma distância  $\epsilon$  de seu valor máximo, condição mostrada na equação (2.7) (Bertsekas, 1990; Dimeas & Hatziargyriou, 2005; Bertsekas & Castañon, 1992):

$$a_{ij_i} - p_{j_i} \geq \max_{j=1,\dots,n} \{ a_{ij} - p_j \} - \epsilon \quad (2.7)$$

Considera-se que a alocação encontra o seu quase equilíbrio de preços quando todas as pessoas se encontram quase felizes no início de nova rodada, encerrando-se assim o leilão. Essa condição, introduzida inicialmente em 1979 no algoritmo de leilões, é conhecida como folga complementar  $\epsilon$  ( *$\epsilon$ -complementary slackness*). Assim, o incremento de preço a cada lance passa a ser dado pela equação (2.8) (Bertsekas, 1990).

$$\gamma_i = v_i - \omega_i + \epsilon \quad (2.8)$$

Com isso, garante-se um incremento mínimo de  $\epsilon$ . Pode-se demonstrar que o algoritmo de leilão assim reformulado chega à condição de quase equilíbrio em um número finito de iterações, condição que pode ou não ser o ótimo global, o que dependerá fundamentalmente do valor de  $\epsilon$ . Pode-se também demonstrar que o benefício total da alocação final estará a uma distância máxima de  $n \times \epsilon$  do ótimo global. Bertsekas (1990) prova que uma alocação que esteja em quase equilíbrio pode ser vista como a condição de equilíbrio para um problema ligeiramente diferente, em que os benefícios  $a_{ij}$  são os mesmos exceto pelos  $n$  benefícios dos pares alocados, cujos preços foram incrementados por um valor não maior que  $\epsilon$ .

Em particular, supondo-se que todos os benefícios intrínsecos  $a_{ij}$  sejam valores inteiros (caso sejam valores racionais basta multiplicá-los por um número comum apropriado), tem-se o benefício total ou social de qualquer alocação como um valor igualmente inteiro sempre. Neste caso, se  $n \times \epsilon < 1$ , qualquer alocação completa estará a uma distância máxima  $n \times \epsilon$  de ser ótima. Conforme demonstrado por Bertsekas (1981), a condição suficiente para a otimalidade da alocação final seria dada pela equação (2.9).

$$\epsilon < \frac{1}{(n-1)} \quad (2.9)$$

Da mesma forma que as alocações obtidas estão a uma distância  $n \times \epsilon$  de serem ótimas, ou seja, de maximizar  $\sum_{i=1}^n a_{ij}$ , o conjunto final de preços obtido está também a  $n \times \epsilon$  de ser a solução ótima do problema dual mostrado na equação (2.10) (Bertsekas, 1990).

$$\min_{p_j} \left\{ \sum_{j=1}^n p_j + \sum_{i=1}^n \max_j \{ a_{ij} + p_j \} \right\} \quad (2.10)$$

É possível demonstrar que a cada iteração, o algoritmo seleciona o lance cujo preço ofertado se aproxime ao máximo, a uma distância menor que  $\epsilon$ , do preço que minimizaria o custo dual, mantidos fixos os demais preços (Bertsekas, 1990).

No algoritmo até aqui descrito, apenas uma pessoa apresenta seu lance a cada rodada do leilão. Esta versão do algoritmo é conhecida como implementação Gauss-Seidel. Uma alternativa, conhecida como implementação Jacobi, seria permitir que todas as pessoas apresentassem seus lances ao mesmo tempo a cada rodada para seus objetos preferidos, conferindo cada objeto à pessoa que apresentar o maior lance, e incrementando seus preços de acordo. Esta implementação converge igualmente bem, embora geralmente se mostre um pouco mais lenta, sendo mais adequada para implementações paralelizadas (Bertsekas, 1990).

A parametrização do algoritmo também é muito importante em sua eficiência, assim como as condições iniciais estabelecidas (vetor de preços inicial). Em particular, depende fortemente da magnitude de  $\epsilon$  em relação ao valor intrínseco máximo  $C$  do conjunto de objetos, como mostrado na equação (2.11) (Bertsekas, 1990).

$$C = \max_{i,j} |a_{ij}| \quad (2.11)$$

O número máximo de iterações tende geralmente a ser proporcional a  $C/\epsilon$ .

Assim, é comum a utilização da técnica conhecida como escalonamento- $\epsilon$  ( $\epsilon$ -scaling). Esta técnica consiste em aplicar o algoritmo diversas vezes, iniciando com um valor maior de  $\epsilon$ , e ir sucessivamente reduzindo-o, até um valor final menor que o valor crítico  $1/n$ , e é particularmente útil em problemas esparsos, isto é, problemas cujo número de alocações factíveis é restrito.

Em Bertsekas (1990), são recomendadas equações e técnicas para o escalonamento- $\epsilon$ , com a redução exponencial de  $\epsilon$  ao longo das iterações, até o valor final crítico, bem como

recomendações para a parametrização inicial visando obter-se o melhor desempenho, dependendo das características de cada problema. Grande número de simulações demonstram a eficiência dos algoritmos de leilões para os problemas de alocação esparsos e de grandes dimensões, com sua vantagem aumentando quanto maiores forem as dimensões e a esparsidade do problema. Tal vantagem é também corroborada por análises teóricas de complexidade computacional em Bertsekas & Eckstein (1988), Bertsekas *et al.* (1989) e Bertsekas & Castanon (1989).

Diversos estudos demonstraram também o ganho substancial de velocidade que se pode obter com algoritmos de leilões em suas implementações paralelizadas, podendo chegar a convergir dez vezes mais rápido, no caso de problemas esparsos, o que naturalmente indica sua aplicabilidade para o uso em SMAs (Bertsekas, 1990).

## 2.7. Conclusão

Neste capítulo foram apresentados os principais conceitos da área de MRs inteligentes de energia elétrica. Mostrou-se como a tecnologia das MRs, apesar de relativamente recente, vem sendo utilizada com sucesso em diversos países, tendo sido identificada sua relevância para o desenvolvimento dos futuros *smart grids*, e para viabilizar a integração em grande escala de REDs renováveis. Entretanto seu uso em maior escala nas grandes redes de distribuição ainda depende da superação de uma série de desafios técnicos e regulatórios. O desenvolvimento de novas estratégias de gerenciamento de energia permitiria reduzir os investimentos de implantação e os custos operacionais das MRs.

Apresentou-se, também, o problema do gerenciamento ótimo de energia em MRs, sua complexidade e importância e seus aspectos mais relevantes. Foram discutidas as principais características das estratégias centralizadas e descentralizadas de gerenciamento de energia em MRs, com suas vantagens e limitações. Mostra-se, sobretudo, as vantagens geralmente observadas nas estratégias centralizadas, utilizando técnicas clássicas de otimização, nos contextos atuais, mas também suas limitações no que diz respeito à escalabilidade, no esperado contexto de maior difusão das MRs e de crescimento exponencial da tecnologia da informação. Limitações essas que, de acordo com análises teóricas e simulações, podem ser superadas com estratégias descentralizadas, sobretudo com o emprego de plataformas de SMAs. Entre os diversos algoritmos distribuídos já avaliados para a solução do problema de gerenciamento de energia com SMAs, os algoritmos de leilões são frequentemente sugeridos na literatura, pelo seu ótimo desempenho em problemas de alocação, sobretudo em problemas de grandes proporções e alta esparsidade, características que o tornam muito promissor para o gerenciamento de energia em MRs de grandes proporções.

A aplicação de algoritmos formais, definidos abstratamente e formalmente analisados e avaliados na ciência da computação, à problemas reais de engenharia, entretanto, é, em si, uma

área complexa de pesquisa, requerendo, antes de mais nada, o adequado modelamento matemático do problema a ser resolvido (Hillier & Lieberman, 2010).

No capítulo seguinte, descreve-se o modelamento matemático do problema do gerenciamento ótimo de energia em MRs, considerando características relevantes das MRs atuais. Primeiro, apresenta-se o modelamento centralizado clássico, como um problema linear inteiro-misto, aplicando-se técnicas de linearização. Em seguida, o mesmo problema é modelado como um SMA, com estratégia descentralizada, utilizando algoritmo simétrico de leilão.



# Capítulo 3

## Formulação matemática

### 3.1. Introdução

Neste trabalho será analisada a otimização interna das MRs em modo conectado, representada pela alocação ótima de seus recursos energéticos, com função objetivo buscando a minimização de custos no horizonte de um dia.

Assume-se que os preços de compra e venda de energia da macrorrede são conhecidos para cada dia e horário da semana.

A arquitetura avaliada toma como base a MR descrita na Seção 4.2, incluindo microfones despacháveis não-renováveis e não-despacháveis-renováveis, e o SAE, representado por um banco de baterias. Porém o modelo aqui descrito é generalizável para quaisquer MRs com esses componentes típicos. Considera-se apenas o modo conectado da MR.

Inicia-se com a descrição do modelo matemático da estratégia de otimização centralizada clássica, usando programação linear inteira mista, em dois horizontes de tempo, *day-ahead* (24 horas) e tempo real (5 minutos). O problema em si é não-linear, porém passível de ser linearizado, o que reduz a complexidade computacional e garante a convergência para o ótimo global (M. Pardalos & Resende, 2002; Palma-Behnke *et al.*, 2013; Olivares *et al.*, 2014).

Apresenta-se, em seguida, o modelamento do gerenciamento em tempo real da mesma MR, com estratégia multiagente, utilizando algoritmos de leilões, tomando como referência as técnicas propostas por Dimeas & Hatziargyriou (2005).

### 3.2. Modelo centralizado

No modelo centralizado, o gerenciamento ótimo de energia é realizado por intermédio do sistema SCADA central da MR, utilizando-se modelos de otimização como os que serão a seguir descritos.

O modelo é dividido em dois horizontes, o tempo real, no qual é realizado o balanço de energia considerando as previsões de demanda e de disponibilidade de geração em um horizonte de alguns minutos, e o modelo que leva em conta previsões para as próximas 24 horas, sendo por isso chamado de *day-ahead*. No que se refere à programação dos REDs da MR, sobretudo quando deve ser considerada a estratégia de carga e descarga dos sistemas de armazenamento, 24 horas é um prazo considerado adequado na literatura (Stadler *et al.*, 2015; Palma-Behnke *et al.*, 2013; Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M. Khambadkone, 2012; Chaouachi *et al.*, 2013; Farzan *et al.*, 2013).

O modelo do *day-ahead* é executado a cada 30 minutos, sempre observando um horizonte de 24 horas, em uma janela deslizante. O gerenciador de energia deve obter dados de previsão do tempo que permitam estimar a geração das fontes dependentes de variáveis meteorológicas, como solar e eólica, para cada intervalo das próximas 24 horas, bem como a previsão de demanda para cada um desses intervalos. As previsões devem ser realizadas com uso de técnicas adequadas, como, por exemplo, as que utilizam inteligência artificial propostas por Raza & Khosravi (2015) e Carvalho (2017). O gerenciador de energia também deve obter os preços de mercado para a compra e venda de energia para cada intervalo das próximas 24 horas. O processo de obtenção em si desses dados não é o foco deste trabalho.

Após resolvido o problema do *day-ahead*, os valores de referência (*set points*) das potências calculadas para cada intervalo futuro são informados aos CLs dos REDs, que passam à fase operacional, buscando executar o plano determinado para os próximos 30 minutos. Naturalmente, sempre haverá desvios dos valores reais de demanda e de potência disponível nos REDs renováveis dependentes de variáveis meteorológicas, em relação àqueles previstos no *day-ahead*. Tais desvios são tratados pelo algoritmo de tempo real, buscando-se a minimização de custos nas novas condições, com o menor desvio possível em relação ao plano estabelecido no *day-ahead*. Esse algoritmo roda a cada intervalo de 5 minutos, excetuando-se os intervalos nos quais é realizado novo *day-ahead*, cujos resultados já são usados no intervalo de 5 minutos subsequente.

Se em algum intervalo os desvios em relação às previsões utilizadas no *day-ahead* sejam maiores que determinados níveis considerados aceitáveis, o sistema de gerenciamento pode refazer o planejamento do *day-ahead* antes dos 30 minutos previstos, sendo necessário o estabelecimento de critérios para essa decisão, o que também não será abordado no presente trabalho (Stadler *et al.*, 2015; Planas *et al.*, 2013; Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M. Khambadkone, 2012; Palma-Behnke *et al.*, 2013).

A programação do *day-ahead* permite avaliar *ex-ante* as decisões que levarão ao gerenciamento ótimo no horizonte de 24 horas, considerando o estado de carga e a melhor utilização dos SAEs, e dos geradores não-renováveis, cujos custos de operação dependem do custo de partida, ou seja, do estado no qual se encontravam no intervalo anterior. Esses REDs terão seus valores alterados no tempo real somente em situações específicas, como no caso de risco de ultrapassagem da demanda contratada, porque o consumo está acima do previsto ou a geração está abaixo do previsto.

Caso, em tempo real, o SAE precise ser descarregado além do previsto no *day-ahead*, o seu estado de carga apresentará um desvio no intervalo subsequente, em relação ao planejado no *day-ahead*. Nos intervalos seguintes, buscar-se-á que o banco de baterias volte ao valor planejado.

Primeiramente descreve-se o modelo de otimização de *day-ahead* para, em seguida, descrever o modelo de otimização de tempo real.



### 3.2.1. Modelo de programação do *day-ahead*

O modelo do *day-ahead* utiliza discretização de tempo em intervalos menores para os períodos mais recentes, para os quais é possível realizar previsões com maior confiabilidade e com intervalos maiores em períodos mais distantes. Na primeira meia hora da janela deslizante, são utilizados intervalos de 5 minutos (seis intervalos ao todo). A segunda meia hora é tratada como intervalo único de 30 minutos. A partir da segunda hora, a discretização é feita com 23 intervalos de 1 hora (Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M. Khambadkone, 2012; Palma-Behnke *et al.*, 2013). São consideradas as previsões de geração de energia pelas fontes renováveis, dependendo das previsões meteorológicas, bem como as previsões de demanda para a MR.

O problema de otimização leva em consideração múltiplos intervalos e o custo de oportunidade da bateria. A seguir, são apresentados os conjuntos, variáveis e parâmetros utilizados no modelo.

#### A. Conjuntos

$N$	Número de unidades despacháveis na MR
$NK$	Número de cargas
$NR$	Número de fontes renováveis não despacháveis
$T$	Número total de intervalos de discretização

#### B. Parâmetros

$BS$	Capacidade total de carga de cada bateria, em kWh
$Cic_{max}$	Limite máximo do número de meio-ciclos no horizonte do <i>day-ahead</i>
$CSC$	Custo de partida do gerador
$DC^t$	Demanda contratada da distribuidora no intervalo $t$
$PRV_{max}$	Máximo da potência de energia vendida à macrorrede
$PRCD_{max}$	Máximo da potência de ultrapassagem
$nB$	Número de baterias no banco de baterias
$nf$	Taxa de manutenção de carga da bateria a cada hora
$nf^t$	Taxa de manutenção de carga durante o período $t$
$PC_k^t$	Potência média demandada pela carga $k$ no intervalo $t$
$PR_n^t$	Potência gerada pela fonte renovável não despachável $n$ no intervalo $t$
$P_{i,max}$	Máximo da potência gerada pelo gerador não-renovável $i$
$P_{i,min}$	Mínima potência que o gerador não-renovável $i$ pode gerar, quando ligado

$P_{sc,max}$	Potência máxima de carga do banco de baterias
$P_{sd,max}$	Potência máxima de descarga do banco de baterias
$SOC_{max}$	Limite superior do estado de carga ( <i>state of charge</i> ) do banco de baterias
$SOC_{min}$	Limite inferior do estado de carga ( <i>state of charge</i> ) do banco de baterias
$tE^t$	Tarifa de compra de energia da macrorrede no intervalo $t$
$tf_{ps}$	Valor da penalização por utilizar o sistema de armazenamento
$tU^t$	Tarifa da potência contratada da macrorrede no intervalo $t$
$tV^t$	Tarifa de venda de energia para a macrorrede no intervalo $t$
$\delta t^t$	Duração do intervalo discreto de tempo $t$ , em horas
$CC^i$	Custo por litro de combustível para a unidade geradora $i$

### C. Variáveis binárias

$B_{cr}^t$	Variável binária que será 1, se a MR estiver comprando energia da macrorrede
$B_{desc}^t$	Variável binária que será 1, se o banco de baterias estiver sendo descarregado em $t$
$B_{d, fim}^t$	Variável binária que será 1, se o banco de baterias terminou um ciclo de descarga em $t$
$B_{d, ini}^t$	Variável binária que será 1, se o banco de baterias iniciou novo ciclo de descarga em $t$
$B_i^t$	Variável binária que será 1, se gerador $i$ estiver ligado em $t$
$B_{iD}^t$	Variável binária que será 1, se o gerador $i$ for desligado em $t$
$B_{iL}^t$	Variável binária que será 1, se gerador $i$ for ligado em $t$
$B_{ud}^t$	Variável binária que será 1, se houver ultrapassagem de demanda ( $P_{rcd}^t > 0$ )

### D. Variáveis contínuas

$C_b^t$	Custo de uso do sistema de armazenamento
$C_{cr}^t$	Custo de compra de energia da macrorrede
$C_f^t$	Custo dos geradores não-renováveis
$Cic^t$	Número de meio-ciclos de carga/descarga até o instante $t$
$Cons^i$	Consumo de combustível por unidade de potência gerada pela unidade geradora $i$

$P_i^t$	Potência entregue pela unidade despachável $i$ no intervalo $t$
$P_{rc}^t$	Potência com a qual é comprada energia da macrorrede no intervalo $t$ , inferior a demanda contratada
$P_{rcd}^t$	Potência fornecida pela macrorrede que ultrapassa a demanda contratada da macrorrede no intervalo $t$
$P_{rv}^t$	Potência com a qual é vendida energia à macrorrede no intervalo $t$
$P_{sc}^t$	Potência com a qual é carregado o banco de baterias durante o intervalo $t$
$P_{sd}^t$	Potência com a qual é descarregado o banco de baterias durante o intervalo $t$
$R_{vr}^t$	Receita da venda de excedente de energia produzida na MR para a macrorrede
$SOC^t$	Estado de carga da bateria no final do período $t$

## Função objetivo

A função objetivo, que se deseja minimizar, é mostrada na equação (3.1). Compõe-se de quatro termos, representando os custos das fontes despacháveis não renováveis  $C_f$ , os custos de compra de energia da macrorrede  $C_{cr}$ , a receita de venda de energia para macrorrede  $R_{rv}$ , e finalmente o custo de uso do banco de baterias  $C_b$ .

$$Custo = \sum_{t=1}^T [C_f^t + C_{cr}^t - R_{rv}^t + C_b^t] \quad (3.1)$$

O custo associado ao uso das fontes despacháveis  $C_f^t$  é dado pela equação (3.2), cujo primeiro termo representa o custo do combustível consumido. Já o segundo termo representa o custo de partida do gerador no intervalo  $t$ .

$$C_f = \sum_{i=1}^N Cons^i \cdot CC^i \cdot \delta t + C_{stup}^i \quad (3.2)$$

O consumo de combustível (litro/hora) pode ser obtido conforme mostra a equação (3.3), na qual  $a$ ,  $b$  e  $c$  são constantes dependentes da tecnologia do gerador. Note que a equação é não linear, porém passível de ser linearizada por partes (Hillier & Lieberman, 2010; Palma-Behnke *et al.*, 2013; Jiang *et al.*, 2013).

$$Cons^i = a \cdot P_i^2 + b \cdot P_i + c \quad (3.3)$$

A Figura 3.1 mostra um exemplo de linearização por partes da curva de custo por potência gerada de um gerador diesel, onde a curva com tracejado contínuo é resultado da interpolação polinomial quadrática da curva representada pelos dados apresentados no manual do

equipamento, usando a equação (3.3), enquanto a curva tracejada representa exemplo de linearização em dois intervalos desta mesma curva.

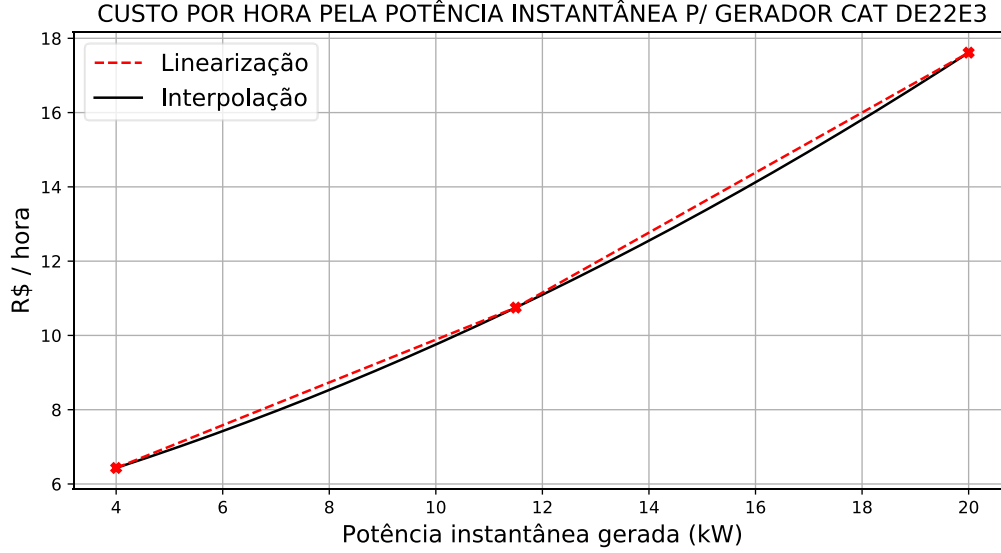


Figura 3.1: Curvas quadrática e linearizada por partes do custo por hora pela pot. instantânea para gerador a diesel.

O custo de partida no intervalo  $t$  é dado pela equação (3.4), em que a variável binária  $B_{iL}^t$  indica se o gerador  $i$  foi ligado neste intervalo. A constante  $CSC$  representa o custo de partida do gerador (Rangel *et al.*, 2016).

$$C_{stup}^i = B_{iL}^t \times CSC \quad (3.4)$$

Para determinar os custos de compra de energia da macrorrede  $C_{cr}^t$  é necessário utilizar as tarifas praticadas pela distribuidora. Considera-se haver uma demanda contratada, a partir da qual cobra-se uma penalização pela potência de ultrapassagem, correspondente ao dobro da tarifa de demanda contratada. Considera-se também a cobrança de tarifas diferenciadas para dias úteis e finais de semana, e horários de ponta e fora de ponta em dias de semana, correspondendo à categoria A4, e modalidade tarifária azul, de acordo com ANEEL (2010).

O custo de compra de energia da macrorrede é calculado como mostra a equação (3.5). O primeiro termo da equação se refere ao custo da energia total consumida no intervalo  $t$ , e o segundo à multa pela potência  $P_{rcd}^t$ .

$$C_{cr} = (P_{rc}^t + P_{rcd}^t) \cdot \delta t^t \cdot tE^t + 2 \times P_{rcd}^t \cdot tU^t \quad (3.5)$$

Não é considerado o custo da demanda contratada, pois trata-se de um custo constante, sem influência no processo de otimização. Além disso, vale a pena ressaltar que a multa por ultrapassar a demanda contratada é aplicada no período tarifário de um mês, quando a mesma é superada ao menos em um período de 15 minutos, sendo utilizada a maior potência de

ultrapassagem para a aplicação da multa, independentemente da quantidade de vezes que foi ultrapassada.

Neste trabalho, a ultrapassagem da demanda é penalizada em todos os períodos em que ocorrer. Como consequência, os custos calculados na função objetivo não correspondem ao valor a ser pago pelo consumidor ao final do ciclo tarifário de um mês.

A receita resultante da venda do excedente de energia produzida na MR  $R_{vr}^t$  é dada pela equação (3.6). Assim como no cálculo do custo de compra de energia, a tarifa também depende do tipo de dia (dia de semana ou final de semana), e do posto horário (ponta ou fora de ponta).

$$R_{vr} = P_{rv}^t \cdot tV^t \cdot \delta t^t \quad (3.6)$$

Note que a possibilidade de venda de energia à distribuidora, embora já ocorra em outros países, não é atualmente regulamentada no Brasil para consumidores cativos, para os quais admite-se apenas a compensação da energia excedente (Alvez, 2015; Godoi, 2017; Borges, 2016; ANEEL, 2016; Falcão, 2009).

As baterias, como unidades de armazenamento de energia, idealmente, se forem desconsideradas as perdas, não produzem nem consomem energia. Entretanto os seguintes custos podem ser considerados (Chaouachi *et al.*, 2013; Han *et al.*, 2014; Zhou *et al.*, 2011; Zhang *et al.*, 2017; Su & Wang, 2012; Katiraei *et al.*, 2008; Chen *et al.*, 2011):

1. Custos de oportunidade: perder a oportunidade de carregar quando a energia está mais barata e descarregar quando está mais cara.
2. Custos de depreciação: redução da vida útil devido, principalmente, ao número e à profundidade dos ciclos de carga/descarga, mas também outras variáveis, como a temperatura, tensão e potência.
3. Custos de operação e manutenção: podem depender da potência nominal do SAE e de sua taxa horária de descarregamento, com a magnitude desses custos variando muito conforme a tecnologia empregada.

O custo de depreciação é de difícil determinação, dependendo da tecnologia do sistema de armazenamento utilizado, tendo natureza não-linear e sendo influenciado por uma série de variáveis, como a temperatura, tensão, potência, e sobretudo do ciclo de carga e descarga do sistema (Zhou *et al.*, 2011; Palma-Behnke *et al.*, 2013).

