

GRUPO DE ESTUDO DE COMERCIALIZAÇÃO, ECONOMIA E REGULAÇÃO DO MERCADO DE ENERGIA ELÉTRICA - GCR

SIMULADOR DE LONGO PRAZO PARA MERCADOS HIDROTÉRMICOS BASEADOS EM OFERTAS COM ESTUDOS DE CASO NO SISTEMA BRASILEIRO

JOAQUIM DIAS GARCIA (1,2); ALEXANDRE STREET DE AGUIAR (2);
GABRIEL ROCHA DE ALMEIDA CUNHA (1); MARIO VEIGA FERRAZ PEREIRA (1);
PSR SOLUÇÕES E CONSULTORIA EM ENERGIA LTDA (1); PUC-RIO (2)

RESUMO

A representação de agentes estratégicos considerando restrições intertemporais e incertezas traz complexidade adicional para o problema de oferta ótima. Propomos um simulador que aborda efetivamente esses desafios para sistemas hidrotérmicos larga-escala. Demonstramos a eficácia da metodologia em estudos de casos com dados reais do Brasil. Mostramos os efeitos da concentração de mercado, como contratos podem ser usados para mitigá-los e como o poder de mercado pode afetar a configuração atual no Brasil. O método desenvolvido pode beneficiar significativamente formuladores de políticas, monitores e designers de mercado, pois as simulações podem ser usadas para entender sistemas existentes e experimentar políticas alternativas.

PALAVRAS-CHAVE

Simulador de sistema de potência, Oferta estratégica, SDDP, Despacho hidrotérmico, Poder de mercado, Contratos

1.0 INTRODUÇÃO

A energia hidrelétrica é uma das fontes de energia mais amplamente utilizadas em todo o mundo e a fonte de energia renovável mais utilizada, responsável por mais de quatro mil TWh por ano, de acordo com a Agência Internacional de Energia (IEA, 2022). Muitos países dependem de usinas hidrelétricas para uma parcela significativa de sua geração, mas alguns países têm a energia hidrelétrica como sua principal fonte de energia, como o Brasil, a Nova Zelândia, a Colômbia e a Noruega. A operação de sistemas com grande penetração de energia hidrelétrica é muito desafiadora, uma vez que os reservatórios são dispositivos de armazenamento que criam um forte acoplamento temporal e vazões são variáveis aleatórias. O *framework* de Otimização Estocástica Multiestágio (MSO, do inglês *Multi-Stage Stochastic Optimization*) é o *framework* mais utilizado para lidar com esse tipo de problema, e o algoritmo fundamental é a Programação Dinâmica Dual Estocástica (SDDP, do inglês *Stochastic Dual Dynamic Programming*), que foi motivado pela operação centralizada de sistemas de energia hidrotérmica baseada em custo (PEREIRA, 1991). As mudanças na regulamentação dos sistemas de energia nas últimas décadas levaram à criação de mercados de energia liberalizados baseados em ofertas, incluindo os mercados hidrotérmicos. Uma nova variante do SDDP que combina ideias de discretização do *Stochastic Dynamic Programming* (SDP) menos escalável foi desenvolvida em (GJELSVIK, 1999) para o uso de participantes do mercado que desejam incorporar incertezas de preço em seus despachos e decisões de ofertas. Esta última também é conhecida como SDDP Markoviano.

