

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

EDSON APARECIDO ROZAS THEODORO

**SIMMARKETSTRATEGY: UMA FERRAMENTA COMPUTACIONAL PARA
AVALIAÇÃO DE ESTRATÉGIAS DE VENDA DE ENERGIA ELÉTRICA EM
MERCADOS COM PRECIFICAÇÃO POR OFERTA**

DOIS VIZINHOS

2023

EDSON APARECIDO ROZAS THEODORO

**SIMMARKETSTRATEGY: UMA FERRAMENTA COMPUTACIONAL PARA
AVALIAÇÃO DE ESTRATÉGIAS DE VENDA DE ENERGIA ELÉTRICA EM
MERCADOS COM PRECIFICAÇÃO POR OFERTA**

**SIMMARKETSTRATEGY: A COMPUTATIONAL TOOL FOR ELECTRICITY
SELLING STRATEGY ASSESSMENT IN OFFER-BASED PRICING MARKETS**

Trabalho de conclusão de curso de especialização apresentado como requisito para obtenção do título de Especialista em Tecnologia Python para Negócios da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientador(a): Prof. Dr. Yuri Kaszubowski Lopes.

DOIS VIZINHOS

2023



Esta licença permite download e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

EDSON APARECIDO ROZAS THEODORO

**SIMMARKETSTRATEGY: UMA FERRAMENTA COMPUTACIONAL PARA
AVALIAÇÃO DE ESTRATÉGIAS DE VENDA DE ENERGIA ELÉTRICA EM
MERCADOS COM PRECIFICAÇÃO POR OFERTA**

Trabalho de Conclusão de Curso de Especialização apresentado como requisito para obtenção do título de Especialista em Tecnologia Python para Negócios da Universidade Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 03/abril/2023

Prof. Dr. Yuri Kaszubowski Lopes (Orientador)
Universidade do Estado de Santa Catarina – Campus Joinville

Prof. Dr. Rodolfo Adamshuk Silva (Membro)
Universidade Tecnológica Federal do Paraná – Campus Dois Vizinhos

Prof. Dr. Rafael Alves Paes de Oliveira (Membro)
Universidade Tecnológica Federal do Paraná – Campus Dois Vizinhos

DOIS VIZINHOS

2023

Com muito amor dedico este trabalho à minha
sempre companheira Cibele Matsuura por todo o
carinho, atenção e compreensão ao longo de toda a
minha jornada nesta especialização.

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus por me inspirar e ensinar a perseverar tanto em seu amor como na esperança de um mundo melhor.

Agradeço ao meu orientador Prof. Dr. Yuri Kaszubowski Lopes por sua confiança em meu trabalho e por toda a compreensão que dispôs ao longo do desenvolvimento desta proposta.

A todos os professores do Curso de Especialização em Tecnologia Python para Negócios, o meu sincero obrigado por todos os momentos e ensinamentos compartilhados, e por sua infundável dedicação no preparo dos materiais didáticos e atendimento aos alunos.

Aos meus colegas da 1ª Turma do Curso de Especialização em Tecnologia Python para Negócios, o meu muito obrigado por todas as discussões e momentos compartilhados.

A Secretaria do Curso de Especialização, pela atenção e cooperação em todos os momentos necessários.

A Universidade Tecnológica Federal do Paraná por me propiciar a oportunidade de cursar a pós-graduação *latu sensu*.

“Never invest in a business you cannot understand
(Warren Buffett, 21 out. 1991)”.

(RATCLIFFE, 2018)

RESUMO

Seguindo as tendências mundiais, após a década de 1990, de descabornização, digitalização e descentralização, o mercado de energia elétrica brasileiro tem sofrido um processo extenso de reestruturação. Entre as novas propostas para o setor está a adoção de um modelo de precificação por oferta, no qual os agentes vendedores (geradores de energia elétrica) poderão ofertar livremente seus custos marginais de operação de modo a competir nos leilões de energia, se diferenciando do modelo atual onde seus custos são auditados pelo operador do mercado. Neste sentido, o presente trabalho propõe a elaboração de uma ferramenta computacional baseada em simulação por agentes, utilizando técnicas de aprendizagem por reforço (*Q-learning*), e implementada em linguagem Python. Esta ferramenta realiza a avaliação de estratégias de venda de energia elétrica, considerando mercados com liquidação horária no dia anterior ao próximo dia operativo (*day-ahead*), sendo aplicada na seleção das melhores ofertas para o agente vendedor (maximização do lucro operacional). Como validação da prova de conceito, objetivando o posterior desenvolvimento de um produto minimamente viável, foram realizados testes em um sistema elétrico de pequeno porte visando determinar: (i) o potencial dos geradores no exercício de poder de mercado, (ii) o estudo de fenômenos de coalisão tácita em mercados com informação imperfeita, e (iii) a seleção de melhores ofertas de venda de energia.

Palavras-chave: Python, mercados de energia elétrica; simulação baseada em agentes; aprendizado de máquina; precificação por oferta.

ABSTRACT

After 1990s, following global trends of decarbonization, digitalization and decentralization, Brazilian electricity market has been extensively transformed. Among the new proposals is the adoption of an offer-based pricing for energy auctions, in which sellers (generators) can offer marginal operation costs freely without any auditing procedure by market operator. This work intends to propose an agent-based simulation tool, using reinforcement learning techniques (Q-learning) and Python programming language. This tool is used for energy selling strategy assessment in day-ahead markets with hourly discretization, and seeks the best selling offers in order to maximize agent's operational profit. The proof of concept validation was conducted in a small power grid in order to: (i) gain insights about generators market power, (ii) study tacit collusion phenomena among sellers in imperfect information environments, and (iii) improve generators' offer behavior for profit maximization.

Keywords: Python, electricity markets; agent-based simulation; machine learning; offer-based pricing.

LISTA DE ILUSTRAÇÕES

Figura 1 – Ambientes de contratação de energia elétrica	22
Figura 2 – Simulação de MEE baseada em agentes.....	26
Figura 3 – Processo de decisão de Markov	27
Figura 4 – Processo de liquidação simplificado do MEE.....	34
Figura 5 – Processo de liquidação do MEE	34
Figura 6 – Despacho econômico do SEE	37
Figura 7 – Invariância do despacho econômico aos custos fixos da geração ..	40
Figura 8 – Busca da melhor ação na tabela- Q	42
Figura 9 – Algoritmo para aplicação do método Q -learning.....	43
Figura 10 – Diagrama de classes simplificado (<i>SimMarketStrategy</i>)	46
Figura 11 – Sistema teste de 6 barras e 3 geradores	48
Gráfico 1 – Demanda horária do sistema utilizada nos testes	49
Gráfico 2 – Geração e demanda totais do SEE (caso primário)	50
Gráfico 3 – Distribuição da geração do SEE (caso primário)	51
Gráfico 4 – Carregamento das linhas de transmissão (caso primário)	51
Gráfico 5 – PMLs nos barramentos dos geradores (caso primário)	52
Gráfico 6 – Preço médio no SEE (treino do agente G1)	53
Gráfico 7 – PLM médio nos barramentos (treino do agente G1)	54
Gráfico 8 – Ação dos agentes no mercado (treino do agente G1)	54
Gráfico 9 – PLM médio nos barramentos (melhor ação do agente G1)	55
Gráfico 10 – Preço médio no SEE (treino do agente G2)	56
Gráfico 11 – PLM médio nos barramentos (treino do agente G2)	56
Gráfico 12 – PLM médio nos barramentos (melhor ação do agente G2)	57
Gráfico 13 – Preço médio no SEE (treino do agente G3)	58
Gráfico 14 – PLM médio nos barramentos (treino do agente G3)	58
Gráfico 15 – PLM médio nos barramentos (melhor ação do agente G3)	59
Gráfico 16 – Preço médio no SEE (treino do agente G1 considerando sua troca de localização física com o agente G2)	61
Gráfico 17 – PLM médio nos barramentos (melhor ação do agente G1 considerando sua troca de localização física com o agente G2)	61
Gráfico 18 – Preço médio no SEE (treino do agente G1 considerando sua troca de localização física com o agente G3)	62
Gráfico 19 – PLM médio nos barramentos (melhor ação do agente G1 considerando sua troca de localização física com o agente G3)	63
Gráfico 20 – Preço médio no SEE (treino de todos os agentes)	65
Gráfico 21 – PLM médio nos barramentos (treino de todos os agentes)	65
Gráfico 22 – Ação dos agentes no mercado (treino de todos os agentes)	65
Gráfico 23 – PLM médio nos barramentos (treino de todos os agentes)	66

LISTA DE TABELAS

Tabela 1 – Parâmetros das funções de custo operacional do sistema teste.....	49
Tabela 2 – Limites operacionais dos geradores do sistema teste.....	49
Tabela 3 – Resultados econômicos agentes (caso primário).....	52
Tabela 4 – Seleção das ações durante a fase de treino (treino do agente G1) ..	55
Tabela 5 – Resultados econômicos dos agentes (melhor ação do agente G1) .	55
Tabela 6 – Seleção das ações durante a fase de treino (treino do agente G2) ..	57
Tabela 7 – Resultados econômicos dos agentes (melhor ação do agente G2) .	57
Tabela 8 – Seleção das ações durante a fase de treino (treino do agente G3) ..	59
Tabela 9 – Resultados econômicos dos agentes (melhor ação do agente G3) .	59
Tabela 10 – Resultados econômicos dos agentes (melhor ação do agente G1 considerando sua troca de localização física com o agente G2).....	62
Tabela 11 – Resultados econômicos dos agentes (melhor ação do agente G1 considerando sua troca de localização física com o agente G3).....	63
Tabela 12 – Resultados econômicos dos agentes (melhor ação de todos os agentes).....	66

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulado
ANEEL	Agência Nacional de Energia Elétrica
AR	Aprendizado por Reforço
CCEE	Câmara de Comercialização de Energia Elétrica
CMO	Custo Marginal de Operação
CMSE	Comitê de Monitoramento do Setor Elétrico
EPE	Empresa de Pesquisa Energética
ESS	Encargos de Serviço dos Sistemas
KKT	Karush-Kuhn-Tucker (condições de otimalidade)
MAE	Mercado Atacadista de Energia
MCP	Mercado de Curto Prazo
MEE	Mercado de Energia Elétrica
ONS	Operador Nacional do Sistema Elétrico
PLD	Preço de Liquidação das Diferenças
PML	Preço Marginal Locacional
RESEB	Reestruturação do Setor Elétrico Brasileiro
SEE (SEP)	Sistema de Energia Elétrica (Sistema Elétrico de Potência)

LISTA DE SÍMBOLOS

$\$$	Unidade monetária (não atrelada a lastro ou país)
α	Passo de atualização (hiperparâmetro do algoritmo de AR)
β_i^t	Fator de ganho aplicado sobre o custo marginal de operação real do gerador “i” no instante “t”
γ	Taxa de desconto (hiperparâmetro do algoritmo de AR)
ε	Parâmetro de escolha das ações do agente durante a exploração do ambiente (hiperparâmetro do algoritmo Metrópolis)
θ_T	Parâmetro de decaimento geométrico da temperatura
λ_k^t	Preço marginal locacional da energia elétrica na barra “k” para o instante “t” (correspondente ao multiplicador de Lagrange associado às restrições de igualdade do problema de liquidação do mercado)
μ	Multiplicador de Lagrange associado às restrições de desigualdade do problema de liquidação do mercado
A	Espaço de ações (conjunto discreto)
$C_i(P_{g_i})$	Função de custo operacional do gerador “i”
$C_{m_i}(P_{g_i})$	Função de custo marginal operacional do gerador “i”
$\mathcal{L}(x, \lambda, \mu)$	Função lagrangeana
MVAR-h	Megavoltampère-reactivo-hora (unidade de medida para energia elétrica reativa)
MW	Megawatt (unidade de medida para potência elétrica ativa)
MWh	Megawatt-hora (unidade de medida para energia elétrica ativa)
MW-médio	Média da energia elétrica ativa (MWh/h) gerada em um determinado período de tempo
N_A	Número total de ações possíveis ao agente
N_B	Número de barramentos no sistema de transmissão do SEE
N_G	Número de geradores conectados no sistema de transmissão do SEE
N_{Neg}	Número de negociações realizadas pelo agente no mercado <i>day-ahead</i> (cada negociação consiste na oferta para a venda de energia elétrica respectiva às 24h do próximo dia operativo)
N_S	Número total de estados possíveis ao ambiente
P_{d_i}	Potência elétrica ativa consumida na barra “i”
P_{g_i}	Potência elétrica ativa gerada pelo gerador “i”
P_{km}	Fluxo de potência elétrica ativa entre as barras “k” e “m”
$Q_i(s_t, a_t)$	Função ação-valor (calcula o retorno esperado futuro) do gerador “i”
R_t	Recompensa recebida pelo agente no instante “t”
S	Espaço de estados (conjunto discreto)
T	Temperatura (hiperparâmetro do algoritmo Metrópolis)
a_p	Ação escolhida, segundo a política atual, pelo agente
a_r	Ação escolhida arbitrariamente (aleatória) pelo agente
a_t	Ação (decisão) tomada pelo agente no instante “t”
c_{0_i}	Termo independente na função de custo operacional do gerador “i”
c_{1_i}	Termo linear na função de custo operacional do gerador “i”
c_{2_i}	Termo quadrático na função de custo operacional do gerador “i”
$f(x)$	Função de custo do problema de otimização
$g(x)$	Função que descreve as restrições de igualdade associadas ao

	problema de otimização
$h(x)$	Função que descreve as restrições de desigualdade associadas ao problema de otimização
s_t	Estado atual do ambiente (ou ocupado pelo agente) no instante "t"
t	Instante de tempo "t"
x	Variável de decisão do problema de otimização

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Justificativa da proposta de desenvolvimento	15
1.2	Objetivo geral e proposta metodológica	16
1.2.1	Objetivos específicos e especificação do público-alvo	17
1.3	Organização do trabalho	18
2	REVISÃO CONCEITUAL DA LITERATURA	20
2.1	Histórico da reestruturação do mercado de energia elétrica	20
2.2	Precificação por oferta em mercados de energia elétrica	23
2.3	Estudo de mercados utilizando simulação baseada em agentes	25
3	PROJETO DA FERRAMENTA <i>SIMMARKETSTRATEGY</i>	29
3.1	Enquadramento do projeto e definição do escopo	29
3.2	Modelagem da liquidação financeira do mercado	29
3.2.1	Formação de preço no MEE.....	34
3.2.2	Remuneração dos agentes geradores	38
3.3	Modelagem das ofertas dos agentes geradores.....	41
3.4	Aprendizado das políticas de decisão utilizando <i>Q-learning</i>	42
4	TESTES DA FERRAMENTA <i>SIMMARKETSTRATEGY</i>	48
4.1	Apresentação do sistema teste.....	48
4.2	Estudo do caso primário do SEE	50
4.3	Estudo do poder de mercado dos agentes	52
4.4	Estudo da Influência da localização física do agente	60
4.5	Estudo do fenômeno de coalisão tácita entre os agentes.....	64
5	CONCLUSÃO	68
5.1	Perspectivas Futuras	68
	REFERÊNCIAS.....	70

1 INTRODUÇÃO

Os Sistemas de Energia Elétrica (SEEs), também conhecidos como Sistemas Elétricos de Potência (SEPs), são responsáveis por fornecer energia elétrica aos consumidores (carga), operando de forma confiável e econômica sob padrões de serviço pré-estabelecidos (AGÊNCIA [...], 2021).

Fisicamente, os SEEs são compostos pelos subsistemas de geração, transmissão e distribuição de energia elétrica. Tais subsistemas são responsáveis, respectivamente, pela transformação da energia das fontes primárias (encontradas na natureza) em energia elétrica, sua transmissão à longas distâncias com baixas perdas, e sua distribuição aos consumidores finais nos centros de carga (MONTICELLI; GARCIA, 2011).

Deste modo, constata-se que os SEEs são:

- De grande porte (no caso brasileiro são milhares de subestações e linhas de transmissão de alta tensão, bem como centenas de unidades geradoras);
- Ricos em não linearidades (centenas de malhas de controle operando em conjunto nos mais variados tipos de equipamentos);
- Exibem comportamento estocástico (milhões de consumidores com comportamentos distintos e atuando em diversos setores).

No entanto, a fim de prover os incentivos necessários à construção, operação e manutenção destes empreendimentos (aproveitamentos energéticos) um quarto elemento é necessário aos SEEs: o Mercado de Energia Elétrica (MEE).

Os MEEs são instrumentos institucionais necessários ao financiamento das atividades do setor elétrico e, em última análise, os responsáveis por prover os sinais econômicos necessários à manutenção e expansão do fornecimento de energia elétrica aos consumidores. A existência destes mercados é o que torna a exploração econômica das fontes de energia primária (oferta) atrativa aos investidores à medida que a carga (demanda) do sistema aumenta.