O termo  $C_b^t$  na função objetivo, adiciona uma penalização pelo uso do SAE, representando, mesmo que de forma muito aproximada, o custo de redução de sua vida útil. Utiliza-se um custo fixo por unidade potência de carga e descarga  $tf_{ps}$ , como mostrado na equação (3.7).

$$C_b^t = (P_{sc}^t + P_{sd}^t) \cdot tf_{ps} \quad (3.7)$$

## Restrições

O problema está sujeito ao seguinte conjunto de restrições:

$$\sum_{i=1}^N P_i^t + P_{rc}^t + P_{rcd}^t - P_{rv}^t + P_{sd}^t - P_{sc}^t + \sum_{n=1}^{NR} PR_n^t = \sum_{k=1}^{NK} PC_k^t \quad (3.8)$$

$$B_{ud}^t \cdot DC^t \leq P_{rc}^t \leq B_{cr}^t \cdot DC^t \quad (3.9)$$

$$0 \leq P_{rcd}^t \leq B_{ud}^t \cdot PRCD_{max} \quad (3.10)$$

$$0 \leq P_{rv}^t \leq (1 - B_{cr}^t) \cdot PRV_{max} \quad (3.11)$$

$$B_i^t \cdot P_{i,min} \leq P_i^t \leq B_i^t \cdot P_{i,max} \quad (3.12)$$

$$B_{iL}^t - B_{iD}^t = B_i^t - B_i^{t-1} \quad (3.13)$$

$$B_{iL}^t + B_{iD}^t \leq 1 \quad (3.14)$$

$$0 \leq P_{sd}^t \leq B_{desc}^t \cdot P_{sd,max} \quad (3.15)$$

$$0 \leq P_{sc}^t \leq (1 - B_{desc}^t) \cdot P_{sc,max} \quad (3.16)$$

$$SOC^t = n f^t \cdot SOC^{t-1} - \frac{(P_{sd}^t \cdot \delta t^t)}{(nB \cdot BS)} + \frac{(P_{sc}^t \cdot \delta t^t)}{(nB \cdot BS)} \quad (3.17)$$

$$SOC_{mim} \leq SOC^t \leq SOC_{max} \quad (3.18)$$

$$B_{d,ini}^t - B_{d,fim}^t = B_{desc}^t - B_{desc}^{t-1} \quad (3.19)$$

$$Cic^t = Cic^{t-1} + B_{d,ini}^t + B_{d,fim}^t \quad (3.20)$$

$$B_{d,ini}^t + B_{d,fim}^t \leq 1 \quad (3.21)$$

$$Cic^t \leq Cic_{max} \quad (3.22)$$

$$\forall t \in \{1, \dots, T\}$$

A equação (3.8) apresenta o balanço de potência, com a oferta de energia igualando-se à demanda em cada intervalo  $t$ .

As equações (3.9) e (3.10) indicam que a potência com a qual é comprada energia da macrorrede pode ser menor que a demanda contratada ou pode superá-la. Note que a variável  $B_{ud}^t$ , se for verdadeira, torna  $P_{rc}^t = DC^t$ , e permite a  $P_{rcd}^t$  assumir valores positivos não nulos, até o limite  $PRCD_{max}$ . Caso  $B_{cr}^t$  seja nulo, ou seja, se não houver compra de energia da macrorrede,  $P_{rc}^t$  e  $B_{ud}^t$  serão também zero.

A equação (3.11) limita a potência  $P_{rv}^t$  a zero, se  $B_{cr}^t$  for verdadeiro, ou a  $PRV_{max}$ , caso  $B_{cr}^t$  seja falso.

A potência com a qual pode ser despachada cada unidade geradora despachável é limitada pela equação (3.12). Ambos os limites serão nulos se a unidade  $i$  estiver desligada, ou seja, se  $B_i^t = 0$ .

A equação (3.13) define os valores de  $B_{iL}^t$  e  $B_{iD}^t$ , que indicam se o gerador  $i$  foi ligado ou desligado em  $t$ , com base nos valores de  $B_i^t$  e  $B_i^{t-1}$ . O valor de  $B_{iL}^t$  é utilizado na equação (3.4), para o cálculo do custo de partida dos geradores. A equação (3.14) impede que  $B_{iL}^t$  e  $B_{iD}^t$  sejam ambos verdadeiros, caso  $B_i^t = B_i^{t-1}$ .

As restrições representadas nas equações (3.15) e (3.16) limitam as potências de carga  $P_{sc}^t$  e descarga  $P_{sd}^t$  da bateria. A variável binária  $B_{desc}^t$  é usada para implementar a restrição que limita o número de ciclos de carga e descarga, cujo objetivo é aumentar o tempo de vida útil da bateria. Caso  $B_{desc}^t$  seja 1, a restrição (3.15) permite que  $P_{sd}^t$  adote um valor positivo, igual ou inferior a  $P_{sd,max}$ , enquanto  $P_{sc}^t$  será zero, conforme mostra a equação (3.16). Já no caso de  $B_{desc}^t$  ser nulo, a equação (3.16) permite que  $P_{sc}^t$  tenha um valor positivo, igual ou inferior a  $P_{sc,max}$ , sendo  $P_{sd}^t$  restrita a zero pela equação (3.15).

Na equação (3.17) calcula-se o estado de carga no final de cada período  $t$ . Não é considerada a eficiência do ciclo de carga e descarga, eficiência que, entretanto, dependendo da tecnologia da bateria e dos limites da faixa de operação do estado de carga, pode ser mantida próxima a 100%. A eficiência do ciclo das baterias depende da tecnologia, e pode ser não-linear, dependendo da tecnologia utilizada. Como mostram Palma-Behnke *et al.* (2013) e Tenfen (2015), entretanto, é possível aplicar a linearização por partes no modelamento destas perdas. Também não são consideradas as eficiências dos inversores, que podem também ser mantidas em valores muito altos, acima de 95%, podendo ser modelados facilmente com o acréscimo de duas constantes, como mostram diversos autores. A metodologia adequada de modelamento dessas perdas, entretanto, além do baixo impacto nos casos avaliados, não é ainda consolidada nas estratégias descentralizadas, dificultando a comparação realizada neste trabalho (Palma-Behnke *et al.*, 2013; Tenfen, 2015; Du *et al.*, 2017; Rangel *et al.*, 2016; Zhang *et al.*, 2017; Lukacs & Bhadra, 2003).

A constante  $nf^t$  resulta da taxa de auto descarregamento da bateria durante o intervalo  $\delta t$ . Tal constante é calculada com base na taxa de auto descarregamento da bateria a cada hora  $nf$ , elevada à  $\delta t$ , cálculo mostrado na equação (3.23).

$$nf^t = nf^{\delta t} \quad (3.23)$$

Os valores máximo e mínimo do estado de carga são restringidos pela equação (3.18).

As transições de valores de  $B_{desc}^t$  são utilizadas para determinar os valores binários  $B_{dini}^t$  e  $B_{dfim}^t$ , através da equação (3.19), as quais representam, respectivamente, o início e o fim de uma rampa de descarga. A restrição (3.21) impede que essas duas variáveis binárias sejam verdadeiras simultaneamente. Estas variáveis são utilizadas na equação (3.20) para determinar a contagem de meio-ciclos de carga/descarga da bateria, representada pela variável  $Cic^t$ . Por

fim, a variável  $Cic^t$  é limitada pela equação (3.22), restringindo-se assim o número máximo de meio-ciclos de descarga, que, juntamente com a penalização mostrada na equação (3.7), contribuem para aumentar a vida útil da bateria.

### 3.2.2. Modelo de tempo real

O gerenciamento ótimo em tempo real é um problema de minimização de custos decorrentes do desvio da potência disponível e da demanda em relação às previstas no *day-ahead*, em um intervalo de tempo  $\delta_t = 5 \text{ min}$ , sujeito às restrições dos diversos componentes da MR. Trata-se de um problema semelhante ao do *day-ahead*, porém compreendendo um único intervalo, no qual busca-se preferencialmente manter inalteradas as potências planejadas no *day-ahead* para os REDs cujos estados atuais e futuros dependam de seus estados anteriores, caso das unidades geradoras não-renováveis e dos sistemas de armazenamento. Estes só terão seus pontos de operação alterados, em relação ao planejado no *day-ahead*, no caso de risco de ultrapassagem da demanda contratada, como será detalhado mais adiante. Isto porque a otimização de tais valores tem implicações em intervalos posteriores e não há como otimizá-los adequadamente sem considerar os intervalos futuros. A alternativa de estabelecer regras diferenciadas para diferentes combinações de estados, sem considerar os intervalos futuros, de acordo com Stadler *et al.* (2015), na prática se mostra pouco eficiente. Os autores recomendam manter o estado de carga dos SAEs nos níveis planejados no *day-ahead*, permitindo que a potência da macrorrede flutue livremente e absorva quaisquer desvios de oferta ou demanda, a não ser no caso de ultrapassagem de demanda, em que a prioridade passa a ser evitar a condição da ultrapassagem.

Na estratégia proposta por Stadler *et al.* (2015), portanto, a otimização de tempo real é realizada seguindo regras estabelecidas durante o *day-ahead*, visando a manutenção do balanço de potências, na qual utiliza-se a energia do SAE apenas no caso de ultrapassagem. De fato, considerando as dimensões da MR tomada como referência neste trabalho, seria possível, sem dificuldades, fazer o mesmo, não sendo necessário um modelo matemático de otimização. Optou-se, entretanto, neste trabalho, por desenvolver modelo matemático que possa ser generalizável para MRs mais complexas, com maior número e variedade de REDs.

Como já mencionado, as previsões de oferta e demanda em MRs com alta resolução de tempo, para horizontes de curto e médio prazo, são ainda considerados grandes desafios. Entre as técnicas mais comuns para a previsão em horizontes muito curtos de tempo, da ordem de alguns minutos, estão as utilizadas por Dimeas & Hatziargyriou (2005), que são tomada como base para este trabalho. A técnica do limite superior (*upper limit*), que consiste em considerar como limite máximo de oferta a capacidade nominal, é vista como adequada para os geradores não-renováveis. Já a técnica do limite persistente (*persistent method*), pela qual a medição presente é projetada como a média esperada para o próximo intervalo de poucos minutos, pode ser aplicada para a oferta de fontes renováveis intermitentes e para a previsão de demanda. Ou seja, considera-se que a demanda medida no início de cada intervalo de 5 minutos irá



permanecer estável ao longo de todo esse intervalo (Chen, 2001; Singh *et al.*, 2014; Carvalho, 2017).

As variáveis utilizadas são, em sua maioria, as mesmas do problema de *day-ahead*, embora geralmente omitindo o índice sobrescrito  $t$ , já que este algoritmo trabalha em um único intervalo. Este índice será usado apenas para diferenciar variáveis de seus valores em intervalos anteriores, quando necessário. A seguir, descrevem-se as variáveis e parâmetros constantes utilizadas apenas em tempo real, não mencionadas na descrição do problema do *day-ahead*.

#### A. Parâmetros

$B_{i,da}^t$	Constante binária que será 1, se o planejamento realizado no <i>day-ahead</i> previa que o gerador estaria ligado no período $t$
$B_{sz,da}$	Constante binária que será 1, se a potência $P_{sd,da}$ for nula, e zero caso contrário
$B_{ud,da}$	Constante binária que será 1, se o planejamento realizado no <i>day-ahead</i> indica a ultrapassagem de demanda (ou seja, $P_{rcd}^t > 0$ )
$B_{us}$	Constante binária que será zero, se o planejamento realizado no <i>day-ahead</i> indicar a ultrapassagem de demanda (ou seja, $P_{rcd}^t > 0$ ) sem a utilização da energia do SAE (ou seja, com $P_{sd}^t = 0$ )
$PRD_{max}$	Máxima potência de ultrapassagem $P_{rcd}$ possível
$PRV_{max}$	Máxima potência de energia vendida à macrorrede
$P_{i,da}$	Potência média da unidade geradora não renovável $P_i$ planejado no <i>day-ahead</i>
$SOC_{da}^{t-1}$	Estado de carga da bateria inicial que havia sido planejado no <i>day-ahead</i>
$P_{sd,da}$	Potência média de descarga do SAE planejada no <i>day-ahead</i>
$P_{sc,da}$	Potência média de carga do SAE planejada no <i>day-ahead</i>
$P_{s,da}$	É a potência média de carga(-)/descarga(+) $P_s$ do SAE planejada no <i>day-ahead</i> . Pode ser definida como $P_{s,da} = (P_{sd,da} - P_{sc,da})$
$\Delta P_{s,da}$	Desvio na potência $P_s$ usado para compensar desvios do intervalo anterior, quando o SOC inicial do intervalo é diferente do planejado no <i>day-ahead</i> . Pode ocorrer, se houve demanda de ultrapassagem no intervalo anterior, que obrigou a MR a descarregar a bateria além do planejado
$\Delta P_{s,da}$	Constante que indica o valor bruto de $\Delta P_s$ necessário para compensar desvios do intervalo anterior, sem considerar os limites factíveis ou o risco de nova ultrapassagem da demanda contratada

#### B. Variáveis contínuas

- $P_s$  Potência de carga ou descarga do banco de baterias. Assume valor positivo para descarga, e negativo para carga
- $\Delta P_s$  Desvio da potência média de carga(-)/descarga(+)  $P_s$  do banco de baterias com relação à potência média  $P_{s,da}$  planejada no *day-ahead*

A constante binária  $B_{ud}$ , que indica a ultrapassagem da demanda contratada, será utilizada para permitir o aumento da potência disponibilizada pelas unidades geradoras não-renováveis ou pelo banco de baterias, de maneira a reduzir ou evitar a multa por ultrapassagem. Entretanto não será permitido ao modelo de tempo real modificar o planejamento do *day-ahead*, mesmo em caso de ultrapassagem de demanda, caso o planejamento de *day-ahead* tenha previsto a condição de ultrapassagem e ainda assim tenha decidido não utilizar a energia do SAE. Esta última condição é identificada por meio da variável binária  $B_{us}$ , definida na equação (3.24).

$$B_{us} = 1 - (B_{ud,da} \times B_{sz,da}) \quad (3.24)$$

Onde  $B_{sz,da}$  é dado pela equação (3.25).

$$B_{sz,da} = \begin{cases} 1 & \text{se } P_{sd,da} = 0 \\ 0 & \text{se } P_{sd,da} > 0 \end{cases} \quad (3.25)$$

No caso de  $B_{us}$  ser falso, supõe-se que o planejamento de *day-ahead* tenha optado por não utilizar a energia armazenada, mesmo em uma condição de ultrapassagem, por estar prevendo uma condição possivelmente ainda pior em um intervalo posterior.

Caso se observe que a demanda contratada não será ultrapassada, opta-se por não alterar em tempo real as potências determinadas pelo modelo do *day-ahead* do SAE. Caso contrário, se  $B_{ud} = 1$ , e caso  $B_{us}$  seja verdadeiro, permite-se o uso da energia armazenada na bateria e dos geradores não-renováveis para os próximos 5 minutos. Isso resultará em um maior uso da bateria em determinado intervalo  $t$ , resultando em um desvio no estado de carga inicial no intervalo  $t + I$ , em relação ao planejado no *day-ahead*. Assim que o risco de ultrapassagem cessar, soma-se um valor negativo (carga) e constante  $\Delta P_{s,da}$  na potência planejada  $P_{s,da}$ , de maneira a trazer o estado de carga ao valor programado no *day-ahead*.

O valor  $\Delta P_{s,da}$  necessário para levar o estado de carga do banco de baterias novamente ao valor planejado durante o próximo intervalo de duração  $\delta t$  pode ser calculado por meio da equação (3.26).

$$\Delta P_{s,da} = -(SOC_{da}^{t-1} - SOC^{t-1}). (nBat \times BS) / \delta t \quad (3.26)$$

A função objetivo a ser minimizada pode ser expressada como:

$$\text{Custo} = \sum_{i=1}^N C_f^i + C_{cr} - R_{vr} \quad (3.27)$$

Sujeito às seguintes restrições:

$$\sum_{i=1}^N P_i + P_{rc} + P_{rcd} - P_{rv} + P_s + \sum_{n=1}^{NR} PR_n = \sum_{k=1}^{NK} PC_k \quad (3.28)$$

$$B_i^t \cdot P_{i,min} \leq P_i \leq B_i^t \cdot P_{i,max} \quad (3.29)$$

$$B_i^t \geq B_{i,da}^t \quad (3.30)$$

$$B_{ud} \cdot DC \leq P_{rc} \leq B_{cr} \cdot DC \quad (3.31)$$

$$0 \leq P_{rv} \leq (1 - B_{cr}) \cdot PRV_{max} \quad (3.32)$$

$$0 \leq P_{rcd} \leq B_{ud} \cdot PRD_{max} \quad (3.33)$$

$$B_{ud} - B_{cr} \leq 0 \quad (3.34)$$

$$\Delta P_s = P_s - (P_{sd,da} - P_{sc,da}) + \Delta P_{s,da} \quad (3.35)$$

$$2 \times B_{us} \times P_{sc,max} \leq \Delta P_s \leq 2 \times B_{us} \times P_{sd,max} \quad (3.36)$$

$$2 \times B_{ud} \times P_{sc,max} \leq \Delta P_s \leq 2 \times B_{ud} \times P_{sd,max} \quad (3.37)$$

$$P_{s,min} \leq P_s \leq P_{s,max} \quad (3.38)$$

$$P_s \leq (1 - B_{ud}) \cdot P_{s,max} + B_{ud} \cdot \left( \sum_{k=1}^{NK} PC_k^t - \sum_{i=1}^N P_{i,da} - \sum_{n=1}^{NR} PR_n^t - DC \right) \quad (3.39)$$

$$SOC^t = n f^t \cdot SOC^{t-1} - P_s \cdot \delta t / (nB \times BS) \quad (3.40)$$

$$SOC_{mim} \leq SOC^t \leq SOC_{max} \quad (3.41)$$

Na equação (3.27), o primeiro termo,  $C_f$ , fornece o custo das unidades geradoras despacháveis não renováveis, sendo  $P_i$  a potência a ser gerada no intervalo de tempo  $\delta_t$ . Já o segundo termo,  $C_{cr}$ , determina o custo de compra de energia da macrorrede, enquanto o terceiro termo,  $R_{vr}$ , calcula a receita da venda de excedente de energia à macrorrede no mesmo intervalo. Esses três termos são calculados da mesma forma que no modelo do *day-ahead*, considerando um único intervalo de 5 minutos.

A equação (3.28) representa o balanço de potências, garantindo que a energia gerada seja equivalente à consumida.

A equação (3.29) limita as potências  $P_i$  das unidades geradoras não-renováveis. A variável binária  $B_i^t$ , indica se a unidade geradora  $i$  está ligada. Caso seja zero, indica que o gerador estará desligado, fixando a potência  $P_i$  associada em zero. Esta variável binária será usada para calcular o custo de partida do gerador, como será visto mais adiante, com o mesmo procedimento usado no *day-ahead*.

O modelo de tempo real permite que o sistema altere as potências  $P_i$  dos geradores, desde que isso não implique em um desligamento não previsto. Ou seja, se o planejamento de *day-ahead* previa o uso de determinado gerador  $i$  no intervalo  $t$ , o modelo de tempo real poderá alterar livremente a potência do gerador, visando equilibrar diferenças dos valores de oferta e

demanda em relação as previsões, sempre que os custos compensarem, porém não poderá desligar o gerador. Optou-se por essa estratégia porque o desligamento não previsto poderá implicar no acréscimo do custo de partida para religá-lo posteriormente, o que poderia comprometer o planejamento de *day-ahead*. Essa restrição é garantida pela equação (3.30).

A equação (3.31) restringe  $P_{rc}$ , a potência média de energia comprada da macrorrede até o limite da demanda contratada. A equação (3.31) garante que  $P_{rc}$  não ultrapassará a demanda contratada e que será zero, caso  $B_{cr} = 0$ , ou seja, caso a MR não esteja comprando energia da macrorrede. Permite, também, a  $P_{rc}$  assumir valores positivos, caso não seja registrado excesso de demanda ( $B_{ud} = 0$ ), porém garante que  $P_{rc}$  será igual ao valor da demanda contratada se houver ultrapassagem da demanda, ou seja, se  $B_{ud} = 1$ . Neste caso, o valor que ultrapassar a demanda contratada será representado por  $P_{rcd}$ .

A equação (3.32) estabelece a relação entre a variável binária  $B_{cr}$ , que indica se a MR irá comprar energia da macrorrede, com a potência média de energia vendida. Caso  $B_{cr} = 1$ , não há venda de energia à macrorrede e, portanto, restringe-se  $P_{rv}$  a zero. A equação também garante que  $P_{rv}$  seja uma variável positiva.

Já na equação (3.33) limita-se a potência de ultrapassagem com a utilização da variável binária  $B_{ud}$ . Nesta equação, apenas admite-se que a potência de ultrapassagem  $P_{rcd}$  seja não nula caso  $B_{ud} = 1$ . Esta variável binária é utilizada na equação (3.37) para fixar em zero a variável  $\Delta P_s$  caso não ocorra ultrapassagem da demanda (ou seja, se  $B_{ud} = 0$ ), o que garante que a potência do SAE seguirá o planejado no *day-ahead*. Ou seja, o algoritmo apenas permite que a potência do SAE se desvie do planejado no *day-ahead* se ocorrer a ultrapassagem da demanda. Mas mesmo na ocorrência de ultrapassagem, a energia do SAE só poderá ser desviada do planejado no *day-ahead* se  $B_{us} = 1$ , o que é garantido pela equação (3.36). Ou seja, mesmo na ocorrência de ultrapassagem, caso o *day-ahead* tenha previsto a condição de ultrapassagem, e ainda assim tenha optado por não despachar o SAE, situação em que tem-se  $B_{us} = 0$ , deve-se manter  $\Delta P_s = 0$ , preservando a carga do SAE para uso futuro, em situação provavelmente mais crítica.

A equação (3.34) vincula a ocorrência de excesso de demanda à compra de energia da macrorrede. Note que, caso  $B_{ud} = 1$ , para que a condição seja satisfeita, tem-se que ter necessariamente  $B_{cr} = 1$ .

Na equação (3.35) calcula-se  $P_s$  com base nas potências  $P_{sc,da}$  e  $P_{sd,da}$  planejadas no *day-ahead*, e os possíveis desvios devido à ocorrência de desvio prévio em intervalo anterior, representado pela constante  $\Delta P_{s,da}$ , e devido a mudanças nas previsões de geração e demanda para o próximo intervalo  $\delta t$ , desvio representado pela variável  $\Delta P_s$ . Esta variável é restringida, em seus valores máximo e mínimo, pela equação (3.36). Note que, como resultado dessas duas equações, caso  $B_{ud} = 0$ , ou seja, se não houver ultrapassagem de demanda, tem-se como resultado que  $\Delta P_s = 0$ , e com isso, com base na equação (3.35), tem-se que  $P_s = (P_{s,da} + \Delta P_{s,da}) + \Delta P_{s,da}$ . Ou seja, nesse caso,  $P_s$  será uma constante equivalente à soma do valor

planejado no *day-ahead*, somado a eventual compensação por desvio em intervalos anteriores visando trazer o estado de carga de volta ao planejado.

Os valores limites ( $2 \times B_{ud} \times P_{sc,max}$ ) e ( $2 \times B_{ed} \times P_{sd,max}$ ) da equação (3.36), são derivados da equação (3.35). Uma vez que  $P_{sc,max} \leq P_s \leq P_{sd,max}$  e que  $P_{sc,max} \leq (P_{s,da} + \Delta P_{s,da}) \leq P_{sd,max}$ , pode-se deduzir que, caso não exista ultrapassagem da demanda contratada,  $2 \times P_{sc,max} \leq \Delta P_s \leq 2 \times P_{sd,max}$ . Esses limites, entretanto, na prática podem não ser atingidos, pois o valor de  $P_s$  precisa também respeitar limites máximos e mínimos, garantidos pela equação (3.39). Nessa equação, no caso de ultrapassagem de demanda, ou seja, caso  $B_{ud}$  seja verdadeiro, e supondo  $B_{us} = 1$ , o limite de  $P_s$  corresponde ao valor máximo de potência necessário para prevenir a condição de ultrapassagem da demanda contratada, limite representado pela subtração da demanda líquida (demanda bruta menos geração renovável) pela demanda contratada somada à energia fornecida pelos geradores despacháveis. Em quaisquer situações, seja em condição de ultrapassagem ou não, a equação (3.38) garante que  $P_s$  não irá desrespeitar o limite suportado pelo SAE.

Os limites máximo e mínimo utilizados na equação (3.37) são obtidos de maneira análoga aos da equação (3.36).

A equação (3.40) calcula o estado de carga  $SOC^t$  no final do intervalo, com base no estado de carga no início do intervalo ( $SOC^{t-1}$ ) e na potência de carga/descarga  $P_s$ , de maneira análoga ao já realizado para o *day-ahead* na equação (3.17), com a diferença que, aqui, não se faz necessário separar  $P_s$  (potência de carga/descarga) em  $P_{sc}$  (potência de carga) e  $P_{sd}$  (potência de descarga), já que não se aplica a penalidade  $C_b$  no tempo real. Supõe-se que os custos marginais de vida útil da bateria, representados no *day-ahead* pela constante  $tf_{ps}$  na equação (3.7), sejam muito inferiores aos custos da multa por ultrapassagem da demanda, única condição em que o banco de baterias será acionado além do planejado.

Como no caso da equação (3.17), a constante  $nf^t$  na equação (3.40) é obtida a partir da taxa de autodescarregamento do banco de baterias para o intervalo  $\delta t$ , a qual é obtida da taxa de autodescarregamento por hora, como mostrado na equação (3.23).

A equação (3.41) limita o estado de carga final do intervalo a valores máximos e mínimos  $SOC_{min}$  e  $SOC_{max}$ , o que restringe também os valores factíveis de  $P_s$ .

No modelo aqui apresentado a potência da bateria definida no plano de *day-ahead* será considerada constante enquanto a energia comprada da macrorrede não ultrapassar a demanda contratada. Caso a demanda contratada seja ultrapassada, e essa ultrapassagem não tenha sido prevista no planejamento de *day-ahead* (ou seja, se  $B_{us} = 1$ ), em vista dos altos custos da multa aplicada, passa-se a permitir o uso da energia do SAE em níveis não planejados no *day-ahead*, considerando o custo de sua energia como nulo, até o limite necessário para compensar a ultrapassagem.

A consideração dos custos de oportunidade durante a otimização em tempo real, de maneira mais sistemática, depende do uso de técnicas para a determinação dos custos marginais em cada intervalo, durante a otimização em *day-ahead*, como as apresentadas por Wang *et al.* (2015).

Uma alternativa para considerar os custos de desgaste na otimização de tempo real seria implementar o método proposto em Han *et al.* (2014). Trata-se de um modelo não-linear, porém também passível de ser linearizado.

