

An Agent-Based Model Applied to Brazilian Wind Energy Auctions

M. Machado, M. Fujii, C. Ribeiro, and E. Rego

Abstract—This article, for the first time, adopts the agent-based model simulation technique to analyze the pricing process of energy in the Brazilian electricity market (auctions). Within this model, it is possible to analyze how the energy price is affected when a government intervention is observed through the increase in number of public companies participating in the auctions. In this paper, auctions of new and reserve energy of wind power are simulated. Through this model it is possible to compare the choice of bids from participating sellers in the auctions, categorized in two different groups: public and private companies. The agents (sellers) participate in the auctions by learning from the historical and simulated auctions that is regulated by the Brazilian government. Learning is performed through the usage of a variation of the Q-learning algorithm, which provides the sellers the optimal price-bid considering the conditions presented, which means that this price-bid will provide them the maximum reward possible. The results clearly show the average price difference between both generator profiles. In addition, it is possible to state that the price of energy changes due to the relative participation of public or private sellers in the auctions.

Index Terms—Agent-based, Wind energy auction, Energy regulation, Energy pricing.

I. INTRODUÇÃO

A DETERMINAÇÃO de preços de energia elétrica é um importante problema de âmbito mundial. Países possuem abordagens distintas para a negociação de preços, as quais variam de leilões realizados por entidades governamentais a negociações de contratos em mercados de derivativos. Entender a dinâmica de formação de preços em cada mercado é um trabalho desafiador e que vem ocupando espaço na literatura de engenharia econômica.

Esta pesquisa teve apoio financeiro do CNPq (Conselho Brasileiro Nacional de Pesquisa), projeto 445925/2014-0 e FAPESP (Fundação de Pesquisa de São Paulo) /BG Brazil, através do Centro de Pesquisa para Inovação em Gás, projeto 2014/50279-4.

M. R. Machado é estudante de doutorado na Universidade de Ontario Instituto de Tecnologia (UOIT), na cidade de Oshawa, ON, Canada (e-mail: marcos.machado@uoit.net).

M. K. Fujii é um estudante de Engenharia de Produção na Universidade de São Paulo (USP), na cidade de São Paulo, SP, Brasil (e-mail: murilo.fujii@usp.br).

C. O. Ribeiro é Professora Assistente na Universidade de São Paulo (USP) localizada na cidade de São Paulo, SP, Brasil (e-mail: celma@usp.br).

E. E. Rego é Professor Assistente na Universidade de São Paulo (USP) localizada na cidade de São Paulo, SP, Brasil (e-mail: erikreg@usp.br).

O objetivo principal deste artigo é a construção de um modelo baseado em agentes para o mercado de leilões brasileiro de energia elétrica, a partir do qual será analisado o processo de precificação de energia eólica. Além disso, a pergunta que se quer responder é como se comportam os preços da energia, dada a participação relativa de vendedores com perfis públicos e privados nos pleitos.

O mercado brasileiro de energia elétrica possui peculiaridades que o distingue em relação aos demais, particularmente no que se refere ao modelo institucional (licitações, concessões e permissões). A comercialização da energia é realizada em dois ambientes de comercialização: o ACR - Ambiente de Contratação Regulada e o ACL - Ambiente de Contratação Livre. No mercado regulado as empresas distribuidoras compram eletricidade por meio de leilões, enquanto que no mercado livre, grandes consumidores e geradores negociam eletricidade de forma bilateral. De acordo com dados da CCEE (Câmara de comercialização de energia elétrica) de maio de 2019 [1], os leilões (de energia nova e de reserva para fonte eólica), que são objetos de estudo deste trabalho, negociaram em média, 396,5 MW médios em licitações que ocorreram até três vezes por ano desde 2004. A literatura sobre modelos matemáticos para análise de preços do mercado brasileiro é reduzida devido à limitada disponibilidade de dados, um dos fatos que justifica a realização desse trabalho.

Mercados de energia elétrica apresentam um grau de complexidade alto sem solução analítica trivial para formação de preços. Devido à complexidade do setor, vários pesquisadores sugerem a aplicação de técnicas de simulação baseada em agentes para análise de preços de leilões de energia elétrica. Dentro dessas abordagens encontram-se os modelos baseados em agentes – ABM [2] [3] [4].

No ABM, os agentes (compradores e vendedores) que atuam nos leilões interagem nesse ambiente e tomam suas decisões com base em expectativas de preço e demanda futuros, assim como das ofertas de seus concorrentes. Naturalmente é possível utilizar modelos de equilíbrio para tratar tais problemas, porém, modelos baseados em agentes possuem flexibilidade para que se incorpore aprendizado no processo de definição de estratégias de negociação. Modelos baseados em agentes são bastante empregados na análise de leilões em geral, pois possibilitam que haja uma compreensão aprofundada a respeito da iteração entre os diversos agentes que neles atuam, o que não poderia ser obtido a partir das modelagens tradicionais baseadas em modelos de equilíbrio. Sendo assim, devido a questões teóricas e práticas, de disponibilidade de dados, a abordagem escolhida para este artigo foi a criação de um ABM.

Outra característica que justifica o uso de ABM para modelar a comercialização de energia no Brasil e no mundo é a existência de heterogeneidade dos agentes econômicos. Os agentes ativos no mercado brasileiro são os geradores e a entidade governamental responsável pelo leilão. As diferentes fontes de energia nesse mercado (hídrica, eólica, biomassa, gás natural, dentre outras), as mais diversas capacidades de geração em função de recursos naturais e sazonais, e características geográficas distintas são fatores que diferenciam os geradores. Tais agentes interagem entre si e podem aprender ao longo do processo, o que torna adequada a abordagem em questão. Estes modelos replicam o comportamento de agentes heterogêneos que interagem em um ambiente artificial, criado por meio de um programa ou arquivo computacional, e se adaptam entre si [5] [6] [7] [8].

O problema tratado neste artigo é, então, o estudo do comportamento de preços de energia eólica negociados nos leilões de energia nova e de reserva do mercado brasileiro, com uso de técnicas de modelos baseados em agentes. A contribuição deste trabalho baseia-se na análise realizada dos resultados obtidos, onde é possível verificar que o preço da energia elétrica nos leilões do Brasil varia conforme perfil das empresas que neles participam. A exploração dos dados resultantes das simulações pode contribuir não só para uma maior compreensão da formação de preços no ACR do mercado brasileiro, mas também possibilita que a análise seja estendida para países que adotam mecanismos de comercialização semelhantes ao brasileiro, como nos casos da Colômbia, Chile, Peru e Austrália [9].

II. COMERCIALIZAÇÃO DE ENERGIA NO BRASIL - LEILÕES

Há diferentes tipos de leilões de energia elétrica, dentre eles: o leilão inglês (preço aberto ascendente ou descendente), leilão relógio e leilão holandês (ou selado), e suas combinações. No leilão inglês, os lances são realizados de forma aberta e sequencialmente, cada lance é melhor que o anterior. O leilão ocorre até que não se apresentem outros lances ou até que não se verifique melhor proposta (maior ou menor) e, então, o leiloeiro anuncia o ganhador. De acordo com [10], o formato mais comum de leilão de energia elétrica é o leilão inglês. O próprio autor aponta também a existência de uma variação desse formato de leilão, quando o preço é descendente (preço final do leilão é menor que o preço inicial), também conhecido por leilão inglês reverso. Outra variação é o leilão de relógio, no qual o decremento não é anunciado, e sim automático, portanto se define (um) procedimento iterativo onde os compradores indicam a quantidade desejada a cada preço anunciado pelo leiloeiro, até que não haja itens em estoque [11]. Há ainda o leilão selado ou leilão holandês, no qual os agentes apresentam simultaneamente propostas fechadas definindo a melhor oferta, bem como a oferta final, quem submete a maior (se ascendente) ou a menor (se descendente) oferta vence o leilão [12] [10].