Neste contexto, durante a década de 1990, os MEEs sofreram um forte movimento de reestruturação caracterizado pela desverticalização do setor elétrico. A partir de então, o Estado deixou de ser o principal provedor da *commodity* energia elétrica, houve a ampliação do uso dos instrumentos administrativos de autorização, permissão e concessão para que empresas de capital privado (ou misto)

explorassem os serviços públicos de geração, transmissão e distribuição de energia elétrica (SOUZA; LEGEY, 2008).

No Brasil não foi diferente, com o objetivo de atrair capital privado para o financiamento da expansão do setor, o Estado criou diversas instituições para prover a regulamentação e fiscalização dos agentes. Entre estas, a Câmara de Comercialização de Energia Elétrica (CCEE) é responsável por viabilizar os contratos de compra e venda de energia elétrica em seus Ambientes de Contratação Regulado (ACR) e Livre (ACL), bem como a liquidação das diferenças entre a energia consumida/produzida e a contratada no Mercado de Curto Prazo (MCP).

No ACR os agentes compradores são as distribuidoras de energia elétrica representadas num *pool* que realiza a compra de energia através de leilões (MASILI *et al.*, 2003), dos quais os agentes vendedores (geradores) participam através de ofertas seguindo regras estabelecidas pela Agência Nacional de Energia Elétrica (ANEEL). Após a compra, a energia é repartida pelos componentes do *pool* tomando em consideração critérios de modicidade tarifária a fim de promover o melhor benefício aos consumidores cativos (CÂMARA [...], 2022a).

No ACL ocorrem as negociações bilaterais, onde os agentes compradores, à exceção das distribuidoras, compram energia elétrica diretamente dos agentes vendedores à preços e condições de entrega negociados livremente.

No MCP, responsável por precificar a diferença entre o consumo/produção verificado (medido) dos agentes e seus respectivos contratos (CASTRO; FILHO, 2004), ocorre a liquidação das diferenças ocorridas durante a operação do SEE a um preço *ex-ante* (publicado para o próximo dia operativo), calculado com base horária pela CCEE.

Com isso, a CCEE promove a contabilização e liquidação dos contratos no MEE nacional desde sua criação em 2004 (na verdade, instituída anteriormente em 1999 sob a denominação de Administradora de Serviços do Mercado Atacadista de Energia), bem como a composição dos sinais econômicos (preços) responsáveis por influenciar os agentes investidores do setor elétrico.

É fato notório que os MEEs internacionais continuam seus movimentos de modernização seguindo tendências de descarbonização (energias renováveis), descentralização (geração e armazenamento distribuídos) e digitalização (redes inteligentes). A CCEE dentro do seu propósito de desenvolver mercados de energia

eficientes, inovadores e sustentáveis vem promovendo estudos em variados temas estratégicos a fim de seguir tais tendências (PORTO, 2022):

- Abertura de mercado (diminuição de exigências para participação no mercado livre de energia);
- Segurança de mercado (estruturação de garantias, distribuição de risco e transparência de informação);
- Formação de preços (precificação por oferta);
- Modernização do mercado regulado (mercados de capacidade);
- Certificação de energia (produção de hidrogênio verde).

Constatações públicas dos esforços da CCEE no desenvolvimento destas temáticas residem tanto na sua participação nos workshops de “Soluções Matemáticas para Problemas Industriais”, promovidos pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (CENTRO [...], 2018), como na cooperação técnica no desenvolvimento de projetos de pesquisa e desenvolvimento com empresas do setor elétrico (ENGIE, 2022).

Tendo em vista que o **estudo de mecanismos de formação de preço** é um dos **temas estratégicos** necessários à modernização do MEE nacional, este trabalho propõe o desenvolvimento de uma ferramenta computacional, aqui denominada *SimMarketStrategy*, para avaliação de estratégias de venda de energia elétrica em mercados com precificação por oferta.

A seguir, exibem-se em maiores detalhes a proposta de desenvolvimento deste trabalho, bem como as respectivas justificativas para sua composição.

1.1 Justificativa da proposta de desenvolvimento

Como anteriormente discutido, a CCEE empenhada inúmeros esforços a fim de desenhar um novo modelo competitivo para a negociação da energia elétrica no Brasil (PORTO, [2020?]). Entre tais propostas, figura a migração do atual processo de formação de preço de um modelo baseado em custos auditados, no qual o custo da energia é determinado pelo custo marginal de operação (CMO) do sistema, para um novo modelo baseado em ofertas, no qual o preço será definido a partir da liquidação das ofertas de compra e venda entre os agentes do mercado.

Tal mudança do mecanismo de precificação da energia elétrica visa permitir a autoregulação do mercado, proporcionar melhores sinais econômicos para os

agentes de forma a fomentar seu planejamento de custos e investimentos, e uma maior competição trazendo maior benefício social aos consumidores.

Obviamente, dada a característica de oligopólio natural (poucos vendedores) do MEE, órgãos reguladores estudam mecanismos para fiscalização do poder de mercado (capacidade de alterar unilateralmente o preço de liquidação/equilíbrio do mercado) dos agentes, de modo a fomentar as melhores condições de competição entre os mesmos (VIANA, 2018).

Diversas técnicas de simulação são atualmente empregadas no estudo de MEEs, especificamente a simulação baseada em agentes é amplamente utilizada para analisar mercados com precificação por oferta (BAKIRTZIS; TELLIDOU, 2006; FREZZI *et al.*, 2007). Este tipo de simulação utiliza, frequentemente, a teoria de aprendizado por reforço (AR) para realizar a construção das políticas de decisão (treinamento) dos agentes no mercado.

Admitindo poucas hipóteses (BACH *et al.*, 2012), a atuação dos agentes nos MEEs pode ser expressa como um problema de decisão sequencial. Neste contexto, o uso de técnicas de AR (SUTTON; BARTO, 2018) é adequado à construção e avaliação de políticas (estratégias) para os agentes, tendo em vista que estes devem escolher a melhor ação a ser tomada de modo a maximizar sua recompensa (função objetivo).

Ante tais fatos, considerando a importância do estudo de MEEs para o atual cenário brasileiro (e internacional) e a relevância da aplicação de técnicas de AR neste contexto, justifica-se a presente proposta de produto de *software* para o desenvolvimento de um simulador de mercados com formação de preço por oferta, utilizando técnicas de AR, capaz de avaliar estratégias de venda de energia elétrica.

1.2 Objetivo geral e proposta metodológica

Como objetivo geral do presente trabalho propõe-se:

- Implementar um simulador de estratégias de venda de energia elétrica para unidades geradoras, através de leilões horários, em mercados com precificação por oferta.

Como proposta metodológica ressalta-se que a presente implementação trata-se de uma **prova de conceito de uma aplicação desktop**, tendo como foco a tecnologia a ser utilizada em seu desenvolvimento e, deste modo, como objetivo avaliar a factibilidade da proposta de produto de *software SimMarketStrategy*.

É importante observar que provas de conceito, protótipos e produtos minimamente viáveis são estágios iniciais no ciclo de vida do desenvolvimento de um produto de *software*. Estes três estágios podem “grosseiramente” ser associados a: validação da factibilidade (enfoque na tecnologia), validação da usabilidade (foco no ciclo/fluxo produtivo) e validação da proposta de valor (foco na avaliação das demandas e capacidade de atendimento do segmento de mercado pretendido).

Assim, com o intuito de atender ao objetivo geral anteriormente exposto, este trabalho adota as seguintes premissas tecnológicas em sua concepção: (i) a linguagem de programação Python como vetor principal no desenvolvimento do produto de *software* pretendido, haja vista sua extensa utilização tanto na simulação de sistemas elétricos (THURNER *et al.*, 2018), assim como para a implementação de ferramentas de aprendizado de máquina (GÉRON, 2019), e (ii) a utilização de técnicas de AR, em particular *Q-learning*, para o treinamento da política de decisão dos agentes que interagem no mercado, considerando os relatos de sucesso em sua aplicação na análise de mercados de energia elétrica (BACH *et al.*, 2012; BACH *et al.*, 2013; BAKIRTZIS; TELLIDOU, 2006).

Portanto, neste trabalho as premissas tecnológicas anteriores serão testadas através da construção de uma prova de conceito (aplicação desktop), que será validada através de testes em um sistema de energia elétrica de pequeno porte.

1.2.1 Objetivos específicos e especificação do público-alvo

Embora este trabalho tenha como temática central a implementação de um produto de *software*, neste momento, é relevante salientar os interesses a respeito dos possíveis resultados obtidos a partir da aplicação da ferramenta proposta.

Nesse sentido, como objetivos específicos deste trabalho propõem-se:

- Avaliar a relação entre os custos marginais de operação do gerador, sua capacidade (limites de geração), seu ponto de instalação na rede elétrica, e o exercício de poder de mercado (influência uniliteral sobre os preços da energia elétrica);
- Verificar a influência do congestionamento do sistema de transmissão de energia elétrica sobre o lucro operacional dos geradores;
- Identificar a possibilidade de ocorrência do fenômeno de coalisão tácita (coordenação das ofertas na ausência de troca de informação

explícita a respeito de suas estratégias de venda) entre os geradores a fim de exercer poder de mercado.

Diante de tais objetivos específicos, delinea-se como possíveis usuários (público-alvo) da proposta de produto de *software* apresentada os agentes atuantes em MEEs, com precificação por oferta, com destaque para:

- Agentes vendedores (geradores) de energia elétrica: que necessitam de ferramentas para criar e avaliar estratégias de venda de energia com o objetivo de maximizar seu lucro operacional;
- Operador (monitor) do mercado de energia elétrica: que necessita mensurar o impacto de mudanças nas regras de comercialização sobre as estratégias de venda utilizadas pelos agentes, assim como avaliar os cenários onde exista possibilidade de exercício de poder de mercado por estes agentes.

1.3 Organização do trabalho

Este trabalho está organizado em cinco capítulos de modo a apresentar ao leitor uma visão abrangente dos temas envolvidos no desenvolvimento da presente proposta de produto de *software*.

No Capítulo 2, é realizada uma breve discussão a respeito do histórico recente do desenvolvimento/reestruturação do mercado de energia elétrica brasileiro, pós-década de 1990, assim como da proposta de precificação por oferta neste mercado. Por fim, as técnicas de simulação baseada em agentes, treinados a partir de técnicas de AR neste trabalho, serão apresentadas com o objetivo de aplicá-las ao estudo de estratégias de venda de energia elétrica em MEEs com precificação por oferta.

No Capítulo 3, será dado enfoque na modelagem dos mercados de energia elétrica, incluindo as descrições da oferta e demanda utilizadas neste trabalho, assim como na modelagem dos elementos essenciais à aplicação da técnica *Q-learning* na composição da ferramenta *SimMarketStrategy*. É relevante ressaltar que as premissas/hipóteses utilizadas neste trabalho se prestam a viabilizar o desenvolvimento de uma prova de conceito e à avaliação da factibilidade técnica da proposta de produto de *software* apresentada.

No Capítulo 4, serão apresentados e analisados os diversos testes, utilizando a prova de conceito, da ferramenta *SimMarketStrategy* em um sistema de energia elétrica de pequeno porte. Por fim, analisam-se as influências dos custos marginais de operação, dos limites operacionais, e da localização física dos geradores sobre sua capacidade de exercer poder de mercado, assim como as consequências da ocorrência dos fenômenos de congestionamento do sistema de transmissão, e de coalisão tácita entre os agentes vendedores no MEE.

No Capítulo 5, as conclusões finais e algumas das perspectivas futuras para a continuação do trabalho serão comentadas.

2 REVISÃO CONCEITUAL DA LITERATURA

Neste capítulo realiza-se uma breve revisão conceitual da literatura pertinente à proposta de desenvolvimento de produto de *software* aqui defendida. Em especial, será dado enfoque à reestruturação do setor elétrico brasileiro, a proposta de adoção de um modelo de precificação por ofertas, assim como a utilização de técnicas de simulação de mercados baseadas em agentes inteligentes.

2.1 Histórico da reestruturação do mercado de energia elétrica

Segundo Souza e Legey (2008) o histórico do setor elétrico brasileiro pode ser apresentado em três fases: (i) anterior a promulgação da constituição de 1988, (ii) a primeira etapa do projeto de Reestruturação do Setor Elétrico Brasileiro (RESEB) entre 1988 e início dos anos 2000, e (iii) segunda etapa do RESEB após os anos 2000.

Na primeira fase histórica, o setor elétrico brasileiro foi consolidado com a criação da ELETROBRÁS (Centrais Elétricas Brasileiras S.A.), no início da década de 1960, que era responsável por controlar todas as companhias de geração e transmissão no Brasil, tendo também participação societária em todas as distribuidoras do país. Desde então, até meados dos anos 1990, o planejamento centralizado da operação e expansão do sistema era coordenado pela ELETROBRÁS.

Este modelo mostrou sua inadequação no final da década de 1970, e ao longo da década seguinte, quando as políticas de controle da inflação conduziram a retenção dos preços da energia elétrica, o que resultou em baixos retornos financeiros para as empresas do setor, maiores débitos públicos e escasseamento de fundos para expansão do sistema.

Tal cenário conduziu o setor elétrico à sua segunda fase histórica, onde a promulgação da constituição de 1988 tornou possível ao Estado conceder à empresas privadas o direito à prestação de serviços públicos sob dispositivos de permissão e concessão. Com isso, as tarifas de energia deixaram de ter o mesmo valor em todo o território nacional, e os vencedores dos leilões de concessão do sistema de distribuição de energia eram determinados pela menor tarifa oferecida ao mercado cativo.

Em 1992 as companhias da ELETROBRÁS foram incluídas no Programa Nacional de Privatizações, como parte das reformas do setor (sendo excluída do referido programa em 2004 após a venda de diversas companhias). Desta forma, previa-se a diversificação de capitais nas empresas do setor (movimento de desverticalização) e o aumento de competitividade no MEE recém estruturado.

Surgiram, então, os conceitos de produtor independente de energia (com direito à venda de energia produzida) e de consumidor livre (com direito de negociar livremente a compra de energia consumida), ambos com direitos de atuar no MEE. Diversas instituições também foram criadas neste período, a saber: a Agência Nacional de Energia Elétrica (ANEEL), em 1996, responsável por estabelecer os critérios de qualidade no suprimento de energia e pela fiscalização dos agentes, o Operador Nacional do Sistema (ONS), em 1998, responsável por operar o sistema elétrico brasileiro, e o Mercado Atacadista de Energia (MAE), em 1998, composta por um mercado de negociações bilateral e um mercado de curto prazo (responsável por liquidar as diferenças, verificadas na operação, entre energia consumida/suprida e energia contratada).

Embora a reestruturação do setor elétrico brasileiro tenha avançado muito nesta segunda fase, a complexidade de sua estrutura física e operacional, aliada a uma estrutura regulatória ainda incompleta, a falta de um planejamento determinante e a instabilidade econômica do período causaram a interrupção dos investimentos necessários à expansão no setor.

Tais fatos, conjuntamente com a escassez hídrica do ano de 2001, culminou na maior crise energética que o Brasil já enfrentou, resultando no racionamento de energia elétrica por todo o ano de 2001 até meados de 2002.

A terceira fase histórica do setor se inicia em 2003, com a posse de um novo presidente e a promessa de assegurar o fornecimento universal de energia elétrica à nação. Este movimento culminou na criação de outras instituições atuais, a saber: a Empresa de Pesquisa Energética (EPE), em 2004, responsável pelo planejamento energético a longo prazo, o Comitê de Monitoramento do Setor Elétrico (CMSE), em 2004, responsável por avaliar e manter a segurança do suprimento de energia elétrica no Brasil, e a Câmara de Comercialização de Energia Elétrica (CCEE), também em 2004, criada para substituir o antigo MAE.

Com a criação da CCEE, tem-se implantado o modelo de funcionamento atual do MEE brasileiro. Neste modelo a comercialização de energia elétrica se dá através de dois ambientes de contratação: o ACR e o ACL (resumidos na Figura 1).

Figura 1 – Ambientes de contratação de energia elétrica



Fonte: Adaptado de Souza e Legey (2008)

Após a operação física do SEE, a CCEE contabiliza a diferença entre a energia elétrica efetivamente consumida/produzida e a contratada. Tal diferença deve ser liquidada pelos agentes no MCP, sendo a mesma precificada ao CMO do sistema nas condições de operação “previstas” (*ex-ante*) durante a entrega física da energia.

É interessante notar que o MCP é contabilizado após a operação, no entanto, a energia é precificada antes da operação, mais especificamente 24 horas antes do dia operativo corrente.