### 3.3. Modelo descentralizado

Neste trabalho, não serão avaliadas metodologias de otimização de *day-ahead* com estratégias distribuídas, em plataformas de SMA. Como já exposto na Seção 2.4, a otimização de *day-ahead* é ainda um desafio em MRs, mesmo com modelos centralizados. Um dos fatores dificultadores é o fato de as condições de operação geralmente mudarem com muita rapidez, sendo difíceis de antecipar (Katiraei *et al.*, 2008).

Em Dimeas & Hatziargyriou (2005) apresenta-se sistema de gerenciamento ótimo de energia em tempo real para uma MR modelada como SMA com algoritmo descentralizado de leilão direto simétrico clássico. A estratégia de gerenciamento apresentada nele utiliza como base o algoritmo descrito por Bertsekas (1990).

O sistema de gerenciamento de energia descrito por Dimeas & Hatziargyriou (2005) foi implementado na MR emulada no *Power System Laboratory of the National Technical University of Athens*, utilizando o *framework* JADE (*Java Agent DEvelopment Framework*). A estratégia utilizada no referido trabalho foi tomada como base para o modelo descentralizado desenvolvido neste trabalho.

Entretanto, o citado trabalho não considera os custos de oportunidade dos SAEs. Os agentes controladores dos SAEs, comunicando-se com os demais e considerando seu estado de carga atual, podem tomar a decisão, de maneira autônoma, de comprar ou vender energia, armazenando em instantes de alta produção das fontes renováveis, e vendendo energia quando a oferta das fontes renováveis é menor, não havendo detalhamento de como tais decisões são formuladas (Katiraei *et al.*, 2008; Hatziargyriou, 2014).

O modelo SMA proposto por Dimeas & Hatziargyriou (2005) utiliza uma arquitetura de controle semidescentralizada, sendo composta dos seguintes níveis hierárquicos:

1. Nível dos Operadores de Rede e de Mercado: equivale ao nível de rede do modelo tradicional discutido na Seção 2.5.
2. MGCC (*Microgrid Central Controller*): é o sistema SCADA central, equivalente ao sistema de gerenciamento do modelo tradicional, discutido na Seção 2.5.
3. LCs (*Local Controllers*): nível mais baixo da hierarquia, equivalente ao nível de campo da hierarquia apresentada na Seção 2.5.

Em cada uma dessas camadas, diferentes categorias de agentes cumprem funções específicas, trocando informações entre si. Neste trabalho, considera-se uma arquitetura de SMA constituída dos elementos mostrados na Figura 2.5. Para o gerenciamento ótimo de energia, no modelo tomado como base, os seguintes agentes se destacam:

1. Agente Supervisor: tem relevância sobretudo os agentes mediador e regulador, membros da Sociedade/Agente Supervisor (lembrando que o Agente Supervisor é em si uma sociedade de agentes que atua como agente único). O Agente Mediador é responsável por mediar as negociações entre os agentes de mercado, seguindo as regras estabelecidas pelo Agente Regulador. O Agente Regulador, por sua vez, estabelece regras com base em informações trocadas com a camada analítica, com o Agente Mediador e o Simulador de Rede.
2. Agentes Controladores Locais: agentes “físicos”, ou seja, que modelam e controlam entidades físicas reais, neste caso os REDs compradores (cargas e painéis de carga), vendedores (microfontes) e acumuladores (SAEs).
3. Agentes de Mercado: são agentes virtuais criados pelos agentes Controladores Locais especificamente para negociar, representando suas sociedades de origem, no período de negociação, mediados pelo Agente Mediador. São criados contendo apenas as informações necessárias para a negociação, como informações de custos e função utilidade de suas sociedades de origem.

### 3.3.1. Gerenciamento ótimo de energia em tempo real

Em Dimeas & Hatziargyriou (2005), utiliza-se algoritmo de leilão direto simétrico, com implementação *Gauss-Seidel*. A MR é modelada como SMA cuja otimização local é totalmente descentralizada.

O SCADA central da MR hospeda o Agente/Sociedade Supervisor, o qual contém os agentes Mediador e Regulador. Cabe a ele negociar com o operador de mercado da rede da distribuidora os preços de compra e venda de energia da macrorrede e então dar início ao período de negociação, passando a mediar a negociação entre os agentes vendedores e compradores, representantes dos CLs das microfontes e cargas da MR, determinando também o final do período de negociação.

O algoritmo utiliza agentes físicos, que representam e controlam componentes físicos, como microfontes e cargas ou painéis de cargas, e agentes virtuais, que são utilizados para finalidades específicas temporárias. Em cada período de negociação, os agentes físicos das fontes e cargas do sistema criam agentes negociadores virtuais, os Agentes de Mercado, responsáveis por representar seus agentes (ou sociedades de agentes) físicos de origem, nas negociações mediadas pelo Agente Supervisor (Dimeas & Hatziargyriou, 2005; Hatziargyriou, 2014).

Uma vez iniciado o período de negociação pelo Agente Mediador, a negociação passa a ocorrer entre os Agentes de Mercado, vendedores ou compradores, os quais fecham contratos

de compra e venda entre si, até que estes cheguem à condição de equilíbrio de preços, ou até atingirem um limite de tempo de negociação de 5 minutos. A Figura 3.2 ilustra o processo de negociação (Dimeas & Hatziargyriou, 2005; Hatziargyriou, 2014).




Figura 3.2: Negociação entre agentes virtuais de mercado, criados por agentes físicos, fontes ou cargas. Fonte: adaptado de (Hatziargyriou, 2014).

Passado o período de negociação, tem início o período de operação, no qual os CLs das microfuentes e dos sistemas de armazenamento da MR, de posse dos pontos de referência (*set points*) definidos na melhor solução encontrada no período de negociação, passam a trabalhar no controle dos sistemas locais visando manter os patamares de geração negociados. A cada 15 minutos o ciclo se repete, como mostrado na Figura 3.3.

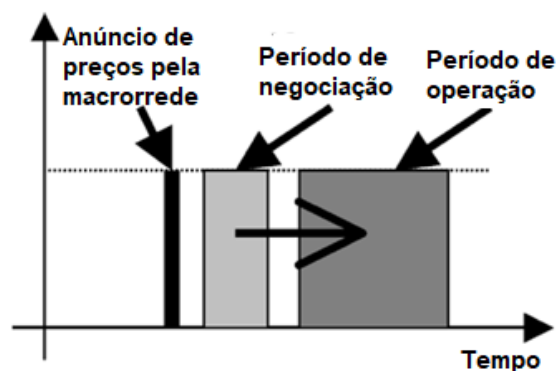


Figura 3.3: Sequência de ações no tempo da operação de mercado da MR. Fonte: adaptado de (Dimeas & Hatziargyriou, 2005).

As fontes da MR são representadas por agentes negociadores, ou de mercado, vendedores, enquanto as cargas são representadas por agentes negociadores compradores. A rede da distribuidora, assim como os agentes que representam SAEs, sendo capacitada tanto para comprar como para vender energia, pode ser representada tanto por agentes vendedores como por agentes compradores, dependendo da estratégia escolhida pela sociedade de origem, ou imposta pelo Agente Regulador. Na implementação do algoritmo de leilão, no período de negociação, os agentes compradores representam as “pessoas”, enquanto os vendedores são os “objetos” (Dimeas & Hatziargyriou, 2005; Bertsekas, 1990).



Os limites de compra e venda da macrorrede são desconsiderados. Considera-se tais limites como muito superiores às capacidades da MR (Dimeas & Hatziargyriou, 2005).

Para que se possa aplicar o algoritmo simétrico de alocação única ao problema do gerenciamento de energia, é necessário dividir, tanto a energia disponível para a venda, como a demanda de energia em blocos de igual tamanho. Ou seja, torna-se necessária a criação de agentes virtuais de mercado que representem blocos de energia disponíveis para venda (agentes vendedores), ou blocos de demanda de energia (agentes compradores), cada um representando unidades iguais de energia. Caso a energia gerada na MR não seja igual à energia demandada, haverá um número diferente de agentes compradores e vendedores, tornando o problema assimétrico. O problema pode ser transformado em um problema simétrico com a adição de agentes virtuais de mercado, que podem ser compradores ou vendedores, representando a macrorrede, de maneira a equilibrar o número de compradores e vendedores. Esse processo de discretização de blocos de energia de oferta e demanda é mostrado na Figura 3.4. Nela, uma porção de carga “virtual”, mostrada em vermelho, composta por dois blocos de energia adicionais, é somada à demanda real, representando energia passível de ser vendida à macrorrede, de maneira a transformar o problema de alocação em um problema simétrico (Hatziargyriou, 2014; Dimeas & Hatziargyriou, 2005).




Figura 3.4: Blocos de energia de oferta e demanda, compondo o problema de alocação única simétrico. Fonte: Adaptado de (Hatziargyriou, 2014).

No início do processo de negociação, os agentes controladores das cargas da MR determinam suas previsões de demanda para o próximo ciclo de operação e geram um número proporcional de Agentes de Mercado compradores para representá-los, cada um negociando a compra de um bloco de energia. Da mesma forma, os agentes controladores das fontes da MR determinam a energia passível de ser gerada, criando Agentes de Mercado vendedores em número proporcional à energia disponível para venda, cada um representando um bloco discreto de energia disponível.

Segue-se o seguinte procedimento, no período de negociação (Dimeas & Hatziargyriou, 2005):

1. O agente supervisor anuncia o início de novo período de mercado, com os preços negociados ou obtidos com o operador de mercado da macrorrede.

2. As sociedades de agentes locais que representam as fontes internas de geração da MR estimam suas capacidades de produção, criando um número proporcional de agentes negociadores vendedores, cada um representando um pacote discreto de energia.
3. As sociedades de agentes locais que representam as cargas da MR estimam suas demandas reais atuais, gerando um número proporcional de agentes negociadores compradores, cada um também representando um pacote discreto de energia demandada. Obviamente, para manter o problema simétrico, cada pacote de oferta e de demanda deve representar uma quantidade idêntica de energia.
4. O agente que representa a macrorrede da distribuidora gera um número de agentes vendedores ou compradores correspondendo à diferença entre o número de agentes compradores e vendedores gerados pelos Agentes Controladores Locais, de maneira a equilibrar oferta e demanda e tornar o problema de alocação um problema simétrico. Ou seja, se houver mais agentes locais compradores que vendedores na MR, o agente da macrorrede irá gerar agentes vendedores, de maneira a equalizar o número de compradores e vendedores no sistema. Na situação contrária, irá gerar agentes compradores.
5. O Agente Supervisor anuncia o início de novo período de negociação.
6. Inicia-se, então, o leilão entre os agentes negociadores (Agentes de Mercado).
7. O Agente Supervisor anuncia o fim do período de negociação assim que identifica o atingimento do ótimo global, em que todos os compradores estejam satisfeitos, ou após decorrido o tempo máximo de negociação ou o número máximo de iterações.
8. Os agentes negociadores informam às suas sociedades de origem (seus agentes “pais”) os contratos firmados durante a negociação, ou seja, seus pontos de referência ou de operação (*set points*), indicando a energia a ser produzida ou consumida no próximo período de operação. Os Agentes de Mercado então se autodestroem.
9. O Agente Supervisor anuncia o final do período de mercado.
10. Inicia-se novo período de operação, com os pontos de referência definidos pelos agentes negociadores sendo usados como referência pelos Agentes Controladores Locais dos REDs.

Na estratégia de otimização apresentada por Dimeas & Hatziargyriou (2005), os Agentes de Mercado são criados e se mantêm hospedados nos mesmos servidores dos Agentes Controladores Locais em que foram criados, enviando seus lances ou propostas, em cada rodada de negociações, via rede de comunicação Ethernet, para o servidor que hospeda o sistema SCADA central, onde funciona o Agente Supervisor. Como os autores comentam, esta técnica torna a latência da rede um gargalo, tendo a vantagem de tornar mais simples a manutenção da privacidade dos proprietários dos diferentes REDs. Caso todos os REDs tenham o mesmo proprietário, ou caso seja possível confiar na manutenção da privacidade por parte do Agente

Supervisor, uma opção seria tirar vantagem da capacidade de mobilidade dos agentes em um SMA, recurso suportado por *frameworks* multiagente como o JADE, através da qual pode-se transportar tanto o estado como o próprio código executável de um agente entre servidores de uma mesma plataforma. Pode-se, dessa forma, no início de cada ciclo de negociação, transferir os Agentes de Mercado criados pelas sociedades de CLs para o mesmo servidor físico que hospeda o Agente Supervisor. Com isso, todas as negociações podem ocorrer em um mesmo servidor físico, eliminando-se, assim, o gargalo representado pela latência da rede de comunicação. Nesse caso, o processamento do algoritmo de otimização ocorreria de maneira centralizada em um mesmo ambiente computacional, reduzindo-se a necessidade de comunicação de dados, já que os Agentes de Mercado não precisam conhecer detalhadamente os modelos das sociedades de origem, mas apenas as informações imprescindíveis para a negociação em curso. Incorre-se, porém, no risco de sobrecarregar o servidor central, se o número de agentes for excessivamente alto. Assim sendo, porém, como destaca Hatziargyriou (2014), existe sempre a alternativa de adicionar-se novas camadas de hierarquia ao SMA, algo relativamente simples, levando-se em conta as habilidades sociais dos agentes, promovendo maior escalabilidade (Bellifemine *et al.*, 2010).

Apresenta-se, a seguir, um exemplo simples do mecanismo de negociação entre os agentes, semelhante aos apresentados por Dimeas & Hatziargyriou (2005) e por Bertsekas (1990), ilustrando o procedimento implementado neste trabalho. Considerando-se uma MR com 30 kW de demanda média, e com sistema fotovoltaico fornecendo 20 kW de potência, em determinado intervalo hipotético de 1 hora. Considera-se, para fins didáticos, uma discretização de 10 kW por Agente de Mercado. Com isso, tem-se a criação de 3 agentes compradores (3 pessoas), e dois agentes vendedores (2 objetos), respectivamente pelas sociedades de cargas e fontes. A fim de tornar o problema simétrico, a sociedade que representa a macrorrede cria então um agente vendedor adicional.

Supondo-se que o custo de corte de carga seja de R\$100,00 por pacote de energia (ou seja, R\$10,00 / kWh) para todos os agentes virtuais compradores, este é o preço máximo que tais agentes estarão dispostos a pagar por pacotes de energia dos agentes vendedores. Supondo-se ainda que a energia gerada pelo sistema fotovoltaico tenha custo zero, os agentes vendedores representantes desse sistema terão custo de operação zero. Já o agente vendedor da macrorrede terá um custo mínimo equivalente à tarifa cobrada pela distribuidora, que será suposta como sendo de R\$0,30 / kWh, neste exemplo.

Pode-se considerar, então, que os benefícios intrínsecos iniciais para as três cargas são de R\$100,00 para os pacotes de energia solar, e de R\$99,70 para o pacote de energia vendido pela macrorrede. Para que se possa garantir a convergência ao ótimo global, utiliza-se, então, a técnica apresentada na Seção 2.6.4, multiplicando-se os valores intrínsecos por uma constante, neste caso 100, de maneira a tornar todos os valores intrínsecos inteiros. Obtém-se, dessa forma, valores intrínsecos de 997 para o pacote vendido pela macrorrede, e de 1000 para os pacotes vendidos pelo sistema fotovoltaico, podendo-se, assim, iniciar o leilão com os preços em zero.

Vale lembrar que os preços utilizados no mecanismo de leilão não tem qualquer relação com os preços reais de mercado ou com os custos para o consumidor, sendo apenas artifícios utilizados no processo de otimização, representando o nível de desejo global por cada objeto (Dimeas & Hatziargyriou, 2005).

Com base na equação (3.10), tem-se então  $\epsilon = \frac{1}{n-1} = 0,5$ . A Tabela 2 ilustra o processo de solução, com o algoritmo de leilão simétrico direto.

O algoritmo inicia, na iteração 1, sem objetos alocados. As 3 pessoas valoram igualmente os 3 objetos, dando maior valor aos objetos 1 e 2, que representam os pacotes de energia ofertados pelo sistema fotovoltaico. Como se tem inicialmente três objetos não alocados, iniciam-se os lances pela pessoa 1 (a escolha aqui é arbitrária, seguindo a ordem numérica, porém, dependendo do sistema, pode-se estabelecer um critério de priorização). A pessoa 1 tem, como objetos de igual valor real, os objetos 1 e 2, optando, novamente de maneira arbitrária, pelo objeto 1, como o de menor valor numérico. O lance ofertado é de  $\epsilon$ , de acordo com a equação (2.8), já que não há diferença entre os valores reais do melhor objeto e do segundo melhor objeto. O objeto 1, tendo seu preço inicial zero, naturalmente aceita a oferta, ficando alocado à pessoa 1, que se torna quase feliz na iteração 2 (Dimeas & Hatziargyriou, 2005; Bertsekas, 1990).

Com isso, na iteração 2, tem-se as pessoas 2 e 3 ainda dispostas a dar lances, optando-se novamente, de maneira arbitrária, pela de menor valor numérico, a pessoa 2. Esta oferece lance ao objeto 2, o de maior valor real nesta iteração, considerando que o objeto 1 passa a valer  $\epsilon$ . O incremento da oferta de preços em relação ao preço atual do objeto 2 dessa vez será maior que  $\epsilon$ , já que há uma diferença entre o valor real do objeto preferido (1000) e o do segundo melhor objeto (999,5), resultando em um incremento de  $2 \cdot \epsilon$ .

A cada iteração, ou lance, uma pessoa não alocada é selecionada para dar um lance a seu objeto preferido, ou seja, ao objeto que apresenta o maior valor real, dado pelo valor intrínseco menos o preço atual do objeto, com o preço ofertado dado pelo preço atual do objeto preferido mais o incremento dado pela equação (2.4).

A cada iteração, enquanto os valores reais dos objetos 1 e 2 continuarem inferiores ao valor real do objeto 3, as 3 pessoas seguirão disputando os objetos 1 e 2, elevando seus preços. Esse processo prossegue até que os valores reais desses objetos se tornem inferiores ao valor real do objeto 3, o que finalmente ocorre na iteração 9. Nela, a pessoa 3, que restou sem alocação, seleciona o objeto 3, o qual não está também alocado a nenhuma pessoa, ofertando a ele um lance, o que resulta em uma nova iteração com todas as pessoas quase felizes, encerrando-se, assim, o período de negociação.

A arquitetura da MR utilizada como referência por Dimeas & Hatziargyriou (2005) utiliza geradores fotovoltaicos como fonte primária de energia, integrando também banco de baterias. Como já referido, a estratégia de carga e descarga das baterias não é detalhada. Ao tentar aplicar

o modelo proposto pelos autores à MR do instituto KERI, usada como referência neste trabalho (ver Seção 4.2), observou-se algumas limitações do mesmo.

Tabela 2: exemplo de solução de problema de alocação com 3 vendedores e 3 compradores, com algoritmo de leilão simétrico.

Iter.	Preços dos objetos	Pares	Pessoas quase felizes	Valores reais dos objetos	Licitante / obj. preferido	Incremento do lance
1	0 / 0 / 0	(1,-)(2,-)(3,-)	-	1000 / 1000 / 997	1 / 1	$\epsilon = 0,5$
2	0,5 / 0 / 0	(1,1)(2,-)(3,-)	1	999,5 / 1000 / 997	2 / 2	$2 \cdot \epsilon = 1$
3	0,5 / 1 / 0	(1,1)(2,2)(3,-)	1 / 2	999,5 / 999 / 997	3 / 1	$2 \cdot \epsilon = 1$
4	1,5 / 1 / 0	(1,-)(2,2)(3,1)	2 / 3	998,5 / 999 / 997	1 / 2	$2 \cdot \epsilon = 1$
5	1,5 / 2 / 0	(1,2)(2,-)(3,1)	1 / 3	998,5 / 998 / 997	2 / 1	$2 \cdot \epsilon = 1$
6	2,5 / 2 / 0	(1,2)(2,1)(3,-)	1 / 2	997,5 / 998 / 997	3 / 2	$2 \cdot \epsilon = 1$
7	2,5 / 3 / 0	(1,-)(2,1)(3,2)	2 / 3	997,5 / 997 / 997	1 / 1	$2 \cdot \epsilon = 1$
8	3,5 / 3 / 0	(1,1)(2,-)(3,2)	1 / 3	996,5 / 997 / 997	2 / 2	$2 \cdot \epsilon = 1$
9	3,5 / 4 / 0	(1,1)(2,2)(3,-)	1 / 2	996,5 / 996 / 997	3 / 3	$2 \cdot \epsilon = 1$
10	3,5 / 4 / 1	(1,1)(2,2)(3,3)	<b>1 / 2 / 3</b>	996,5 / 996 / 996		

### Dificuldades para otimização com o gerador a diesel

A estratégia descrita por Dimeas & Hatziargyriou (2005) mostra-se eficaz no gerenciamento de energia em MR contendo apenas fontes primárias fotovoltaicas, já que a energia gerada pelos geradores solares tem custos operacionais muito baixos ou até desprezíveis, sendo sempre preferível à importação da macrorrede, devendo ser preferencialmente consumida internamente na MR, ou mesmo vendida à MR, se houver excedente.

Se for considerada, entretanto, uma MR contendo fontes despacháveis não renováveis, como o gerador a diesel, a estratégia descrita por Dimeas & Hatziargyriou (2005) mostra limitações importantes. A seguir, apresenta-se um exemplo para ilustrar as limitações identificadas.

Considerando-se, por exemplo, o gerador com capacidade nominal de 20kW, desconsiderando-se o custo de partida e a potência mínima, supondo ainda uma discretização com pequena resolução, para fins didáticos, de 10kW por Agente de Mercado, tem-se dois agentes negociadores vendedores representando o gerador no mercado, durante o período de negociação. Considerando ainda que se tenha 10 kW de potência disponível sendo gerada pelo sistema fotovoltaico e uma carga de 30 kW para atender. Com isso, serão criados também um agente vendedor representando a sociedade do sistema fotovoltaico, e três agentes compradores representando a sociedade de cargas da MR. Como resultado, obtém-se um problema simétrico,

com três compradores e três vendedores, sem a necessidade de criar agentes negociadores da macrorrede.

É fácil deduzir, nesta situação, que o resultado do algoritmo de leilão, desde que os consumidores estejam dispostos a pagar o maior preço oferecido pelo gerador, ou seja, se existir alocação factível, esta será a de utilizar toda a energia disponível do sistema solar e do gerador, sem comprar nada da macrorrede.

Vê-se, portanto, que o algoritmo não dará chance aos consumidores de adquirir energia da macrorrede enquanto houver energia disponível nas fontes internas da MR. Uma vez que a energia vendida pela macrorrede, ou pelo menos até o limite da demanda contratada, tem geralmente custo muito menor que a gerada pelo gerador a diesel, percebe-se facilmente que esse algoritmo não é adequado para a otimização dos recursos energéticos quando a MR contém REDs com pacotes de energia de maior custo que a macrorrede. Isso porque a estratégia proposta por Dimeas & Hatziaargyriou (2005) utiliza toda a energia disponível na MR sempre, antes de adquirir energia da macrorrede, mesmo quando a energia das fontes locais tem custo muito maior que a vendida pela macrorrede, pois esta só será utilizada para solucionar assimetrias entre oferta e demanda.

Uma possível solução seria exigir da macrorrede a criação de Agentes de Mercado vendedores ou compradores sempre, em todas as negociações, em número suficiente para competir com as cargas e fontes internas da MR, ou pelo menos com as fontes que têm a possibilidade de apresentar custos de operação significativos em relação à tarifa de energia da distribuidora. Tal estratégia, entretanto, certamente tornaria o problema assimétrico. Existem variações do algoritmo de leilão para a solução de problemas assimétricos, sobretudo com variações diretas-reversas do algoritmo, indicando ser possível conceber uma estratégia efetiva e eficiente para lidar com o problema em questão (Bertsekas *et al.*, 1993).

Além disso, a estratégia direta proposta por Dimeas & Hatziaargyriou (2005) também não permite considerar os custos de partida, ou as restrição de potência mínima, presente no modelo do gerador diesel apresentado em 3.2.2, o que impede o mesmo de fornecer, uma vez ligado, potência abaixo de 20% da nominal.

Nas análises conduzidas nesse trabalho, as fontes não-renováveis despacháveis não foram simuladas nas estratégias descentralizadas.

### **3.4. Conclusão**

Neste capítulo, apresentou-se o modelamento matemático do problema de otimização representado pelo gerenciamento ótimo de energia.

Foi apresentado modelo centralizado, linear inteiro-misto, em dois níveis de horizontes de tempo, 24 horas (*day-ahead*) e de 5 minutos (tempo real). O modelo desenvolvido levou em consideração as variáveis mais relevantes sugeridas na literatura.

O modelo descentralizado foi desenvolvido apenas para o tempo real. Como já exposto, a execução do planejamento de *day-ahead* com estratégias descentralizadas, em SMAs, é ainda considerada um desafio, envolvendo, provavelmente, a utilização de técnicas avançadas de inteligência artificial nos agentes do sistema, sobretudo nos CLs dos SAEs. Apresentou-se apenas o modelo descentralizado para o tempo real, utilizando algoritmos de leilões diretos simétricos, como utilizado por Dimeas & Hatziargyriou (2005). Foram analisadas as limitações deste algoritmo observadas no modelamento de não-linearidades, como as representadas pelo custo de partida e as restrições de potência mínima dos geradores.

Os modelos desenvolvidos foram implementados computacionalmente, testados e comparados. No próximo capítulo, os testes realizados são descritos, e os resultados analisados.





# Capítulo 4

## Testes e resultados

### 4.1. Introdução

Neste capítulo, serão descritos os testes realizados com as estratégias propostas, comparando-se a estratégia centralizada clássica com a descentralizada.

Será primeiro descrita a MR tomada como referência nos testes deste capítulo. Em seguida, descrevem-se os testes com o modelo de otimização de *day-ahead* apresentado na Seção 3.2.1. A seguir, aplicando-se uma perturbação nos dados de oferta e demanda da MR, serão testados os modelos de otimização de curto prazo centralizado e descentralizado, a fim de ajustar, de maneira ótima, o balanço de potências, equalizando a oferta e a demanda.

Os resultados são, então, comparados e analisados.

### 4.2. Sistema Teste

A MR tomada como referência é a MR piloto construída no centro de pesquisas sul coreano KERI (*Korea Electrotechnology Research Institute*), mostrada na Figura 4.1, com capacidade de 50kVA, cuja arquitetura é descrita em Jeon *et al.* (2010).