Os leilões podem ser classificados também conforme preço de venda/compra. Os autores [4] classificam esses leilões como: (i) preço uniforme: o mesmo valor é pago a todos vencedores;

(ii) preço discriminatório (*pay-as-bid*): os ganhadores são remunerados de forma distinta, de acordo com cada lance individual; e (iii) *Vickrey* segundo melhor preço (maior ou menor, definido pelas regras dos leilões – ascendente ou descendente), a partir do lance vencedor.

Os leilões de comercialização de energia elétrica no ACR são realizados em duas fases – a primeira, inglesa reversa (relógio de preço descendente) e a segunda, holandesa discriminatória de lance fechado, em que cada vencedor é remunerado por seu lance único [13]. O objetivo da realização dos leilões em duas etapas é garantir a redução do excedente do gerador, possibilitando redução de preço final da energia para os consumidores cativos. É importante ressaltar que independentemente do tipo da fonte geradora de energia (hídrica, eólica, solar, termelétrica, dentre outras) não existe diferença no desenho dos leilões e o mesmo é definido, conforme regra de remuneração, como “pago pelo lance”, já que cada ganhador é remunerado conforme seu lance final vencedor do pleito.

Na primeira fase, dado o preço, os geradores apontam se continuam ou não ofertando a quantidade informada no primeiro lance, dado o novo (menor) preço. Essas iterações acontecem até que se chegue a uma demanda “segura” - que garanta maior competição na segunda fase do leilão, sendo ainda, a oferta maior que a demanda. Em seguida, tem início a segunda etapa do leilão onde, dada a quantidade, os geradores apontam seu preço, que deve ter ao menos um decréscimo do preço final da primeira etapa. Ganham o leilão os geradores que ofertarem menor preço (é comum existir mais de um ganhador, o(s) mesmo(s) são classificados até que a demanda seja toda suprida).

De acordo com dados públicos disponibilizados pela ONS (Operador Nacional do Sistema) em abril de 2019 [14], é possível verificar que o pleito que comercializou menor quantidade de energia vendeu aproximadamente 22.000 MWh e o maior volume comercializado foi de aproximadamente 1,2 bilhões de MWh.

III. ABM – MODELOS BASEADOS EM AGENTES

De acordo com [2], a modelagem baseada em agentes faz uso de conceitos e instrumentos das ciências da computação com intuito de resolver problemas das ciências sociais, através da análise de relações causais em sistemas multi-agentes.

O autor [15] indica que, existem três tipos distintos de uso da técnica de ABM: (i) a técnica simples, que se assemelha à aplicação de pesquisa operacional; (ii) aplicação para solução de problemas, que considera modelos matemáticos que podem ser escritos, mas nem sempre resolvidos através de ferramentas computacionais e (iii) aplicações para solução de problemas que envolvam relações entre agentes e determinado ambiente no qual eles estejam inseridos, nesse caso os agentes aprendem no processo de simulação.

Os agentes envolvidos na modelagem são autônomos, aprendem e interagem entre si e consigo mesmo. Devido à possibilidade de aprendizagem por parte dos agentes existentes, é possível capturar a complexidade das decisões, ações e

interações de situações “reais”. Os agentes que participam de uma simulação desse tipo têm comportamento e memória sobre as decisões tomadas e, portanto, têm a opção de mudança de informação.

Os autores [16] apontam uma série de perguntas relevantes que devem ser realizadas previamente à construção de um modelo dessa natureza, a fim de obter uma prévia do desenho do modelo, dentre elas: Qual o problema que se quer responder com o modelo? Quais são os agentes do modelo, onde serão obtidos os dados para criar o modelo e calibrar a aprendizagem e como os agentes devem interagir entre si no modelo?

Já [8] propõem em seu trabalho um tutorial com o esquema da construção de simulações baseadas em agentes que inicia com a indicação de que é necessário definir-se o escopo das simulações e se encerra com a recomendação de validar-se o modelo.

A aplicabilidade de ABM no setor de energia elétrica, bibliograficamente, iniciou-se com [17], que aplicaram a técnica para analisar um problema de demanda de eletricidade. A partir de então, tal técnica é utilizada para estudar os mais variados problemas nos mais diversos mercados de energia do mundo, por exemplo no mercado australiano, onde os pesquisadores [4] simulam e comparam o comportamento do mercado de energia dado a ocorrência de três tipos de leilões, classificados pela forma de remuneração dos ganhadores do leilão e tentam confirmar em quais desenhos se verifica maior poder de mercado, volatilidade de preços e maiores lucros para geradores.

Apesar da existência de um número considerável de pesquisas que utilizam ABM no setor de energia, inclusive na análise de precificação [18] [19] [20] [21], é possível notar que existem poucos trabalhos relacionados ao mercado brasileiro que foram amplamente divulgados e/ou publicados, o que auxilia também a justificar a realização deste trabalho.

IV. APRENDIZADO COMPUTACIONAL APLICADO AO ABM

Algumas técnicas comumente utilizadas para aplicar aprendizagem dos agentes tratados nos modelos de simulação são o algoritmo genético [3] [22], o algoritmo de *Roth-Erev* comum e modificado [23] [24] [2] e o *Q-learning* [25] [26] [27]. Há uma extensa literatura que trata desse tipo de aprendizagem para simulações baseadas em agentes, [28] já sugeria trabalhar a aprendizagem para explorar problemas de sistemas complexos.

Na sequência serão explorados os conceitos fundamentais do algoritmo de aprendizagem com reforço *Q-learning*, que é o algoritmo utilizado na construção do modelo explorado neste artigo. O *Q-learning* foi criado por [29] para resolver problemas de decisão *markoviana* com informações incompletas. A convergência dessa nova forma de induzir aprendizado computacional foi comprovada mais tarde por [30].

O *Q-learning* é um algoritmo no qual a cada par estado/ ação (para cada estado, existe um conjunto de ações possíveis), está associado um valor V^* , que consiste no valor esperado que se deve obter ao escolher aquela ação e, a partir de então, continua-se a selecionar a política ótima [31].

O processo desse algoritmo pode ser descrito, com simplificações, da seguinte forma: assume-se que um agente interage com seu ambiente em cada uma das sequências de tempo discreto $t = 1, 2, 3, 4, \dots$. O conjunto $S = \{s_1, s_2, s_3, \dots, s_n\}$ é um conjunto finito de estados possíveis do ambiente de cada agente e $A = \{a_1, a_2, a_3, \dots, a_n\}$ é o conjunto finito de ações possíveis que podem ser tomadas em cada estado por cada agente. Assim, em cada período de tempo t , cada agente está em um estado $s_t = s \in S$ do seu ambiente e devem selecionar uma ação $a_t = a \in A$.

O resultado da escolha de determinada ação acarreta no recebimento de uma recompensa $r(t)$ e na mudança de estado que passa de s_t para s_{t+1} ainda pertencente ao conjunto S , essa alteração ocorre com uma determinada probabilidade de transição $P_{s(t),s(t+1)}(a)$. O objetivo dessas iterações para os agentes é encontrar uma política ótima $\pi^*(s) \in A$ para cada estado S que maximiza a quantidade total de recompensas recebidas ao longo de cada conjunto de iterações. Nesse sentido, o *Q-learning* provém uma técnica eficiente para determinar uma política ótima para estimar um par de estado/ação.