Esta aparente incongruência entre contabilização e precificação reside na filosofia de mercado adotada no Brasil, segundo a qual a precificação da energia é atrelada ao planejamento da operação, de modo que sua informação antecipada possa ser endossada e utilizada pelos agentes a fim de propiciar estabilidade em suas decisões.

Por fim, é relevante observar que a comercialização da energia no ACR é realizada através da modalidade de leilões. Esta modalidade de negociação será o principal foco deste trabalho, tendo em vista ser a mais adequada ao ambiente competitivo preconizado pelo modelo de precificação por oferta discutido a seguir.

2.2 Precificação por oferta em mercados de energia elétrica

Antes de expor o modelo de precificação por oferta em MEEs, inicialmente discuti-se o modelo de precificação por custos utilizado no Brasil, de modo a contrastar as diferenças entre ambos.

Segundo PSR (2021a), o mecanismo de **precificação por custos** consiste em calcular o preço final da energia elétrica a partir dos custos de operação do sistema, no entanto, neste modelo tais custos são calculados a partir de informações técnicas e econômicas dos geradores (agentes vendedores) que são auditadas pelo operador do mercado (no Brasil este processo é realizado pelo ONS, sendo tais informações utilizadas pela CCEE no cálculos dos preços da energia).

Desta forma, nos ambientes de comercialização supervisionados (operados) pela CCEE, a precificação da energia ocorre da seguinte maneira:

- No ACR, de modo simplificado, a venda da energia é realizada em leilões nos quais os agentes geradores fazem ofertas de lotes (potência em “MW-médio”) em “R\$/MWh”, para produtos do tipo quantidade, ou por “R\$/ano”, para produtos do tipo disponibilidade. Os preços declarados são ordenados de modo crescente e os lotes vencedores são contemplados de modo que sua soma não seja inferior à quantidade demandada. O operador do mercado habilita a participação dos agentes no leilão a partir de critérios técnicos e limita as ofertas por um preço *cap*¹ (preço máximo) definido com base nos dados de custo auditados;
- No ACL, o preço da energia pode ser negociado livremente entre os consumidores livres e os geradores (ou seus respectivos representantes), seguindo as regras e procedimentos de comercialização estipulados pelo operador do mercado;
- Por fim, no MCP o preço da energia, aqui denominado preço de liquidação das diferenças (PLD), é calculado a fim de remunerar a energia consumida, durante a operação em tempo real do sistema elétrico, que não foi previamente contratada. Este preço é calculado, a partir dos custo de operação auditados de todos os geradores do

¹ Este preço máximo é utilizado como uma ferramenta de controle de poder de mercado, evitando que um agente (ou grupo de agentes agindo em comum acordo) possa influenciar os preço de equilíbrio (fechamento) de modo a tornar o leilão menos competitivo ou ineficiente.

SEE, pelo operador do mercado como sendo o CMO do sistema (respectivo à produção de 1 MW adicional) em base horária.

Como pode-se notar a partir da análise da formação de preços nos diferentes ambientes de negociação brasileiros, o modo de precificar a energia elétrica por custos segue variadas regras, a depender de quais agentes e em qual situação a transação é realizada. O motivo deste fato é que o mecanismo de precificação da energia é apenas um dos elementos do que se conhece por desenho de mercado.

O desenho de mercado é definido como a estrutura de regras e procedimentos que fazem com que o mercado funcione de modo eficiente (VIANA, 2018). O desenho de mercado utilizado no Brasil é complexo, trazendo em si não apenas regras para precificação direta da energia elétrica, como também diversos outros dispositivos tais como: mecanismo de realocação de energia, mecanismo de compensação de sobras e déficits, mecanismo de resposta da demanda, mecanismo de vendas de excedentes, entre outros, que irão influenciar direta e/ou indiretamente o preço da energia (MENDES *et.al.*, 2003; SOUZA; LEGEY, 2008).

Dito isto, é importante mencionar que os diversos elementos do desenho de mercado tem como objetivo principal prover as melhores ferramentas para a composição dos portfólios de compra e venda dos agentes.

O mecanismo de **precificação por ofertas** preconiza que a oferta dos agentes é livre de qualquer tipo de auditoria no que se refere a corroborar sua correspondência com custos de operação/produção da energia elétrica (PSR, 2021a). Este tipo de mecanismo já foi implantado em diversos países, tais como Estados Unidos, México, Noruega, Espanha, Colômbia, entre outros (PSR, 2021b).

Segundo PSR (2021a), a principal vantagem na adoção da formação de preços por oferta é a gestão distribuída da informação, de modo mais específico observa-se neste modelo:

- Preços aderentes aos custos reais da geração, incluindo custos de oportunidade, advindos de um processo competitivo e uma realidade dinâmica que demanda a atualização de preços mais frequente;
- Presença de informação descentralizada e incentivo à precisão, haja vista a necessidade dos agentes realizarem suas próprias previsões de despacho e decidirem sobre a composição de suas ofertas;

- Alocação de riscos decidida voluntariamente pelos próprios agentes, uma vez que cada agente deve decidir como precificar as incertezas da operação do sistema elétrico em face da sua própria disposição e portfólio de contratos.

Em um ambiente competitivo, este tipo de precificação conduz a melhores sinais de preço (em consonância com a demanda do mercado) contribuindo para a melhoria da qualidade do fornecimento de energia elétrica e também para a eficiência na exploração da matriz energética.

No entanto, a adoção da formação de preços por oferta também conduz a algumas desvantagens, cuja mitigação deve ser objeto de estudo durante o desenho de mercado, a saber: aumento da complexidade para o monitoramento do mercado por parte do operador, e maior risco de exercício de poder de mercado por parte dos agentes.

Neste trabalho, o exercício de poder de mercado, bem como o fenômeno de coalisão tácita entre os agentes, serão explorados na avaliação de estratégias de venda de energia elétrica em mercados com precificação por oferta.

2.3 Estudo de mercados utilizando simulação baseada em agentes

No estudo de MEEs, técnicas tradicionais assumem fatos sociais sobre a conformação do mercado, *e.g.* existência de comportamento cooperativo, e psicológicos sobre os agentes, tal como a racionalidade na tomada de decisões. No entanto, tais abordagens tendem delinear o comportamento dos agentes a partir do comportamento macroscópico observado, conduzindo as simulações a resultados imprecisos quando comparados à realidade do mercado (FREZZI *et al.*, 2007).

A abordagem baseada em agentes se tornou popular por não realizar hipóteses sobre o comportamento dos agentes, fazendo com que tanto a estrutura quanto os fatos sociais, relevantes ao mercado, surjam da interação entre os agentes ao buscarem maximizar seus próprios ganhos.

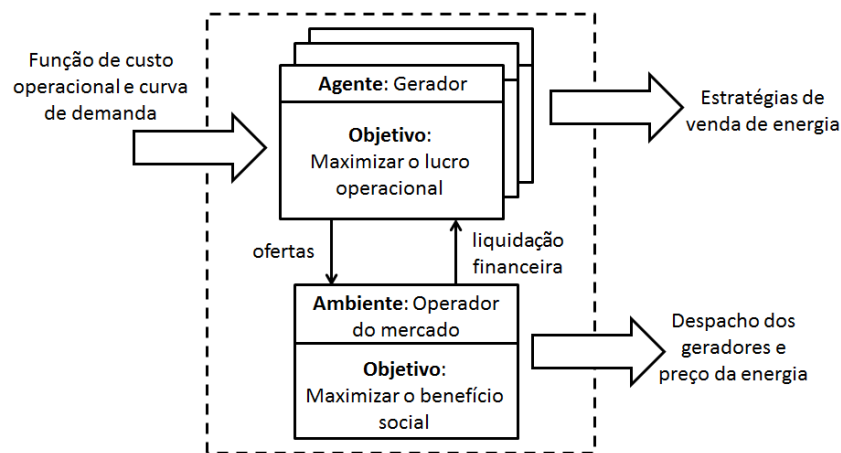
Krause e Andersson (2007) exaltam os benefícios da abordagem baseada em agentes, entre os quais citam-se:

- Avaliação da influência das características físicas e comportamentais dos agentes sobre o mercado (*e.g.* variação de preços e criação de regras tácitas);

- Estudo dos efeitos relacionados ao comportamento repetitivo do mercado sobre o aprendizado do exercício de poder de mercado pelos agentes;
- Contabilização das características oligopolistas do mercado, refletindo a observabilidade limitada do sistema, a presença de informação imperfeita² e a não satisfação da hipótese de competição perfeita.

Os principais elementos da abordagem baseada em agentes, aplicado ao estudo de MEEs, são resumidamente apresentados na Figura 2.

Figura 2 – Simulação de MEE baseada em agentes



Fonte: Adaptado de Frezzi et al. (2007)

Nota-se que todos os agentes recebem como informação suas próprias funções de custo operacional, bem como a curva de demanda do sistema, e fazem ofertas de venda de energia que serão utilizadas pelo operador do mercado no processo de liquidação a fim de estabelecer tanto o despacho dos geradores como o preço da energia elétrica.

É importante observar que os geradores formam sua estratégia de venda a fim de maximizar seu lucro operacional, enquanto o operador do mercado realiza o processo de liquidação financeira com o objetivo de maximizar o benefício social, traduzido na minimização do custo total de operação do sistema e, portanto, na minimização do preço final da energia (CRUZ, 2017).


Na literatura a abordagem baseada em agentes é amplamente utilizada para: composição de estratégias de venda de energia (BACH *et al.*, 2012; BACH *et*

² O conceito de informação imperfeita é utilizado na Teoria de Jogos para se referir ao fato de que durante a tomada de decisão de um agente, nem toda a informação relevante está disponível, sendo esta ocultada seja por outro agente ou pelo próprio mercado.

al., 2013), estudo da formação de coalisões (FREZZI *et al.*, 2007), avaliação do impacto do congestionamento do sistema de transmissão na formação de preços (KRAUSE; ANDERSSON, 2007), e estudo das regras de precificação em leilões de energia (BAKIRTZIS; TELLIDOU, 2006).

Como ponto comum na aplicação da simulação de MEEs baseada em agentes, nota-se a ampla utilização de técnicas de AR na composição das políticas de decisão dos agentes. Tais técnicas são aplicadas a qualquer processo sequencial de decisão que possa ser modelado por um processo de decisão de Markov³, seguindo o paradigma apresentado na Figura 3.

Figura 3 – Processo de decisão de Markov



Fonte: Adaptado de Sutton e Barto (2018)

Conforme a Figura 3, a interação entre o agente e o ambiente se dá na forma de uma ação, tomada a partir do conhecimento do estado atual e da recompensa obtida neste estado, que produz uma nova recompensa em um estado futuro. As ações são escolhidas a partir de uma política de decisão (foco dos algoritmos de treino), que visa maximizar a recompensa total do agente sobre todo o intervalo de tempo considerado na análise (SUTTON; BARTO, 2018).

A adaptação do problema, e.g. a definição de uma estratégia de venda de energia elétrica, ao paradigma descrito pelo processo de decisão de Markov não é direto. É necessário ao pesquisador criatividade para definir as fronteiras entre o agente e o ambiente segundo o objetivo a ser alcançado.

Também não é uma tarefa trivial definir a recompensa a ser maximizada, tendo em vista que esta deve descrever como o agente se aproxima do objetivo pretendido em função do estado atual. O estado observado pelo agente também se mostra como um desafio de modelagem, uma vez que este não se presta à simulação do ambiente, mas ao reconhecimento da melhor ação a ser tomada pelo agente.

³ Um processo de decisão de Markov se caracteriza pelo fato da decisão atual do agente depender somente do estado atual observado pelo agente, ou seja, ser independente da trajetória passada do sistema.

No próximo capítulo deste trabalho, serão discutidos em maiores detalhes os elementos necessários para a aplicação de técnicas de AR, em particular do método *Q-learning*, na concepção de um simulador de MEEs, com precificação por oferta, para avaliação de estratégias de venda de energia elétrica em leilões horários.

3 PROJETO DA FERRAMENTA *SIMMARKETSTRATEGY*

Neste capítulo é apresentada a modelagem, bem como as hipóteses e premissas, utilizadas na implementação da prova de conceito da ferramenta *SimMarketStrategy*. Em particular, o processo de liquidação financeira realizada pelo operador do mercado, a representação da demanda e das opções de oferta dos geradores, assim como o método *Q-learning* serão discutidos.

3.1 Enquadramento do projeto e definição do escopo

Seguindo a proposta metodológica descrita no Capítulo 1 deste trabalho, defende-se a implementação de uma prova de conceito para a ferramenta *SimMarketStrategy*, de modo a verificar sua factibilidade. Neste mesmo sentido, é necessário delimitar o enquadramento do projeto em uma determinada modalidade e propor um escopo para o seu desenvolvimento.

Na teoria de gerenciamento de projetos, não se tratando especificamente projetos de *software*, um projeto é desenvolvido seguindo as etapas: projeto informacional, para o levantamento de informações e a definição de requisitos inicial, projeto conceitual, para o estudo das premissas técnicas aproximadas e possíveis soluções, e projeto detalhado, para a configuração final do produto e preparação da produção.

Embora na engenharia de *software* o uso de metodologias ágeis preconize a validação das propostas em ciclos menores e o início antecipado da produção, neste trabalho, opta-se pela concepção de um **projeto conceitual**, tendo como seu escopo o estudo das premissas técnicas e dos componentes (teóricos e práticos) necessários à composição da ferramenta proposta.

3.2 Modelagem da liquidação financeira do mercado

Para entender os custos e subsídios associados ao mecanismo de formação dos preços, assim como a remuneração dos agentes vendedores, é necessário reconhecer a existência de diferentes tipos de mercados de energia elétrica. Segundo Viana (2018), pode-se classificar os MEEs em três tipos:

- **Mercados de Energia:** negociam o produto energia, medido em “MWh”, destinado ao atendimento da carga já existente, podendo ser

concebido em duas vertentes não mutuamente excludentes: mercado a curto prazo (*real-time*), destinado à liquidação das diferenças, entre energia consumida/produzida e àquela previamente contratada, durante a operação física do sistema, e mercado antecipado (*forward*), normalmente utilizado como *hedge*⁴ para evitar a exposição ao mercado de curto prazo;

- **Mercados de Reserva:** negociam a prestação de serviços técnicos (serviços ancilares⁵), medidos em disponibilidade (horas), potência ativa (MW) ou energia ativa/reactiva (MWh/MVAr-h), necessários à manutenção do controle e da segurança do SEE;
- **Mercados de Capacidade:** negociam o produto energia, medido em “MWh”, destinado à expansão do parque gerador e atendimento da demanda futura esperada. Segundo Viana (2018), os preços nos mercados de energia atacadistas não são suficientes para atrair novos investimentos, devido às distorções ubíquas no MEE, de modo que a criação de mercados de capacidade são essenciais para assegurar o suprimento energético futuro do sistema.

Estes mercados negociam o uso da energia elétrica e a prestação de serviços técnicos para finalidades distintas: suprimento da demanda atual (mercados de energia), serviços ancilares (mercados de reserva), e expansão do fornecimento para suprimento da demanda futura (mercados de capacidade). Desta forma, todo desenho de MEE deve acomodar os dispositivos destes três diferentes tipos de mercado para o completo atendimento de sua demanda presente e futura.

No Brasil, o mercado de energia *real-time* é implementado no instituto do MCP, o mercado de energia *forward* é constituído na forma dos leilões de energia existente no ACR e nas negociações do ACL, o mercado de reserva é fomentado, principalmente, pela adição dos Encargos de Serviço dos Sistemas (ESS) na

⁴ Operações de *hedge*, ou cobertura, são destinadas para assegurar o preço de um ativo financeiro no futuro tanto para compra como para venda, de modo a evitar a exposição à volatilidade dos preços de mercado a curto prazo.

⁵ No Brasil, segundo a resolução ANEEL 1.030 (AGÊNCIA [...], 2022), os serviços ancilares são aqueles relativos ao autorrestabelecimento de usinas geradoras (a partir da parada total), controle secundário de frequência (recuperação da frequência síncrona de 60 Hz), suporte de reativos (uso de geradores para fornecer ou absorver potência reativa com a finalidade de controle de tensão), sistemas especiais de proteção (esquemas de salvaguarda automática do sistema elétrico), e manutenção da reserva operativa (despacho de usinas térmicas para aumentar o volume armazenado nos reservatórios de hidroelétricas).

tarifação de energia aplicada aos agentes, subsídios governamentais e leilões de energia de reserva no ACR. Por fim, o mercado de capacidade é instituído pelos leilões de energia nova e de projetos estruturantes no ACR .