Essa MR é composta basicamente por um gerador a diesel, um gerador renovável solar/eólico híbrido, banco de baterias e duas cargas, sendo a MR conectada à rede da distribuidora por um ponto de acoplamento comum.

As transições entre os modos ilhado e conectado são realizadas automaticamente, a comando do sistema SCADA central. O sistema de controle segue o padrão semidescentralizado proposto pelo *CERTS Microgrid Concept*, já discutido na seção 2.2 (Lasseter *et al.*, 2002; Jeon *et al.*, 2010).

Em Jeon *et al.* (2010), utiliza-se modelo de gerador diesel de 20 kVA. O gerador diesel utilizado nas simulações foi o gerador Caterpillar modelo CAT D322E3, de 20kW em *stand-by*. A potência fornecida pelo gerador é limitada a um mínimo de 20% da potência nominal (CATERPILLAR, 2016).

De acordo com Nam *et al.* (2009), a MR possui ainda banco de baterias constituído por 12 baterias de chumbo-ácido ligadas em série, com capacidade total de fornecer 200AH a uma tensão de 144V. Ainda segundo Nam *et al.* (2009), o sistema híbrido incluiria um arranjo de células solares com capacidade nominal de 9kW e 400V, e uma turbina eólica com capacidade nominal de 11kW e 220V. Nas simulações foi utilizada a bateria de chumbo-ácido da marca

MOURA, modelo 12MF220, com capacidade total de fornecer 200AH (Moura, 2014; Jeon *et al.*, 2010)

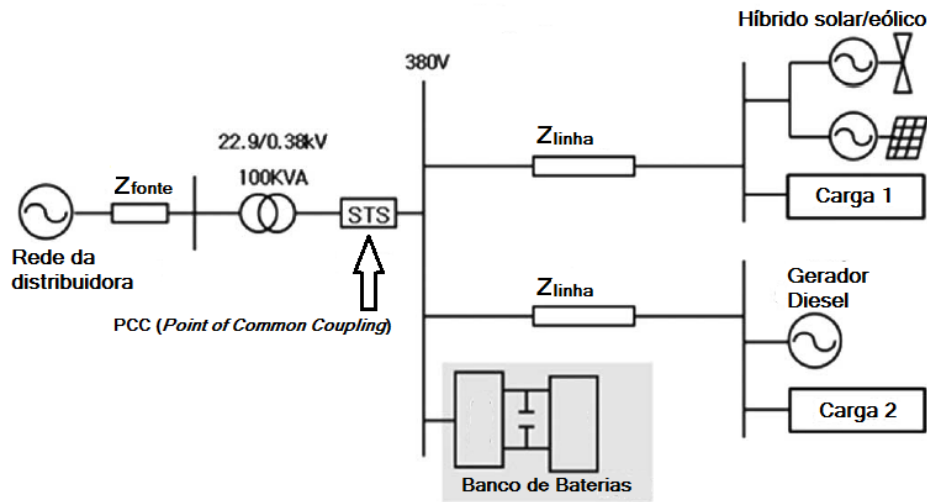


Figura 4.1. Arquitetura da planta piloto da MR do instituto KERI. Fonte: adaptado de Jeon *et al.* (2010).

Os painéis solares operam sempre em seus pontos de máxima transferência de potência, com a energia disponibilizada dependendo apenas da radiação solar. Cabe à MR buscar o máximo aproveitamento das fontes renováveis locais, decidindo, em cada instante, no caso de haver excedente de geração, se armazena energia para uso futuro ou vende o excedente para a macrorrede.

A MR conta ainda com um barramento de corrente alternada (CA) de 380V interconectando seus elementos entre si e ao PCC, que por sua vez faz a conexão à rede da distribuidora via um transformador de 100kVA (Jeon *et al.*, 2010; Nam *et al.*, 2009).

Com a finalidade de facilitar a comparação entre as estratégias centralizada e descentralizada, serão desprezadas, neste trabalho, as perdas nas linhas de transmissão.

Considera-se, nestas simulações, que o sistema híbrido consiste apenas de sistemas fotovoltaicos, com capacidade de 20kW.

### 4.3. Procedimentos de testes

As simulações das estratégias centralizadas foram realizadas utilizando a ferramenta GAMS (*General Algebraic Modeling System*), com o *solver* CPLEX. A entrada de dados e a análise dos resultados foram realizadas por intermédio de software desenvolvido na linguagem Python, o qual utiliza os recursos do GAMS através da API (*Application Programming Interface*) disponibilizada pelo fabricante. Para a avaliação da estratégia descentralizada, foi desenvolvido software orientado a objetos em linguagem C++, simulando a negociação dos agentes, com a utilização do algoritmo de leilões descrito na Seção 3.3.1.

Como ferramenta de análise e manipulação de dados, utilizou-se a ferramenta *Jupyter Notebook* como ambiente de desenvolvimento, com a linguagem *Python* 3.6.5. Nesta ferramenta, realiza-se o carregamento de dados da curva de demanda e das previsões de irradiação solar de arquivos texto, os quais são então normalizados, com a discretização adequada, para a utilização nos modelos avaliados. O *software* permite a rotação dos dados de entrada, simulando a janela deslizante.

Após a normalização dos dados, elabora-se em *Python* o arquivo de modelo matemático do problema de *day-ahead* no formato *.gms*, formato de entrada proprietário do *software* GAMS. O arquivo *.gms* é então enviado ao GAMS por intermédio de sua API, o qual executa o algoritmo de otimização de programação linear inteira-mista. Os resultados são então lidos pelo *software Python* por meio da mesma API, e os dados são processados e analisados no *notebook Python*. A Figura 4.2 ilustra o processo de testes do modelo de *day-ahead*.

Com base nos resultados do *day-ahead*, cria-se, ainda usando *Python*, uma lista de planos de pontos de operação para cada RED, e das previsões de oferta de energia de REDs renováveis e demanda, para cada intervalo de 5 minutos do próximo período de meia hora. Com base nesses planos, são em seguida realizadas as simulações da otimização em tempo real. Para testar as estratégias de otimização de curto prazo, insere-se uma perturbação randômica, para representar a diferença entre os valores previstos e realizados de oferta e demanda. Realiza-se, então, a otimização no modelo centralizado, utilizando GAMS, e em seguida no modelo descentralizado, com o simulador SMA desenvolvido em C++, para cada intervalo de 5 minutos da próxima meia hora. Os resultados das duas estratégias são então analisados e comparados. O processo de testes é ilustrado na Figura 4.3.

#### 4.4. Otimização de *day-ahead*

A curva de demanda utilizada e a de irradiação solar atenuada são mostradas na Figura 4.4. Mostra-se também a demanda líquida, resultante da subtração da geração solar da demanda da MR, indicando a carga remanescente a ser atendida pela macrorrede e pelos demais REDs despacháveis.

Para os valores das tarifas de compra e venda de energia da distribuidora e da demanda contratada, nos diferentes postos horários, foram considerados como referência, nas simulações realizadas, os utilizados em Alvez (2015), mostrados na Tabela 3. Considera-se também uma demanda contratada de 20kW para posto horário na ponta, e de 24,76 kW para posto horário fora de ponta.

A fim de avaliar o efeito da otimização utilizando cada RED individual, foram realizadas simulações considerando quatro casos:

1. Caso 1: MR com sistema fotovoltaico, sem banco de baterias e sem gerador diesel.
2. Caso 2: MR com sistema fotovoltaico, banco de baterias e gerador diesel.
3. Caso 3: MR com sistema fotovoltaico, sem banco de baterias e com gerador diesel.

4. Caso 4: MR com sistema fotovoltaico, com banco de baterias e sem gerador diesel.

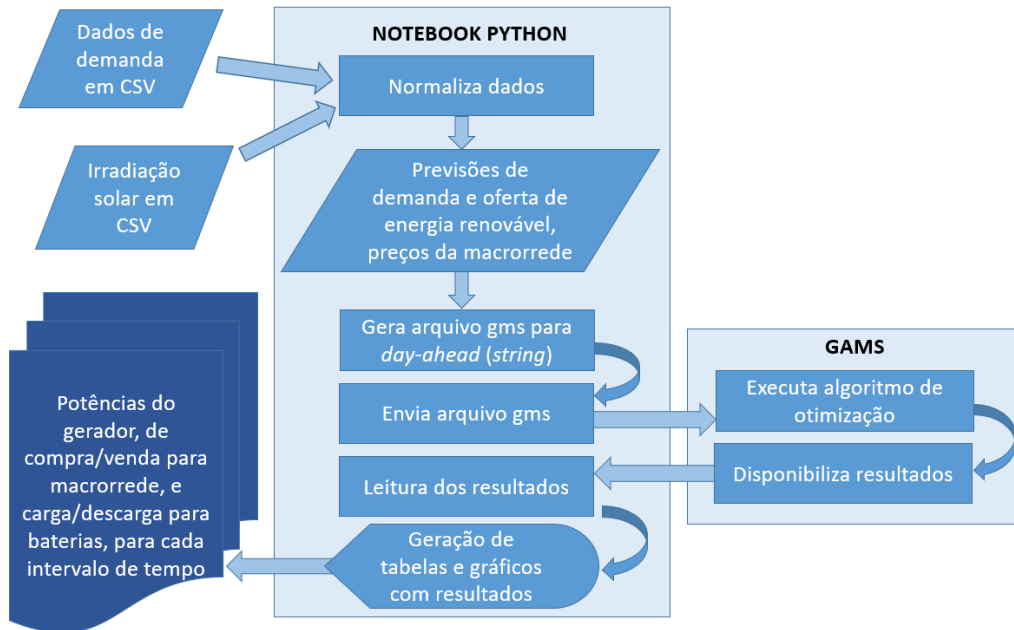


Figura 4.2: Fluxograma do processo de simulação da otimização de *day-ahead*.

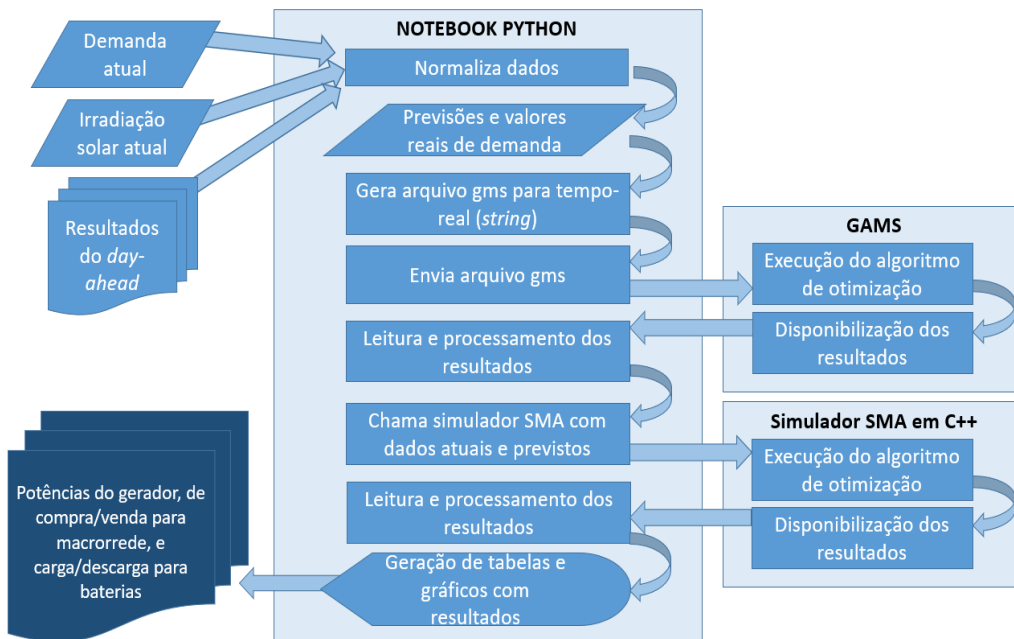


Figura 4.3: Fluxograma do processo de simulação da otimização de tempo real, nas estratégias centralizada e descentralizada.

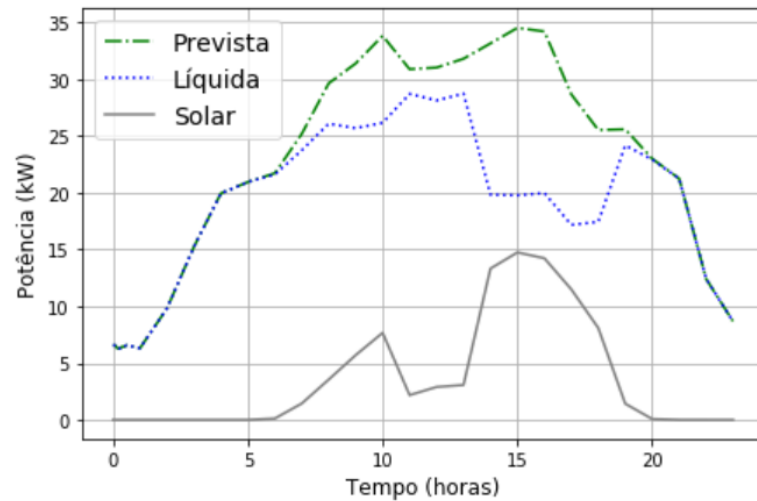


Figura 4.4: Demanda e geração solar previstas para as próximas 24 horas, e demanda líquida.

Tabela 3: Tarifas de energia elétrica utilizadas nas simulações. Fonte: (Alvez, 2015).

Tarifas	Semana		Final de Semana	
	Ponta	Fora de ponta	Ponta	Fora de ponta
Compra de Energia	0,47987	0,29908	0,29908	0,29908
Venda de Energia	0,2	0,2	0,2	0,2
Demanda contratada	28,85	8,82	8,82	8,82

A Figura 4.5 permite comparar a curva da demanda prevista, já discretizada conforme os intervalos descritos na Seção 3, com a demanda contratada.

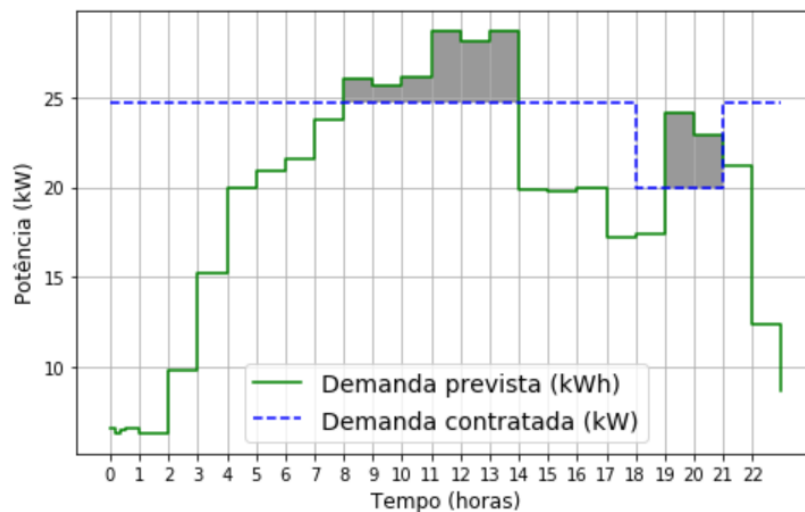


Figura 4.5: Demanda prevista x contratada em cada intervalo.

#### 4.4.1. Caso 1 - Microrrede com sistema fotovoltaico, sem banco de baterias e sem gerador diesel

As Figuras de Figura 4.6 a Figura 4.11 mostram os resultados das simulações para os quatro casos avaliados. Nelas, a variável  $P_s = P_{sd} - P_{sc}$  representa a potência de carga/descarga do banco de baterias. Na Figura 4.6 mostram-se os resultados com o gerador e o sistema de armazenamento inativos em modo conectado. Nesse caso, toda a demanda de energia local precisa ser suprida pela macrorrede. Note que não é possível evitar a ultrapassagem da demanda contratada, com a potência  $P_{rc}$  assumindo seu valor máximo permitido em diversos horários, igualando-se à demanda contratada, sem ainda suprir toda a demanda da MR, exigindo a compra de parcela de energia além da demanda contratada, representada pela potência  $P_{rcd}$ . Com isso, há a cobrança de multa, elevando-se os custos.

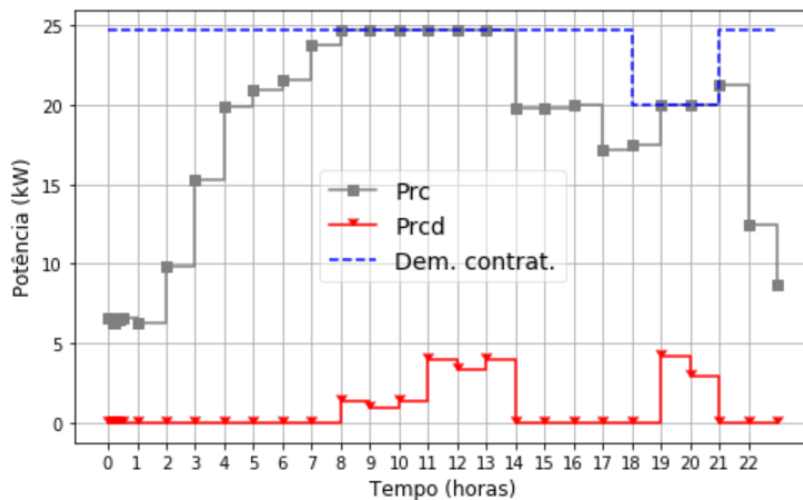


Figura 4.6: Balanço de potência, na simulação sem gerador nem banco de baterias (caso 1).

#### 4.4.2. Caso 2 - Microrrede com sistema fotovoltaico, banco de baterias e gerador diesel

As Figuras Figura 4.7 e Figura 4.8 apresentam os resultados para o caso 2. Note que o sistema passa a utilizar o banco de baterias quando ocorre a ultrapassagem da demanda contratada, até que o *SOC* atinja o valor próximo ao mínimo permitido de 42%. Não podendo mais contar com a energia remanescente armazenada para evitar a ultrapassagem e ainda com demanda não atendida, o sistema então liga o gerador. Como há previsão de nova ultrapassagem em horário de ponta, após a demanda retornar a um valor inferior à contratada, o banco de baterias é novamente carregado a partir das 16 horas.




Figura 4.7: Estado de carga (SOC) da bateria no caso 2.

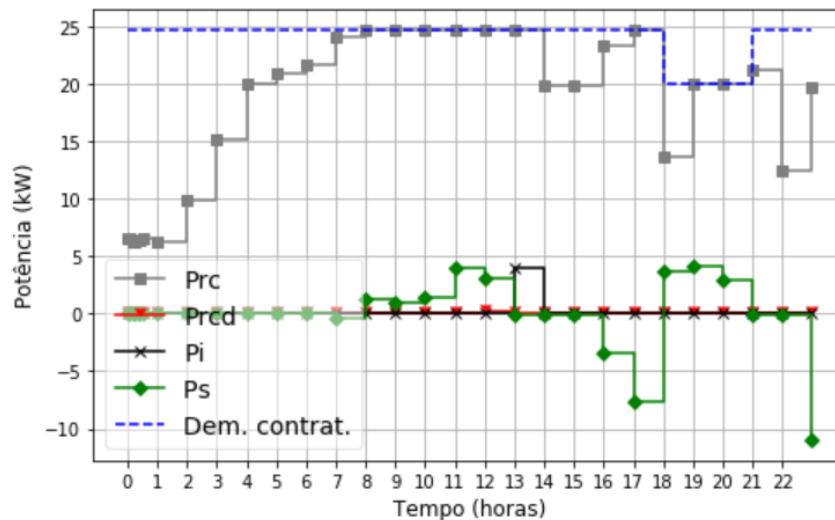


Figura 4.8: Balanço de potência em cada período no caso 2.

#### 4.4.3. Caso 3 - Microrrede com sistema fotovoltaico, sem banco de baterias e com gerador diesel.

Na Figura 4.9 mostram-se os resultados da simulação do caso 3, com uso do gerador e sem banco de baterias. Nota-se que o sistema passa a utilizar o gerador para evitar a ultrapassagem da demanda, até que a demanda seja reduzida, chegando novamente a patamar inferior à contratada. Percebe-se também, comparando os resultados com os da Figura 4.6, que, além de compensar  $P_{rcd}$ , o gerador fornece um pouco mais de potência em alguns intervalos, tornando  $P_{rc}$  um pouco inferior à demanda contratada. Este efeito se deve à limitação da potência mínima fornecida pelo gerador, pois uma vez ligado, o mesmo não fornecerá menos de 4kW, correspondendo a 20% da potência nominal.

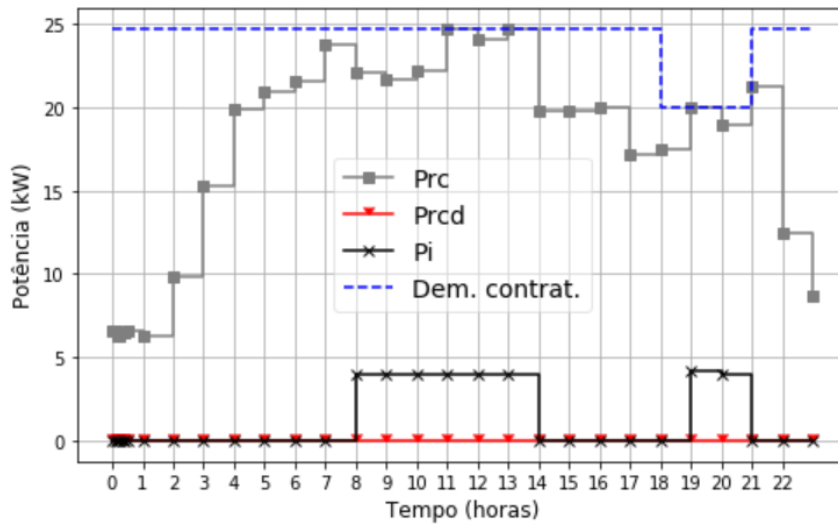


Figura 4.9: Balanço de potência, na simulação com gerador e sem banco de baterias (caso 3).

#### 4.4.4. Caso 4 - Microrrede com sistema fotovoltaico, com banco de baterias e sem gerador diesel

Finalmente, nas Figuras Figura 4.10 e Figura 4.11, apresentam-se os resultados do caso 4, com o uso apenas da bateria, sem o gerador. Nota-se que, novamente, não se é possível evitar a ultrapassagem da demanda, mesmo utilizando toda a carga armazenada da bateria. Com isso,  $P_{rcd}$  assume valor positivo a partir das 13 horas, quando as baterias atingem o  $SOC$  mínimo. Percebe-se também que a Figura 4.10 se mostra idêntica à Figura 4.7, já que nos dois casos a energia armazenada no SOE é utilizada até o limite, buscando evitar a ultrapassagem da demanda contratada. A única diferença é a opção pelo uso do gerador, no caso 2, evitando a ultrapassagem, ou a opção pela compra da microrrede, no caso 4, incorrendo em multa devido à ultrapassagem.

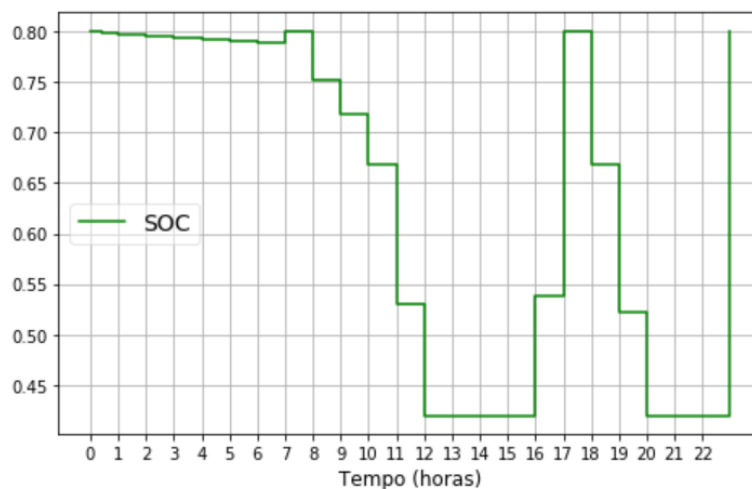


Figura 4.10: Resultados para o estado de carga (0-1), na simulação sem o gerador e com banco de baterias (caso 4).






Figura 4.11: Balanço de potência, na simulação sem gerador e com banco de baterias (caso 4).

Os resultados da função objetivo e os custos reais nos quatro casos acima são mostrados na Tabela 4. Os custos reais refletem os custos totais que o consumidor teria que efetivamente pagar à empresa local de energia, devido aos níveis de potências de importação e exportação de energia da macrorrede, com base nas regras estabelecidas pela resolução ANEEL (2010).

Tabela 4 : Resultados da função objetivo e de custos reais.

CASO	Função Objetivo	Custos Reais
1	R\$825,10	R\$1290,50
2	R\$167,17	R\$601,45
3	R\$206,41	R\$643,11
4	R\$225,66	R\$667,74

As simulações de *day-ahead* foram realizadas em um *notebook* com processador Intel Core i5 de 1,7 GHz, com 4 GB de RAM e sistema operacional Windows 10. Os tempos totais de cada simulação, em todos os casos, considerando a interface com o *Python*, ficaram em torno de 2 segundos. Para essa MR, portanto, ou pelo menos no que concerne ao custo computacional do processo de otimização em si, seria perfeitamente factível executar o planejamento de *day-ahead* a cada 5 minutos, sem necessidade da estratégia de tempo real. Entretanto a otimização de tempo real foi implementada neste trabalho visando a obtenção de uma estratégia generalizável, considerando as necessidades de MRs de maior porte, com base na experiência de outros autores.

Note que a MR sem otimização teria um custo de energia e ultrapassagem, computado pela função objetivo, de R\$825.10, custo reduzido a R\$167,17 com a otimização, uma redução de 79,74%. Em termos de custos reais, considerando as regras de cobrança da demanda contratada e de ultrapassagem da mesma vigentes no país, a redução seria ainda de mais de 50%. Note que o sistema prioriza o uso da energia armazenada para a compensação da demanda

excedente, utilizando o gerador a diesel apenas quando a energia armazenada não é suficiente para evitar a condição de ultrapassagem da demanda contratada.

Na comparação do uso exclusivo do gerador ou do banco de baterias, o gerador apresentou o melhor desempenho. Isso é compreensível pelo fato de, nos casos avaliados, não haver energia suficiente no sistema de armazenamento para compensar plenamente todo o excesso de demanda e evitar a ultrapassagem.