O problema de ofertas para sistemas hidrotérmicos é revisado em (STEEGER, 2014), que classifica o problema em duas variantes principais, dependendo se o ofertante é um tomador de preço ou um formador de preço. Um tomador de preço, ou agente não estratégico, é um agente que é pequeno demais para afetar os preços de mercado com mudanças em sua operação ou um agente grande que não deseja fazê-lo. Por outro lado, um formador de preço, ou agente estratégico, é um agente que pode alterar os preços alterando sua operação, o que também é conhecido como poder de mercado. A revisão também contrasta a versão hidrotérmica do problema, que inclui tanto o acoplamento temporal quanto a incerteza, com a versão puramente térmica do problema, onde o acoplamento temporal é ignorado e as incertezas frequentemente são desconsideradas. Uma conclusão fundamental é que as versões do problema para tomadores de preço estão resolvidas na literatura, uma vez que os geradores térmicos oferecerão seus custos operacionais variáveis (GROSS, 2000). Enquanto isso, os agentes hidrelétricos farão ofertas com base em seus custos marginais da água, que podem ser vistos a partir da perspectiva do operador (PEREIRA, 1991) ou da perspectiva do agente (GJELSVIK, 1999). Por outro lado, as versões do problema para formadores de preço são muito mais difíceis de serem tratadas computacionalmente. A simulação do comportamento de um único agente térmico formador de preço pode ser feita usando a otimização binível (STEEGER, 2014), onde o líder é um

formador de preço, também conhecido como licitante estratégico, e o problema do seguidor representa a minimização de custos do despacho de mercado. Uma extensão desse framework para o caso de agentes estratégicos puramente hidrelétricos, onde o restante do mercado é puramente térmico, foi desenvolvida no trabalho seminal (FLACH, 2010). Este último incorpora um programa binível no algoritmo SDDP, mas convexifica cada subproblema para seguir as suposições do SDDP. Uma variante do método anterior foi proposta em (STEEGER, 2017), que lida com a natureza não convexa do subproblema com relaxação Lagrangiana combinada com o SDDP.

Ainda mais desafiadora é a simulação de múltiplos agentes atuando como formadores de preço em um mercado. Um dos principais frameworks é a teoria dos jogos. Por exemplo, no caso puramente térmico, (BARROSO, 2006) modela a versão térmica como um equilíbrio de Nash usando as condições KKT da operação do mercado e expansões binárias para otimizar uma aproximação do problema numérico com resolvidores MIP. Novamente, o caso hidrotérmico é mais desafiador. Um dos primeiros trabalhos na literatura, (SCOTT, 1996), modela um problema com dois pequenos reservatórios e 10 usinas em um esquema chamado de Programação Dinâmica Dual (diferente do trabalho de (PEREIRA, 1991)), onde cada subproblema é um duopólio de Cournot. Em seguida, (KELMAN, 2021) desenvolveu um esquema de SDP para melhor considerar o efeito de estocasticidade em um problema com 2 hidros e 23 térmicas. Nos dois trabalhos, contratos são testados para mitigar o poder de mercado. (VILLAR, 2003) utiliza programação dinâmica determinística para simular 3 agentes (mas apenas 2 com reservatórios) em um mercado de curto prazo. Na última referência, os subproblemas de um único estágio são resolvidos com um esquema iterativo, também chamado de diagonalização na literatura. Mais recentemente, (STEEGER, 2015) utiliza uma estratégia de programação dinâmica determinística para simular o comportamento de dois reservatórios hidrelétricos competindo, onde cada estágio requer a solução de um MIP que busca pontos de equilíbrio de Pareto ótimos. (LÖSCHENBRAND, 2018) resolve o problema com um esquema de programação dinâmica modificado que leva em conta a incerteza, com 15 cenários, e resolve um subproblema de três agentes iterativamente para aproximar a decisão de comprometimento, enquanto o equilíbrio em cada estágio é modelado como um MIP semelhante a (BARROSO, 2006). Finalmente, (WU, 2020) utiliza a Programação Dinâmica Estocástica de Amostragem (SSDP, do inglês *Sample Stochastic Dynamic Programming*), em que os subproblemas de estágio são resolvidos por meio de diagonalização.