Neste trabalho, especificamente, se propõe o estudo de estratégias de venda de energia elétrica em mercados de energia *forward* (constituído de leilões horários ocorridos 24h antes do próximo dia operativo, ou seja, *day-ahead*) através da ferramenta computacional *SimMarketStrategy*.

Assumindo a premissa de construir uma prova de conceito, para a ferramenta *SimMarketStrategy*, serão adotadas as hipóteses simplificadoras a seguir (BACH *et al.*, 2012; BAYATI; NAGHIBI-SISTANI, 2022):

- A demanda do sistema (oferta de compra) é inelástica, ou seja, invariante aos níveis preço da energia elétrica no mercado;
- A liquidação horária do mercado de energia *day-ahead*, negociado 24h antes do próximo dia operativo, é realizada através de um leilão unilateral entre as unidades geradoras;
- O sistema elétrico é composto por unidades geradoras termoelétricas cujas funções de custo operacional são polinômios quadráticos da potência gerada;
- As perdas elétricas e a variação das tensões nodais no sistema de transmissão são desprezadas⁶;
- Os geradores participam do leilão (para cada hora do próximo dia operativo) disponibilizando a totalidade de sua capacidade de produção (não é considerada a parcela de reserva girante e descarta-se a opção de ofertas virtuais que excedem os limites operacionais);
- Todas as unidades térmicas serão consideradas comprometidas (gerando ao menos sua produção mínima) durante o despacho físico, de modo que nunca serão desligadas e seus custos de inicialização serão desconsiderados⁷;

⁶ Estas hipóteses auxiliam a aplicação de um modelo linearizado para o cálculo da distribuição dos fluxos de potência no SEE, deste modo possibilitando um processo de cálculo simplificado durante a liquidação pelo operador do mercado (BALDICK, 2021).

⁷ Ao considerar todas as unidades térmicas sempre ligadas, o problema de otimização a ser solucionado deixa de envolver variáveis inteiras, passando a exibir apenas variáveis contínuas em sua modelagem, simplificando significativamente a busca de soluções (BALDICK, 2021).

- As restrições de tempo para aumento e declínio da geração serão desconsiderados, de modo que a especificação da geração para a hora “ h ” represente a média sobre o referido intervalo;
- As unidades geradoras não partilham informações entre si (mercado com informação imperfeita), conhecendo apenas a demanda horária agregada do SEE fornecida pelo operador do mercado.

O operador do mercado *day-ahead*, no leilão, deve definir as ofertas de venda de energia elétrica aceitas para cada hora do próximo dia operativo, de modo que se obtenha como resultado o atendimento completo da demanda do sistema com o mínimo custo operativo, priorizando a modicidade tarifária e, com isso, maximizando o benefício social.

O operador de mercado realiza a resolução de um problema de otimização muito próximo ao problema do operador do sistema, que realiza o despacho físico (determinação da potência produzida) das unidades geradoras. De fato, no caso brasileiro, a principal diferença entre estes modelos reside em não considerar as restrições elétricas dentro dos submercados⁸, durante o cálculo dos preços de equilíbrio, de maneira a manter o preço da energia uniforme dentro das fronteiras geográficas destas regiões.

Considerando, então, um SEE com N_L cargas (compradores de energia) acopladas nas barras⁹ do sistema de transmissão, e N_G geradores (vendedores de energia), com custos operacionais (C_i), relativos à máquina “ i ”, modelados por uma função quadrática da potência ativa gerada (P_{g_i}):

$$C_i(P_{g_i}) = c_{2_i}P_{g_i}^2 + c_{1_i}P_{g_i} + c_{0_i} \quad (1)$$

sendo $c_{0_i}, c_{1_i}, c_{2_i} \in \mathbb{R}$.

Deste modo, com o objetivo de maximizar o benefício social, o operador do mercado deve resolver um problema de otimização restrito a fim de determinar a liquidação das ofertas de venda de energia elétrica que minimizem o custo total de operação do sistema elétrico, para a demanda projetada da hora “ h ” do próximo dia operativo, dado por:

⁸ No Brasil existem 4 submercados: Sul, Sudeste/Centro-Oeste, Norte e Nordeste, definidos segundo as restrições de transmissão de energia elétrica entre estas regiões (CÂMARA [...], 2022b).

⁹ As barras ou barramentos no SEE são equipamentos (estruturas metálicas) de suporte e conexão para os condutores das linhas de transmissão, geralmente localizados nas dependências das subestações de energia elétrica, utilizados com o objetivo de coletar e distribuir a energia elétrica para os demais equipamentos nas proximidades.

$$\min \sum_{i=1}^{N_G} C_i(P_{g_i}) \quad (2)$$

sujeito as seguintes restrições:

$$P_g^k - P_l^k = \sum_{m \in \Omega_k} P_{km}, \text{ com } P_{km} = \frac{\theta_k - \theta_m}{x_{km}} \quad (3)$$

$$|P_{km}| \leq P_{km}^{max} \quad (4)$$

$$P_{g_i}^{min} \leq P_{g_i} \leq P_{g_i}^{max} \quad (5)$$

sendo $k = 1, \dots, N_B$, com N_B igual ao número de barras no sistema de transmissão, P_g^k e P_l^k as potências geradas e consumidas (demanda) na barra “ k ”, Ω_k o conjunto das barras vizinhas (conectadas diretamente) à barra “ k ”, P_{km} o fluxo de potência ativa entre as barras “ k ” e “ m ”, x_{km} a reatância do equipamento que interconecta as barras “ k ” e “ m ”, P_{km}^{max} o limite superior de fluxo de potência ativa no equipamento de transmissão, $P_{g_i}^{min}$ e $P_{g_i}^{max}$ os limites operacionais mínimo e máximo do gerador “ i ”.

Observando as restrições do problema de otimização anterior é possível constatar que: a restrição de igualdade (3) traduz o balanço de potência elétrica ativa nos barramentos do SEE, as restrições de desigualdades (4) e (5) tratam respectivamente dos limites operativos dos equipamentos de transmissão e geração conectados ao sistema.

A título de esclarecimento, o problema de otimização não linear definido em (2)-(5) é geralmente resolvido em sua forma linearizada, tomando como referência o ponto de operação atual ou previsto para o SEE, utilizando uma classe de métodos conhecida como métodos dos pontos interiores (WANG, 2007). Na implementação da ferramenta *SimMarketStrategy*, serão utilizados os métodos presentes no módulo “Pandapower”¹⁰ (THURNER *et al.*, 2018) para sua solução.

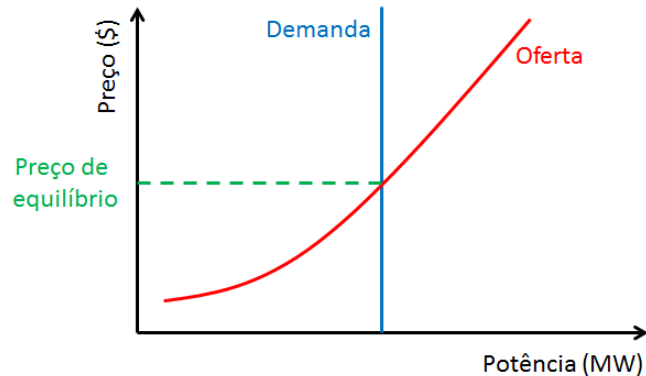
Ao resolver o problema de despacho anterior, as potências dos geradores são determinadas de modo a atender a demanda do sistema, estipulada para a hora “ h ” do próximo dia operativo. Na próxima seção deste trabalho discute-se o cálculo de preço derivados da resolução do problema (2)-(5) durante o processo de liquidação financeira conduzido pelo operador do mercado.

¹⁰ O módulo (*software*) “Pandapower”, versão 2.10.1, é licenciado segunda a licença BSD de 3 cláusulas, sendo portanto legal utilizá-lo parcial ou totalmente na produção de software proprietário, desde que obedecidas as cláusulas da referida licença.

3.2.1 Formação de preço no MEE

Considerando uma demanda inelástica (insensível à variação de preço), e uma curva de oferta de geração simplificada, pode-se visualizar o processo de formação de preço, considerando um único leilão de energia para a hora “h” do próximo dia operativo, no MEE conforme apresentado na Figura 4.

Figura 4 – Processo de liquidação simplificado do MEE

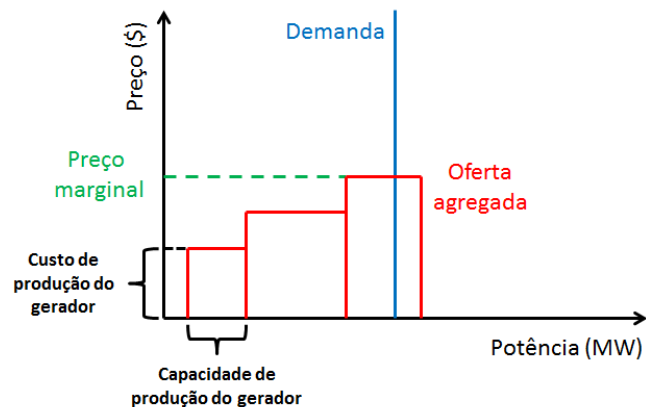


Fonte: Autoria própria (2023)

Na Figura 4 é facilmente reconhecível que a determinação do preço de equilíbrio do mercado, resultante do processo de liquidação financeira, é resultado da intersecção entre as curvas de oferta e demanda.

No entanto, em MEEs reais, a curva de oferta não é tão simples, haja vista a presença de diferentes de geradores com curvas de custo operacional diferentes. Neste sentido, supondo que os custos operacionais sejam constantes para qualquer nível de geração das máquinas, e que as máquinas participem do com a totalidade de sua capacidade no leilão, tem-se a situação representada na Figura 5.

Figura 5 – Processo de liquidação do MEE



Fonte: Autoria própria (2023)

Desta maneira, os geradores aparecem na curva de oferta ordenados em ordem crescente segundo seus custos de produção, de modo que os mais baratos

são aceitos para compor o atendimento da demanda. Com isto, o operador do mercado promove o máximo benefício social, pois ao escolher as ofertas mais baratas beneficia os agentes mais eficientes e diminui o custo total de produção do sistema refletindo também a modicidade tarifária.

O preço de equilíbrio é, agora, denominado “preço marginal” e isto surge da necessidade do pagamento individualizado dos agentes vendedores. Segundo Masili *et al.* (2003) e Viana (2018), a principal questão na formação de preços em leilões é a escolha entre o mecanismo de precificação uniforme (*single clearing price*) ou discricionário (*pay-as-bid*).

A precificação uniforme estabelece que todos os agentes devem receber o preço marginal, favorecendo assim o aumento do lucro operacional dos agentes mais eficientes, enquanto, a precificação discricionária estabelece que o pagamento do agente vendedor é realizado segundo sua oferta de venda, favorecendo assim o menor preço de compra e a modicidade tarifária para o consumidor final da energia.

Este é um assunto amplamente debatido na literatura dos MEEs, embora sob determinadas hipóteses seja possível demonstrar a equivalência dos rendimentos obtidos pelos agentes, independente do mecanismo de formação de preço adotado.

Neste trabalho, adota-se o mecanismo uniforme, defendido segundo a visão de Baldick (2019), para a formação de preço nos leilões de energia a fim de propiciar os sinais econômicos favoráveis à atração de investimentos necessários à expansão do setor.

Ressalta-se que a adoção do mecanismo de preço uniforme para o leilão de energia elétrica não necessariamente irá resultar em um preço único para todo o sistema, uma vez que restrições físicas (limites operacionais relacionados aos equipamentos de transmissão) impõem a separação de um MEE em submercados, impedindo que transações comerciais ocorram entre os mesmos, resultando em preços uniformes diferentes para cada submercado (MAYO, 2012).

Retomando, então, o problema de otimização resolvido pelo operador de mercado, descrito por (2)-(5), prossegue-se à sua solução definindo a função Lagrangeana associada ao problema:

$$\mathcal{L}(x, \lambda, \mu) = f(x) + \lambda^T g(x) + \mu^T h(x) \quad (6)$$

sendo x o vetor de variáveis de decisão do problema, neste caso refere-se às potências elétricas ativas dos geradores, $f(x)$ a função vetorial de custos, $g(x)$ a

função vetorial de restrições de igualdade, $h(x)$ a função vetorial de restrições de desigualdades, λ^T e μ^T os vetores (transpostos) dos multiplicadores de Lagrange associados respectivamente às restrições de igualdade e desigualdade do problema¹¹.

Definida a função Lagrangeana, pode-se calcular seus pontos críticos (pontos onde o gradiente da função é zero), e conseqüentemente os pontos mínimos locais do problema original (2)-(5), assumindo a satisfação das condições de otimalidade de primeira ordem de Karush-Kuhn-Tucker (KKT).

De posse de uma solução ótima local, dada por (x^*, λ^*, μ^*) , tem-se o despacho físico das unidades geradoras (x^*) representando o montante das ofertas de venda aceitas, e os multiplicadores de Lagrange associados às restrições do problema.

Os multiplicadores de Lagrange possuem uma interpretação econômica importante, pois quando observados pela ótica do problema dual associado ao problema original (2)-(5) os mesmos podem ser interpretados de modo que:

- λ^* representa o CMO do sistema, ou seja, o custo em “\$” necessário para produzir a próxima unidade do produto energia elétrica¹²;
- μ^* representa o custo associado a satisfação dos limites operacionais (é relevante observar que $\mu_i^* = 0$ sempre que a restrição de desigualdade “ i ” permanece inativa, ou seja, sempre que os limites operacionais são obedecidos de modo que $h_i(x) < 0$).

Desta forma, o multiplicador de Lagrange λ^* é tomado como sendo o **preço marginal locacional** (PML) da energia elétrica. Nota-se que sendo $\lambda^* \in \mathbb{R}^{N_B}$, o preço da energia elétrica é definido por barra, e todos os componentes deste vetor

¹¹ Na literatura é sempre assumido que a função de custo $f(x)$ é diferenciável por partes, com derivadas contínuas, as restrições de igualdade estão escritas na forma: $g(x) = 0$, e as restrições de desigualdade na forma: $h(x) \leq 0$ (BALDICK, 2021).

¹² Ao considerar o problema de otimização somente com restrições de igualdade (2)-(3), ou seja, desprezando as restrições de desigualdade (4)-(5), ao se calcular o ponto crítico do gradiente da função Lagrangeana resultante, em relação à potência gerada pela máquina “ i ”, resulta:

$$\frac{\partial \mathcal{L}}{\partial x_i} = \frac{\partial f_i(x_i)}{\partial x_i} - \lambda_i = 0 \leftrightarrow \lambda_i = \frac{\partial f_i(x_i)}{\partial x_i}$$

sendo, portanto, λ_i igual a variação do custo de produção de 1 unidade de potência (MW) gerada pela máquina “ i ” em relação ao ponto de operação atual. É relevante mencionar que a derivada de $g(x)$ em relação a $x_i = P_{g_i}$ resulta negativa, pois considera-se $g(P_g) = \sum_{i=1}^{N_B} (P_i - P_{g_i}) = 0$, ao se desprezar as perdas elétricas ativas no sistema de transmissão.

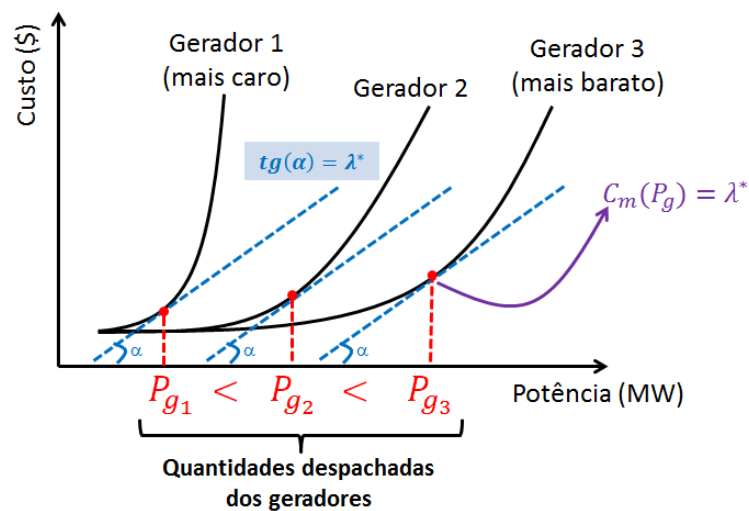
terão o mesmo valor¹³, seguindo a premissa do mecanismo de precificação uniforme adotado, sempre que nenhum limite operacional dos equipamentos de transmissão for violado.