A equação (1) origina toda série de variações do algoritmo que é bastante utilizado nos dias de hoje. Trata-se de função de utilidade aplicada no algoritmo de aprendizagem que tem por objetivo maximizar resultados da variável que se quer estudar. Tal equação foi apresentada por [28] e explorada em estudos futuros por [32] [33] [34] [35] [36] [37] [38]. Esses estudos foram de grande importância para desenvolvimento de técnicas de aprendizado por reforço, onde as situações problema são modeladas como tendo tempo discreto e estados finitos em processos de decisão *markoviana*. Assim, o *Q-learning* considera tomadas de decisões atuais com base em decisões tomadas no passado, em históricos dos próprios agentes que buscam maximizar suas soluções. Os procedimentos do algoritmo podem ser observados na Figura 1.

$$Q_{t+1}(s_t, a_t) = Q_t(s_t, a_t) + \alpha[r(t) + \gamma \cdot V_t(S_{t+1}) - Q_t(s_t, a_t)] \quad (1)$$

Onde:

- A função $Q_{t+1}(s_t, a_t)$ define a recompensa futura esperada ao se escolher a ação a_t no estado s_t e é solucionada com programação dinâmica através de um algoritmo que segue política ótima;
- α é a taxa de aprendizagem do modelo, define qual percentual de importância que os agentes participantes do modelo devem dar às experiências anteriores e consequentemente à exploração de novas situações;
- $r(t)$ é a função de recompensa, ou penalidade, que resulta da escolha da ação a no estado s . Essa função é construída conforme cada situação explorada;
- γ é um fator de desconto que pode ser, ou não, incorporado ao modelo a fim de maximizar resultados e também é definido a partir das situações estudadas;
- $V_t(S_{t+1}) = \max Q(S_{t+1}, a)$ é a utilidade do estado s resultante da ação a , obtida utilizando a função Q que foi tratada

com o aprendizado computacional até o presente momento.

Para cada par (s,a) inicialize com $Q(s,a)=0$; Observe s;
 Repita:
 Selecione a ação a usando a política de ações atual;
 Execute a ação a;
 Receba a recompensa imediata $r(s,a)$;
 Observe o novo estado s' ;
 Atualize o item $Q(s,a)$ de acordo com a equação (1).
 Defina o novo estado $s \leftarrow s'$
 Até que critério de parada seja satisfeito.

Fig. 1. Procedimentos: algoritmo Q-learning. Fonte: Elaborado por [39], adaptado pelos autores.

Ainda com relação aos procedimentos a serem executados pelo algoritmo (Figura 1), [30] garantem que uma vez que todos os pares estado-ação tenham sido visitados um número infinito de vezes, as estimativas Q_t convergem para o valor de Q em tempo finito, embora de forma lenta.

V. DEFINIÇÕES DO MODELO: OS AGENTES E SEUS ATRIBUTOS

Os agentes que atuam no mercado simulado são os vendedores e o órgão governamental que regula o leilão, o qual funciona como um monopsonio em nome das distribuidoras, embora não compre energia de fato, uma vez que os contratos são firmados entre geradores e distribuidoras. Na sequência, serão apresentadas as suas decisões, processo de aprendizado e atributos.

Os vendedores (V_j) são descritos através do tipo de fonte de energia, da capacidade de oferta e pelas ofertas descritas por pares ordenados de preços e volume. Já o leiloeiro (L) é descrito por receber lances de oferta e demanda e por encontrar os pares (V_j, C_k), que são os preços pelos quais os vendedores (V_j) e compradores (C_k) comercializaram a energia em cada etapa do leilão.

Com relação à tomada de decisão, é possível afirmar referente à segunda fase dos leilões, que os geradores escolhem o preço que ofertam como lance. Já o leiloeiro é responsável por definir os pares (comprador x vendedor) e atualizar a informação que será disponibilizada aos compradores e vendedores em cada leilão.

São assumidas as seguintes hipóteses:

a) Geração de um lance de vendedor: O vendedor sabe qual a sua capacidade total de geração de energia. Nos leilões brasileiros de energia nova ou reserva os vendedores correspondem a projetos e essa capacidade não pode ser subdividida (uma vez que novos projetos são ativos não fracionáveis).

b) Aprendizado de vendedores: No caso brasileiro, analisa-se resultados de leilões anteriores, considerando se os preços praticados pelo próprio vendedor (na fase dois) foram vencedores e se poderia ter sido considerado preço maior.

c) Ações e aprendizado do leiloeiro: Os leiloeiros são apenas executores de regras, não aprendem. Definem quais são os pares (comprador/vendedor) e estabelecem critérios para encerramento de etapas de leilão.

VI. DEFINIÇÕES DO MODELO: APRENDIZAGEM DOS AGENTES

No modelo desenvolvido, o “*Q-Learning*” é responsável por definir a melhor ação \bar{a} que se pode tomar a partir de um estado de referência e_0 . Para isso, constrói-se a matriz de recompensas R e a matriz Q (matrizes cuja criação é explorada ainda nessa seção) para cada gerador ativo na segunda fase em cada iteração do leilão com base nas séries históricas de preços de cada gerador e no preço de referência (P_{ref}) que, nesse modelo, é o preço mínimo de atratividade de cada gerador e que é, também, o estado-objetivo. A ideia geral é definir o estado e_0 como sendo o preço mínimo P_i do gerador i e chegar o mais próximo possível do preço de corte para a segunda fase do leilão P_{ref} considerando as séries históricas. Observe que os dados de entrada são P_i, P_{ref} e as séries de preços.

Assim, neste modelo, os vendedores aprendem ao longo dos leilões através do algoritmo *Q-Learning*, onde, cada par (estado-ação) está associado ao preço esperado que se deve obter ao escolher aquela ação. Na equação (2) são apresentadas as funções de utilidade do algoritmo aqui criado, onde são definidos o estado inicial e o estado ideal do modelo, tais relações são variações da equação original (equação 1) proposta por [29].

$$Q_{0(i,j)}(s_0, a_0) = P_{min(i,j)}$$

$$Q_{t+1(i,j)}(s_t, a_t) = r(t) + \gamma \cdot (V_{t(i,j)}(s_{t+1})) \quad (2)$$

Onde:

- $Q_{0(i,j)}(s_0, a_0)$: É o valor da função de utilidade no estado inicial do vendedor i no leilão j . O estado inicial de cada gerador no modelo é escolhido aleatoriamente no conjunto de lances históricos de cada gerador e preços de cortes de leilões anteriores;
- $P_{min(i,j)}$: Preço mínimo de atratividade do gerador i no leilão j ;
- $Q_{t+1(i,j)}(s_t, a_t)$: Função de utilidade, define o valor futuro esperado por escolher a ação a no estado s do vendedor i no leilão j ;
- γ : Taxa de aprendizagem – nestas simulações foram considerados para efeito de comparação: 0,8; 0,5 e 0,3. A ideia de ter diferentes taxas de aprendizagem se baseia na possibilidade de obter um leque maior de resultados para análises futuras e, de certa forma, calibração do modelo;
- $r(t)$: É a função de recompensa utilizada para construção da matriz de recompensas, que é melhor definida e explorada ainda nessa seção (Item “Matriz de Recompensas”);
- $(V_{t(i,j)}(s_{t+1}))$: É o valor máximo de determinado estado para todas as ações possíveis observadas ($\max Q (S_{t+1}, a)$);

A evolução do processo se dá através das relações (Equação 2) vinculadas aos preços históricos e preços mínimos de

atratividade de cada vendedor. A partir daí, os geradores escolhem a opção de adotar estratégia similar a alguma situação de seu histórico ou explorar uma situação nova. Essas opções de escolha que induzem a aprendizagem são denominadas na literatura por [36] de *Exploration or Exploitation*.