## 4.5. Otimização de tempo real

Para as simulações da estratégia de gerenciamento em tempo real, insere-se uma perturbação randômica, com desvio padrão de 15%, nos dados previstos de demanda líquida (demanda menos geração renovável), para representar a diferença entre os valores previstos e realizados.

As simulações foram realizadas apenas para o caso 4 da Seção 4.4, sem considerar o gerador, de forma a possibilitar a comparação com a estratégia descentralizada, já que o gerador não foi considerado nesta, pelas razões expostas na Seção 3.3.1.

Para permitir a análise do comportamento do sistema no caso de ultrapassagem da demanda contratada, as simulações foram realizadas compreendendo os horários de 11 horas às 16 horas mostrados na Figura 4.4, cujos valores são mostrados na Figura 4.12.

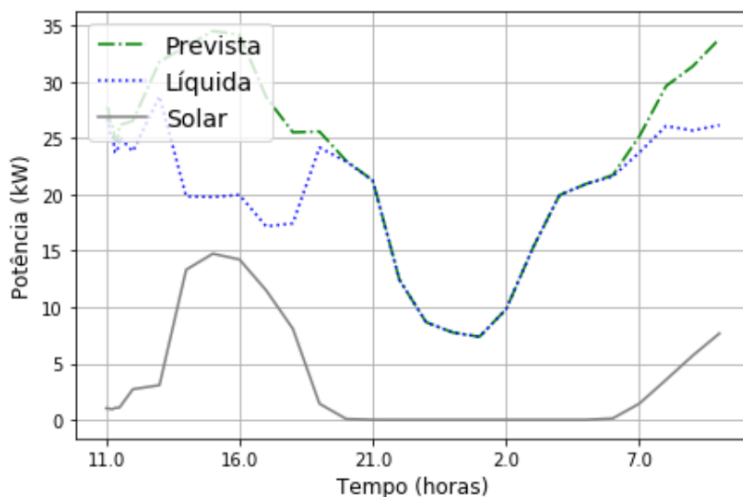


Figura 4.12: Demanda, geração solar e demanda líquida previstas para as próximas 24 horas, a partir das 11 horas da manhã.

A Figura 4.13 mostra as demandas previstas e contratadas rotacionadas em 11 horas. Note que o formato da Figura 4.13 na hora 11, que equivale à hora 11 da Figura 4.5, mostra-se um pouco diferente, já que, na Figura 4.13, a hora 11 é discretizada em intervalos de 5 minutos na primeira meia hora, e de meia hora mesmo na segunda meia hora, enquanto que na Figura 4.5 a discretização da hora 11 é naturalmente de 1 hora.




Figura 4.13: Demandas prevista e contratada, rotacionadas em 11 horas.

Na Figura 4.14 mostra-se a demanda líquida prevista no *day-ahead* da primeira meia hora da Figura 4.3, ampliada, comparando-a com a demanda líquida prevista para a próxima hora, com base nos dados mais atuais, obtidos aqui, na prática, aplicando-se uma perturbação aos dados usados no *day-ahead*. Como já mencionado, nas simulações realizadas, a demanda líquida prevista para o próximo intervalo é obtida adicionando-se uma perturbação pseudoaleatória à prevista no *day-ahead*.




Figura 4.14: Demanda líquida prevista no *day-ahead* versus a demanda prevista para a próxima meia hora.

A Figura 4.15 mostra o efeito que a perturbação na demanda líquida exerce na variação da potência  $P_r$ , fornecida pela macrorrede à MR. Percebe-se que, sem a otimização de tempo real, a macrorrede absorve sozinha as perturbações na demanda líquida.

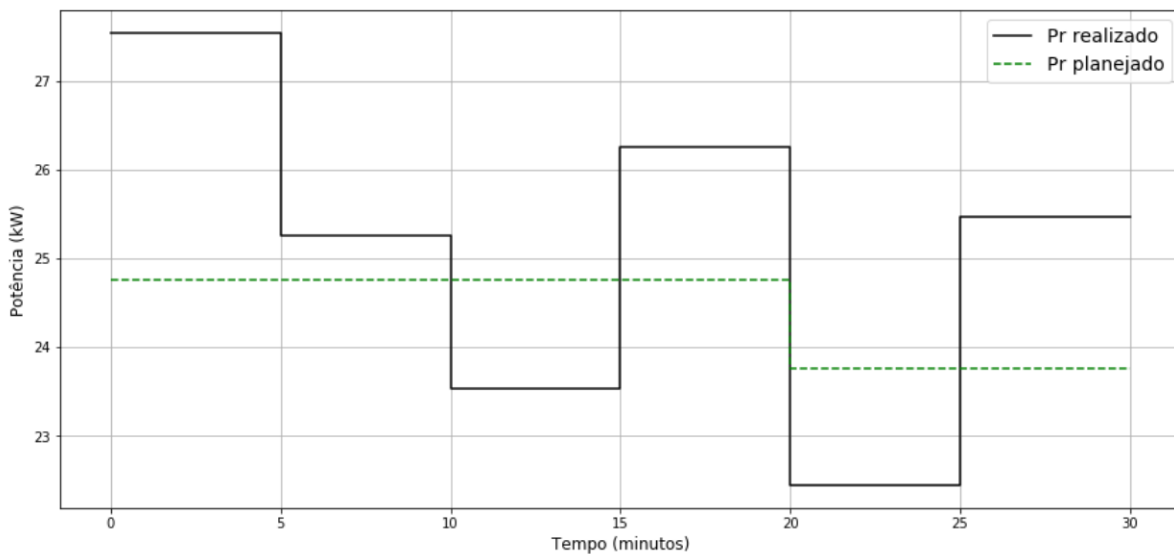


Figura 4.15: Potência média de energia comprada da macrorrede em cada intervalo, comparando a prevista para o próximo intervalo de 30 minutos com a prevista no *day-ahead*.

Supondo que não houvesse a otimização de tempo real, e o planejamento de *day-ahead* executado no início da hora 11 fosse seguido à risca, o estado de carga planejado para o banco de baterias não seria alterado. Com isso, a variação de custos mostrada na Tabela 5 seria observada.

Tabela 5: Custos reais previstos no *day-ahead* x realizados sem otimização de tempo real, para os primeiros seis intervalos de 5 minutos.

INTERVALO (min.)	CUSTO PREVISTO	CUSTO REALIZADO	VARIÇÃO DE CUSTOS (%)
0-5	R\$0,62	R\$49,65	7.908,06%
5-10	R\$0,62	R\$8,88	1.332,26%
10-15	R\$0,62	R\$0,59	-4,84%
15-20	R\$0,62	R\$27,07	4.266,13%
20-25	R\$0,59	R\$0,56	-5,08%
25-30	R\$0,59	R\$13,15	2.128,81%

Pode-se perceber, portanto, a imensa variação nos custos reais que uma perturbação de poucos kW pode provocar, no caso de a MR estar operando próximo a demanda contratada, evidenciando a importância da otimização de curto prazo, nos casos em que o cálculo do *day-ahead* mostrar-se computacionalmente dispendioso para ser executado em cada intervalo de curto prazo.

A seguir, serão avaliados os resultados das duas estratégias de otimização de curto prazo estudadas neste trabalho.

#### 4.5.1. Estratégia centralizada

Aplicando-se o modelo de otimização apresentado na Seção 3.2.2 ao caso anterior, os resultados mostrados na Tabela 6 são obtidos. Pode-se comparar com os resultados da Tabela 5, observando-se a significativa redução de custos.

Tabela 6: Custos reais previstos no *day-ahead* x realizados com otimização de tempo real com estratégia centralizada, para os primeiros seis intervalos de 5 minutos.

INTERVALO (min.)	CUSTO PREVISTO	CUSTO REALIZADO	VARIAÇÃO DE CUSTOS (%)
0-5	R\$0,62	R\$0,62	0,00%
5-10	R\$0,62	R\$0,62	0,00%
10-15	R\$0,62	R\$0,62	0,00%
15-20	R\$0,62	R\$0,62	0,00%
20-25	R\$0,59	R\$0,62	5,08%
25-30	R\$0,59	R\$0,62	5,08%

A redução de custos é obtida com uma maior utilização da energia acumulada no banco de baterias, como pode-se ver na Figura 4.16.

No primeiro intervalo, quase 1% de *SOC* é utilizado além do planejado para prevenir a ultrapassagem da demanda, devido ao aumento de cerca de 10% na demanda líquida em relação à prevista no *day-ahead*. No intervalo seguinte, como ocorre uma redução da demanda líquida para valor pouco abaixo da contratada, o sistema tenta recarregar o banco de baterias, buscando aproximar-se do *SOC* planejado no *day-ahead* novamente. Porém, já no intervalo seguinte, a demanda líquida sobe novamente para além do planejado e da demanda contratada, exigindo novamente a utilização da energia do SAE em quantidade acima do planejado.

Nota-se que a diferença de custo no intervalo de 20 a 25 minutos pode ser explicada pela tentativa do sistema de recarregar o banco de baterias, após utilização não prevista no *day-ahead* em intervalos anteriores, para evitar a ultrapassagem da demanda contratada. Pode-se notar, na Figura 4.16, a significativa recuperação da carga do SAE neste intervalo. Entretanto, no intervalo seguinte, como novamente a demanda líquida passa a exceder a demanda contratada, o sistema opta por utilizar novamente a energia do SAE, reduzindo novamente o *SOC*, e comprando energia da macrorrede apenas até o limite da demanda contratada, gerando o custo de R\$0,62, equivalente à compra de 24,76kW médios em 5 minutos.

A potência  $P_r$  de energia comprada da macrorrede fica com valor fixo em 24,76 kW, o mesmo valor da demanda contratada, em todos os intervalos. Observa-se que ela fica com esse valor no caso de demandas líquidas acima do planejado, porque o sistema utiliza mais energia do SAE, evitando a condição de ultrapassagem. Por outro lado, o mesmo valor de potência é observado nos intervalos em que a demanda líquida está abaixo da prevista e abaixo inclusive

da demanda contratada, porque neles o sistema tenta recuperar a carga do SAE, buscando trazê-la para valores o mais próximo possível do *SOC* previsto no *day-ahead*.




Figura 4.16: Comparação entre *SOC* do banco de baterias previsto no *day-ahead* e realizado para o próximo intervalo de 30 minutos.

#### 4.5.2. Estratégia descentralizada

Na estratégia descentralizada, simulando SMA, implementada conforme descrição na Seção 3.3, utiliza-se diferentes configurações de discretização de potência, ou seja, de número de Agentes de Mercado. Cada Agente de Mercado, como já explicado, é responsável por negociar um pacote de energia, seja de oferta (agente vendedor) ou de demanda (agente comprador), dependendo se a sociedade de origem é uma fonte ou carga.

Supõe-se que o Agente Regulador, em contato com o Mediador e com a camada Analítica, ou de Rede, e com os Agentes de Simulação, realize ou dirija o planejamento de longo prazo, e estabeleça regras para a negociação de curto prazo, realizada com estratégia descentralizada, por meio das negociações entre os Agentes de Mercado. Nas simulações aqui apresentadas, essas regras tomam como base o planejamento de *day-ahead* realizado com a estratégia clássica apresentada na Seção 3.2.1. Alternativamente, o Agente Regulador pode realizar o planejamento de longo prazo, utilizando-se de outra estratégia centralizada, semidescentralizada ou descentralizada, podendo utilizar técnicas de otimização clássicas, meta-heurísticas, como Algoritmos Genéticos ou Lógica *Fuzzy*, de inteligência artificial, como Redes Neurais ou outras, com base no histórico do sistema e nas previsões de oferta e demanda para as próximas 24 horas. As metodologias de otimização de longo prazo em MRs utilizando SMA, como já referido na Seção 2.4, são o foco de intensas pesquisas, com diversos desafios ainda a serem superados e não serão abordadas neste trabalho (Olivares *et al.*, 2014; Chen *et al.*, 2011; Pilo *et al.*, 2007; Katiraei *et al.*, 2008; Cirrincione *et al.*, 2009).

O Agente Regulador, na estratégia proposta neste trabalho, fixa a potência de carga/descarga do SAE para o período com base no planejamento de *day-ahead*, o que determina se o SAE irá gerar Agentes de Mercado compradores (carga) ou vendedores (descarga) e em qual quantidade. Caso, entretanto, verifique-se o risco de ultrapassagem de demanda devido às previsões de curto prazo, com a demanda atual somada à potência  $P_{sm}$  planejada no *day-ahead* ultrapassando a demanda contratada, o Agente Regulador irá alterar o valor de  $P_{s,da}$ , priorizando a prevenção da condição de ultrapassagem. A potência recomendada pelo Agente Regulador é informada ao Agente Controlador do SAE, que busca cumpri-la, desde que não viole suas restrições.

Nos testes realizados, supõe-se que as seguintes regras sejam estabelecidas pelo Agente Regulador para a otimização em tempo real:

1. Caso a demanda líquida prevista para o período, menos às potências  $P_{s,da}$  e  $P_{i,da}$  planejadas no *day-ahead*, seja inferior à demanda contratada, deve-se respeitar as potências  $P_s = P_{s,da}$  de carga/descarga da bateria previstas no *day-ahead*. Poderão ser somados à potência  $P_s$  o valor  $\Delta P_{s,da}$ , valor negativo sempre (carga), visando compensar descargas não planejadas em períodos anteriores, realizadas para evitar ultrapassagem da demanda contratada, de maneira a trazer o *SOC*, novamente ao valor planejado no *day-ahead*.
2. Caso a demanda líquida prevista menos as potências  $P_{s,da}$  e  $P_{i,da}$  exceda a demanda contratada, o valor de  $P_{s,da}$ , se negativo (carga), deverá ser limitado a fim de evitar que  $P_r$  exceda à demanda contratada.
3. Se mesmo limitando-se  $P_{s,da}$  não for possível evitar a condição de ultrapassagem, o valor de  $P_{s,da}$  planejado no *day-ahead* será desconsiderado, e será solicitada do SAE a potência necessária para atender à demanda líquida excedente. Ou seja, será estabelecida a potência do SAE com base na equação (4.1).

$$P_s = (DL - DC) - P_{i,da} \quad (4.1)$$

Segue-se então o seguinte procedimento no início de cada novo intervalo de tempo real:

1. O Agente Mediador, de posse das regras estabelecidas pelo Agente Regulador, anuncia o início de novo período de mercado, com os preços obtidos ou negociados com o operador de mercado da macrorrede.
2. A Sociedade das fontes internas da MR, nesse caso representando os Agentes Controladores Locais do sistema de geração fotovoltaico, avaliam sua previsão de oferta para os próximos 5 minutos, utilizando o método persistente descrito na Seção 3.2.2. A Sociedade, então, cria um número proporcional de Agentes de Mercado vendedores, cada um representando um pacote discreto da energia ofertada ao mercado da MR por uma fonte de energia. Caso o valor projetado não corresponda a um número inteiro de Agentes de Mercado, o número de Agentes é aproximado para o valor inteiro mais próximo.

3. A Sociedade de Cargas estima a demanda para o próximo intervalo de 5 minutos, utilizando o método persistente, criando um número proporcional de Agentes de Mercado compradores, cada um representando um pacote discreto de energia demandada por uma carga da MR. Se o número de Agentes calculado não for inteiro, o mesmo será aproximado para o valor inteiro mais próximo.
4. A Sociedade dos Agentes Controladores Locais dos SAEs recebe as regulações estabelecidas pelo Agente Regulador, fixando a potência de carga ou descarga a disponibilizar para o próximo período de maneira a minimizar os custos da MR no longo prazo. De posse das informações de limites de potência e nível de estado de carga, o Agente de Mercado que representa cada SAE determina o nível de potência passível de ser liberado, buscando aproximar-se ao máximo da potência estabelecida pelo Agente Regulador. São então criados Agentes de Mercado para representar o SAE, sejam compradores, no caso de carga, ou vendedores, no caso de descarga, em número proporcional ao número de pacotes de energia a serem ofertados ou demandados da MR pelo SAE.
5. O Agente Mediador informa ao Agente Controlador Local, que representa a macrorrede, o número de Agentes de Mercado compradores e vendedores disponíveis na MR. O Agente da macrorrede, então, cria seus Agentes de Mercado de maneira a equilibrar o número de vendedores e compradores, tornando o problema de alocação um problema simétrico. Ou seja, caso exista um número  $n$  de compradores e  $m$  de vendedores na MR, supondo ser  $n > m$ , o Agente Controlador Local da macrorrede irá gerar um número  $k = (n - m)$  de Agentes de Mercado vendedores. Por outro lado, no caso de ter-se  $m > n$ , serão criados  $k = (m - n)$  Agentes de Mercado compradores representando a macrorrede.
6. Define-se, a seguir, a folga complementar  $-\epsilon$ , de acordo com a seguinte equação  $\epsilon = 1/(n - 1)$ , onde  $n$  é o maior valor entre o número de Agentes compradores ou de Agentes vendedores internos da MR, ou seja, excluindo-se os da macrorrede. O valor  $n$  será igual ao número de alocações finais da solução ótima.
7. O Agente Mediador anuncia o início do período de negociação.
8. O leilão tem início entre os Agentes de Mercado, seguindo as regras do algoritmo de leilão para o Problema de Alocação Simétrico, descrito na Seção 2.6.4, com os Agentes compradores dando lances com incremento mínimo de  $\epsilon$ , em sucessivas rodadas, até que todos os compradores estejam alocados, ou o Agente Mediador anunciar o fim do período de negociações.
9. Após o atingimento da condição de término (todos os compradores alocados), ou após esgotado o tempo limite ou o número máximo de iterações estabelecido, o Agente Mediador anuncia o final do período de negociações.
10. De posse dos contratos negociados, os Agentes de Mercado devem então informar as suas sociedades de origem os novos pontos de operação (*set points*), de acordo



com os contratos de compra e venda negociados, para o próximo período de operação, e então se autodestroem.

11. O Agente Mediador anuncia o fim do período de mercado.

12. Tem início novo período de operação, até o final do atual intervalo de 5 minutos.

Na criação de Agentes de Mercado compradores representando cargas internas da MR, foram atribuídos valores intrínsecos muito altos, com valor de 1 bilhão de reais, a todas as fontes disponíveis, representando na prática um valor intrínseco infinito que as cargas atribuem a qualquer fonte, sem preferência por uma ou outra. Ou seja, parte-se do princípio de que, em modo conectado, não é admissível haver cortes seletivos de cargas na MR, e os consumidores da MR não estão dispostos a pagar mais caro por quaisquer tipos específicos de fontes, desde que atendam suas demandas (ou seja, todas as fontes apresentam a mesma utilidade para todas as cargas).

Já na criação de Agentes de Mercado vendedores representando microfontes internas da MR, é atribuída a cada vendedor um preço de custo, representando o preço inicial do ativo no leilão e a proposta mínima que o mesmo irá aceitar.

No caso dos Agentes de Mercado representantes da macrorrede, os valores intrínsecos, no caso dos compradores, e os preços de custos, para os vendedores, equivalem às tarifas de energia estabelecidas para o intervalo, além da eventual multa por ultrapassagem.

Nas simulações realizadas para este trabalho, foram testadas as discretizações de 1 kW, 0,1 kW e 0,01 kW de potência média por Agente de Mercado. O algoritmo foi implementado em sua forma serial clássica, na chamada implementação *Gauss-Seidel*.

Como mencionado na Seção 3.3, nas simulações descritas por Dimeas & Hatziargyriou (2005), foi utilizada discretização de 1 kW por Agente de Mercado, limitando-se também em 100 o número máximo de iterações. Segundo os autores, além desses limites, o tempo de processamento se torna proibitivo, sobretudo devido à latência da rede de comunicação. A latência, entretanto, como também já discutido, perde a importância se for possível confiar no servidor em que roda o Agente Supervisor, movendo todos os agentes de mercado para o mesmo ambiente computacional. Nas simulações deste trabalho, foram avaliados os tempos de processamento estimados com e sem a latência da rede.

### **Discretização de 1kW por Agente de Mercado**

A Tabela 7 mostra os resultados da otimização com estratégia multiagente, usando algoritmo de leilão simétrico, do problema mostrado na Seção 4.5.1. Percebe-se a semelhança alcançada pelos valores, mesmo utilizando-se uma resolução tão baixa.

Tabela 7: Resultados da otimização de tempo real com estratégia multiagente, usando algoritmo de leilões, com discretização de 1 kW por Agente de Mercado.

Intervalo (minutos)	$P_r$ (kW) centralizado	$P_r$ (kW) descentraliz.	SOC (%) centralizado	SOC (%) descentraliz.	Custo centraliz.	Custo descentr.
0-5	24,76	24,00	51,71	51,64	R\$0,62	R\$0,60
5-10	24,76	24,00	51,04	50,77	R\$0,62	R\$0,60
10-15	24,76	24,00	51,28	50,77	R\$0,62	R\$0,60
15-20	24,76	24,00	50,74	49,91	R\$0,62	R\$0,60
20-25	24,76	24,00	51,40	50,49	R\$0,62	R\$0,60
25-30	24,76	24,00	51,19	49,91	R\$0,62	R\$0,60

A Figura 4.17 mostra a diferença no uso da energia do SAE nas duas estratégias. Nota-se que há um padrão de uso semelhante, porém com pequenas diferenças, de cerca de 1%, devido à discretização. Percebe-se o uso efetivo da potência do SAE para evitar a condição da ultrapassagem da demanda contratada e para novamente aproximar o SOC do valor planejado no *day-ahead*, quando o risco de ultrapassagem desaparece.




Figura 4.17: Comparação entre o SOC previsto no *day-ahead* e o realizado com estratégia centralizada e descentralizada com discretização de 1kW.

### Discretização de 0,1 kW por Agente de Mercado

Reduzindo-se a discretização para 0,1 kW por Agente de Mercado, obtém-se os dados mostrados na Tabela 8, com resultados ainda mais semelhantes que no caso anterior.

Tabela 8: Resultados da otimização de tempo real com estratégia multiagente, usando algoritmo de leilões, com discretização de 0,1 kW por Agente de Mercado.

Intervalo (minutos)	$P_r$ (kW) centralizado	$P_r$ (kW) descentraliz.	$SOC$ (%) centralizado	$SOC$ (%) descentraliz.	Custo centraliz.	Custo descentr.
0-5	24,76	24,70	51,71	51,70	R\$0,62	R\$0,62
5-10	24,76	24,70	51,04	51,00	R\$0,62	R\$0,62
10-15	24,76	24,70	51,28	51,24	R\$0,62	R\$0,62
15-20	24,76	24,70	50,74	50,69	R\$0,62	R\$0,62
20-25	24,76	24,70	51,40	51,35	R\$0,62	R\$0,62
25-30	24,76	24,70	51,19	51,15	R\$0,62	R\$0,62

A Figura 4.18 mostra a proximidade dos valores de  $SOC$  entre as duas estratégias, significativamente maior que no caso anterior, com as duas curvas praticamente coincidindo.




Figura 4.18: Comparação entre o SOC previsto no *day-ahead* e o realizado com estratégia centralizada e descentralizada com discretização de 0,1kW.

### Discretização de 0,01 kW por Agente de Mercado

Utilizando-se discretização de 0,01 kW por Agente de Mercado, obtém-se os dados mostrados na Tabela 9. Percebe-se uma aproximação ainda maior dos resultados obtidos na estratégia centralizada, porém com uma redução de diferenças bem menos significativa que a observada entre as resoluções de 1 kW para 0,1 kW.

Tabela 9: Resultados da otimização de tempo real com estratégia multiagente, usando algoritmo de leilões, com discretização de 0,01 kW por Agente de Mercado.

Intervalo (minutos)	$P_r$ (kW) centralizado	$P_r$ (kW) descentraliz.	SOC (%) centralizado	SOC (%) descentraliz.	Custo centraliz.	Custo descentr.
0-5	24,76	24,75	51,71	51,72	R\$0,62	R\$0,62
5-10	24,76	24,75	51,04	51,06	R\$0,62	R\$0,62
10-15	24,76	24,75	51,28	51,31	R\$0,62	R\$0,62
15-20	24,76	24,75	50,74	50,77	R\$0,62	R\$0,62
20-25	24,76	24,75	51,40	51,44	R\$0,62	R\$0,62
25-30	24,76	24,75	51,19	51,23	R\$0,62	R\$0,62

A Figura 4.19 mostra os valores de SOC entre a estratégia centralizada e a descentralizada com resolução de 0,01 kW, com uma proximidade pouco melhor que no caso anterior.




Figura 4.19: Comparação entre o SOC previsto no *day-ahead* e o realizado com estratégia centralizada e descentralizada com discretização de 0,01kW.

### Análise de desempenho da estratégia descentralizada

A solução do problema de tempo real, nas diferentes estratégias testadas, é mostrada na Tabela 10. Nela são mostrados os tempos para a solução centralizada, cujos resultados foram mostrados na Seção 4.5.1 e os da estratégia descentralizada com diferentes resoluções de potência. Os tempos de solução da estratégia centralizada são os mostrados pelo GAMS em seu arquivo de saída com extensão *.lst*. Já os tempos de processamento da estratégia descentralizada foram medidos no *software* de simulação em C++, utilizando-se a função `std::chrono::high_resolution_clock::now()` do padrão C++11, compilado em Windows no Microsoft Visual Studio 2017.

Os resultados indicam ser possível, dependendo da resolução utilizada, atingir desempenho compatível e até melhor que a solução centralizada, obtendo-se soluções com resultados muito próximos. Em particular, a solução descentralizada com resolução de 0,1 kW se mostrou significativamente mais eficiente em termos de tempo de processamento, produzindo resultados de potência muito próximos ao da solução centralizada, como mostrado na Tabela 8 e na Figura 4.18.

É importante ressaltar que o algoritmo descentralizado foi executado em um mesmo ambiente computacional, sem a necessidade de comunicação via rede de comunicação entre os Agentes de Mercado. Os resultados mostrados na Tabela 10 podem apenas ter algum significado caso se considere que os Agentes de Mercado, uma vez criados em suas sociedades de origem, são transportados para o mesmo servidor físico do Agente Supervisor, onde ocorrem todas as negociações.

Tabela 10: Tempos de processamento para a solução do problema de tempo real, em diferentes estratégias, e sem o uso de escalonamento- $\epsilon$ .