Assumindo então a inexistência de restrições elétricas internas ao MEE, tem-se que o PML será o mesmo em todas as barras do SEE, de modo que também serão iguais os custos marginais de operação (investimento necessário para produzir o próximo MW) das unidades geradoras definidos por:

$$C_{m_i}(P_{g_i}) = \frac{dC_i(P_{g_i})}{dP_{g_i}} = 2c_{2i}P_{g_i} + c_{1i}, \text{ com } i = 1, \dots, N_G \quad (7)$$

Este fato explica como se dá a escolha das quantidades a serem geradas pelos agentes, ou seja, quais ofertas de venda serão aceitas de modo a minimizar o custo total da operação do sistema, como apresentado na Figura 6.

Figura 6 – Despacho econômico do SEE



Fonte: Autoria própria (2023)

Na Figura 6 as retas tracejadas (azuis) possuem coeficiente angular igual a λ^* , de modo que ao fazê-las tocar tangencialmente as curva de custo de produção dos geradores verifica-se o ponto (P_{g_i}) em que ocorre a igualdade entre o CMO dos geradores e o multiplicador de Lagrange (preço da energia elétrica) definido pela solução do problema de liquidação do mercado. Com isso demonstra-se que quanto

¹³ Ao considerar o sistema sem perdas elétricas ativas, é possível equivaler as N_B restrições representadas em (3) por uma única restrição de igualdade na forma $\sum_{i=1}^{N_B} (P_{l_i} - P_{g_i}) = 0$, de modo que exista apenas um multiplicador de Lagrange λ^* definido para todo o sistema. O mesmo argumento pode ser utilizado para comprovar a uniformidade dos valores de λ dentro dos submercados, quando da existência de restrições elétricas impedindo a transferência de potência pelas linhas de transmissão.

maior a taxa de variação do custo marginal do gerador, menor será o despacho físico do referido agente.

O PML da energia elétrica nos barramentos do SEE pode, também, ser definido para considerar o valor dos multiplicadores de Lagrange das restrições de desigualdade, μ^* , em MEEs onde as restrições operacionais dos equipamentos sejam violadas (BALDICK, 2021). Nestes casos, uma média ponderada dos valores de μ^* é incluída no cálculo do preço da energia com o objetivo de precificar tais violações.

Neste trabalho, reitera-se que o autor realizou a opção por representar o PML nas barras do SEE, exclusivamente, pelo valor do multiplicador de Lagrange associado às restrições de igualdade λ^* .

3.2.2 Remuneração dos agentes geradores

A remuneração dos agentes vendedores (geradores) no MEE é uma questão importante e deve ser tratada com o devido cuidado, haja vista, ser esta responsável por não apenas por suprir a produção da *commodity* energia elétrica, mas também por impulsionar novos investimentos que irão financiar a expansão da oferta.

Sabendo que o preço locacional da energia elétrica é igual ao valor do multiplicador de Lagrange λ^* , define-se a remuneração (receita) da potência elétrica ativa, fornecida pelo agente “*i*”, como $\lambda^* \times P_{g_i}$.

A partir da definição da receita obtida pela venda da energia produzida, Baldick (2021) define o lucro operacional do gerador “*i*”, operando por uma hora com geração de potência fixa igual a P_{g_i} e remunerado a um PML igual a λ^* , como:

$$\Pi_{g_i}(\lambda^*, P_{g_i}) = (\lambda^* \times P_{g_i}) - C_i(P_{g_i}) \quad (8)$$

É interessante observar que, determinado o preço λ^* pelo operador do mercado, o objetivo do agente vendedor é fornecer potência elétrica de modo a maximizar o lucro operacional, encontrando uma solução para o seguinte problema:

$$P_{g_i} = \arg \max_{P_{g_i}} \{\Pi_{g_i}(\lambda^*, P_{g_i})\} = \arg \max_{P_{g_i}} \{(\lambda^* \times P_{g_i}) - C_i(P_{g_i})\} \quad (9)$$

Por outro lado, o operador do mercado resolve o problema de liquidação financeira (2)-(5), para determina o PML λ^* e as potências geradas por cada agente, de modo a minimizar o custo operacional total, e com isso também minimizar a diferença entre o custo de produção e o pagamento pela energia elétrica:

$$P_{g_i}(\lambda^*) = \arg \min_{P_{g_i}} \{C_i(P_{g_i}) - (\lambda^* \times P_{g_i})\}, \text{ com } i = 1, \dots, N_G \quad (10)$$

Os problemas (9) e (10) são equivalentes, e decorrente desta constatação segue que a melhor estratégia dos geradores, assumindo que estes não possuam a capacidade de influenciar individualmente o preço da energia elétrica, é fornecer o seu custo de operação verdadeiro como oferta para a venda da energia.

O resultado anterior é importante no modelo de precificação por ofertas, onde os agentes podem declarar seus custos (ofertas) livremente. No próximo capítulo deste trabalho, a ferramenta *SinMarketStrategy* será utilizada para avaliar as estratégias de venda dos geradores de modo a mensurar suas capacidades de influenciar os preços no MEE.

Retornando o foco da discussão para a receita obtida pelos agentes vendedores, é interessante observar quais custos operacionais são cobertos por tal receita, haja vista existirem diversos subsídios governamentais, bem como métodos de obtenção de receitas complementares pelos agentes, legalmente instituídos para promover a expansão do parque gerador dos SEEs (BALDICK, 2021).


Observa-se que o preço da energia, λ^* , pago aos geradores é definido pelo CMO do sistema (custo para a produção do próximo “MW”), que se refere ao custo marginal de operação da unidade mais barata no referido ponto de operação ($P_{g_i}^*$), deste modo tem-se para uma máquina “i”:

$$\lambda^* = \frac{dC_i(P_{g_i}^*)}{dP_{g_i}} = C_{m_i}(P_{g_i}^*) = \frac{dC_i(P_{g_i}^*)}{dP_{g_i}} = 2c_{2_i}P_{g_i}^* + c_{1_i} \quad (11)$$

A relação (11) é importante porque o método utilizado na resolução do problema (2)-(5), baseado na aplicação das condições de KKT, exige apenas a avaliação das funções de custo marginal das máquinas, de modo que as funções de custo $C_i(P_{g_i})$ não são avaliadas ou mesmo necessárias para a obtenção de soluções.

Isto implica que o processo de liquidação financeira realizado pelo operador do mercado, na determinação dos PMLs (λ^*) e do despacho físico ($P_{g_i}^*$) dos agentes, depende apenas dos coeficientes relativos aos custos variáveis (c_{1_i} , c_{2_i}) em (1), e consequentemente independe dos custos fixos (c_{0_i}) da função de custo operacional dos geradores, conforme exemplificado na Figura 7.

Figura 7 – Invariância do despacho econômico aos custos fixos da geração



Fonte: Autoria própria (2023)

Analisando a Figura 7, nota-se que a alteração dos custos fixos na função de custo operacional $C(P_g)$ do gerador é capaz de alterar o custo total da produção de energia elétrica no SEE. No entanto, tal alteração é incapaz de exercer influência sobre o resultado do problema de otimização (2)-(5), de modo que tanto o despacho físico das unidades geradoras como o PML permanecem inalterados.

Assim, conclui-se que **o CMO do sistema, coincidente com o $C_m(P_g)$ da máquina mais barata, depende apenas dos custos variáveis de produção da energia elétrica**, ou seja, apenas dos custos proporcionais à quantidade de “MW” produzida, e não dos custos fixos (auxiliares) associados a produção.

Deste modo, finalmente, pode-se afirmar que a receita do agente gerador, proveniente da venda de energia elétrica, $\lambda^* \times P_{g_i}$, visa cobrir apenas os custos variáveis da produção de energia, e, portanto, o lucro operacional calculado em (8) pode resultar negativo se não houver a satisfação da seguinte condição:

$$(\lambda^* \times P_{g_i}) - (c_{2_i}P_{g_i}^2 + c_{1_i}P_{g_i}) > c_{0_i} \quad (12)$$

A resolução do problema de otimização (2)-(5) realizada pelo operador do mercado não garante a satisfação da condição (12). Por tal razão, existem dispositivos legais implantados nos diversos ambiente de negociação dos MEEs para permitir a reposição destes custos, seja por meio de subsídios, sobretaxas, compensação por redução de impostos, diluição em outros dispositivos do mercado (aumento do preço *cap* nos leilões), recálculo de preços, etc.

A título de esclarecimento, a satisfação da condição (12) pode ser tratada diretamente no problema de otimização, quando há análise de comprometimento (determinação de quais máquinas serão despachadas, desligadas ou mantidas aquecidas com produção nula, para segurança do fornecimento, durante os

intervalos de atendimento da demanda) dos geradores, o que resulta no uso de um dispositivo conhecido na literatura como “pagamento integral”, no entanto, ao custo de tornar o problema de liquidação muito mais complexo (BALDICK, 2021).

3.3 Modelagem das ofertas dos agentes geradores

Em um processo de formação de preço por oferta, os agentes compradores (demandantes de energia elétrica, e.g. distribuidoras) e os vendedores (geradores) submetem à um leilão suas curvas de demanda e oferta respectivamente, de modo que o operador do mercado deve resolver um problema de otimização para determinar as quantidades despachadas por cada usina geradora (referindo deste modo as quantidades transacionadas por cada vencedor do leilão de energia).

Neste trabalho, os leilões no mercado de energia *day-ahead* serão utilizados para o cálculo dos preços em um intervalo de tempo que se enquadra no curto-prazo, podendo ser estendida para o tempo real se desejado, de modo a propiciar um ambiente comercial mais próximo ao ambiente operacional.

Considera-se também que apenas os agentes geradores irão declarar suas ofertas de venda, no mercado de energia *day-ahead*, na forma de funções de custo marginal operacional. Tais ofertas serão enviadas ao operador do mercado, por cada agente vendedor “ i ”, na forma dos parâmetros $(c_{1_i}^R, c_{2_i}^R)$ definidos como:

$$c_{1_i}^R = \beta_i c_{1_i} \text{ e } c_{2_i}^R = \beta_i c_{2_i}, \text{ com } \beta_i \in \mathbb{R} \quad (13)$$

sendo β_i denominado de fator de ganho sobre o custo marginal operacional real.

Desta maneira, as ofertas de energia são realizadas por meio da livre declaração do CMO das unidades geradoras, tornando possível aos geradores construir suas estratégias de venda alterando o fator β .

Em um MEE onde nenhum agente gerador possa influenciar unilateralmente a formação do preço da energia, aumentar o fator β não implicaria no aumento do preço, e diminuiria o despacho do agente, ao tornar sua produção mais cara quando comparada aos concorrentes mais baratos, resultando em uma receita e lucro operacional menores. Neste cenário, com a ausência do exercício de poder de mercado, a melhor estratégia do agente é sempre fornecer sua função de custo marginal operacional real (BALDICK, 2021).

Entretanto, em se tratando de MEEs reais, estes se caracterizam por um oligopólio, ou seja, possuem poucos agentes vendedores, inevitavelmente gerando

ineficiências na formação de preço devido à falhas de competição entre os agentes. Tais falhas podem ser observadas pela concentração de poder de mercado nos agentes que detêm a maior capacidade produtiva.

Diante disso, os agentes tem a oportunidade de aumentar o valor de suas ofertas (multiplicando seus CMOs por um ganho β) na expectativa de influenciar o preço da energia e obter maiores lucros operacionais.


Por sua vez, o operador de mercado se resguarda o direito de monitorar os processos competitivos e estabelecer meios para mitigar o exercício de poder de mercado pelos agentes. Uma forma de mitigação comum, utilizada em leilões nos mercados, é estabelecer um preço *cap* (máximo) a ser pago pela energia gerada.

Na próxima seção deste trabalho, o método *Q-learning* será discutido e aplicado na formação de políticas de decisão (estratégias de venda) pelos agentes geradores em MEEs com precificação por oferta.

3.4 Aprendizado das políticas de decisão utilizando *Q-learning*

Segundo Sutton e Barto (2018), o método *Q-learning* consiste em aproximar uma função ação-valor $Q(S,A)$, dependente do estado atual e da ação escolhida pelo agente, cuja imagem é o retorno esperado futuro, ou seja, a soma das recompensas que podem ser obtidas pelo agente a partir do estado atual até o final do episódio (ciclo completo de interações entre o agente e o ambiente) ao se seguir a política induzida por $Q(S,A)$.

A política induzida por $Q(S,A)$ consiste na escolha da melhor ação, em cada estado observado pelo agente, como pode ser observado na Figura 8 para o caso onde os espaços de estado e ações são discretos.



Fonte: Autoria própria (2023)

O processo de aproximação para a função ação-valor $Q(S, A)$ é conhecido na literatura como **treinamento do agente** (SUTTON; BARTO, 2018), sendo realizado pelo método *Q-learning*, no caso discreto, através da seguinte equação:

$$Q(s_t, a_t) = Q(s_t, a_t) + \alpha \left[R_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t) \right] \quad (14)$$

sendo $s_t \in S$ o estado observado pelo agente no instante “ t ”, $a_t \in A$ a ação tomada pelo agente no instante “ t ”, α o passo de atualização, R_{t+1} a recompensa obtida pelo agente após realizar a ação no instante “ t ”, γ o valor de desconto utilizado para ponderar as recompensas futuras frente às recompensas atuais.

O algoritmo completo para a aplicação do método *Q-learning* no treinamento de políticas de decisão dos agentes está resumido na Figura 9.

Figura 9 – Algoritmo para aplicação do método *Q-learning*

Método Q-learning:
<ul style="list-style-type: none"> - Defina os hiperparâmetros: $\alpha \in (0,1]$, $\varepsilon > 0$ (pequeno); - Inicialize arbitrariamente $Q(s, a)$, com $s \in S$ e $a \in A$; - Para cada episódio faça: <ul style="list-style-type: none"> - Inicialize o estado (defina a condição inicial s); - Escolha uma ação $a \in A$, a partir do estado atual, segundo a política definida para o agente (esta política pode ou não ser derivada da função $Q(s, a)$); - Realize a ação a, observe o novo estado s' e a recompensa R; - Atualize a função ação-valor segundo (14).

Fonte: Adaptado de Sutton e Barto (2018)

O método *Q-learning* é o que se conhece por *model-free*, ou seja, a aproximação da função $Q(S, A)$ não leva em conta nenhum parâmetro do ambiente no qual o agente está imerso, sendo a estimativa dos retornos esperados futuros construída a partir das informações obtidas exclusivamente pelo agente.

Além disso, o método *Q-learning* é também *off-policy*, ou seja, as atitudes tomadas pelo agente durante o treinamento não necessariamente derivam da política sendo aprendida, de modo que outra política pode ser adotada durante o processo de treino sem impedir a aplicação do método.

Neste trabalho, o autor optou por utilizar a política induzida pela função $Q(S, A)$ como a política utilizada pelo agente ao longo de seu treinamento.

É necessário também discutir uma importante questão associada às técnicas de AR: “O que traz maior benefício durante o treinamento do agente, seguir a

política atual e obter a avaliação das ações produzidas pela mesma, ou explorar o ambiente de alguma outra forma em busca de novas experiências?”. Este dilema é conhecido na literatura de aprendizado de máquina como “*explore-exploit*” (GÉRON, 2019).

O consenso geral é que no início do treino, acumular novas experiências é fundamental ao agente a fim de obter uma diversidade maior de ajustes na função ação-valor $Q(S, A)$. No entanto, à medida que o treino progride a repetibilidade dos pares (s_t, a_t) é o fator central para o aumento da precisão das estimativas de retorno esperado futuro (SUTTON; BARTO, 2018).

Neste trabalho, adota-se o algoritmo Metrópolis (BACH *et al.*, 2012; MAOZU *et al.*, 2004) para tratar o dilema “*explore-exploit*”, segundo o qual as ações a_t do agente, durante o treinamento, são escolhidas da seguinte maneira:

1. Selecione de modo arbitrário (aleatório) uma ação $a_r \in A$;
2. Selecione, segundo a política atual (podendo esta ser a mesma que está sob desenvolvimento), a ação $a_p \in A$;
3. Gere um valor aleatório¹⁴ $\varepsilon \in [0,1)$;
4. Se $\varepsilon < e^{\left(\frac{Q(s_t, a_r) - Q(s_t, a_p)}{T}\right)}$, então, faça $a_t = a_r$, caso contrário escolha $a_t = a_p$.

Observa-se no algoritmo Metrópolis a existência de um hiperparâmetro, $T \in \mathbb{R}$, conhecido como temperatura. Este para valor é atualizado segundo um critério de decaimento, adotado neste trabalho como a série geométrica: $T_t = \theta_T \times T_{t-1}$, com $\theta_T \in (0,5; 1)$ seguindo a sugestão em (MAOZU *et al.*, 2004).

A seguir, propõe-se a aplicação do método *Q-learning* na concepção de estratégias de venda de energia elétrica por agentes (geradores) em MEEs com precificação por oferta. A modelagem apresentada é inspirada na proposta de Bach *et al.* (2012).