Com relação à taxa de aprendizagem, o gamma, é possível afirmar que esse parâmetro indica qual a relevância que o agente dá para a matriz Q (matriz de estados do histórico) e matriz R (a matriz de recompensas, criada a partir do histórico para cada agente) em cada tomada de decisão. Se o gamma é um valor próximo de 1, o agente considera mais a matriz Q do que a matriz R, se gamma próximo de 0, considera-se mais a matriz R na função de utilidade aplicada no algoritmo *Q-learning*.

O critério de parada desse algoritmo no modelo aqui tratado é definido pela quantidade de iterações, isto é, o número de iterações define o quanto se permite que o agente tente encontrar o melhor lance em seu histórico nas suas matrizes: estado e recompensas.

Matriz de recompensas (R)

Sejam $S_i = \{s_1^i, s_2^i, \dots, s_n^i\}$ a série histórica de n lances finais do gerador i referentes aos n leilões ocorridos, $\bar{S}_i = \{s_1^{-i}, s_2^{-i}, \dots, s_n^{-i}\}$ a série histórica de últimos preços de primeira fase dos n leilões ocorridos. A partir desses conjuntos, formam-se os conjuntos de estados e ações $E = A = S_i \cup \bar{S}_i$, assim definidos a fim de criar maior quantidade possível de pares ordenados de estados e ações para cada gerador durante a escolha de lance final neste modelo. Esses conjuntos também são necessários para definir a função de recompensas $R_i = E \rightarrow A$ que formará a matriz $m \times n$ (onde m é a cardinalidade do conjunto de estados) de recompensas do gerador i .

Assim, a matriz de recompensas terá dimensão $m \times n$, com $m = 2n$ conforme indicado na Figura 2.

estado\ação	$s_1^i = a_1$	$s_2^i = a_2$...	$s_n^i = a_n$	$\bar{s}_1^i = a_{n+1}$	$\bar{s}_2^i = a_{n+2}$...	$\bar{s}_n^i = a_{2n}$
$s_1^i = e_1$	$r_1(e_1, a_1)$	$r_1(e_1, a_2)$	$r_1(e_1, a_{2n})$
$s_2^i = e_2$	$r_1(e_2, a_1)$	$r_1(e_2, a_2)$	$r_1(e_2, a_{2n})$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
$s_n^i = e_n$	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
$\bar{s}_1^i = e_{n+1}$	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
$\bar{s}_2^i = e_{n+2}$	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
$\bar{s}_n^i = e_{2n}$	$r_1(e_{2n}, a_1)$	$r_1(e_{2n}, a_2)$	$r_1(e_{2n}, a_{2n})$

Fig. 2. Matriz de Recompensas (R). Fonte: Elaborado pelos autores.

Para finalizar a criação da matriz de recompensas (R), assume-se uma função cujo objetivo é atribuir um valor alto ao par ordenado (e_j, a_k) se $a_k > e_j$ (maximização do lucro do gerador) e um valor baixo se $a_k < e_j$ estiver próximo de a_k (redução do lucro do gerador), sendo assim, para o cálculo do valor de $r_i(e_j, a_k)$ que provém da matriz de recompensa (R), considerou-se a função de recompensas (Equação 3):

$$r_i(e_j, a_k) = \begin{cases} \frac{a_k}{e_j} & \text{se } a_k > e_j \\ 0 & \text{se } a_k = e_j \\ -\frac{a_k}{e_j} & \text{se } a_k < e_j \end{cases} \quad (3)$$

Matriz Q

O processo iterativo para o cálculo da matriz Q_i referente ao gerador i está descrito a seguir, considerando o mesmo conjunto de estados $E = \{e_1^i, e_2^i, \dots, e_j^i\}$ e ações $A = \{a_1^i, a_2^i, \dots, a_k^i\}$ utilizados para compor a matriz de recompensas. Seja $\bar{e} = P_{ref}$ o estado-objetivo e o número de iterações como sendo o critério de parada.

A matriz Q_i é construída iterativamente até que o critério de parada J seja satisfeito ou até que o estado objetivo não seja atingido:

Repita:

- Passo 1: Seleção aleatória do estado inicial $e_k \in E$;
- Passo 2: Seleção aleatória da ação $a_k \in A$;
- Passo 3: Atualização de $q_i(e_k, a_k)$ da matriz Q_i por meio da expressão $q_i(e_k, a_k) = r_i(e_k, a_k) + \gamma \cdot \max_x Q_i(a_k, x)$ em que $x \in A$;
- Passo 4: Define-se $e_{k+1} = a_k$;

Até que: $e_{k+1} = \bar{e}$ (estado atual seja igual ao estado objetivo) ou critério de parada (número de iterações) seja atendido.

VII. DEFINIÇÕES DO MODELO: LEILÕES DE ENERGIA NOVA E DE RESERVA PARA FONTE EÓLICA – HISTÓRICO

O tipo e a fonte dos leilões brasileiros são essenciais para definição de parâmetros como demanda e preço médio de um leilão, uma vez que pleitos de diferentes tipos/fontes não são realizados em conjunto. Nesse artigo, explorar-se-á os leilões de energia nova e de reserva da fonte eólica.

Historicamente, ocorreram no Brasil, de 2011 a 2015, oito leilões de energia nova (LENs) e seis leilões de energia de reserva (LERs) para fonte eólica. Os vendedores desses leilões foram agrupados em públicos e privados. Foi considerado um vendedor público, todo aquele que na sua estrutura societária tinha uma das seguintes empresas: Eletrosul Centrais Elétricas S.A.; Companhia Paranaense de Energia; Centrais Elétricas Brasileiras S.A.; Eletrobrás; CEMIG – Geração e Transmissão S.A.; Companhia Energética de Minas Gerais; Furnas Centrais Elétricas S.A.; Companhia Hidro Elétrica do São Francisco; Petrobras Petróleo Brasileiro e BNDES Participações S.A. Os vendedores privados são os que, em sua estrutura societária, não tinham nenhuma das empresas mencionadas anteriormente.

Na Figura 3 é possível observar o volume contratado (em MW médios) e o preço médio de venda dos vencedores em cada um desses pleitos. Já na Tabela 1, é possível verificar média e desvio padrão de preço e volume dos leilões, considerando a classificação dos vendedores, entre público e privado.

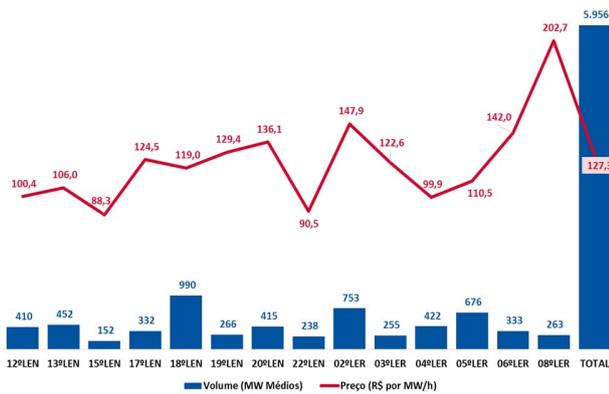


Fig. 3. Volume x preço médio comercializado por vendedores LENs e LERs de fonte eólica. Fonte: Dados públicos, elaborado pelos autores.