Intervalo (minutos)	Centralizada (GAMS)	Descentralizada res. = 1 kW	Descentralizada res. = 0,1 kW	Descentralizada res. = 0,01 kW
0-5	32 ms	0,50 ms	8,24 ms	469,16 ms
5-10	47 ms	0,58 ms	10,15 ms	287,88 ms
10-15	32 ms	0,69 ms	4,64 ms	326,40 ms
15-20	47 ms	0,50 ms	5,74 ms	317,68 ms
20-25	62 ms	0,50 ms	5,97 ms	400,90 ms
25-30	32 ms	0,50 ms	5,67 ms	279,74 ms

Caso não seja possível confiar na manutenção da privacidade em um servidor centralizado, ou por algum outro motivo seja necessário manter os Agentes de Mercado em seus servidores de origem, a cada proposta serão necessárias comunicações via rede entre os negociadores, tornando a latência da rede um grande gargalo para o tempo de solução. Neste caso, o número de propostas e iterações ganha grande importância. As Tabelas 11, 12 e 13 mostram o número de iterações e propostas necessárias para a solução em cada caso, para o algoritmo descentralizado. Observa-se que todas as propostas são aceitas em todos os casos. Isso pode ser explicado como consequência do fato de todos os objetos (Agentes vendedores) terem o mesmo valor intrínseco para todas as pessoas (Agentes compradores). Uma vez que todos os compradores valoram da mesma forma os objetos desejados, as propostas podem ser sempre efetivas, o que acelera o processo de otimização. Tal situação, entretanto, só seria concebível no caso de todas as cargas terem um mesmo proprietário, que valora de igual forma todas as fontes locais de energia. Além disso, se forem levadas em consideração as perdas no sistema de transmissão, com cada transação individual gerando uma taxa específica de transportes definida pela Sociedade de Transportes, tal paridade entre os diferentes compradores pode ser quebrada.

Nota-se que, para um intervalo de tempo real de 5 minutos, somente a discretização de 1 kW teria desempenho satisfatório, caso fosse necessário considerar a latência da rede a cada transação e caso fosse desejável o ótimo global. Naturalmente, pode-se interromper o algoritmo antes, se for aceitável uma solução subótima.

Tabela 11: Número de iterações, propostas e latência total estimada para a solução com estratégia SMA com resolução de 1 kW, considerando latência média da rede de 200 ms.

Intervalo (minutos)	Iterações ou rodadas	Propostas realizadas	Propostas aceitas	Latência estimada
0-5	3	72	72	14,40 s
5-10	2	52	52	10,40 s
10-15	2	31	31	6,20 s
15-20	2	52	52	10,40 s
20-25	2	31	31	6,20 s
25-30	2	45	45	9,20 s
Médias	2,17	47,17	47,17	9,43 s

Tabela 12: Número de iterações, propostas e latência total estimada para a solução com estratégia SMA com resolução de 0,1 kW, considerando latência média da rede de 200 ms.

Intervalo (minutos)	Iterações ou rodadas	Propostas realizadas	Propostas aceitas	Latência estimada
0-5	3	703	703	140,60 s
5-10	2	519	519	103,80 s
10-15	2	310	310	62 s
15-20	2	443	443	88,60 s
20-25	2	324	324	64,80 s
25-30	2	373	372	74,60 s
Médias	2,17	393,80	393,80	78,76 s

### Técnica do escalonamento- $\epsilon$

A fim de verificar a possibilidade de ganho de desempenho utilizando a técnica de escalonamento descrita por Bertsekas (1990), aplicou-se a técnica na otimização com resolução de 0,01 kW. A técnica foi aplicada como implementada e testada pelo autor, com a multiplicação de todos os benefícios intrínsecos por  $(n + 1)$ , seguida do escalonamento exponencial, com a constante  $\epsilon$  sendo calculada a cada iteração por meio da equação (4.2), onde  $\Delta > 0$  e  $\theta > 1$ .

$$\epsilon(k) = \max\{1, \Delta/\theta^k\}, k = 0, 1, \dots, \quad (4.2)$$

A cada iteração do processo de escalonamento, o período de negociações é reiniciado com um  $\epsilon$  menor, porém utilizando-se dos preços negociados na iteração anterior como condição inicial para o novo leilão. O algoritmo termina após a negociação com  $\epsilon \leq 1$ , condição suficiente para atingir do ótimo, uma vez que os benefícios intrínsecos foram multiplicados por  $(n + 1)$ .

Tabela 13: Número de iterações, propostas e latência total estimada para a solução com estratégia SMA com resolução de 0,01 kW, considerando latência média da rede de 200 ms.

Intervalo (minutos)	Iterações ou rodadas	Propostas realizadas	Propostas aceitas	Latência estimada
0-5	3	6.987	6.987	1.397,40 s
5-10	2	5.139	5.139	1.027,80 s
10-15	2	3.133	3.133	626,60 s
15-20	2	4.428	4.428	885,60 s
20-25	2	3.210	3.210	642 s
25-30	2	3.714	3.714	742,80 s
Médias	2,17	4.435,17	4.435,17	887,03 s

De acordo com Bertsekas (1990), sendo  $C$  o maior benefício intrínseco, valores comuns para  $\Delta$  e  $\theta$ , para problemas esparsos, seriam  $C/5 \leq \Delta \leq C/2$  e  $4 \leq \theta \leq 10$ . Já para problemas não esparsos, ainda segundo o autor, pode ocorrer que um valor de  $\Delta = 1$ , valor que equivale a não realizar o escalonamento, já se mostrar uma boa solução.

Os problemas testados neste trabalho são pouco esparsos, com as negociações sendo concluídas em poucas rodadas, geralmente duas ou três, até que os preços atinjam os custos das microfones mais caras. Uma vez que não foram considerados os geradores não-renováveis, os Agentes vendedores de energia da macrorrede serão os que apresentarão custos mais elevados, com custos de energia relativamente baixos ainda. Com isso, optou-se por iniciar os testes com o menor escalonamento possível, utilizando-se  $\Delta = \theta = 2$ . Obteve-se, assim, o ótimo em no máximo de duas iterações de escalonamento, com  $k = 1$ . Os resultados são mostrados na Tabela 14.

Comparando-se os resultados mostrados na Tabela 14 com os da Tabela 13, pode-se notar que o escalonamento piorou os resultados em todos os intervalos, exigindo um número médio de propostas 44% maior para alcançar o ótimo. O resultado indica ser esse um dos casos em que, devido à baixa esparsidade, o algoritmo tem melhor desempenho sem escalonamento, conforme exposto por Bertsekas (1990).

Tabela 14: Número de iterações, propostas e latência total estimada para a estratégia SMA com resolução de 0,01 kW, utilizando escalonamento- $\epsilon$  e latência média da rede de 200ms.

Intervalo (minutos)	Iterações ou rodadas	Propostas realizadas	Propostas aceitas	Latência estimada
0-5	4	8.334	8.334	1.666,80 s
5-10	4	6.948	6.948	1.389,60 s
10-15	3	5.420	5.420	1.084 s
15-20	3	6.345	6.345	1.269 s
20-25	3	5.475	5.475	1.095 s
25-30	3	5.835	5.835	1.167 s
Médias	3,33	6.392,83	6.392,83	1.278,57 s

## 4.6. Conclusão

Descreveu-se neste capítulo os testes realizados com os modelos desenvolvidos no capítulo 3, analisando-se e comparando-se os resultados.

Pode-se perceber, pelos resultados, o grande impacto que o uso de modelos de otimização de *day-ahead* podem ter nos custos de operação de uma MR, utilizando-se modelos lineares, com técnicas de linearização, com grande eficiência computacional.

Nos testes do modelo centralizado de tempo real, percebe-se também a relevância desse nível de otimização, sobretudo quando há riscos de ultrapassagem da demanda contratada, ou outra condição equivalente, não prevista, que eleve consideravelmente os custos marginais.

Nos testes do modelo descentralizado, percebe-se a grade eficiência dos algoritmos de leilões e sua capacidade de chegar a resultados semelhantes à estratégia centralizada mesmo quando se utiliza uma baixa resolução na discretização da potência. Vale ressaltar que o caso avaliado tem baixa esparsidade e pequenas dimensões, enquanto esses algoritmos, segundo indicam as referências na literatura, destacam-se, sobretudo, com problemas de alta esparsidade e grandes dimensões, o que pode torná-los ainda mais interessantes para as futuras MRs.

Há, entretanto, conforme exposto, limitações nos algoritmos descritos na literatura, havendo a necessidade de pesquisar novas alternativas.



# Capítulo 5

## Conclusão

Este trabalho apresentou o estudo do problema do gerenciamento ótimo de energia em MRs inteligentes, destacando as principais metodologias implementadas atualmente ou em avaliação pelos pesquisadores da área. Foram realizados também experimentos que permitiram a comparação entre duas das principais abordagens de solução do problema.

Fez-se primeiro o levantamento bibliográfico, apresentando-se um panorama atual do desenvolvimento da tecnologia das MRs inteligentes, sua importância, benefícios e os desafios para sua maior difusão. Em especial, destacou-se o importante papel das MRs na evolução das RIEEs, até seu estágio avançado, no qual se espera que venham a ser constituídas de grandes redes de MRs inteligentes interligadas.

O problema do gerenciamento de energia em MRs foi então aprofundado, apresentando-se um panorama de seus principais aspectos e desafios. Destacou-se a importância do desenvolvimento de pesquisas de metodologias de gerenciamento de energia, visando a minimização de custos em MRs em modo conectado, de maneira a compensar os altos investimentos iniciais necessários à sua implantação, custos estes considerados como um dos mais relevantes fatores dificultadores à adoção em maior escala das MRs.

Discorreu-se, em seguida, sobre as principais estratégias de solução do problema apresentadas na literatura e avaliadas em experimentos em diversos países. As diferenças, vantagens e desvantagens das duas principais categorias de estratégias de solução, as estratégias centralizadas e descentralizadas, foram avaliadas. As principais abordagens e metodologias em cada uma dessas categorias foram apresentadas e discutidas. Apresentou-se, também, as vantagens do uso das plataformas de SMA nas estratégias descentralizadas de solução, e o porquê de o paradigma de desenvolvimento multiagente vem sendo visto como o mais promissor para as futuras soluções descentralizadas, capazes de alavancar o desenvolvimento das futuras RIEEs, permitindo a interação tanto com sistemas mais antigos, como com uma grande variedade de novas tecnologias e dispositivos inteligentes interligados.

Apresentou-se um breve resumo dos principais conceitos do paradigma multiagente, e sua aplicação a sistemas elétricos de potência, particularmente ao gerenciamento de MRs inteligentes. Foram brevemente discutidos os principais algoritmos de solução utilizados com SMAs para o gerenciamento de energia em MRs, em particular aprofundou-se a análise dos algoritmos de leilões, os quais estão entre os mais utilizados com SMAs e considerados entre os mais promissores para o problema estudado, sendo por isso selecionado para as simulações realizadas neste trabalho. Foram discutidas as vantagens de eficiência e eficácia do algoritmo

na solução de problemas de otimização combinatória, particularmente com grande número de elementos e alta esparsidade e sua ótima adequação ao uso em plataformas de SMA.

Desenvolveu-se, em seguida, modelo de gerenciamento ótimo centralizado linear inteiro-misto, utilizando técnicas de linearização por partes, tendo em vista ser o problema de natureza não-linear e descontínua. O modelo foi desenvolvido avaliando-se as técnicas mais consolidadas e mais utilizadas nas MRs atuais, com base no conceito do CERTS *Microgrid Concept*, utilizando uma estratégia de solução em dois níveis, uma de longo prazo, com horizonte de 24 horas (*day-ahead*) e outra de tempo real, com horizonte de 5 minutos. Foi dada ênfase aos aspectos mais consolidados e mais relevantes do problema, focando-se na possibilidade de compará-lo com a abordagem descentralizada. Foram utilizadas técnicas de linearização, tornando o problema de natureza não linear e descontínua em um problema de programação linear inteiro-misto, reduzindo-se, assim, significativamente seus custos computacionais e garantindo sua convergência.

Desenvolveu-se, então, um modelo de gerenciamento ótimo com estratégia descentralizada, tomando como base uma arquitetura de SMA em três níveis hierárquicos, a mais comum na literatura, considerada por alguns autores como a melhor solução de compromisso entre a resiliência e a flexibilidade da descentralização total e a redução de custos possível com a maior centralização. Detalhou-se a metodologia de solução do problema do gerenciamento ótimo de energia em tempo real, utilizando o algoritmo de leilões, modelando o problema como um problema de alocação única simétrico. Verificou-se a dificuldade de modelamento do gerador não-renovável com a utilização do algoritmo de leilões. Uma solução adequada não foi encontrada descrita na literatura. Foram apresentadas sugestões de possíveis soluções, utilizando-se variações diretas-reversas, não simétricas e de alocações múltiplas desses algoritmos.

Por fim, os modelos de gerenciamento desenvolvidos, tanto o centralizado em dois níveis como o descentralizado multiagente de tempo real, foram aplicados ao mesmo problema, tomando-se como base a MR teste, e os resultados foram avaliados e comparados.

Mostrou-se o grande impacto na redução de custos que as estratégias de otimização em modo conectado podem proporcionar.

Percebeu-se que, para a MR de pequenas dimensões usada nas simulações, o modelo centralizado de *day-ahead* sozinho poderia ser utilizado sem quaisquer restrições de desempenho. As avaliações, entretanto, foram realizadas com foco em sua generalização e aplicabilidade em casos mais complexos, considerando, como visto nos capítulos iniciais, a grande variedade de possibilidades e dimensões possíveis para MRs reais.

Na comparação das estratégias centralizada e descentralizada em tempo real, verificou-se que a solução por SMA com algoritmo de leilão, que exige a discretização da energia demanda e ofertada em pacotes de energia de mesmo valor, permite obter-se uma solução muito

próxima, mesmo com a utilização de uma baixa resolução de 1 kW de potência média por pacote de energia negociado.

Em termos de desempenho, na estratégia descentralizada, um fator crucial é avaliar a localização física dos Agentes de Mercado, durante o período de negociação. Se for possível realizar o deslocamento de todos os agentes negociadores para o mesmo servidor físico, por meio da propriedade da mobilidade dos agentes em plataformas de SMA, evitando-se assim a latência da rede, pode-se solucionar o problema para a MR de referência em questão de milissegundos. Mostra-se, assim, o ótimo desempenho desse algoritmo, mesmo sendo aplicado a um problema com baixa esparsidade, visto que há diversas referências que apresentam o algoritmo de leilão como apresentando seus principais diferenciais em problemas com alta esparsidade e grande número de agentes.

Avaliou-se, também, o possível impacto da latência da rede, no caso de ter-se os Agentes de Mercado negociando em diferentes servidores, por meio da rede de comunicação. Verificou-se que, como já mostrado em simulações por outros autores, tal estratégia pode ser viável, desde que uma baixa resolução de discretização de potências seja utilizada, ou se for satisfatória uma solução subótima.

A melhor abordagem para o problema depende de uma diversidade de fatores, como exposto neste trabalho, com a solução descentralizada em plataformas de SMAs provavelmente se tornando cada vez mais promissora, considerando o esperado crescimento da complexidade e número de componentes inteligentes distribuídos. Outros fatores que tendem a aumentar a atratividade das soluções descentralizadas são a diversidade de tecnologias nas MRs das futuras RIEEs e o esperado crescimento exponencial da capacidade computacional e dos sistemas de comunicação.

Como sugestões de trabalhos futuros, propõe-se a implementação do algoritmo em um sistema SCADA comercial, controlando MR simulada em RTDS, ou mesmo uma MR real, implementando-se a solução centralizada com o GAMS, e a descentralizada em um SMA, com base em um *framework*, como o JADE, testando-se diferentes cenários, e, inclusive, avaliando a escalabilidade das soluções, na medida em que o número e a diversidade de REDs conectados vier a crescer.

A avaliação de SMAs contando com a implementação de agentes em *hardware* reais, nos CLs dos REDs e cargas, como discutido na Seção 2.6.2, são também considerados pela literatura como grandes desafios na área de MRs modeladas como SMA.

O aperfeiçoamento e a simplificação dos modelos de custos de redução da vida útil e de oportunidade das diversas tecnologias de SAE, durante o *day-ahead*, ainda se mostram necessários. Da mesma forma, também se mostram relevantes a avaliação das técnicas de determinação dos custos marginais do SAE no modelo de otimização em tempo real, sobretudo nas estratégias descentralizadas.

Mostra-se também necessário o incremento das pesquisas de alternativas de variações de algoritmos de leilões, podendo-se explorar os diferentes mecanismos de leilões direto-reverso, assimétricos e de multialocação, e suas possíveis combinações, de maneira a atender as restrições de potência mínima e a modelagem do custo de partida dos geradores.

Outra limitação que merece ser estudada, como discutido da Seção 3.3, é o fato de o algoritmo simétrico priorizar sempre as fontes internas da MR. Uma possibilidade seria a avaliação de algoritmos de leilão assimétricos, que permitissem a competição direta entre as fontes internas e externas.

Finalmente, vê-se como vertente importante de pesquisa para futuros trabalhos o desenvolvimento de novas estratégias de planejamento de *day-ahead* com modelo descentralizado.

# Referências Bibliográficas

- ANEEL (2010). *Resolução Normativa Nº 414, de 9 de setembro de 2010*, p. 156.
- Ahn, S., Member, S., Moon, S. (2009). Economic Scheduling of Distributed Generators in a Microgrid Considering Various Constraints, *PES 2009 GENERAL MEETING*, Calgary, Alberta Canada, p. 1–6.
- Alcântara, M.V.P. (2011). Microrredes inteligentes: um novo modelo de negócio para a distribuição de energia elétrica, *Smart grids - Redes inteligentes (Dc)*: 36–45.
- Alves, A.A. (2016). *Avaliação da Estabilidade de Tensão nos Sistemas de Distribuição Considerando a Injeção de Potência da Geração Distribuída*, Dissertação de mestrado, Universidade Estadual do Oeste do Paraná - UNIOESTE, Foz do Iguaçu.
- Alvez, C.A. (2015). *Seleção e operação ótima de recursos energéticos distribuídos inseridos em uma microrrede de energia elétrica*, Dissertação de mestrado, Universidade Estadual do Oeste do Paraná, Foz do Iguaçu.
- Amin, M., Schewe, P.F. (2007). Preventing blackouts: building a smarter power grid, *Scientific American*: 60–67.
- ANEEL (2016). Micro e minigeração distribuídas, *Cadernos Temáticos ANEEL*: 34.
- ANEEL (2012). *Resolução Normativa Nº 482, de 17 de abril de 2012*, p. 12.
- Asano, H., Bando, S. (2008). Economic evaluation of microgrids, *2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*, IEEE, p. 1–6.
- Basu, A.K., Chowdhury, S.P., Chowdhury, S., Paul, S. (2011). Microgrids: Energy management by strategic deployment of DERs - A comprehensive survey, *Renewable and Sustainable Energy Reviews* **15**(9): 4348–4356.
- Bellifemine, F., Caire, G., Trucco, T., Rimassa, G. (2010). Jade programmer's guide, *Jade version (C)*: 1–49.
- Bellifemine, F.L., Caire, G., Greenwood, D., Wiley InterScience (Online service) (2007). *Developing multi-agent systems with JADE*, John Wiley.
- Berkeley Lab (2016). Microgrids at Berkeley Lab, [online]. Available from: <https://building-microgrid.lbl.gov/> [Acessado junho 10, 2016].
- Berrada, A., Loudiyi, K. (2016). Operation, sizing, and economic evaluation of storage for solar and wind power plants, *Renewable and Sustainable Energy Reviews* **59**: 1117–1129.
- Bertsekas, D.P. (1981). A new algorithm for the assignment problem, *Mathematical*

*Programming* **21**(1): 152–171.

- Bertsekas, D.P. (1990). The Auction Algorithm for Assignment and Other Network Flow Problems: A Tutorial, *Interfaces* **20**(4): 133–149.
- Bertsekas, D.P., Castañon, D.A. (1992). A forward/reverse auction algorithm for asymmetric assignment problems, *Computational Optimization and Applications* **1**(3): 277–297.
- Bertsekas, D.P., Castañon, D.A., Tsaknakis, H. (1993). Reverse Auction and the Solution of Inequality Constrained Assignment Problems, *SIAM Journal on Optimization* **3**(2): 268–297.
- Bertsekas, D.P., Eckstein, J. (1988). Dual coordinate step methods for linear network flow problems, *Mathematical Programming* **42**(1–3): 203–243.
- Bertsekas, D.P., Showers, B., Ed, Clark, A., Gupta, R.M. (1989). Title: Parallel and distributed computation: numerical methods Library science Title: Library analytics and metrics: using data to drive decisions and services Title: Surfing uncertainty: prediction, action, and the embodied mind Religion Title: Bhagavata,
- Bertsekas, D.P., Castanon, D.A. (1989). *The Auction Algorithm for the Minimum Cost Network Flow Problem*, Cambridge, Estados Unidos.
- Bhave, M.P. (2016). *The microgrid revolution : business strategies for next-generation electricity*, Praeger, Santa Barbara, Estados Unidos.
- Borges, P.V. de S. (2016). *Análise regulatória e econômica de microrredes elétricas no Brasil*, Dissertação de mestrado, Universidade Federal do Rio de Janeiro - UFRJ, Rio de Janeiro.
- Burkard, R.E., Dell’Amico, M., Martello, S., Society for Industrial and Applied Mathematics. (2012). *Assignment problems*, Society for Industrial and Applied Mathematics (SIAM, 3600 Market Street, Floor 6, Philadelphia, PA 19104).
- Carvalho, M.P. da R. (2017). *Previsão de demanda de um prédio universitário por redes neurais artificiais*, Dissertação de mestrado, Universidade Estadual Paulista - UNESP, Ilha Solteira.
- CATERPILLAR (2016). *Diesel Generator Set DE22E3 Manual*, CATERPILLAR, Deerfield, Illinois, Estados Unidos.
- Chaouachi, A., Kamel, R.M., Andoulsi, R., Nagasaka, K. (2013). Multiobjective Intelligent Energy Management for a Microgrid \_ Aymen Chaouachi - Academia, *IEEE Transactions on Industrial Electronics* **60**(4): 1688–1699.
- Chen, C., Duan, S., Cai, T., Liu, B., Hu, G. (2011). Smart energy management system for optimal microgrid economic operation, *IET Renewable Power Generation* **5**(3): 258.
- Chen, Q. (2001). A Neural Network Based Very Short Term load Forecaster For The Interim

ISO New England Electricity Market System, *IEEE PES International Conference on Power Industry and Computer Applications*: 217–222.

- Cirincione, M., Cossentino, M., Gaglio, S., Hilaire, V., Koukam, A., Pucci, M., Sabatucci, L., Vitale, G. (2009). Intelligent energy management system, *2009 7th IEEE International Conference on Industrial Informatics*: 232–237.
- Colson, C.M., Nehrir, M.H. (2009). A review of challenges to real-time power management of microgrids, *2009 IEEE Power and Energy Society General Meeting, PES '09*.
- Cossentino, M., Lodato, C. (2011). A multi-agent architecture for simulating and managing microgrids, *Proceedings of the Federated Conference on Computer Science and Information Systems*: 619–622.
- Costa, P.M., Matos, M.A., Lopes, J.A.P. (2007). A Regulatory Framework for Microgeneration and Microgrids, *2007 IEEE Lausanne Power Tech*, IEEE, p. 633–638.
- Dimeas, A.L., Hatziargyriou, N.D. (2005). Operation of a Multiagent System for Microgrid Control, *IEEE Transactions on Power Systems* **20**(3): 1447–1455.
- Dou, C., Yue, D., Member, S., Li, X., Xue, Y. (2016). MAS-Based Management and Control Strategies for Integrated Hybrid Energy System, *IEEE Transactions on Industrial Informatics* **12**(4): 1332–1349.
- Du, Y., Pei, W., Chen, N., Ge, X., Xiao, H. (2017). Real-time microgrid economic dispatch based on model predictive control strategy, *Journal of Modern Power Systems and Clean Energy* **5**(5): 787–796.
- Easley, D., Kleinberg, J. (2010). *Games, Networks, Crowds, and Markets: Reasoning about a Highly Connected World.*: 155–208.
- Falcão, D.M. (2009). Smart Grids E Microredes : O Futuro Já É Presente, *VIII Simpase*: 1–11.
- Faqiry, M.N., Kundu, R., Mukherjee, R., Das, S., Pahwa, A. (2014). Game theoretic model of energy trading strategies at equilibrium in microgrids, *2014 North American Power Symposium (NAPS)*: 1–4.
- Farag, H.E., El-Saadany, E.F., El Chaar, L. (2011). A multilayer control framework for distribution systems with high DG penetration, *2011 International Conference on Innovations in Information Technology, IIT 2011*: 94–99.
- Farhangi, H. (2010). The path of the smart grid, *IEEE Power and Energy Magazine* **8**(1): 18–28.
- Farzan, B.F., Lahiri, S., Kleinberg, M., Gharieh, K., Farzan, F., Jafari, M. (2013). Microgrids for Fun and Profit, *IEEE Power and Energy Magazine* (july/august): 52–58.
- Franklin, S., Graesser, A. (1997). Is It an agent, or just a program?: A taxonomy for autonomous

agents, *International Conference on Autonomous Agents and Multiagent Systems*, Springer, Providence, RI, USA, p. 21–35.

Galvin, R.W., Yeager, K.E., Stuller, J. (2009). *Perfect power : how the microgrid revolution will unleash cleaner, greener, and more abundant energy*, McGraw-Hill.

Gil, H.A., Joos, G. (2008). Models for Quantifying the Economic Benefits of Distributed Generation, *IEEE Transactions on Power Systems* **23**(2): 327–335.

Godoi, L.C.D.E. (2017). *Elementos inibidores e facilitadores na implantação de geração distribuída no brasil*, Dissertação de mestrado, Universidade Estadual do Oeste do Paraná - UNIOESTE, Foz do Iguaçu.

Gu, W., Wu, Z., Bo, R., Liu, W., Zhou, G., Chen, W., Wu, Z. (2014). Modeling , planning and optimal energy management of combined cooling , heating and power microgrid : A review, *International Journal of Electrical Power and Energy Systems* **54**: 26–37.