Na aplicação proposta, defini-se o agente como o gerador (vendedor) de energia elétrica, conectado à barra “*i*” do SEE, a política como a estratégia de oferta (venda) no MEE, e o ambiente como o processo de liquidação das ofertas realizado pelo operador do mercado. O treino do agente é realizado ao longo de um total de

¹⁴ Na implementação realizada neste trabalho, adota-se a distribuição de probabilidade contínua uniforme para o sorteio do valor ε .

N_{Neg} negociações (episódios¹⁵), sendo cada negociação constituída de 24 leilões consecutivos respectivos às 24h do próximo dia operativo.

Com o objetivo de tornar a notação mais clara, o subescrito k será utilizado no lugar do subescrito t para denotar os estados observados e as ações do agente. Isto se deve ao fato de que cada episódio k será constituído de uma única ação do agente, escolha do CMO declarado, que irá ser adotada para os 24 leilões horários consecutivos no mercado *day-ahead*.

O estado s_k , observado pelo agente, ao final do episódio k é definido como o PML médio diário nas barras de geração, ponderado pelas potências geradas nestes barramentos, após a liquidação do mercado de energia *day-ahead* de modo que:

$$s_k = \frac{\sum_{h=1}^{24} \sum_{i=1}^{N_G} \lambda_{g_i}^h P_{g_i}^h}{\sum_{h=1}^{24} \sum_{i=1}^{N_G} P_{g_i}^h} \quad (15)$$

sendo $P_{g_i}^h$ a potência elétrica ativa gerada pela máquina “ i ”, e $\lambda_{g_i}^h$ o PML respectivo à barra de conexão desta geração, ambos calculados pelo operador do mercado para a liquidação financeira da hora “ h ” do próximo dia operativo.

É relevante mencionar que o espaço de estados será discretizado em N_S possíveis estados, sendo cada estado definido como um intervalo de valores entre o preço mínimo e o preço *cap*, considerados respectivamente iguais a 80% e 150% do preço para o caso base¹⁶ do SEE.

As ações do agente serão modeladas como variações discretizadas do fator de ganho β , sobre o CMO do gerador “ i ”, do seguinte modo:

$$a_k = (c_{1_i}^R, c_{2_i}^R) = (\beta_i^k c_{1_i}, \beta_i^k c_{2_i}) \quad (16)$$

$$\beta_i^k = \beta_{min} + \frac{k}{N_A} (\beta_{max} - \beta_{min}), \text{ com } k \in [0, N_A] \quad (17)$$

sendo β_{min} e β_{max} os limites inferior e superior, em relação ao CMO real do gerador, admissíveis para as ofertas do agente (adotados respectivamente como 100% e 200%), k um número natural respectivo à ação escolhida, e N_A o número total de ações possíveis ao agente.

¹⁵ Segundo Sutton e Barto (2018), a definição de episódio para um algoritmo de AR preconiza que ao final desta interação o ambiente/agente retornem ao estado “inicial”, no entanto, neste trabalho assume-se que cada episódio se inicia no estado terminal do episódio anterior. A razão desta abordagem reside no fato do estado (preço médio diário ponderado no SEE) ser dependente da oferta dos agentes, sendo sua determinação “inicial” imprecisa/incerta.

¹⁶ Neste trabalho, o caso base é definido para a liquidação do mercado nas condições iniciais declaradas, na base de dados, para o SEE sob análise.

A recompensa do agente, advinda da ação a_k , é calculada como o lucro operacional (8) do gerador “ i ”, obtido para a venda de energia realizada no mercado *day-ahead*, respectivo às 24h do próximo dia operativo:

$$R_i^k = \sum_{h=1}^{24} [\lambda_{g_i}^h P_{g_i}^h - C_i(P_{g_i}^h)] \quad (18)$$

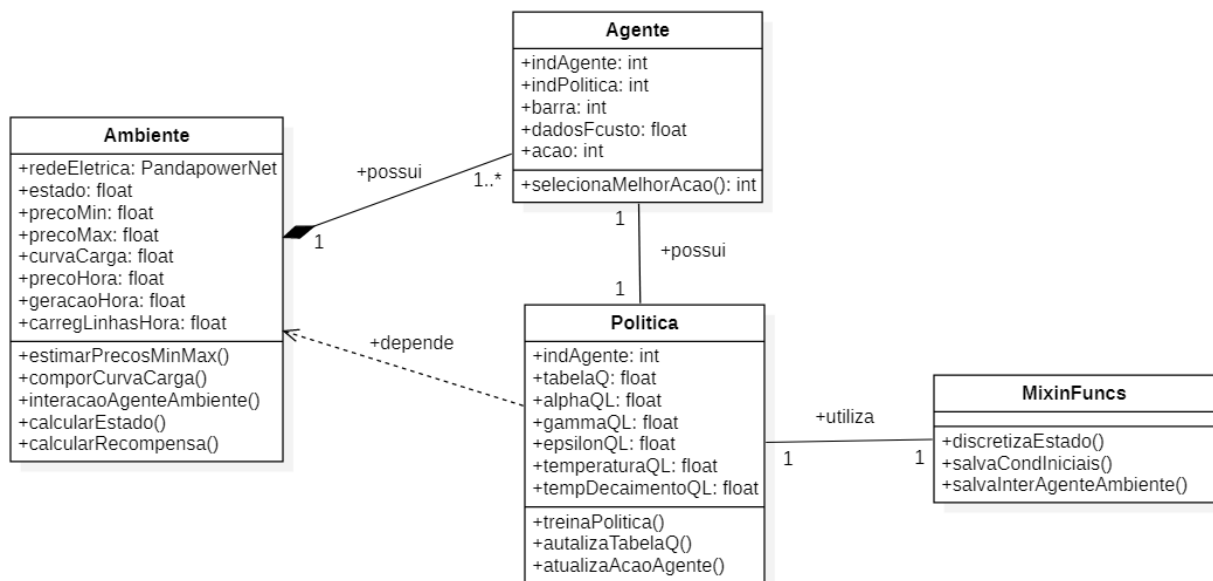
sendo $\lambda_{g_i}^t$ o PML da energia elétrica paga ao gerador conectado à barra “ i ” do sistema elétrico na hora “ h ” do próximo dia operativo.

Neste trabalho, o MEE é modelado como um sistema multiagentes, onde diversos agentes são treinados de modo independente e ao mesmo tempo. Desta forma, as políticas dos agentes competem entre si, pois os agentes estão impedidos de trocar informações sobre suas estratégias.

É relevante notar que a proibição de troca explícita de informação entre os agentes (hipótese de informação imperfeita) é uma medida implementada para evitar o comportamento cooperativo entre os agentes na construção de estratégias de venda de energia elétrica, e assim prevenir exercício de poder de mercado.

Destarte, uma aplicação desktop foi desenvolvida, como prova de conceito da ferramenta *SimMarketStrategy*, com o objetivo de validar as premissas expostas neste trabalho. Na Figura 10 mostra-se o diagrama de classes simplificado utilizado no projeto da prova de conceito do produto de *software* proposto.

Figura 10 – Diagrama de classes simplificado (*SimMarketStrategy*)



Fonte: Autoria própria (2023)

Por fim, ressalta-se que o código, implementado em linguagem Python, da ferramenta *SimMarketStrategy* foi submetido para pedido de registro no Instituto Nacional da Propriedade Intelectual, na modalidade “programa de computador”, sob a titularidade da Universidade Tecnológica Federal do Paraná. Maiores informações podem ser obtidas com o autor deste trabalho.

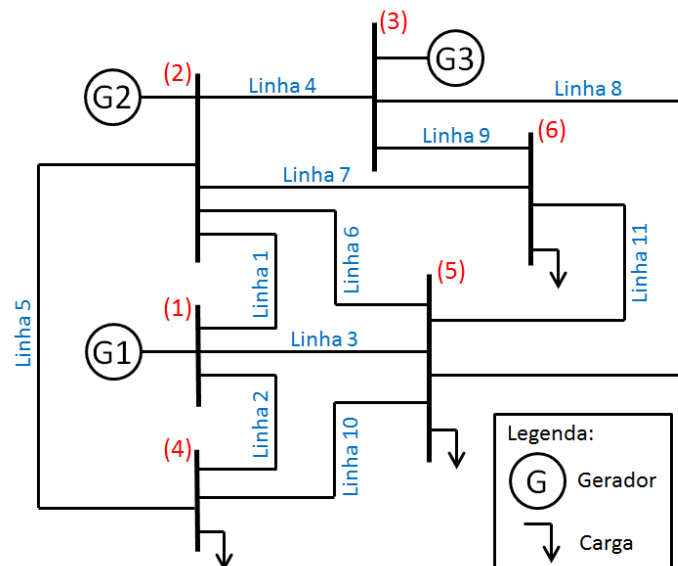
4 TESTES DA FERRAMENTA *SIMMARKETSTRATEGY*

Neste capítulo serão apresentados testes realizados sobre a prova de conceito da ferramenta *SimMarketStrategy* para validar sua factibilidade técnica. A partir dos resultados obtidos com a aplicação da ferramenta, serão elencados alguns dos estudos realizados para a avaliação do poder de mercado dos geradores, considerando tanto a influência da localização física do agente, como a ocorrência do fenômeno de coalisão tácita, entre outros fatores de interesse.

4.1 Apresentação do sistema teste

O sistema teste¹⁷ utilizado para a validação da prova de conceito será tomado da referência (WOOD; WOOLEMBERG, 1996). Este SEE é modelado em seu nível de transmissão, sendo composto de 6 barramentos, 11 linhas de transmissão, 3 geradores térmicos e 3 cargas (representando os consumidores de baixa tensão como cargas agregadas conectadas à barra de alta tensão), conforme mostrado na Figura 11.

Figura 11 – Sistema teste de 6 barras e 3 geradores




Fonte: Adaptado de (WOOD; WOOLEMBERG, 1996)

Os parâmetros elétricos do referido sistema, utilizados nos testes deste capítulo, são àqueles armazenados no módulo “Pandapower” (THURNER *et al.*, 2018), especificamente em seu submódulo “networks” da versão 2.10.1.

¹⁷ É relevante mencionar que o sistema de 6 barras de (WOOD; WOOLEMBERG, 1996) é um *benchmark* para problemas de despacho econômico em SEPs utilizado na literatura desde a década de 1990.

Nos testes será considerado o mercado de energia *day-ahead*, respectivo ao próximo dia operativo, composto de uma sequência de 24 leilões horários, cuja demanda está representada no Gráfico 1.

Gráfico 1 – Demanda horária do sistema utilizada nos testes



Fonte: Autoria própria (2023)

Nos dados da demanda horária apresentada, em relação à carga base (declarada no módulo “Pandapower”) nas barras do sistema, foi considerada a seguinte distribuição:

- 100% da carga base no período das 22h às 5h;
- 130% da carga base no período das 6h às 10h;
- 145% da carga base no período das 11h às 14h;
- 125% da carga base no período das 15h às 18h;
- 110% da carga base no período das 19h às 21h.

Por fim, os parâmetros das funções de custo operacional e os limites operacionais das máquinas, utilizados nos testes, são mostrados nas Tabelas 1 e 2.

Tabela 1 – Parâmetros das funções de custo operacional do sistema teste

Gerador	a (\$/MW ²)	b (\$/MW)	c (\$)
G1	0,00533	11,66900	213,10000
G2	0,00889	10,33300	200,00000
G3	0,00741	10,83300	240,00000

Fonte: Retirado do módulo “Pandapower” (THURNER *et al.*, 2018)

Tabela 2 – Limites operacionais dos geradores do sistema teste

Gerador	P_{gi}^{min} (MW)	P_{gi}^{max} (MW)
G1	50,0	200,0
G2	37,5	150,0
G3	45,0	180,0

Fonte: Retirado do módulo “Pandapower” (THURNER *et al.*, 2018)

Nas próximas seções deste capítulo, a ferramenta *SimMarketStrategy* será utilizada para realizar o estudo do exercício de poder de mercado dos agentes em diversos cenários, de modo a evidenciar os diversos fatores que influenciam a

composição de estratégias de venda de energia elétrica em mercados com precificação por ofertas.

4.2 Estudo do caso primário do SEE

Neste primeiro caso de estudo, se estabelece um conjunto de resultados que servirão de referência para as análises posteriores realizadas neste capítulo.

O seguinte cenário será utilizado para gerar os resultados apresentados:

- Todos os geradores declaram seus CMOs reais como oferta;
- Admite-se a carga conforme a curva mostrada no Gráfico 1;
- Consideram-se os limites operacionais dos geradores conforme declarados na Tabela 2, e das linhas de transmissão conforme consta na base de dados do módulo “Pandapower”.

Como resultado deste cenário observa-se, no Gráfico 2, que a geração e demanda totais no SEE são coincidentes para todas as horas do dia. Isto é esperado devido à restrição de balanço de potência (3) no sistema elétrico.

Gráfico 2 – Geração e demanda totais do SEE (caso primário)



Fonte: Autoria própria (2023)


No Gráfico 3 está representada a potência elétrica produzida por cada agente gerador do MEE. É notável que a unidade G1, mais cara¹⁸, é a unidade com o menor despacho, sendo seu maior incremento de geração no período entre das 10h às 15h para o atendimento do pico da demanda.

No entanto, indaga-se por que o gerador G1 (mais caro) não permanece em seu limite inferior (50 MW) enquanto os demais geradores ainda não atingiram sua capacidade máxima? A resposta é encontrada ao se observar o carregamento das

¹⁸ Verifica-se, para potências acima de 50 MW, que os custos operacionais seguem a seguinte relação: $C_{G1}(P_g) > C_{G3}(P_g) > C_{G2}(P_g)$.


linhas de transmissão, no Gráfico 4, onde fica explícito a ocorrência do fenômeno de congestionamento do sistema de transmissão no intervalo das 6h às 18h.

Gráfico 3 – Distribuição da geração do SEE (caso primário)



Fonte: Autoria própria (2023)

Gráfico 4 – Carregamento das linhas de transmissão (caso primário)



Fonte: Autoria própria (2023)


O congestionamento do sistema de transmissão traz consequências graves à operação econômica do SEE, e também ao MEE, tendo em conta que existindo o impedimento ao escoamento da energia elétrica entre as barras do sistema, impede-se também que a geração mais econômica seja aproveitada em sua totalidade, diminuindo a eficiência do processo de liquidação do mercado de energia.

Dito isto, os PMLs nas barras de conexão dos geradores são mostrados no Gráfico 5. Observa-se que há separação dos preços às 6h, coincidentemente ao início do congestionamento do sistema de transmissão, permanecendo em níveis diferentes até 15h, quando se dá o término do pico de carga caracterizado no intervalo das 10h às 15h.

Em relação aos aspectos econômicos da operação do SEE, na Tabela 3 apresentam-se os resultados obtidos pelos agentes geradores relativos às suas ofertas no MEE, tais como a receita obtida pela venda de energia elétrica, o

custo variável, devido à geração de energia, e o custo fixo de operação dos agentes integralizados ao longo das 24h do dia operativo sob análise.

Gráfico 5 – PMLs nos barramentos dos geradores (caso primário)



Fonte: Autoria própria (2023)

Tabela 3 – Resultados econômicos agentes (caso primário)

Gerador	Receita bruta $[\lambda_g \times P_g](\$)$	Custos variáveis $[c_2(P_g)^2 + c_1P_g](\$)$	Custos fixos $c_0 (\$)$
G1	18.500,80	18.100,46	5.114,40
G2	28.927,09	26.799,11	4.800,00
G3	25.711,84	24.304,49	5.760,00

Fonte: Autoria própria (2023)

Como ressaltado na Seção 3.2.2 deste trabalho, observa-se que a receita bruta dos agentes é maior que suas parcelas de custo variável, haja vista a metodologia adotada pelo operador do mercado no processo de liquidação.

Porém, ao se tomar em consideração a parcela de custo fixo o lucro operacional dos agentes resulta negativo. Como anteriormente discutido, não será foco deste trabalho observar a remuneração integral dos agentes, pois a mesma se dará por meio de outros dispositivos presentes nos MEEs, os quais não estão modelados no processo de cálculo dos PMLs aqui discutido.

4.3 Estudo do poder de mercado dos agentes

Neste segundo caso de estudo, tem-se como objetivo verificar a possibilidade de exercício de poder de mercado por cada um dos agentes geradores, atuando de modo individual, no mercado de energia *day-ahead*.

O seguinte cenário será utilizado para gerar os resultados apresentados nos próximos gráficos e tabelas desta seção:

- O gerador selecionado para treino declara sua oferta como seu CMO multiplicado por um fator de ganho (definido pela política de decisão aprendida através da aplicação do método *Q-learning*);
- Os demais os geradores declaram seus CMOs reais como oferta;
- Admite-se a carga conforme a curva mostrada no Gráfico 1;
- Consideram-se os limites operacionais dos geradores conforme declarados na Tabela 2, e das linhas de transmissão conforme consta na base de dados do módulo “Pandapower”.