TABELA I
MÉDIA E DESVIO PADRÃO DE PREÇO E VOLUME CONTRATADO:
PÚBLICO X PRIVADO

Leilão	Público				Privado			
	Volume Méd.	Desv. Pad.	Preço Méd.	Desv. Pad.	Volume Méd.	Desv. Pad.	Preço Méd.	Desv. Pad.
12ºLEN	60,3	42,7	99,5	2,4	12,0	5,2	101,2	2,5
13ºLEN	12,9	8,9	106,2	2,3	28,4	24,4	105,7	3,6
15ºLEN	10,8	0,9	88,0	0,8	64,9	72,2	88,4	1,0
17ºLEN	7,7	4,6	124,2	1,6	12,4	10,0	124,7	1,3
18ºLEN	40,8	57,1	120,3	1,1	36,8	29,0	117,6	3,7
19ºLEN	18,5	-	128,9	-	17,6	10,7	129,8	0,5
20ºLEN	48,4	0,4	136,3	0,1	24,4	24,1	135,8	0,6
22ºLEN	-	-	-	-	33,9	39,4	181,0	1,2
02ºLER	22,0	30,5	145,9	8,3	10,6	3,0	149,9	3,5
03ºLER	12,2	2,8	121,8	1,6	13,0	3,1	123,4	1,8
04ºLER	10,8	3,0	99,9	0,2	20,5	19,9	99,9	1,0
05ºLER	33,5	21,4	111,4	5,7	62,3	55,4	109,5	6,0
06ºLER	38,2	28,5	142,2	2,8	43,7	35,7	141,7	1,8
08ºLER	54,2	-	203,9	-	41,6	41,6	201,4	14,0
TOTAL	23,8	36,2	122,1	17,5	23,9	31,3	130,2	24,3

Fonte: Resultados da pesquisa, elaborado pelos autores.

A fim de verificar existência de diferença de preço e volume entre vendedores públicos e privados, foi realizado um teste de média cuja a hipótese nula é a existência de igualdade das médias de preço e volume entre os vendedores públicos e privados. É possível observar na Tabela 2 que, com nível de significância de 5%, não existe diferença de volume comercializado entre vendedores públicos e privados, contudo existe diferença de preços entre esses perfis de geradores.

TABELA II
TESTE DE MÉDIA: VOLUME E PREÇO DOS LEN'S DE ENERGIA EÓLICA

Indicadores do teste	Volume		Preço	
	Público	Privado	Público	Privado
Média	23,83	23,97	122,17	130,23
Variância	1.313,95	981,05	306,98	595,10
Observações	84	165	84	165
Graus de Liberdade		147		219
Estatística do Teste		0,03		2,99
Valor-P		0,49		0,00

VIII. RESULTADOS E ANÁLISES: LEILÕES COM PARTICIPAÇÃO RELATIVA DE AGENTES PÚBLICOS E PRIVADOS FIXA

Antes de explorar os resultados obtidos e analisá-los, é importante destacar novamente que a variável observada neste trabalho são os preços pelos quais os vendedores conseguiram vender energia nos leilões históricos e as variáveis simuladas são os preços ofertados como lance final nos leilões de energia nova de fonte eólica.

As simulações realizadas foram agrupadas em blocos distintos. A ideia dessa dinâmica é a possibilidade de alterar parâmetros em um grande número de leilões simulados e obter ao final das simulações um maior número de resultados que possibilitem análises sob mais de um ponto de vista.

Foram agrupados em blocos que tentavam identificar peculiaridades ou características que diferenciavam os leilões ou como se comportavam os leilões a luz de parâmetros do simulador.

Nos blocos de simulações que são apresentados na Tabela 3, a demanda foi fixada em 425,4 MW (que consiste na média de volume comercializado nos leilões que já ocorreram – Figura 3). Se estabeleceu como critério de parada 100 ou 1000 iterações. O preço de corte (preço final da primeira fase do leilão) é igual a R\$ 167/MWh ou R\$ 127/MWh. O Gamma (Γ) é igual a 30%, 50% ou 80%. Por fim a participação dos agentes é fixa, sendo 50% público e 50% privado para todos os casos aqui apresentados.

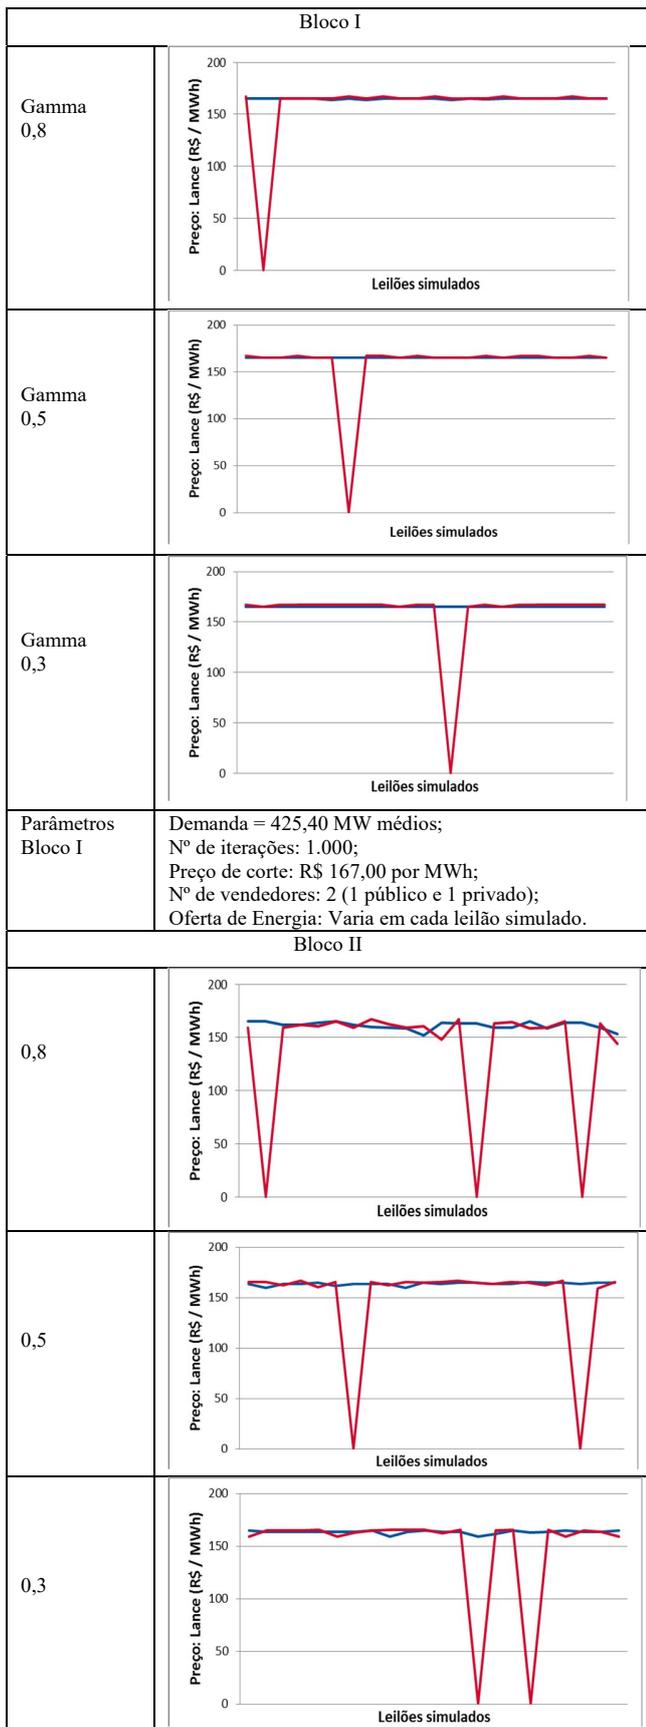
Para cada bloco foram simulados 10.000 leilões que correspondem (no mínimo) à 10.000 preços mínimos de atratividade de um gerador i de mercado. Tal preço foi gerado para cada vendedor de forma aleatória, através de distribuição normal. Por exemplo, um leilão do bloco I tem como entrada a demanda, a quantidade de iterações, o preço de corte, o número de geradores e seus respectivos preços mínimos de atratividade (aleatório para cada uma das 10 mil simulações), capacidade máxima de geração e a taxa de aprendizagem (nas simulações consideramos 30, 50 e 80%). Como saída obtém-se os preços finais dos leilões para cada gerador.