Guerrero, J.M., Chandorkar, M., Lee, T.L., Loh, P.C. (2013). Advanced control architectures for intelligent microgridspart i: Decentralized and hierarchical control, *IEEE Transactions on Industrial Electronics* **60**(4): 1254–1262.

Han, S., Han, S., Aki, H. (2014). A practical battery wear model for electric vehicle charging applications, *Applied Energy* **113**: 1100–1108.

Hatziargyriou, N. (2014). *Microgrid : architectures and control*, John Wiley & Sons, Ltd., West Sussex, Reino Unido.

Hernandez, L., Baladrón, C., Aguiar, J., Carro, B., Sanchez-Esguevillas, A., Lloret, J. (2013). Short-Term Load Forecasting for Microgrids Based on Artificial Neural Networks, *Energies* **6**(3): 1385–1408.

Hernandez, L., Baladron, C., Aguiar, J.M.J.M., Carro, B., Sanchez-Esguevillas, A.J.A.J., Lloret, J., Massana, J. (2014). A survey on electric power demand forecasting: Future trends in smart grids, microgrids and smart buildings, *IEEE Communications Surveys and Tutorials* **16**(3): 1460–1495.

Hillier, F.S., Lieberman, G.J. (2010). *Introduction to operations research*, McGraw-Hill Higher Education.

Hyams, M., Awai, A., Bourgeois, T., Cataldo, K., Hammer, S., Kelly, T., Kraham, S., Mitchell, J., Nurani, L., Pentland, W., Perfetto, L., Van Nostrand, J. (2010). Microgrids: an assessment of the value, opportunities and barriers to deployment in New York State,: 219.

IEEE Standards Coordinating, C. 21 (2011). *IEEE Guide for Design, Operation, and Integration of Distributed Resource Island Systems with Electric Power Systems*, The Institute of Electrical and Electronics Engineers, Inc., Nova York.



- Institute, M. (2018). About Microgrids - Microgrid Institute, [online]. Available from: <http://www.microgridinstitute.org/about-microgrids.html> [Acessado abril 15, 2018].
- Jeon, J.H., Kim, J.Y., Kim, H.M., Kim, S.K., Cho, C., Kim, J.M., Ahn, J.B., Nam, K.Y. (2010). Development of hardware in-the-loop simulation system for testing operation and control functions of microgrid, *IEEE Transactions on Power Electronics* **25**(12): 2919–2929.
- Jiang, Q., Xue, M., Geng, G. (2013). Energy management of microgrid in grid-connected and stand-alone modes, *IEEE Transactions on Power Systems* **28**(3): 3380–3389.
- Kantamneni, A., Brown, L.E., Parker, G., Weaver, W.W. (2015). Survey of multi-agent systems for microgrid control, *Engineering Applications of Artificial Intelligence* **45**: 192–203.
- Katiraei, F., Iravani, R., Hatziargyriou, N., Dimeas, A. (2008). Microgrids management, *IEEE Power and Energy Magazine* **6**(3): 54–65.
- Khan, M.R.B., Jidin, R., Pasupuleti, J. (2016). Multi-agent based distributed control architecture for microgrid energy management and optimization, *Energy Conversion and Management* **112**: 288–307.
- Kueck, J.D., Staunton, R.H., Labinov, S.D., Kirby, B.J. (2003). *Microgrid Energy Management System*, Oak Ridge, Tennessee.
- Kwasinski, A., Weaver, W., Balog, R.S. (2016). *Microgrids and other local area power and energy systems*, Cambridge University Press, Cambridge, UK.
- Lasseter, R., Akhil, A., Marnay, C., Stephens, J., Dagle, J., Guttromson, R., Meliopoulos, A.S., Yinger, R., Eto, J. (2002). Consortium for Electric Reliability Technology Solutions White Paper on Integration of Distributed Energy Resources The CERTS MicroGrid Concept, *Program, Transmission Reliability Systems, Energy Program, Integration Interest, Public Commission, California Energy* (April): 1–29.
- Lasseter, R.H. (2002). MicroGrids, *IEEE Power Engineering Society winter Meeting*: 305–308.
- Logenthiran, T., Srinivasan, D., Khambadkone, A.M. (2011). Multi-agent system for energy resource scheduling of integrated microgrids in a distributed system, *Electric Power Systems Research* **81**(1): 138–148.
- Logenthiran, T., Srinivasan, D., Khambadkone, A.M., Aung, H.N. (2010). Multi-Agent System (MAS) for short-term generation scheduling of a microgrid, *2010 IEEE International Conference on Sustainable Energy Technologies (ICSET)*, IEEE, p. 1–6.
- Lukacs, M., Bhadra, D. (2003). Sealed Lead-Acid Batteries Technical Manual, *Sealed Lead-Acid Batteries Technical Manual* **21**(November): 2004.
- M. Pardalos, P., Resende, M.G.C. (2002). *Handbook of Applied Optimization*, S. Pidgeon & M. Johnson, orgs., Nova York, Estados Unidos.

- Mahmoud, M.S., A.L.-Sunni, F.M., Saif Ur Rahman, M. (2015). Review of microgrid architectures – a system of systems perspective, *IET Renewable Power Generation* **9**(8): 1064–1078.
- McArthur, S.D.J., Davidson, E.M., Catterson, V.M., Dimeas, A.L., Hatziargyriou, N.D., Ponci, F., Funabashi, T. (2007). Multi-Agent Systems for Power Engineering Applications—Part I: Concepts, Approaches, and Technical Challenges, *IEEE Transactions on Power Systems* **22**(4): 1743–1752.
- Montoya, M., Sherick, R., Haralson, P., Neal, R., Yinger, R. (2013). Islands in the Storm: Integrating microgrids into the larger grid, *IEEE Power and Energy Magazine* **11**(4): 33–39.
- Moura, B. (2014). *Moura Clean - Catálogo Técnico*, Belo Jardim, PE.
- Müller, J.P. (Jörg P., Wooldridge, M.J., Jennings, N., European Conference on Artificial Intelligence (1996 : Budapest, H., Workshop on Agent Theories, A. (1997). *Intelligent agents III : agent theories, architectures, and languages : ECAI'96 Workshop (ATAL), Budapest, Hungary, August 12-13, 1996 : proceedings*, Springer.
- Munson, R. (2005). *From Edison to Enron : the business of power and what it means for the future of electricity*, Praeger Publishers.
- Myerson, R.B. (1991). *Game theory : analysis of conflict*, Harvard University Press.
- Nam, K., Ahn, J., Choi, H., Kim, S., Kim, J., Cho, C., Jeon, J. (2009). Establishment of a pilot plant for KERI microgrid system based on power IT development program in Korea, *2009 Transmission & Distribution Conference & Exposition: Asia and Pacific*, IEEE, p. 1–6.
- Ng, E.J., El-Shatshat, R.A. (2010). Multi-microgrid control systems (MMCS), *IEEE PES General Meeting*, IEEE, p. 1–6.
- Olivares, D.E., Mehrizi-Sani, A., Etemadi, A.H., Cañizares, C.A., Iravani, R., Kazerani, M., Hajimiragha, A.H., Gomis-Bellmunt, O., Saeedifard, M., Palma-Behnke, R., Jiménez-Estévez, G.A., Hatziargyriou, N.D. (2014). Trends in microgrid control, *IEEE Transactions on Smart Grid* **5**(4): 1905–1919.
- Palma-Behnke, R., Benavides, C., Lanas, F., Severino, B., Reyes, L., Llanos, J., Saez, D. (2013). A microgrid energy management system based on the rolling horizon strategy, *IEEE Transactions on Smart Grid* **4**(2): 996–1006.
- Peter Lilienthal (2013). How to Classify Microgrids: Setting the Stage for a Distributed Generation Energy Future - HOMER Microgrid News and Insight : HOMER Microgrid News and Insight, [online]. Available from: <http://microgridnews.com/how-to-classify-microgrids-setting-the-stage-for-a-distributed-generation-energy-future/> [Acessado abril 15, 2018].
- Pilo, F., Pisano, G., Soma, G.G. (2007). Neural implementation of MicroGrid central

controllers, *IEEE International Conference on Industrial Informatics (INDIN)* **2**: 925–930.

- Planas, E., Gil-de-Muro, A., Andreu, J., Kortabarria, I., Martínez de Alegría, I. (2013). General aspects, hierarchical controls and droop methods in microgrids: A review, *Renewable and Sustainable Energy Reviews* **17**: 147–159.
- Pulcherio, M., Renjit, A., Illindala, M., Khalsa, A., Eto, J., Klapp, D., Lasseter, R. (2016). Evaluation of Control Methods to Prevent Collapse of a Mixed Source Microgrid, *IEEE Transactions on Industry Applications*: 1–1.
- Rangel, C.M., Mascarella, D., Joos, G. (2016). Real-Time Implementation & Evaluation of Grid- Connected Microgrid Energy Management Systems, *IEEE Electrical Power and Energy Conference (EPEC)*: 1–6.
- Ravichandran, A., Malysz, P., Sirouspour, S., Emadi, A. (2013). The critical role of microgrids in transition to a smarter grid: A technical review, *2013 IEEE Transportation Electrification Conference and Expo: Components, Systems, and Power Electronics - From Technology to Business and Public Policy, ITEC 2013*.
- Raza, M.Q., Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings, *Renewable and Sustainable Energy Reviews* **50**: 1352–1372.
- Saad, W., Han, Z., Poor, H., Basar, T. (2012). Game-Theoretic Methods for the Smart Grid: An Overview of Microgrid Systems, Demand-Side Management, and Smart Grid Communications, *IEEE Signal Processing Magazine* **29**(5): 86–105.
- Shoham, Y., Leyton-Brown, K. (2009). *Multiagent systems : algorithmic, game-theoretic, and logical foundations*, Cambridge University Press.
- Singh, R., Pal, B.C., Jabr, R.A., Hernandez, L., Baladrón, C., Aguiar, J.M.J.M., Carro, B.B., Sanchez-Esguevillas, A.J.A.J., Lloret, J., Raza, M.Q., Khosravi, A., Chen, Q., Hernandez, L., Baladron, C., Aguiar, J.M.J.M., Carro, B.B., Sanchez-Esguevillas, A.J.A.J., Lloret, J., Massana, J., Carvalho, M.P. da R. [UNESP] (2014). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings, *IEEE PES International Conference on Power Industry and Computer Applications* **50**(3): 29–37.
- Stadler, M., Mashayekh, S., Narayanan, S., Deforest, N., Brandt, T., Berkeley, L., Road, C. (2015). *Berkeley Laboratory Supervisory Controller for PV and Storage Microgrids*, Berkeley, CA.
- Su, W., Wang, J. (2012). Energy Management Systems in Microgrid Operations, *The Electricity Journal* **25**(8): 45–60.
- Tenfen, D. (2015). *Desenvolvimento de um modelo de programação linear inteira mista para o problema do gerenciamento energético de microrredes*, Tese de doutorado, Universidade Federal de Santa Catarina, Florianópolis.

- Tenfen, D., Lemos, F.A., Decker, I.C., Fernandes, R.C. (2013). Microgrids and Microgeneration in Brazilian Energy Market: a Discussion of Regulatory and Commercial Aspects, *The 9th Latin-America congress on electricity generation and transmission - CLAGTEE 2013* (October): 1–8.
- Thillainathan Logenthiran, Dipti Srinivasan, Ashwin M. Khambadkone, H.N.A. (2012). Multiagent System for Real-Time Operation of a Microgrid in Real-Time Digital Simulator, *IEEE TRANSACTIONS ON SMART GRID* **3**(2): 925–933.
- Vandoorn, T.L., De Kooning, J.D.M., Meersman, B., Vandeveldel, L. (2013). Review of primary control strategies for islanded microgrids with power-electronic interfaces, *Renewable and Sustainable Energy Reviews* **19**: 613–628.
- Wang, Y., Mao, S., Nelms, R.M. (2015). *Online Algorithms for Optimal Energy Distribution in Microgrids*, Springer International Publishing, Cham.
- Zhang, Z., Wang, J., Ding, T., Wang, X. (2017). A Two-Layer Model for Microgrid Real-Time Dispatch Based on Energy Storage System Charging/Discharging Hidden Costs, *IEEE Transactions on Sustainable Energy* **8**(1): 33–42.
- Zheng, G., Li, N. (2010). Multi-Agent Based Control System for Multi-Microgrids, *2010 International Conference on Computational Intelligence and Software Engineering* (1): 1–4.
- Zhou, C., Qian, K., Allan, M., Zhou, W. (2011). Modeling of the cost of EV battery wear due to V2G application in power systems, *IEEE Transactions on Energy Conversion* **26**(4): 1041–1050.

# Apêndice A

## Modelo de otimização do *day-ahead* no formato do *software* GAMS

Neste apêndice, apresenta-se o arquivo de modelo de otimização de *day-ahead*, formatado como arquivo do *software* GAMS. Este arquivo é construído dinamicamente pela plataforma de simulação em *Python*, e então enviado ao GAMS, que o soluciona, devolvendo posteriormente os resultados. Obviamente os valores das constantes desse modelo podem variar a cada intervalo de análise, na medida em que a janela deslizante avança.

```
$Title Modelo de otimizacao de day-ahead de MR inteligente

*PARAMETROS DO MODELO DO GERADOR DIESEL (consumo)
  Scalar a parametro para modelagem do consumo /0.004446/;
  Scalar b parametro para modelagem do consumo /0.121035/;
  Scalar c parametro para modelagem do consumo /1.653882/;
  Scalar custo_startup custo de acionamento do gerador /6.8/;
  Scalar custo_comb custo de combustivel (R$ por litro) /2.9/;
  Scalar Pi_nominal potencia nominal do gerador /20.000/;

  Sets tdia / semana, fimsemana/
        thora / ponta, foraponta/
;

*PARAMETROS DE COMPRA/VENDA DA MACRORREDE
  Table precos_cr_venda(tdia, thora) precos de compra por kWh da macrorrede
        ponta foraponta
  semana      0.20000  0.20000
  fimsemana   0.20000  0.20000
;

  Table precos_cr_compra(tdia, thora) precos de venda por kWh para a macrorrede
        ponta foraponta
  semana      0.47987  0.29908
  fimsemana   0.29908  0.29908
;

  Parameter demandas_contratadas(thora) demanda contratada em kW /
  ponta       20.00000
  foraponta   24.75770
;/

  Table tarifas_demandas(tdia, thora) multa por kW excedente
        ponta foraponta
  semana      28.85000  8.82000
  fimsemana   8.82000  8.82000
;

*DISCRETIZACAO EM 3 NIVEIS: na primeira meia hora otimiza de 5 em 5 min (dt=.083
*                          horas), na segunda meia hora discretiza em .5 horas,
*                          e no restante das 23 horas do dia, discretiza de
*                          hora em hora (dt = 1 hora).
  Scalar dt1 duracao de intervalos na primeira meia hora em horas /.083333/;
  Scalar dt2 duracao de intervalos na segunda meia hora em horas /.5/;
  Scalar dt3 duracao de intervalos nas 23 horas restantes em horas /1/;

  set t enumeracao com os periodos de tempo dt /
        1*30
  /;
```

```

Parameter dt(t) /
  1*6      .083333
  7        .5
  8*30     1

/;

Set map_th(t, thora) /
  1*13.foraponta
  14*16.ponta
  17*30.foraponta
/;

Set tp_dia(tdia) / semana /;

*PARAMETROS PARA MODELAGEM DA BATERIA
Scalar batSize tamanho da bateria em kWh /2.4/;
Scalar nf taxa de manutencao de carga da bateria a cada hora /.998/;

Parameter nft(t) taxa de manutencao de carga para cada periodo t;
nft(t) = nf ** dt(t);

*LIMITES
Scalar psmax /20.600/;
Scalar psmín /-19.000/;
Scalar soc_max /.8/;
Scalar soc_min /.42/;
Scalar nMaxCiclos numero maximo de ciclos da bateria /4/;
Scalar Nbat /12/;

*CONDICOES INICIAIS
Parameter IniGer(t) Gerador ja estava ligado? /1 0/ ;
Parameter IniBat(t) Estado de carga inicial da bateria (0-1) /1 0.8/ ;

Parameter DL(t) demanda liquida (carga - ger. solar) por periodo /
* (kW)
  1 26.60
  2 26.60
  3 25.10
  4 25.10
  5 23.76
  6 23.76
  7 25.08
  8 23.82
  9 28.73
  10 19.83
  11 19.77
  12 19.97
  13 17.17
  14 17.44
  15 24.17
  16 22.92
  17 21.24
  18 12.42
  19 8.66
  20 7.75
  21 7.37
  22 9.81
  23 15.24
  24 19.94
  25 20.94
  26 21.60
  27 23.74
  28 26.08
  29 25.68
  30 26.16
/;

set i /1*6/ ;

Parameter pival(i) usado na linearização da curva de consumo do gerador /
* i      pi(kW)
  1      0.0

```

```

2          4.0
3          7.0
4          11.5
5          15.0
6          20.0
/;

Parameter consumoger(i) /1 0. /;
consumoger(i)$ (ord(i) > 1) = (a * pival(i) * pival(i) + b * pival(i) + c);

variables lam(t, i);
sos2 variables lam(t, i);

*VARIÁVEIS INDEPENDENTES
Positive Variables
prv(t, tp_dia, thora) pot. de venda a macrorrede por kWh
prc(t, tp_dia, thora) pot. de compra da macrorrede por kWh
prcd(t, tp_dia, thora) pot. comprada alem da demanda contratada
pi(t) potencia gerada pelo gerador diesel
soc(t) estado de carga do final do periodo
psc(t) potencia de carga(-) ou descarga(+) do banco de baterias
psd(t) potencia de carga(-) ou descarga(+) do banco de baterias
rvr(t, tp_dia, thora) receita de vendas de energia para a macrorrede
comb(t) consumo de diesel
ci(t) custo da geracao de energia pelo gerador a diesel
cb(t) custo de penalizacao por uso da bateria
;

Binary variables
* bVG(t, tp_dia, thora) 1 indica q MR esta vendendo energia para a macrorrede
bCG(t, tp_dia, thora) 1 indica q MR esta comprando energia da macrorrede
bGL(t) 1 indica que o gerador diesel esta ligado
bGerLigou(t) 1 indica que o gerador ligou no periodo t
bGerDesligou(t) 1 indica que o gerador desligou no periodo t
bDescIni(t) 1 indica que novo ciclo de descarga foi iniciado em t
bDescFim(t) 1 indica que um ciclo de descarga foi terminado em t
bDesc(t) 1 indica que o banco de baterias esta descarregando em t
;

Variables
z custo total - resultado da funcao objetivo
cr(t, tp_dia, thora) custo de compras de energia da macrorrede
;

Integer Variable nCiclos(t);

*BOUNDARIES
soc.lo(t) = soc_min;
soc.up(t) = soc_max;
soc.fx(t)$ (ord(t) = card(t)) = soc_max;
nCiclos.up(t) = nMaxCiclos;

Equations
obj a funcao objetivo

eqCr(t, tp_dia, thora) calculo do custo de compras da macrorrede
eqRvr(t, tp_dia, thora) calculo da receita de vendas para a macrorrede
eqCi(t) calculo do custo do gerador diesel
eqCBat(t) calculo da penalizacao por uso da bateria

A_1(t, tp_dia, thora) limite superior de prc de acordo com valor de bCG
A_2(t, tp_dia, thora) limite superior de prv de acordo com valor de bVG

B_1(t) calculo do consumo de diesel por kWh
B_2(t) logica liga-desliga do gerador
B_3(t) funcao de normalizacao para linearizacao do consumo
B_4(t) equacao de pi com base no consumo
B_5(t) limite inferior de pi
B_6(t) limite superior de pi
B_7(t)

C_1(t) calculo do soc com base no soc anterior e ps atual
C_2(t) calculo de binarios indicando inicio ou fim de descarga
C_3(t) calculo do numero de ciclos de carga-descarga

```

```

C_4(t)    limite superior de ps
C_5(t)    limite inferior de ps
C_6(t)    nao permite situacao absurda de inicio e fim de descarga

D_1(t, tp_dia, thora)  balanco de potencias
;

obj.. z =e= sum((t, tp_dia, thora)$map_th(t, thora), cr(t, tp_dia, thora) +
               ci(t) - rvr(t, tp_dia, thora));
eqCr(t, tp_dia, thora)$map_th(t, thora).. cr(t, tp_dia, thora) =e=
  (prc(t, tp_dia, thora) + prcd(t, tp_dia, thora)) * dt(t) *
  precos_cr_compra(tp_dia, thora) + prcd(t, tp_dia, thora) *
  tarifas_demandas(tp_dia, thora) * 2 + cb(t);
eqRvr(t, tp_dia, thora)$map_th(t, thora).. rvr(t, tp_dia, thora) =e=
  precos_cr_venda(tp_dia, thora) * prv(t, tp_dia, thora) * dt(t);
eqCi(t).. ci(t) =e= comb(t) * custo_comb + bGerLigou(t) * custo_startup;
eqCBat(t).. cb(t) =e= (psc(t) + psd(t)) * .01 * dt(t);

A_1(t, tp_dia, thora)$map_th(t, thora).. prc(t, tp_dia, thora) =l=
  bCG(t, tp_dia, thora) * demandas_contratadas(thora);
A_2(t, tp_dia, thora)$map_th(t, thora).. prv(t, tp_dia, thora) =l=
  (1-bCG(t, tp_dia, thora)) * demandas_contratadas(thora);

B_1(t).. comb(t) =e= sum(i,lam(t, i) * consumoger(i)) ;
B_2(t).. bGerLigou(t) - bGerDesligou(t) =e= bGL(t) - bGL(t - 1) - IniGer(t);
B_3(t).. sum(i,lam(t, i)) =e= 1 ;
B_4(t).. pi(t) =e= sum(i,lam(t, i)*pival(i)) ;
B_5(t).. pi(t) =g= bGL(t) * (.2 * Pi_nominal);
B_6(t).. pi(t) =l= bGL(t) * Pi_nominal;
B_7(t).. bGerLigou(t) + bGerDesligou(t) =l= 1;

C_1(t).. soc(t) =e= nft(t) * soc(t - 1) - psd(t) * dt(t) / (Nbat * batSize)
  + psc(t) * dt(t) / (Nbat * batSize) + IniBat(t);
C_2(t).. bDescIni(t) - bDescFim(t) =e= bDesc(t) - bDesc(t - 1);
C_3(t).. nCiclos(t) =e= nCiclos(t - 1) + bDescIni(t)+bDescFim(t);
C_4(t).. psd(t) =l= bDesc(t) * psmax;
C_5(t).. psc(t) =l= -(1 - bDesc(t)) * psmin;
C_6(t).. bDescIni(t) + bDescFim(t) =l= 1;

D_1(t, tp_dia, thora)$map_th(t, thora).. prc(t, tp_dia, thora) +
  prcd(t, tp_dia, thora) - prv(t, tp_dia, thora) +
  pi(t) + psd(t) - psc(t) =e= DL(t);

Model MR /all/;

MR.optcr = 0;

option limrow=50, mip=cplex;

Solve MR using mip minimizing z;

display z.l;

```



# Apêndice B

## Modelo de otimização em tempo real no formato do *software* GAMS

Neste apêndice, apresenta-se o arquivo de modelo de otimização em tempo real, formatado como arquivo do *software* GAMS. Este arquivo é construído dinamicamente pela plataforma de simulação em Python a cada iteração, com base nos dados previstos no *day-ahead*, e nas previsões de oferta e demanda para o próximo intervalo de 5 minutos. O arquivo gerado é então enviado ao GAMS, que o soluciona, devolvendo posteriormente os resultados. Obviamente os valores das constantes desse modelo podem variar a cada intervalo de análise.

```
$Title Modelo Linearizado de otimização de tempo real de MR inteligente

Scalar pl carga liquida (demanda menos oferta sist. hibrido) em kW /29.37550/;

Scalar preco_cr_venda preco de venda para a macrorrede por kWh /0.20000/;
Scalar preco_cr_compra preco de compra da macrorrede por kWh /0.29908/;
Scalar tarifa_demanda tarifa demanda contratada por kW /8.82000/;
Scalar demanda_contratada demanda contratada da distribuidora em kW /24.75770/;
Scalar PrcdMax máxima demanda de ultrapassagem fisicamente possivel;
PrcdMax = demanda_contratada;

Scalar a parametro para modelagem do consumo /0.004446/;
Scalar b parametro para modelagem do consumo /0.121035/;
Scalar c parametro para modelagem do consumo /1.653882/;
Scalar Pi_nominal potencia nominal do gerador em kW /20./;
Scalar bGerIni estado inicial do gerador (1-ligado 0-desligado) /0/;
Scalar CSC custo de acionamento (startup) do gerador em R$ /6.8/;
Scalar custo_comb custo de combustivel (R$ por litro) /2.9/;
Scalar pi_m potencia do gerador planejada no dayahead para dt /0.000000/;
Scalar bGL_da constante indicando se gerador estava ligado no day-ahead;
bGL_da = (pi_m > 0);

Scalar dt horizonte de tempo em horas /0.083333/;

Scalar batSize capacidade de cada bateria em kWh /2.4/;
Scalar soci estado de carga inicial (0.0-1.0) /0.800000/;
Scalar socm estado de carga planejado no dayahead /0.800000/;
Scalar nBat numero de baterias em cada banco de baterias /12/;
Scalar ps_m Potencia ps planejada no day-ahead /1.842300/;

Scalar b_us Binario que sera zero se day ahead previu ultrapassagem sem uso do SAE /1/;

Scalar soc_max maximo estado de carga da bateria (0.0-1.0) /.8/;
Scalar soc_min minimo estado de carga da bateria (0.0-1.0) /0.42/;
Scalar psmáx maxima potência de carga(-) ou descarga(+) da bateria /20.6/;
Scalar psmin minima potência de carga(-) ou descarga(+) da bateria /-19.0/;

Scalar nf taxa de manutencao de carga da bateria a cada hora /.998/;
Parameter nft taxa de manutencao de carga para o intervalo dt;
nft = nf ** dt;
```

```

set i /1*6/ ;

Parameter pival(i) usado na linearizacao da curva de consumo do gerador /
2      4.0
3      7.0
4      11.5
5      15.0
6      20.0
/;

Parameter consumoger(i) curva de consumo do gerador interpolada /1 0. /;
consumoger(i)$(ord(i) > 1) = (a * pival(i) * pival(i) + b * pival(i) + c);

Variables
z      objetivo
dPs    variacao da potência de carga(-) ou descarga(+) da bateria
cr      custo unitario de compra de energia da macrorrede
rvr     receita de vendas de energia para a macrorrede
ps      potência de carga(-) ou descarga(+) do banco de baterias
;

Positive Variable
pi      potência a ser gerada pelo gerador diesel
dPi     variação de potencia do gerador em relacao ao planejado no dayahead
comb    combustivel (diesel) a ser consumido em litros
custo_st custo de acionamento do gerador diesel
ci      custo unitario de geracao do gerador diesel
prv     potencia media da energia a ser vendida a macrorrede em dt
prc     potencia media da energia a ser comprada da macrorrede em dt
multa   multa por potencia excedente
prcd    potencia excedente comprada alem do limite de demanda
soc     estado de carga final da bateria no final do intervalo
dPsm    potencia adicional para tentar alcançar socm se soci <> socm
;

sos2 variables lam(i);

Binary variables
bCG 1 = de a MR esta comprando energia da macrorrede
bGL 1 = se o gerador diesel esta ligado
bED 1 = se a potencia fornecida pela macrorrede esta alem da demanda contratada
;

*BOUNDARIES
soc.lo = soc_min;
soc.up = soc_max;

*Potência bruta necessária para ir de soci para socm;
dPsm.fx = (soci - socm) * nBat * batSize / dt;

Equations
A_1 define a função objetivo
A_2 cálculo do custo de compra da macrorrede
A_3 cálculo da receita de venda para a macrorrede
A_4 cálculo do custo do gerador diesel

*RESTRICOES DE COMPRA E VENDA DA MACRORREDE
B_1 limite minimo da potencia comprada nao excedente
B_2 limite maximo da potencia comprada nao excedente
B_3 proibe excesso de demanda se nao estiver comprando da rede
B_4 limite maximo da potencia vendida a macrorrede
B_5 limite superior da potencia de ultrapassagem da demanda contratada

*RESTRICÕES DO GERADOR A DIESEL
C_1 calculo do consumo de diesel em litros por kWh
C_2 calculo do custo de startup do gerador diesel
C_3 calculo de pi linearizado
C_4 restricao da função sos2 definindo um unico intervalo linear para pi
C_5 limite maximo para pi
C_6 limite minimo para pi
C_7 definicao de dPi
C_8 nao permite desligar gerador se day-ahead previu que ficasse ligado

*RESTRICÕES RELATIVAS AO BANCO DE BATERIAS