Na aplicação do método *Q-learning* os seguintes parâmetros serão utilizados, em todos os testes realizados neste capítulo: $\alpha = 0,5$; $\gamma = 0,1$; $T = 100$; $\theta_T = 0,99$; $\beta_{min} = 1,00$; $\beta_{max} = 2,00$; $N_S = 20$; $N_A = 20$; $N_{Neg} = 600$. Durante a realização dos testes os PMLs, nas barras dos geradores, foram delimitados por preços mínimo e máximo iguais a \$9,52 e \$17,85 respectivamente.


Nos Gráficos 6, 7 e 8 estão retratados, para o treinamento do agente G1, a variação do preço médio diário da energia elétrica nas barras de geração do sistema (estado do ambiente), o PML médio diário para cada barra dos agentes geradores, e as ações (ofertas declaradas) realizadas pelos agentes durante às negociações (24 leilões horários consecutivos) no mercado *day-ahead*.

Gráfico 6 – Preço médio no SEE (treino do agente G1)




Fonte: Autoria própria (2023)

Ao analisar o Gráfico 6, concluí-se que o agente G1 possui capacidade de exercer poder de mercado, uma vez que sua oferta tem capacidade de influenciar unilateralmente a formação de preço no MEE. Além disso, as ações do agente G1 se refletem quase inteiramente na variação do PML em seu próprio barramento, praticamente não afetando os PMLs nas barras dos demais agentes, conforme mostrado no Gráfico 7.

Gráfico 7 – PLM médio nos barramentos (treino do agente G1)

Fonte: Autoria própria (2023)

Gráfico 8 – Ação dos agentes no mercado (treino do agente G1)

Fonte: Autoria própria (2023)

Analisando o Gráfico 8, ao longo de todas as 600 negociações realizadas durante o treinamento do agente G1, pode-se confirmar que apenas este agente realizou alterações na oferta de seu CMO, enquanto os demais mantiveram como estratégia ofertar seu custo marginal real.

Para mensurar os resultados advindos da política resultante do treino do agente, antes da imersão do agente no mercado real, é necessário assumir uma determinada ação prévia (oferta anterior) para que o ambiente (processo de liquidação do mercado) forneça um estado a ser observado pelo agente.

Nesse sentido, seguindo a abordagem proposta em (BACH *et al.*, 2012), propõe-se que a avaliação dos resultados advindos da política de decisão seja feita considerando a ação escolhida com maior frequência durante o treinamento. Tal escolha se apoia no fato de que a ação tomada pelo agente, na fase de treino, geralmente segue a política induzida da função ação-valor $Q(S,A)$, ou seja, tende a selecionar a ação que maximiza seu lucro operacional.

Na Tabela 4 nota-se que a ação selecionada mais frequentemente, durante o treino do agente G1, foi a ação a_{19} , que condiz com um fator de ganho sobre o CMO real do gerador igual a $\beta_{19} = 1,95$.


Tabela 4 – Seleção das ações durante a fase de treino (treino do agente G1)

Ação (a_k)	Número de vezes selecionada	Ação (a_k)	Número de vezes selecionada	Ação (a_k)	Número de vezes selecionada
0	4	7	7	14	39
1	4	8	10	15	44
2	5	9	23	16	39
3	4	10	51	17	39
4	5	11	53	18	39
5	4	12	39	19	73
6	7	13	40	20	71

Fonte: Autoria própria (2023)

Selecionando, então, a ação a_{19} como oferta do agente G1 no mercado *day-ahead*, pode-se verificar sua influência nos PMLs através do Gráfico 9.

Gráfico 9 – PLM médio nos barramentos (melhor ação do agente G1)



Fonte: Autoria própria (2023)

O PML na barra do agente G1 supera o limite superior (preço *cap*) do mercado igual a \$17,85. Isto será levado em conta no cálculo da receita, advinda da venda de energia elétrica, apresentada conjuntamente com os demais resultados econômicos obtidos pelos agentes na Tabela 5.

Tabela 5 – Resultados econômicos dos agentes (melhor ação do agente G1)

Gerador	Receita bruta $[\lambda_g \times P_g](\$)$	Custos variáveis $[c_2(P_g)^2 + c_1P_g](\$)$	Receita em relação ao caso primário	Custos variáveis em relação ao caso primário
G1	20.698,91	16.654,79	111,88%	92,01%
G2	25.431,38	23.738,46	87,92%	88,58%
G3	30.986,37	28.949,70	120,51%	119,11%

Fonte: Autoria própria (2023)


Da análise dos resultados verifica-se que o agente G1, através do exercício de poder de mercado, aumentou sua receita em 11,88% e diminuiu seus custos

variáveis de produção em 7,99% em relação ao caso primário apresentado na Tabela 3. Em relação ao lucro operacional (desconsiderando os custos fixos) houve um aumento de 910,17% (de \$400,34 para \$4.044,12).

É interessante notar que o aumento da receita do gerador G1 se dá pelo aumento do PML associado à sua barra no SEE, enquanto o decréscimo de seus custos variáveis indicam que sua geração foi efetivamente diminuída (operador do mercado definiu um despacho menor para o agente na tentativa de equilibrar o pagamento de uma geração mais cara).


No próximo teste, o agente G2 será treinado utilizando o método *Q-learning* enquanto os demais irão ofertar seus CMOs reais. Analisando os Gráficos 10 e 11, verifica-se que as ações do agente G2 produzem, de modo unilateral, variações no preço médio diário ponderado no SEE, e as ações do agente G2 se refletem quase exclusivamente no aumento do PML de sua barra.

Gráfico 10 – Preço médio no SEE (treino do agente G2)



Fonte: Autoria própria (2023)

Gráfico 11 – PLM médio nos barramentos (treino do agente G2)



Fonte: Autoria própria (2023)

Os valores na Tabela 6 mostram que a ação mais frequente, durante o treino do agente G2, foi a ação a_{17} (que condiz a um ganho $\beta_{17} = 1,85$).


Tabela 6 – Seleção das ações durante a fase de treino (treino do agente G2)

Ação (a_k)	Número de vezes selecionada	Ação (a_k)	Número de vezes selecionada	Ação (a_k)	Número de vezes selecionada
0	5	7	3	14	55
1	6	8	4	15	50
2	4	9	5	16	52
3	2	10	6	17	142
4	2	11	6	18	52
5	3	12	54	19	51
6	3	13	47	20	48

Fonte: Autoria própria (2023)

Tomando, então, a ação a_{17} como a mais representativa (promissora) da política desenvolvida pelo agente G2, pode-se analisar sua influência sobre os PMLs nos barramentos dos agentes geradores através do Gráfico 12.

Gráfico 12 – PLM médio nos barramentos (melhor ação do agente G2)



Fonte: Autoria própria (2023)

De modo semelhante ao teste anterior, o PML do agente G2 supera o limite superior (preço *cap*) estipulado pelo operador do mercado igual a \$17,85. Isto reduz a receita do agente proveniente da venda de energia elétrica.

Na tabela 7 estão elencados os resultados econômicos obtidos pelos agentes, considerando a estratégia de oferta adotada pelo agente G2.

Tabela 7 – Resultados econômicos dos agentes (melhor ação do agente G2)

Gerador	Receita bruta $[\lambda_g \times P_g] (\$)$	Custos variáveis $[c_2(P_g)^2 + c_1 P_g] (\$)$	Receita em relação ao caso primário	Custos variáveis em relação ao caso primário
G1	27.775,84	26.657,53	150,13%	147,28%
G2	13.256,17	10.318,08	45,83%	38,50%
G3	35.974,44	33.439,93	139,91%	137,59%

Fonte: Autoria própria (2023)


Observa-se que o agente G2 obteve uma receita de apenas 45,83% em relação ao caso primário (Tabela 3), no entanto, constata-se também que seus custos variáveis de produção diminuíram a um patamar de 38,5% em relação ao

mesmo caso. Isto resulta em um lucro operacional (desconsiderados os custos fixos) de \$2.939,09 e um aumento efetivo de 38,07% quando comparado ao caso primário, cujo lucro operacional (desconsiderados os custos fixos) era de apenas \$2.127,98.

É notório que a recompensa utilizada na implementação do método *Q-learning* é o lucro operacional, conforme discutido na Seção 3.4 deste trabalho, de modo que a estratégia do agente G2, após ser treinado, não condiz meramente com o aumento de sua receita, mas sim com o aumento da diferença entre esta receita e seus custos operacionais.


No último teste, o agente G3 será treinado utilizando o método *Q-learning* enquanto os agentes G1 e G2 irão ofertar seus CMOs reais. Os Gráficos 13 e 14 são representativos do impacto das ações do agente G3 sobre o preço médio diário ponderado da energia elétrica no SEE e a influência destas ações sobre o PMLs nas barras dos geradores.

Gráfico 13 – Preço médio no SEE (treino do agente G3)



Fonte: Autoria própria (2023)

Gráfico 14 – PLM médio nos barramentos (treino do agente G3)



Fonte: Autoria própria (2023)

Através da análise da Tabela 8, concluí-se que a ação mais frequente, durante o treino do agente G3, foi a ação a_{18} (que condiz a um ganho $\beta_{18} = 1,90$).


Tabela 8 – Seleção das ações durante a fase de treino (treino do agente G3)

Ação (a_k)	Número de vezes selecionada	Ação (a_k)	Número de vezes selecionada	Ação (a_k)	Número de vezes selecionada
0	5	7	7	14	40
1	6	8	9	15	40
2	5	9	14	16	40
3	5	10	38	17	37
4	6	11	42	18	72
5	8	12	40	19	70
6	7	13	39	20	70

Fonte: Autoria própria (2023)

Considerando a ação a_{18} como a mais representativa da política de decisão desenvolvida pelo agente G3, pode-se analisar sua influência sobre os PMLs nos barramentos dos agentes geradores, nos leilões horários do *mercado day-ahead*, ao se observar o Gráfico 15.

Gráfico 15 – PLM médio nos barramentos (melhor ação do agente G3)



Fonte: Autoria própria (2023)

Do mesmo modo que nos testes anteriores, o PML do agente G3 supera o limite superior (preço *cap*) estipulado pelo operador do mercado igual a \$17,85, novamente fazendo com que a receita do agente seja diminuída. Os resultados econômicos obtidos pelos agentes, considerando os efeitos das ofertas realizadas pelo agente G3, estão apresentados na Tabela 9.

Tabela 9 – Resultados econômicos dos agentes (melhor ação do agente G3)

Gerador	Receita bruta $[\lambda_g \times P_g](\$)$	Custos variáveis $[c_2(P_g)^2 + c_1P_g](\$)$	Receita em relação ao caso primário	Custos variáveis em relação ao caso primário
G1	24.037,26	23.177,08	129,93%	128,05%
G2	35.773,55	32.706,91	123,67%	122,05%
G3	17.018,12	13.766,18	66,19%	56,64%

Fonte: Autoria própria (2023)

O agente G3 obteve uma receita de apenas 66,19% em relação ao caso primário (apresentado na Tabela 3). Como no teste anterior, verifica-se para este

agente a diminuição de seus custos variáveis de produção a um patamar de 56,64% em relação ao caso primário, o que implica em um aumento do lucro operacional (igual \$3.251,94 ao desconsiderar os custos fixos) de 131,07% quando comparado ao caso primário (com lucro operacional, descontado de custos fixos, igual a \$ 1.407,35).

Como dito anteriormente neste trabalho, é importante lembrar que a recompensa utilizada na implementação do método *Q-learning* é o lucro operacional, de modo que a estratégia do agente G3 não visa apenas o aumento de sua receita, mas sim o aumento da diferença entre esta receita e seus custos operacionais.

4.4 Estudo da Influência da localização física do agente


Neste terceiro caso de estudo, verifica-se a influência da localização física do agente na possibilidade de exercício de poder de mercado, atuando de modo individual, no MEE *day-ahead*.

O seguinte cenário será utilizado para gerar os resultados apresentados nos próximos gráficos e tabelas desta seção:

- O gerador selecionado para treino tem sua posição física (barra de conexão) no sistema trocada com outro agente;
- O gerador selecionado para treino declara sua oferta como seu CMO multiplicado por um fator de ganho (definido pela política de decisão aprendida através da aplicação do método *Q-learning*);
- Os demais os geradores declaram seus CMOs reais como oferta;
- Admite-se a carga conforme a curva mostrada no Gráfico 1;
- Consideram-se os limites operacionais dos geradores conforme declarados na Tabela 2, e das linhas de transmissão conforme consta na base de dados do módulo “Pandapower”.

No primeiro teste, considera-se que o agente G1 será treinado e que sua localização física (barra de conexão no SEE) foi trocada com o agente G2. A influência da estratégia de venda de energia elétrica desenvolvida pelo agente G1, sobre o preço médio diário ponderado da energia elétrica, pode ser observada no Gráfico 16.


Gráfico 16 – Preço médio no SEE (treino do agente G1 considerando sua troca de localização física com o agente G2)



Fonte: Autoria própria (2023)

Analisando o treino do agente G1, nesta nova localização física, conclui-se que a ação a_{20} é a mais frequentemente selecionada durante os episódios. Esta ação corresponde ao fator de ganho igual a $\beta_{20} = 2,00$ sobre seu CMO, sendo o reflexo desta oferta sobre os PMLs (resultado nos leilões horários no mercado *day-ahead*) apresentado no Gráfico 17.

Gráfico 17 – PLM médio nos barramentos (melhor ação do agente G1 considerando sua troca de localização física com o agente G2)



Fonte: Autoria própria (2023)

Observa-se que o PML na barra do agente G1 supera o limite superior (preço *cap*) estipulado pelo operador do mercado igual a \$17,85. Isto acaba por resultar em uma diminuição da receita obtida pelo agente, tendo em conta que o pagamento recebido pela venda de energia estará limitado ao valor limite estipulado.

Os resultados econômicos obtidos pelos agentes, considerando a escolha da ação a_{20} pelo agente G1 e a alteração da localização física entre os agentes G1 e G2, estão resumidos na Tabela 10.

Tabela 10 – Resultados econômicos dos agentes (melhor ação do agente G1 considerando sua troca de localização física com o agente G2)

Gerador	Receita bruta $[\lambda_g \times P_g] (\$)$	Custos variáveis $[c_2(P_g)^2 + c_1P_g] (\$)$	Receita em relação ao caso na Tabela 5	Custos variáveis em relação ao caso na Tabela 5
G1	15.964,45	14.449,38	77,13%	86,76%
G2	30.898,96	28.494,81	121,50%	120,05%
G3	27.866,14	26.209,84	89,93%	90,54%

Fonte: Autoria própria (2023)

A análise dos dados respectivos ao agente G1, presentes na Tabela 10, mostra que houve diminuição de 22,87% em sua receita e, também, a diminuição de 13,25% em seus custos variáveis de produção quando comparado aos resultados obtidos pelo agente em sua localização anterior (Tabela 5). Estes valores implicam na diminuição de 62,54% em seu lucro operacional, desconsiderando seus custos fixos de operação, em relação ao lucro obtido anteriormente.

No segundo teste, novamente considera-se que o agente G1 foi selecionado para treinamento. Entretanto, agora, assume-se que os agentes G1 e G3 trocaram entre si suas posições físicas no sistema.

No Gráfico 18 apresenta-se o resultado da adoção da política de decisão treinada pelo agente G1, ocupando a localização física do agente G3 no sistema, sobre o preço médio diário ponderado da energia elétrica no sistema.


Gráfico 18 – Preço médio no SEE (treino do agente G1 considerando sua troca de localização física com o agente G3)



Fonte: Autoria própria (2023)

Ao analisar o treino do agente G1, nesta nova localização na rede elétrica, conclui-se que a ação a_9 é a mais frequentemente selecionada durante o treino. Esta ação corresponde a um fator de ganho igual a $\beta_9 = 1,45$ sobre seu CMO, sendo o reflexo desta oferta sobre os PMLs (resultado nos leilões horários no mercado *day-ahead*) apresentado no Gráfico 19.

Gráfico 19 – PLM médio nos barramentos (melhor ação do agente G1 considerando sua troca de localização física com o agente G3)



Fonte: Autoria própria (2023)

Mais uma vez, percebe-se que o PML na barra do agente G1 supera o limite superior (preço *cap*) estipulado pelo operador do mercado igual a \$17,85. Conclui-se, diante deste fato, que haverá uma diminuição da receita obtida pelo agente, já que o pagamento recebido pela venda de energia estará limitado ao valor pré-determinado pelo operador do mercado.