TABELA III
DEFINIÇÃO DOS PRIMEIROS BLOCOS PARA SIMULAÇÕES

Blocos	Demanda (MW Médio)	Nº Iterações	Preço de corte (R\$ / MWh)	Nº Geradores	Part. (%) relativa de vendedores (Público x Privado)	Gamma
I		1.000				Em cada bloco foram
II		100	167		50%	considerados
III	425,4	1.000		2	Público x 50%	três gamas
IV		100	127		Privado	distintos: 0,8; 0,5 e 0,3

Fonte: Elaborado pelos autores.

Gráficos apresentados na Figura 4 consideram os dados dos blocos I e II definidos na Tabela 3. Nesse conjunto de gráficos, verifica-se o comportamento dos preços dos vendedores públicos e privados nos cinquenta últimos leilões de cada conjunto de 10.000 simulações.



Parâmetros Bloco II	Demanda = 425,40 MW médios; Nº de iterações: 100; Preço de corte: R\$ 167,00 por MWh; Nº de vendedores: 2 (1 público e 1 privado); Oferta de Energia: Varia em cada leilão simulado.
Legenda: — Público — Privado	

Fig. 4. Resultados da simulação: Blocos I e II.

É possível observar que em alguns leilões o preço de lance ofertado foi zero (isso ocorreu em todos os casos que o preço mínimo de atratividade era maior que o preço de corte do leilão simulado).

Foram realizados testes de igualdade de média e do desvio padrão [40] com objetivo de comparar os dados observados (dados divulgados pela CCEE [1]), com os resultados simulados neste trabalho, isto é, as variáveis predictoras com as observadas.

Na Tabela 4, é possível observar os resultados para o teste z e o teste de desvio padrão. Além disso, são apresentadas as médias e os desvios padrão de cada vetor resultante das simulações.

TABELA IV
RESULTADOS DAS SIMULAÇÕES: TESTES DE MÉDIA E DESVIO PADRÃO

Perfil do Agente	Bloco	Vetores testados	Média	Desv. Pa.	Teste Média Valor P (%)	Teste Des. Pad. Valor P (%)
Público	I	1_Púb_3	165,0	0,3	0,0	0,0
		2_Púb_3	165,2	0,2	0,0	0,0
		3_Púb_3	165,2	0,2	0,0	0,0
		4_Púb_3	161,5	3,1	0,0	0,0
	II	5_Púb_3	164,0	1,1	0,0	0,0
		6_Púb_3	164,1	1,0	0,0	0,0
		7_Púb_3	126,4	0,1	0,0	0,0
	III	8_Púb_3	126,5	0,0	0,0	0,0
		9_Púb_3	126,5	0,0	0,0	0,0
	IV	10_Púb_3	125,3	2,1	0,0	0,0
		11_Púb_3	125,6	1,8	0,0	0,0
		12_Púb_3	126,3	0,4	0,0	0,0
Privado	I	1_Pri_3	165,9	0,8	0,0	0,0
		2_Pri_3	166,3	0,6	0,0	0,0
		3_Pri_3	166,4	0,5	0,0	0,0
		4_Pri_3	161,3	3,5	0,0	0,0
	II	5_Pri_3	164,4	1,6	0,0	0,0
		6_Pri_3	164,5	1,7	0,0	0,0
		7_Pri_3	126,3	0,1	0,0	0,0
	III	8_Pri_3	126,4	0,0	0,0	0,0
		9_Pri_3	126,4	0,0	0,0	0,0
	IV	10_Pri_3	125,4	1,4	0,0	0,0
		11_Pri_3	125,7	1,0	0,0	0,0
		12_Pri_3	126,2	0,2	0,0	0,0

Fonte: Resultados da pesquisa, elaborado pelos autores

Para todos os testes realizados, seja de média ou desvio padrão, é possível inferir a existência de desigualdade entre os preços de lances simulados e os reais (que provêm dos dados históricos).

Vale a pena ressaltar que a desigualdade encontrada nos testes pode estar vinculada à inexistência de divulgação do

preço de corte (preço final da primeira fase dos leilões) por parte do governo do Brasil, já que essa variável está diretamente correlacionada com a estratégia de lances simulados. Além disso, é possível perceber a seriedade do problema da não divulgação das informações do leilão por parte do governo brasileiro, uma vez que o preço de corte da primeira fase dos leilões é uma variável importante e que afeta o resultado dos leilões no modelo [41].

IX. RESULTADOS E ANÁLISES: LEILÕES COM PARTICIPAÇÃO RELATIVA DE AGENTES PÚBLICOS E PRIVADOS VARIÁVEL

Conforme verificado anteriormente, existe diferença de preço médio entre os agentes públicos e privados nos leilões históricos (Tabela 2). Por isso, outros cinco blocos de simulações foram construídos e para cada um desses diferentes leilões foram simulados. A Tabela 5 apresenta os parâmetros que distinguem esses blocos. O objetivo da realização dessas novas simulações (blocos V, VI, VII, VIII e IX) é investigar o comportamento do preço médio final da energia quando o perfil dos vendedores é diferente.

TABELA V
PARÂMETROS PARA DEFINIÇÃO DE NOVOS BLOCOS DE SIMULAÇÕES

Blocos	Demanda (MW médio)	Nº de iterações	Preço corte (R\$/MWh)	Nº geradores	Part % relativa (Público x Privado)	Gamma
V				2	100% Público	
VI				2	100% Privado	
VII	425,4	1	127	2	50% Público e 50% Privado	0,8
VIII				4	75% Público e 25% Privado	
IX				4	25% Público e 75% Privado	

Fonte: Resultados da pesquisa, elaborado pelos autores

A Figura 5 apresenta os gráficos que descrevem os preços médios de vendedores públicos e privados nos blocos V, VI, VII, VIII e IX.

Foram realizados testes de média para analisar se os valores médios de preço da energia elétrica são maiores quando a participação relativa dos vendedores privados aumenta em relação à de vendedores públicos.

No primeiro teste considera-se a hipótese de que o preço médio dos leilões que só tem geradores privados é maior do que quando só há geradores públicos. No segundo, a hipótese nula é de que o preço médio nos leilões que têm 75% dos geradores privados é maior do que quando se tem 50% dos vendedores privados. Por fim, a hipótese nula do último teste é de que o preço médio quando se tem 25% de geradores privados em um leilão é maior do que quando se têm 100% de vendedores público.

A partir dos resultados observados nas Tabela 6 é possível concluir, com nível de significância de 5%, que o preço médio da energia aumenta quando a participação relativa de vendedores privados é maior que a de vendedores públicos.