```

```

D_1  limitacao do SOC final com base no anterior e o valor de ps
D_2  define ps com base na potencia planejada no day ahead e sua variacao
D_3  limite minimo para ps
D_4  limite maximo para ps em condicoes de ultrapassagem
D_5  limite maximo para ps
D_6  sopermite carga da bateria no caso de excesso de demanda
D_7  so permite descarga da bateria no caso de excesso de demanda
D_8
D_9

E_1  restricao do balanco de potencias (oferta igual a demanda)
;

A_1.. z =e= cr - rvr + ci;
A_2.. cr =e= (prc + prcd) * preco_cr_compra * dt +
         tarifa_demanda * 2 * prcd;
A_3.. rvr =e= preco_cr_venda * prv * dt;
A_4.. ci =e= comb * custo_comb *dt + custo_st;

B_1.. prc =g= bED * demanda_contratada;
B_2.. prc =l= bCG * demanda_contratada;
B_3.. bED - bCG =l= 0;
B_4.. prv =l= (1 - bCG) * demanda_contratada;
B_5.. prcd =l= bED * PrcdMax;

C_1.. comb =e= sum(i, lam(i) * consumoger(i)) ;
C_2.. custo_st =e= (bGL * (1 - bGerIni)) * CSC;
C_3.. pi =e= sum(i, lam(i) * pival(i)) ;
C_4.. sum(i, lam(i)) =e= 1 ;
C_5.. pi =l= bGL * .8 * Pi_nominal;
C_6.. pi =g= bGL * .2 * Pi_nominal;
C_7.. dPi =e= pi - pi_m;
C_8.. bGL =g= bGL_da;

D_1.. soc =e= nft * soci - ps * dt / (nBat * batSize);
D_2.. ps =e= dPs + (ps_m + dPsm);
D_3.. ps =g= psmin;
D_4.. ps =l= bED * (pl - demanda_contratada) + (1 - bED) * psmax;
D_5.. ps =l= psmax;
D_6.. dPs =g= bED * 2 * psmin;
D_7.. dPs =l= bED * 2 * psmax;
D_8.. dPs =g= b_us * 2 * psmin;
D_9.. dPs =l= b_us * 2 * psmax;

E_1.. pi + prc + prcd + ps - prv =e= pl;

Model MR /all/;

option limrow=50, mip=cplex;

Solve MR using mip minimizing z;

display prc.l, prcd.l, prv.l, ps.l, dPs.l, pi.l, dPi.l, z.l;

```



# Apêndice C

## Módulo de simulação de SMA

Neste apêndice, descreve-se, brevemente, com a utilização de diagramas UML, o módulo de simulação de sistemas multiagentes (SMA), cuja utilização é mostrada nas Figuras 4.2 e 4.3.

O módulo de simulação de SMA foi desenvolvido com o objetivo específico de permitir a avaliação do modelo descentralizado de otimização de tempo real e sua comparação com o modelo centralizado solucionado com a utilização do *solver* CPLEX, do sistema de modelamento matemático GAMS.

Foram implementados apenas os recursos do conceito de SMAs necessários para a simulação proposta, sem a intenção de implementar uma solução completa de plataforma SMA. Dessa forma, embora tenha-se buscado implementar a hierarquia de classes descrita na Seção 3.3, não foram implementadas, por exemplo, as camadas de comunicação de uma plataforma SMA completa. Com isso, torna-se possível acelerar o processo de simulação e reduzir seu tempo computacional, o que é maximizado pelo uso da linguagem C++.

O módulo SMA foi implementado como um executável de linha de comando, chamado pelo script *Python* com uma série de parâmetros, retornando, ao final do processo de negociação, os níveis de potência gerada ou consumida por cada RED do sistema. Os seguintes parâmetros são fornecidos pelo script em *Python* ao módulo SMA:

1. Carga prevista
2. Potência gerada pelos REDs renováveis
3. Tarifa de venda de energia à macrorrede
4. Tarifa de compra de energia da macrorrede
5. Multa por ultrapassagem da demanda contratada
6. Demanda contratada
7. Intervalo de tempo  $dt$ , do período de operação a ser otimizado
8. SOC inicial do período
9. SOC planejado no *day-ahead* para o início do período
10. Potência de carga/descarga do banco de baterias planejada no *day-ahead*
11. Valor binário indicando se deve ser utilizado o escalonamento- $\epsilon$

Na Figura C.1, mostra-se o diagrama de classes simplificado do módulo referido.

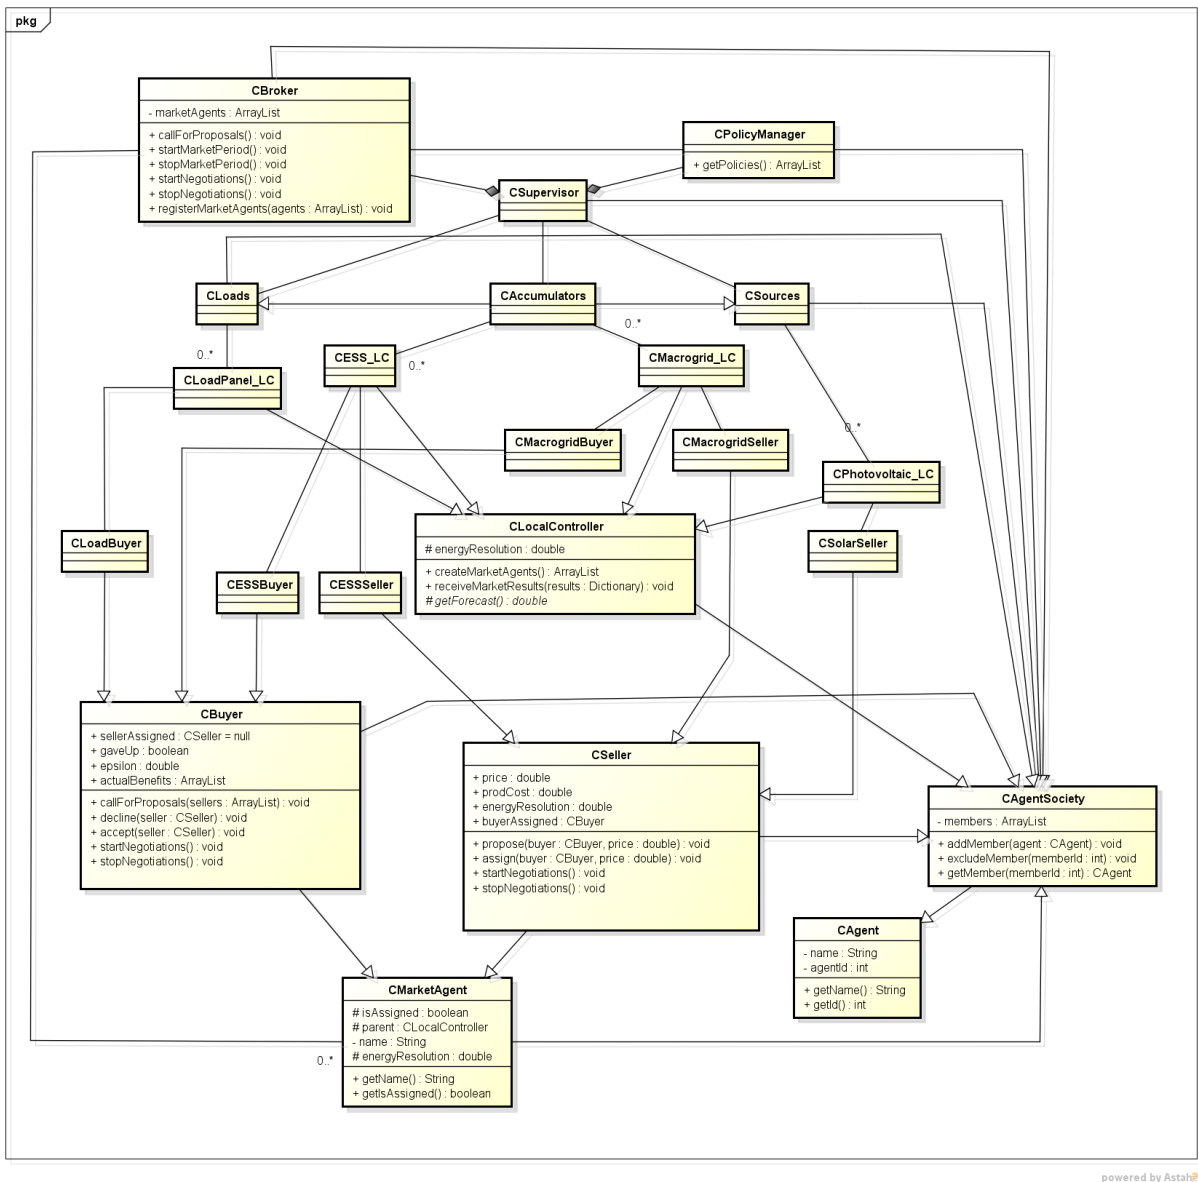


Figura C.1: Diagrama de classe UML simplificado da plataforma SMA simulada.

Note que todas as classes são especializações da classe base *CAgentSociety*, que por sua vez é uma especialização da classe *CAgent*. Ou seja, todos os objetos são agentes e ao mesmo tempo sociedades de agentes, podendo, portanto, conter outros agentes.

O agente Supervisor (*CSupervisor*) é composto pelos agentes Mediador (*CBroker*) e Regulador (*CPolicyManager*). Enquanto o Mediador intermedia as negociações entre os agentes de mercado, o Regulador estabelece as regras, com políticas e restrições em vigor, em cada período de negociação.

O agente Supervisor troca informações com as três sociedades de agentes controladores locais do sistema: sociedade das cargas (*CLoads*); sociedade das fontes (*CSources*); sociedade dos acumuladores ou sistemas de armazenamento (*CAccumulators*). Esta última é definida com

herança múltipla, sendo uma especialização tanto da sociedade de cargas como da de fontes, podendo, portanto, comportar-se como uma sociedade de fontes ou de cargas.

As sociedades de fontes, cargas e acumuladores, possuem cada uma um determinado número de agentes controladores locais (*CLocalController*), os quais modelam e controlam REDs específicos, como por exemplo: controladores de painéis de carga (*CLoadPanel\_CL*); controladores fotovoltaicos (*CPhotovoltaic\_LC*); controlador da macrorrede (*CMacrogrid\_LC*); controladores dos sistemas de armazenamento (*CESS\_LC*).

Os agentes controladores locais tem a capacidade de criar agentes virtuais de mercado, cujo ciclo de vida compreende apenas o período de mercado. Tais agentes são responsáveis por representar pacotes discretos de energia de suas sociedades de origem, podendo ser agentes vendedores ou compradores. Os controladores locais pertencentes à sociedade das cargas têm a capacidade de construir agentes virtuais de mercado compradores, enquanto a sociedade das fontes pode construir agentes virtuais de mercado vendedores. Já a sociedade dos acumuladores pode construir tanto agentes compradores como vendedores, a depender da política ou estratégia estabelecida a cada novo período de mercado. São exemplos de agentes virtuais de mercado compradores: os agentes de mercado de cargas (*CLoadBuyer*) e os agentes compradores da macrorrede (*CMacrogridBuyer*) e do sistema de armazenamento (*CESSBuyer*). Exemplos de agentes de mercado vendedores são os agentes vendedores do sistema fotovoltaico (*CSolarSeller*), os agentes vendedores da macrorrede (*CMacrogridSeller*) e os agentes vendedores do sistema de armazenamento (*CESSSeller*).

Note que os agentes de mercado vendedores são definidos como especializações da classe base *CSeller*, enquanto os agentes de mercado compradores são especializações da classe base *CBuyer*.

A Figura C.2 mostra diagrama de sequência UML representando o ciclo de período de mercado. Conforme descrito na Seção 3.3.1, o novo ciclo de mercado começa com o supervisor anunciando seu início às sociedades de controladores locais. Em seguida, as políticas definidas pelo regulador são informadas às sociedades de cargas e fontes, cujos controladores locais passam a criar agentes virtuais de mercado, levando em consideração tais políticas e a oferta ou demanda de energia dos REDs que representam. Os agentes virtuais de mercado, após sua criação, são registrados no supervisor, podendo então participar do período de negociações.

O período de negociações tem início após todas as sociedades de controladores locais terem registrado no supervisor os agentes de mercado que as representarão no período de negociação. Inicia-se, então, o leilão, representado pela função *doAuction()* na Figura C.2.

Conforme descrito na Seção 4.5.2, caso seja possível garantir a privacidade dos dados de cada agente de mercado, pode-se utilizar a funcionalidade da mobilidade dos agentes, transferindo-os para o mesmo ambiente computacional do agente supervisor. Neste ambiente, então, realiza-se o leilão, chegando-se à solução ótima, ou a uma solução subótima após o atingimento de uma das condições de término. Note que é esta a estratégia retratada na Figura

C.2. Caso não seja possível realizar a mobilidade dos agentes, serão necessárias diversas trocas de mensagens, a cada rodada de negociação, entre o agente mediador e os agentes de mercado, que neste caso permanecerão hospedados em suas sociedades de origem.

Terminado o período de negociações, os resultados das negociações para cada agente de mercado são informados às suas sociedades de origem, através da função *receiveMarketResult()*. Os agentes de mercado são então destruídos, e tem-se início novo ciclo de operação.

Na Figura C.3 apresenta-se um diagrama de sequência exemplificando uma iteração específica de um ciclo ou rodada de negociações, que ocorre dentro da função *doAuction()*. A cada rodada, cabe ao agente supervisor chamar a função *callForProposals()* de cada agente comprador, incitando-o a realizar um lance. Ao executar esta função, o comprador inicialmente avalia os preços atuais de cada agente vendedor. Note que, caso os agentes não estejam no mesmo ambiente computacional, torna-se muito dispendioso requisitar os preços diretamente dos agentes vendedores, sendo importante centralizar as informações de preços em um diretório acessível a todos os compradores (*Directory Facilitator*), recurso disponível em plataformas de SMA como o JADE.

Com base nos preços atuais de cada agente vendedor, o comprador seleciona o vendedor que apresenta maior valor real, resultante da subtração do valor intrínseco atribuído por cada comprador a cada vendedor do preço atual do respectivo vendedor.

Em seguida, o comprador envia um lance ao vendedor predileto, com valor superior a seu preço atual, seguindo as regras descritas na Seção 3.3.1. Considerando que o lance ofertado pelo comprador esteja acima do mínimo aceito pelo vendedor preferido, este irá aceitar a oferta, chamando a função *accept()*, informando ao comprador o aceite da oferta e associando-se ao mesmo e assumindo o valor ofertado como seu novo preço. Caso o vendedor estivesse já alocado a outro comprador, o mesmo será notificado de sua nova associação, ficando sem alocação.

Como descrito na Seção 3.3.1, as rodadas de negociações seguem até que, em determinada rodada, todos os compradores estejam já alocados a seus vendedores prediletos, considerando seus preços atualizados, ou até que uma determinada condição de término, como um limite de tempo ou número máximo de rodadas, seja atingida.



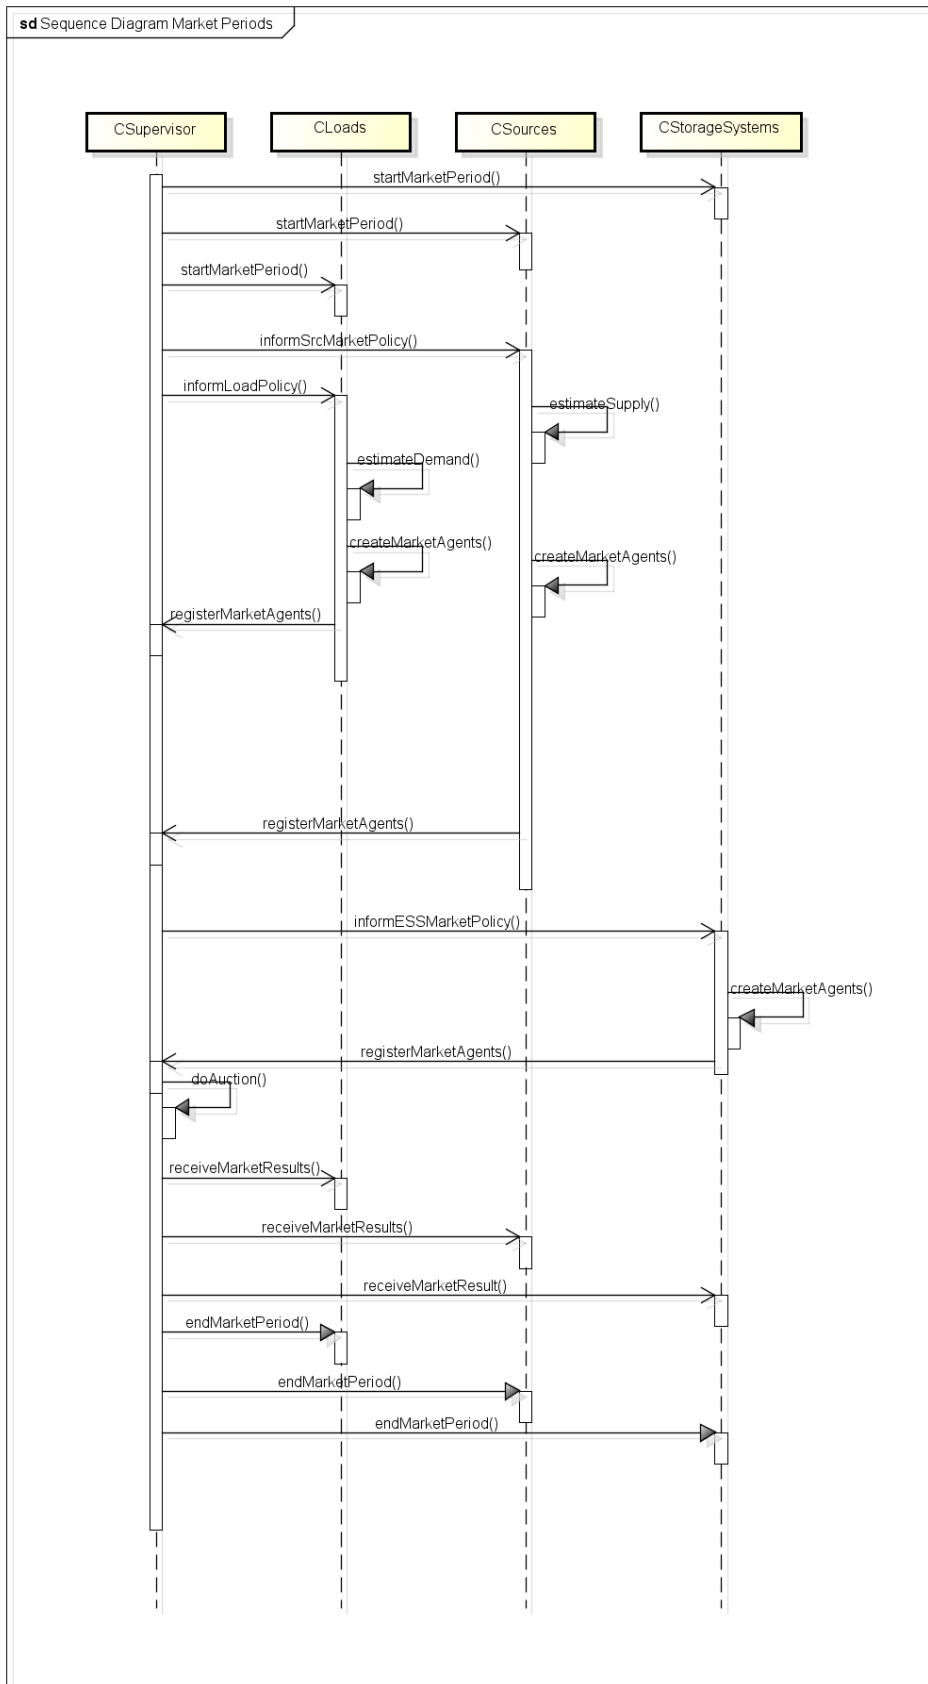
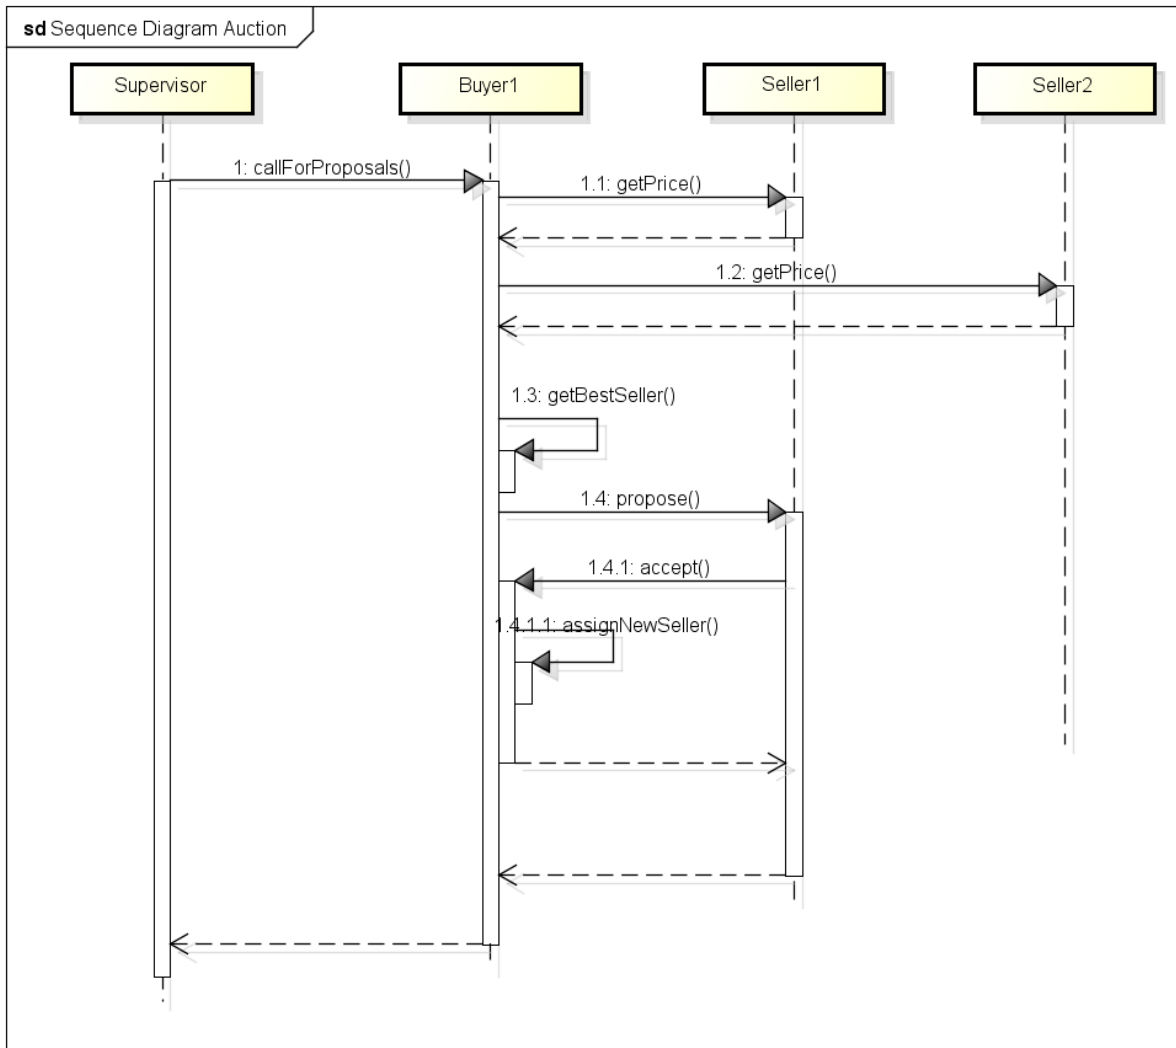


Figura C.2: Diagrama de seqüência representando o período de mercado.



powered by Astah

Figura C.3: Diagrama de sequência mostrando exemplo de negociação entre agentes de mercado.