Na Tabela 11 estão apresentados os resultados econômicos obtidos pelos agentes, assumindo a escolha da ação a_9 pelo agente G1 e a troca de sua localização física com o agente G3.

Tabela 11 – Resultados econômicos dos agentes (melhor ação do agente G1 considerando sua troca de localização física com o agente G3)

Gerador	Receita bruta $[\lambda_g \times P_g](\$)$	Custos variáveis $[c_2(P_g)^2 + c_1P_g](\$)$	Receita em relação ao caso na Tabela 5	Custos variáveis em relação ao caso na Tabela 5
G1	17.952,40	15.868,65	87,73%	95,28%
G2	30.680,55	28.308,91	120,64%	119,25%
G3	26.503,42	25.010,19	85,53%	86,39%

Fonte: Autoria própria (2023)

A análise dos resultados para o agente G1 mostra uma diminuição de 12,27% em sua receita e, também, a diminuição de 4,72% em seus custos variáveis de produção em relação aos resultados apresentados na Tabela 5 (considerando sua localização inicial). Estes resultados mostram uma diminuição de 48,58% em seu lucro operacional, desconsiderando seus custos fixos de operação, em relação ao lucro obtido anteriormente.

Conclui-se, dos resultados apresentados nesta seção, que a localização física (ponto de conexão) do agente no sistema afeta em grande extensão a composição das estratégias de venda obtidas pelo método *Q-learning*. Deste modo o lucro operacional (desconsiderando os custos fixos de operação) do agente G1

pode variar de 278,45% a 910,17% em relação ao caso onde a estratégia do agente é ofertar seu CMO real.

É relevante mencionar que a adoção de uma estratégia (política) de venda foi sempre benéfica ao agente vendedor de energia, quando comparada à estratégia de oferta do CMO real. A localização física do agente pode ser pensada como um adicional à estratégia do investidor no MEE ao intencionar a instalação (ou compra) de uma unidade geradora no SEE.

4.5 Estudo do fenômeno de coalisão tácita entre os agentes

Neste quarto caso de estudo, verifica-se a capacidade dos agentes em promover uma coalisão tácita no mercado. Este tipo de coalisão ocorre em ambientes que exibem alta taxa de repetibilidade, nos quais os agentes exibem comportamento cooperativo, mesmo na impossibilidade de trocar informações entre si (os agentes desconhecem as estratégias de oferta adotadas pelos concorrentes).

O mercado de energia *day-ahead* é por primazia um ambiente com informação imperfeita (sem troca de informações entre os agentes), haja vista que a concorrência entre os agentes vendedores de energia é fator fundamental para a eficiência do mercado.


Com tal requisito em mente, o seguinte cenário será utilizado para gerar os resultados apresentados nos próximos gráficos e tabelas desta seção:

- Os geradores estão em suas localizações físicas originais (tal como mostrado na Figura 11)
- Todos os geradores serão selecionados para treino, ou seja, irão declarar suas respectivas ofertas como seu CMO multiplicado por um fator de ganho (definido pela política de decisão aprendida através da aplicação do método *Q-learning*);
- Admite-se a carga conforme a curva mostrada no Gráfico 1;
- Consideram-se os limites operacionais dos geradores, conforme declarado na Tabela 2, e das linhas de transmissão conforme consta na base de dados do módulo “Pandapower”.

A variação do preço médio diário ponderado da energia elétrica no sistema (estado do ambiente), o PML médio nas barras dos geradores, e as ações (ofertas


declaradas) escolhidas durante o treinamento dos agentes são mostradas nos Gráficos 20, 21 e 22 respectivamente.

Gráfico 20 – Preço médio no SEE (treino de todos os agentes)




Fonte: Autoria própria (2023)

Gráfico 21 – PLM médio nos barramentos (treino de todos os agentes)



Fonte: Autoria própria (2023)

Gráfico 22 – Ação dos agentes no mercado (treino de todos os agentes)




Fonte: Autoria própria (2023)

Observa-se que a política de decisão obtidas pelos 3 agentes tende a se restringir a um pequeno número de ações que se contrabalanceiam e restringem o comportamento dos demais, desta maneira verifica-se que os preços nos barramentos uma variação bastante restrita (como apresentado no Gráfico 21).

As ações mais frequentemente selecionadas, durante a fase de treino dos agentes, são a_5^{G1} , a_{11}^{G2} e a_5^{G3} , correspondentes aos fatores de ganho $\beta_5^{G1} = 1,25$, $\beta_{11}^{G2} = 1,55$ e $\beta_5^{G3} = 1,25$. Estas ações serão tomadas como as mais representativas para as políticas treinadas pelos agentes, de modo que seu reflexo nos PMLs dos barramentos dos agentes está apresentado no Gráfico 23.

Gráfico 23 – PLM médio nos barramentos (treino de todos os agentes)



Fonte: Autoria própria (2023)

Baseado nestas políticas de oferta, resume-se na Tabela 12 os resultados econômicos obtidos pelos agentes.

Tabela 12 – Resultados econômicos dos agentes (melhor ação de todos os agentes)

Gerador	Receita bruta $[\lambda_g \times P_g](\$)$	Custos variáveis $[c_2(P_g)^2 + c_1P_g](\$)$	Receita em relação ao caso primário	Custos variáveis em relação ao caso primário
G1	34.719,80	26.657,53	187,67%	147,28%
G2	15.537,18	10.318,08	53,71%	38,50%
G3	44.968,05	33.439,93	174,89%	137,59%

Fonte: Autoria própria (2023)

Em comparação com os resultados do caso primário (descrito na Tabela 3), os lucros operacionais (desconsiderando os custos fixos) de todos os agentes aumentaram significativamente, de modo que:

- O agente G1 obteve um aumento de 1.913,14% (de \$400,34 para \$8.062,27);
- O agente G2 obteve um aumento de 145,26% (de \$2.127,98 para \$5.219,10);
- O agente G3 obteve um aumento de 719,14% (de \$1.407,35 para \$11.528,12).

É importante salientar que os aumentos relatados são todos maiores que àqueles obtidos pelos agentes atuando de modo individual (vide Tabelas 5, 7 e 9) ao assumir que seus concorrentes ofertarão seus CMOs reais. Isto corrobora a

ocorrência de coalisção tácita entre os agentes vendedores no mercado, uma vez que o comportamento cooperativo permitiu aos agentes elevar significativamente os preços da energia elétrica e com isso aumentar seus lucros operacionais.

5 CONCLUSÃO

Neste trabalho, uma ferramenta para avaliação de estratégias de venda de energia elétrica em mercados *day-ahead*, com precificação por oferta, denominada *SimMarketStrategy* é proposta. Uma prova de conceito da aplicação *desktop* foi implementada, utilizando linguagem Python, e testada em um SEE de pequeno porte com um parque gerador termoelétrico.

A composição das estratégias de venda foi realizada através do método *Q-learning* (técnica de AR). Assim, utilizando a ferramenta proposta, foi possível estudar a concepção de estratégias de venda, para cada um dos agentes geradores conectados ao sistema, e verificar a capacidade de exercício de poder de mercado, considerando tanto a influência da localização física do agente na rede elétrica como a influência dos limites operacionais do sistema de transmissão (congestionamento).

Para os testes realizados no SEE de 6 barras, contendo 3 unidades geradoras térmicas, foi possível verificar que a utilização de um estratégia de venda, derivada da aplicação do método *Q-learning*, pode contribuir com um aumento de mais de 900% do lucro operacional, desconsiderando os custos fixos de produção, do agente gerador quando comparada à oferta de seu CMO real.

Além disso, ao considerar a localização física do agente no sistema como um fator variável, pôde-se concluir que esta impacta o aumento do lucro operacional (desconsiderando os custos fixos) em uma extensão de 278,45% a 910,17% em relação à oferta de seu CMO real.

A partir das análises realizadas neste sistema teste também verificou-se a ocorrência do fenômeno de coalisão tácita (coordenação das ofertas de venda na ausência de troca explícita de informação) entre os agentes. Observou-se que tal comportamento cooperativo resultou no aumento do lucro operacional dos geradores em mais de 1.900% quando comparada à oferta dos seus CMOs reais.

5.1 Perspectivas Futuras

Como perspectivas para a continuação deste trabalho sugere-se que os seguintes tópicos sejam pesquisados:

- Inclusão de ofertas de agentes geradores hidroelétricos, para que a ferramenta possa ser utilizada em mercados mais complexos, nos

quais o armazenamento do combustível (água) é “compartilhado” pelos agentes na mesma bacia hidrográfica (CRUZ, 2017);

- Inclusão de ofertas de agentes geradores eólicos e fotovoltaicos, para que a ferramenta possa ser utilizada em mercados com participação de energias renováveis de grande intermitência;
- Inclusão de restrições nas ofertas dos agentes para cobertura de serviços ancilares (e.g. reserva girante e regulação), para que a ferramenta possa ser utilizada em mercados com atendimento à critérios de segurança operacional;
- Inclusão de ofertas de compra de energia, através da definição de curvas de benefício de carga, de modo a tornar os leilões de energia bilaterais (KRAUSE; ANDERSSON, 2006);
- Estudo do impacto da utilização de outras técnicas de AR, e.g. *double Q-learning* (BAYATI; NAGHIBI-SISTANI, 2022), na composição de estratégias de compra e venda de energia em mercado com precificação por oferta;
- Extensão do modelo de liquidação financeira para inclusão do problema de comprometimento de unidades (otimização não linear inteira mista) com restrições intertemporais para representação da variação temporal das gerações (BALDICK, 2021).

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa ANEEL nº 956 de 7 de dezembro de 2021 - PRODIST**: Módulo 8 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico nacional, Distrito Federal: ANEEL, 2021.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa ANEEL nº 1.030 de 26 de julho de 2022**: Consolida os atos regulatórios relativos ao programa da Resposta da Demanda; à prestação de serviços ancilares e [...], Distrito Federal: ANEEL, 2022.

BACH, T.; YAO, J.; WANG J.; SHENGJIE, Y. Research and application of the Q-learning for wholesale power markets. **2012 2nd International Conference on Consumer Electronics, Communications and Networks (CECNet)**, Yichang, China, 2012, pp. 1192-1197.

BACH, T.; YAO, J.; YANG, S. Fuzzy Q-Learning for Uniform Price Wholesale Power Markets. **2013 International Conference on Communication Systems and Network Technologies**, Gwalior, India, 2013, pp. 578-582.

BALDICK, R. **Restructured Electricity Markets: Locational Marginal Pricing**. Class Notes – University of Texas at Austin. 2021. Austin, TX, USA, 2021.

BALDICK, R. **Single Clearing Price in Electricity Markets**. University of Texas at Austin. 2021. Austin, TX, USA, 2019.

BAKIRTZIS, A. G.; TELLIDOU, A. C. Agent-Based Simulation of Power Markets under Uniform and Pay-as-Bid Pricing Rules using Reinforcement Learning. **2006 IEEE PES Power Systems Conference and Exposition**, Atlanta, GA, USA, 2006, pp. 1168-1173.

BAYATI, A.; NAGHIBI-SISTANI, M. -B. Double Learning for Suppliers' Bidding Strategy in the Electricity Market. **2022 26th International Electrical Power Distribution Conference (EPDC)**, Tehran, Iran, Islamic Republic of, 2022, pp. 24-30.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Primeiros Passos sobre o Setor Elétrico e a CCEE**: Comercialização de Energia e Seus Participantes. São Paulo: CCEE, 2022a.

CÂMARA DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA. **Primeiros Passos sobre o Setor Elétrico e a CCEE**: Diferenças entre o Mundo Físico e o Mundo Comercial. São Paulo: CCEE, 2022b.

CASTRO, R.; FILHO, C. L. Assessing decision on the Brazilian wholesale energy market: the environment. **2004 IEEE/PES Transmission and Distribution Conference and Exposition: Latin America**, Sao Paulo, Brazil, 2004, pp. 132-136.

CENTRO DE PESQUISA, INOVAÇÃO E DIFUSÃO DO CENTRO DE CIÊNCIAS MATEMÁTICAS APLICADAS À INDÚSTRIA. **Report on Problem 1: Pricing Frameworks for unit-commitment hydrothermal problems**. Anais do 4^o workshop “Soluções Matemáticas para Problemas Industriais”. São Carlos, SP: Instituto de Ciências Matemáticas e de Computação - USP, 2018.

CRUZ, M. P. **Estratégias de ofertas em mercados competitivos de energia elétrica com predominância de geração hidrelétrica**. Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Elétrica, Florianópolis, SC, Brasil, 2017.

ENGIE. **P&D preço e despacho por oferta (P&D ANEEL PD-00403-0050/2020)**. Fórum de Debates CCEE - Câmara de Comercialização de Energia Elétrica. São Paulo, SP: CCEE, 2022.

FREZZI, P.; GARCES, F.; HAUBRICH, H. -J. Analysis of Short-term Bidding Strategies in Power Markets. **2007 IEEE Lausanne Power Tech**, Lausanne, Switzerland, 2007, pp. 971-976.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2nd Edition. Canada, ON: O’Reilly. 2019.

KRAUSE, T.; ANDERSSON, G. Evaluating congestion management schemes in liberalized electricity markets using an agent-based simulator. **2006 IEEE Power Engineering Society General Meeting**, Montreal, QC, Canada, 2006, pp. 8.

MAOZU G.; YANG L.; MALEC, J. A new Q-learning algorithm based on the metropolis criterion. **IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)**, vol. 34, no. 5, pp. 2140-2143, Oct. 2004.

MASILI, G. S.; SILVA, A. J.; LANZOTTI, C. R.; CORREIA, P. B. Mecanismo de leilão e a formação de preços da energia no Brasil. **5th Latin-American Congress on Electricity Generation and Transmission**, 2003, São Pedro, SP, Brazil. 2003.

MAYO, R. **Mercados de Eletricidade**. 1^a Edição. Brasil, RJ: Synergia. 2012.

MENDES, D. P.; SANTANA, E. A.; CAMARGO, I. M. T.; ANDRADE, C. S.; NUNES, H. R. A. Modelling issues of the Brazilian market design. **2003 IEEE Power Engineering Society General Meeting**, Toronto, ON, Canada, 2003, pp. 447-452 Vol. 1.

MONTICELLI, A.; GARCIA, A. **Introdução aos Sistemas de Energia Elétrica**. 2^a Edição. Campinas, SP: Editora Unicamp. 2011.

PORTO, T. **O futuro da comercialização de energia elétrica**. Apresentação (slides) – Câmara de Comercialização de Energia Elétrica. Lefosse Energy Day 2022. São Paulo, SP, Brasil, 2022.

PORTO, T. **Mecanismos de Formação de Preços**. Apresentação (slides) – Câmara de Comercialização de Energia Elétrica. Academia Nacional de Engenharia. Rio de Janeiro, RJ, Brasil, [2020?].

PSR. **Entregável 1: Avaliação conceitual e estratégias de desenho - Propostas de metodologias para formação de preços por oferta no Brasil (P&D ANEEL PD-00403-0050/2020)**. Rio de Janeiro, RJ, Brasil, 2021a.

PSR. **Entregável 4: Visão Internacional - Propostas de metodologias para formação de preços por oferta no Brasil (P&D ANEEL PD-00403-0050/2020)**. Rio de Janeiro, RJ, Brasil, 2021b.

RATCLIFFE, S. (ed.). **Oxford Essential Quotations**. Oxford University Press. 2018. Disponível em: <https://www.oxfordreference.com>. Acesso em 23 fev. 2023.

SOUZA, F. C.; LEGEY, L. F. L. Brazilian electricity market structure and risk management tools. **2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century**, Pittsburgh, PA, USA, 2008, pp. 1-8.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. 2nd Edition. Cambridge, MA: The MIT Press. 2018.

THURNER, L.; SCHEIDLER, A.; SCHÄFER, F.; MENKE, J.-H.; DOLLICHON, J.; MEIER, F.; MEINECKE, S.; BRAUN, M. Pandapower – An Open Source Python Tool for Convenient Modeling, Analysis and Optimization of Electric Power Systems, **IEEE Transactions on Power Systems**, vol. 33, no. 6, pp. 6510-6521, Nov. 2018.

VIANA, A. G. **Leilões como mecanismo alocativo para um novo desenho de mercado no Brasil**. Tese (doutorado) - Universidade de São Paulo, Escola Politécnica, Programa de Pós-Graduação em Engenharia Elétrica, São Paulo, 2018.

WANG, H. **On the computation and application of multi-period security constrained optimal power flow for real-time electricity market operations**. Ph.D. dissertation - Cornell University, Ithaca, NY, USA, 2007.

WOOD, A.J.; WOOLEMBERG, B.F. **Power Generation, Operations and Control**. 2nd Edition. New York, NY: John Wiley & Sons. 1996.