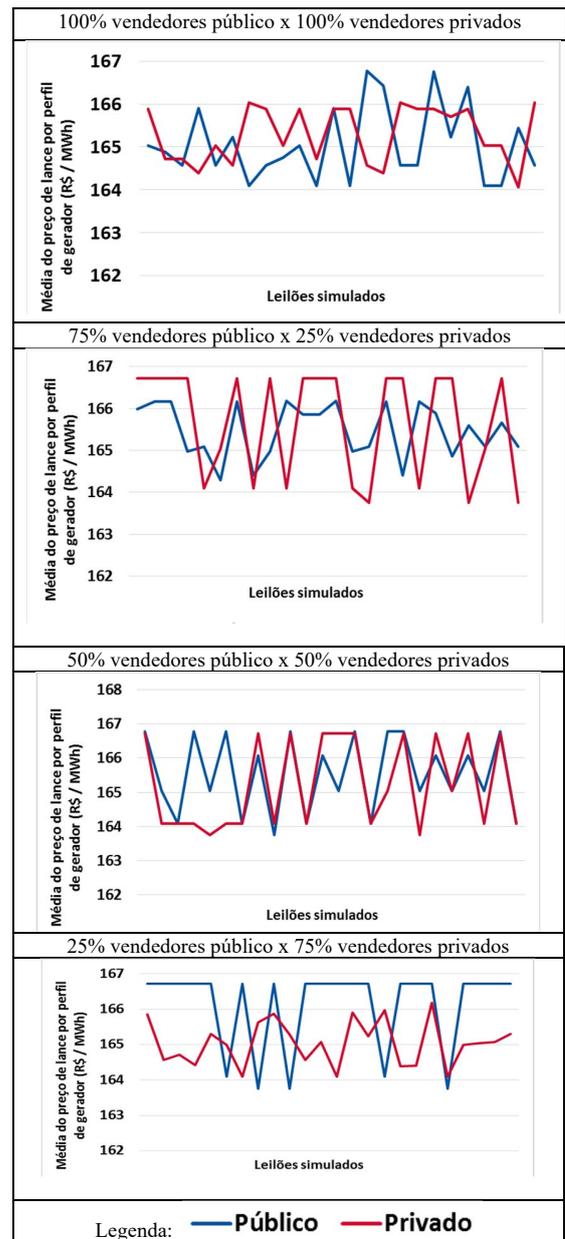


Fig. 5. Preços médios: Considerando part. (%) relativa de vendedores. Fonte: Resultados da pesquisa, elaborado pelos autores.

TABELA VI
TESTE DE MÉDIA: VENDEDORES PÚBLICOS X PRIVADOS

Blocos teste	Hipóteses testadas	Média	Estat. do teste (t)	Valor - P
VI x V	H0: Preço (100% geradores privados) = 165,06	165,00	2,81	0,00
	H1: Preço (100% geradores privados) > 165,06			
IX x VII	H0: Preço (75% geradores privados) = 165,31	165,31	1,93	0,02
	H1: Preço (75% geradores privados) > 165,31			
VIII x V	H0: Preço (25% geradores privados) = 165,06	165,31	11,09	0,00
	H1: Preço (25% geradores privados) > 165,06			

Fonte: Resultados da pesquisa, elaborado pelo autor.

X. CONCLUSÃO

Ao projetar um ABM, do ponto de vista prático é necessário conhecer os costumes dos agentes envolvidos e o ambiente nos quais os mesmos estão inseridos, ou seja, a fundamentação dessa técnica está centrada, em geral, nos processos econômicos de cada problema. Contudo, as soluções são apresentadas, a rigor, em linguagem computacional, matemática e estatística.

O objetivo do estudo desse trabalho foi construir um ABM para o ACR no mercado brasileiro de energia, com o intuito de compreender o processo de precificação e verificar a variabilidade de preços de energia com relação à participação de agentes públicos ou privados nos leilões.

As simulações realizadas possibilitaram analisar informações relevantes sobre a dinâmica dos leilões praticados sob o simulador desenvolvido. O comportamento dos preços da energia eólica que provém de leilões de energia nova e de energia de reserva foi exaustivamente estudado.

Através das inferências estatísticas aqui realizadas, é possível afirmar que preço e volumes simulados são diferentes de preços e volumes observados, tal diferença pode estar vinculada à falta de informações disponibilizadas por parte do governo brasileiro. Essa indisponibilidade de dados interfere nos resultados deste trabalho que poderia indicar políticas mais justas para comercialização, além disso, possibilitaria validar o modelo aqui criado.

Outra conclusão importante desta pesquisa diz respeito ao comportamento do preço médio da energia vinculado ao perfil das empresas (público e privado) participantes dos leilões. Foi possível verificar a existência de diferença entre preços dos vendedores públicos e privados. Além disso, através do modelo baseado em agentes foi possível concluir que quanto maior o número de agentes privados em um leilão maior será o preço médio da energia deste pleito.

Mais uma vez, vale a pena ressaltar a quase inexistência de divulgação de dados dos leilões brasileiros, por parte do governo. Essa insuficiência de dados acarreta na provável dificuldade de validação do modelo aqui estruturado. Contudo, essa investigação de aderência do simulador, bem como a análise de precificação de outras fontes e tipos de energia (nos leilões) pode ser estudada em pesquisas futuras, considerando variantes do algoritmo proposto que permita a simulação em outros mercados de energia, que têm design de leilão diferente do brasileiro. E, como já mencionado ao longo de todo esse trabalho, a construção de ABM é limitado pelo objetivo da pesquisa e pela capacidade de incorporar variáveis ao modelo, portanto, há um vasto campo de opções a serem exploradas através desta técnica.

REFERENCES

- [1] B. CCEE, "Camara de comercializacao de energia elétrica - historico de leiloes", Acesso em Maio de 2019.
- [2] J. M. G. Palomino, "Formação de preço de energia elétrica gerada por biomassa no Ambiente de Contratação Livre brasileiro: uma abordagem computacional baseada em agentes". PhD thesis, Universidade de São Paulo, Ribeirão Preto, São Paulo, 4 2009.
- [3] E. Guerci and A. Sapio, "High wind penetration in an agent-based model of the electricity market", *Revue de l'OFCE*, vol. 124, p. 415, 11 2012.
- [4] L. F. Sugianto and L. Kevin, "Comparison of different auction pricing rules in the electricity market", *Modern Applied Science*, vol. 8, pp. 147-163, 1 2014.
- [5] E. Guerci, A. Kirman, and S. Moulet, "An agent-based model for sequential Dutch auctions," post-print, HAL, Dec. 2013.
- [6] Lebaron B., Agent-based computational nance," in *Handbook of Computational Economics* (L. Tesfatsion and J. K.L., eds.), pp. 1187-1233, Amsterdam: Elsevier Science, 2006.
- [7] L. Tesfatsion and K. Judd, eds., *Handbook of Computational Economics*, vol. 2. Elsevier, 1 ed., 2006.
- [8] T. Zhang and D. Zhang, "Agent-based simulation of consumer purchase decision-making and the decoy e effect," *Journal of Business Research*, vol. 60, pp. 912-922, August 2007.
- [9] L. T. A. Maurer and L. A. Barroso, "Electricity Auctions : An Overview of Efficient Practices". No. 2346 in *World Bank Publications*, The World Bank, January 2011.
- [10] V. Krishna, "Auction Theory". Elsevier, 1 ed., 2002.
- [11] L. M. Ausubel, P. Cramton, and P. Milgrom, "The Clock-Proxy Auction: A Practical Combinatorial Auction Design," University of Maryland, Department of Economics, 2006.
- [12] P. Klemperer, "What Really Matters in Auction Design," *Journal of Economic Perspectives*, vol. 16, pp. 169-189, Winter 2002.
- [13] E. E. Rego and V. Parente, "Brazilian experience in electricity auctions: Comparing outcomes from new and old energy auctions as well as the application of the hybrid anglo-dutch design," *Energy Policy*, vol. 55, no. C, pp. 511-520, 2013.
- [14] B. ONS, "Operador nacional do sistema - histórico de operações," Acesso em 05/2019.
- [15] R. Axtell, "Why agents ? on the varied motivations for agent computing in the social sciences," *Center on Social and Economic Dynamics*, no. 17, 2000.
- [16] C. M. Macal and M. J. North, "Tutorial on agent-based modelling and simulation," *Journal of Simulation*, vol. 4, pp. 151-162, Sep 2010.
- [17] M. Rasanen, R. P. Hamalainen, and J. Ruusunen, "Visual interactive modelling in electricity load analysis", 13a International Conference of International Association of Science and Technology for development (IASTED) - Modelling identification and control, pp. 339-342, 1994.
- [18] K. Raya, Gaxiola, C. G., Castanon, M. "Modelo Basado en Agentes para la Auto-Gestión de Flujos de Red utilizando Negociación". *IEEE Latin America Transactions*, vol. 16, pp. 3731-3737, Jan 2018.
- [19] O. Kraan, G.J. Kramer, I. Nikolic. "Investment in the future electricity system - An agent-based modelling approach". *Energy*, Volume 151, 2018, Pages 569-580, ISSN 0360-5442.
- [20] V. Anatolitis, M. Welisch, Putting renewable energy auctions into action – An agent-based model of onshore wind power auctions in Germany, *Energy Policy*, Volume 110, 2017, Pages 394-402, ISSN 0301-4215.
- [21] T. Novosel, L. Perković, M. Ban, H. Keko, T. Pukšec, G. Krajačić, N. Duić, Agent based modelling and energy planning – Utilization of MATSim for transport energy demand modelling, *Energy*, Volume 92, Part 3, 2015, Pages 466-475, ISSN 0360-5442.
- [22] C. Richter Jr, G. Sheble, and D. Ashlock, "Comprehensive bidding strategies with genetic algorithm/finite state automata," *Power Systems*, *IEEE Transactions on*, vol. 14, pp. 1207-1212, 12 1999.
- [23] A. E. Roth and I. Erev, "Learning in extensive-form games: Experimental data and simple dynamic models in the intermediate term," *Games and Economic Behavior*, vol. 8, no. 1, pp. 164-212, 1995.
- [24] I. Erev and A. E. Roth, "Predicting how people play games: Reinforcement learning in experimental games with unique, mixed strategy equilibria," *The American Economic Review*, vol. 88, no. 4, pp. 848-881, 1998.
- [25] G. Xiong, T. Hashiyama, and S. Okuma, "An electricity supplier bidding strategy through q-learning," in *IEEE Power Engineering Society Summer Meeting*, vol. 3, pp. 1516-1521 vol.3, July 2002.
- [26] X. Sui and H.-f. Leung, "A q-learning based adaptive bidding strategy in combinatorial auctions," *ACM International Conference Proceeding Series*, 08 2009.
- [27] J. Wang, V. Koritarov, and J.-H. Kim, "Cap and Trade Modeling in Electricity Markets Using an Agent-Based Approach", pp. 71-87. 03 2012.
- [28] R. Bellman, "Dynamic programming and stochastic control processes," *Information and Control*, vol. 1, no. 3, pp. 228-239, 1958.
- [29] C. J. C. H. Watkins, "Learning from Delayed Rewards". PhD thesis, King's College, Cambridge, UK, May 1989.
- [30] C. J. C. H. Watkins and P. Dayan, "Q-learning," *Machine Learning*, vol.

- 8, pp. 279-292, May 1992.
- [31] A. B. Pereira, "Q-Learning pessimista: um algoritmo para geração de bots de jogos em turnos". PhD thesis, PUC - Pontifícia Universidade Católica, Rio de Janeiro, Brasil, July 2012.
- [32] W. Y. Kwon, I. H. Suh, and S. Lee, "Sspql: Stochastic shortest path-based q-learning," *International Journal of Control, Automation and Systems*, vol. 9, pp. 328-338, Apr 2011.
- [33] E. Pakizeh, M. Palhang, and M. Mohsen Pedram, "Multi-criteria expertness based cooperative q-learning," *Applied Intelligence*, vol. 39, 07 2013.
- [34] L. Korsos and N. G. Polson, "Analyzing risky choices: Q-learning for deal-no-deal," *Applied Stochastic Models in Business and Industry*, vol. 30, no. 3, pp. 258-270, 2014.
- [35] A. Galindo-Serrano and L. Giupponi, "Self-organized Femtocells: a Fuzzy Q-Learning Approach," accepted for publication in *Wireless Networks*, Springer, vol. 20, pp. 441-445, Apr. 2014.
- [36] G. Xiong, T. Hashiyama, and S. Okuma, "A supplier bidding strategy through qlearning algorithm in electricity auction markets," *Iceej Transactions on Electronics, Information and Systems*, vol. 123, pp. 1134-1141, 01 2003
- [37] H. Pouyllau and G. Caroglio, "Inter-carrier sla negotiation using q-learning," *Telecommunication Systems - TELSIS*, vol. 52, pp. 1-12, 06 2011.
- [38] A. Gosavi, "Reinforcement learning: A tutorial survey and recent advances," *INFORMS Journal on Computing*, vol. 21, no. 2, pp. 178-192, 2009.
- [39] S. T. Monteiro and C. H. C. Ribeiro, "Desempenho de algoritmos de aprendizagem por reforço sob condições de ambiguidade sensorial em robótica móvel," *Sba: Controle Automação da Sociedade Brasileira de Automatica*, vol. 15, pp. 320-338, 09 2004.
- [40] D. Montgomery, "Estatística aplicada e probabilidade para engenheiros". Livros Técnicos e Científicos, 2003.
- [41] A. B. A. Amaral, A. L. Z. L. G. Mendonca, A. A. M. Resende, and E. E. Rego, "Solar energy and distributed generation: 2015, a year of inflection in brazil?," *IEEE Latin America Transactions*, vol. 14, pp. 3731-3737, Aug 2016.



Celma de Oliveira Ribeiro é Professora Assistente na Escola Politécnica da Universidade de São Paulo (USP). Celma tem doutorado em Engenharia de Produção, Mestrado em Matemática Aplicada e Bacharelado em Ciências da Computação, todos títulos foram obtidos na Universidade de São Paulo (USP). Celma também trabalhou em um Pós-Doutorado na Universidade do Porto em Portugal.



Erik Eduardo Rego é Professor Assistente na Escola Politécnica da Universidade de São Paulo (USP). Erik tem Doutorado e Mestrado em Energia, Bacharelado em Engenharia de Produção e outro em Economia. Todos títulos obtidos na Universidade de São Paulo (USP).



Marcos Roberto Machado é atualmente estudante de doutorado do programa de Modelagem e Ciências da Computação na Universidade de Ontario Instituto de Tecnologia (UOIT), em Oshawa, ON, Canada. Possui mestrado em Engenharia de Produção pela Universidade de São Paulo, São Paulo, SP, Brasil (2016). Marcos tem Licenciatura em Matemática

pelo Instituto Federal de Educação, Ciências e Tecnologia do Ceará (IFCE), Fortaleza, CE, Brasil (2009). Interesses de pesquisa são relacionados a economia da energia, machine learning, modelagem matemática e estatística.



Murilo Kenichi Fujii é Engenheiro de Produção, formado pela Universidade de São Paulo (USP), São Paulo, SP, Brasil. Murilo tem interesse em pesquisas que envolvam modelagem matemática e estatística e métodos de otimização no setor de energia.