O segundo grupo de métodos usados para simular a interação entre múltiplos agentes formadores de preço em um mercado hidrotérmico não usa programação dinâmica para decompor o problema. Consequentemente, esses métodos são usados para análises de curto prazo ou médio prazo com poucos estágios temporais. (BUSHNELL, 2003) é um trabalho seminal no assunto, que modela o problema de competição multiestágio em um Programa de Equilíbrio com Restrições de Equilíbrio (em inglês, *Equilibrium Problem with Equilibrium Constraints*, EPEC) monolítico derivado das condições KKT e resolve uma instância de 7 estágios com um *solver* EPEC. (ALMEIDA, 2013) também modela o problema como um EPEC e resolve instâncias menores com um *solver* EPEC, mas o problema de 1 ano com 4 cenários é resolvido via diagonalização. Da mesma forma, (CRUZ, 2016) resolve um problema de 24 horas com 7 jogadores modelando um EPEC e resolvendo-o por diagonalização.

A literatura mencionada acima deixa claro que simular múltiplos agentes em um mercado hidrotérmico de longo prazo baseado em licitações é extremamente desafiador, pois é necessário lidar com múltiplos estágios, incerteza e interação de vários agentes, o que leva a problemas não convexos. Consequentemente, a maioria dos trabalhos limita fortemente o número de estágios, agentes ou cenários. Embora, na teoria, alguns dos métodos acima possam lidar com todas essas características as simulações são feitas em problemas pequenos.

As principais contribuições deste trabalho são:

1. Desenvolver uma metodologia que possa lidar, ao mesmo tempo, com vários estágios, agentes e cenários de incerteza. Essa metodologia será baseada na resolução de problemas de oferta estratégica estocástica multiestágio para cada agente estratégico, enquanto o acoplamento entre agentes é obtido por um procedimento iterativo baseado na diagonalização.
2. Analisar as sensibilidades da competição entre múltiplos agentes com diferentes participações de mercado.
3. Analisar como os contratos podem afetar as simulações de mercado como uma estratégia de mitigação para o poder de mercado.
4. Simular a competição de múltiplos agentes formadores de preço no sistema brasileiro com dados reais.

O restante deste trabalho está organizado da seguinte forma: A Seção 2.0 introduz a notação básica descrevendo um modelo centralizado para sistemas de energia hidrotérmica. A Seção 3.0 descreve a otimização de um único agente formador de preço e destaca como incorporar contratos. A Seção 4.0 detalha um algoritmo para combinar os modelos detalhado anteriormente e simular mercados hidrotérmicos de longo prazo com a presença de múltiplos agentes estratégicos. A Seção 5.0 apresenta estudos de caso para testar o algoritmo proposto e simula um caso real do sistema de energia brasileiro. A Seção 6.0 expõe as principais conclusões.

2.0 DESPACHO HIDROTÉRMICO

O despacho do sistema de energia hidrotérmica é um problema muito complexo, pois é um problema de otimização estocástica multiestágio que inclui muitas restrições físicas e relacionadas a políticas. Apresentamos um modelo de otimização simples, porém geral, que possui todas as principais características necessárias no simulador de mercado proposto neste trabalho. Descrevemos o problema na forma de uma recursão de Bellman, como em (PEREIRA, 1991). Portanto, as equações (1)-(7) apresentam a função objetivo e as restrições de um determinado estágio t e evento aleatório ω_t . O índice t é omitido na maioria das variáveis quando facilmente compreendido pelo contexto, visando uma notação mais leve.

$$\tilde{B}^t(\mathbf{v}^t, \mathbf{a}^{[t-1]}, \omega^t) = \min \sum_{j \in J^G} C_j g_j + E_{\omega^{t+1}}[\tilde{B}^{t+1}(\mathbf{v}^{t+1}, \mathbf{a}^{[t]}, \omega^{t+1})] \quad (1)$$

$$s. a. \sum_{j \in J^G} g_j + \sum_{j \in J^H} \rho_j(u_j) + \sum_{j \in J^R} r_j = D \quad (2)$$

$$v_j^{t+1} = v_j^t - u_j - z_j + \sum_{n \in J^U(j)} (u_n + z_n) + a_j^t, \quad \forall j \in J^H \quad (3)$$

$$0 \leq v_j \leq V_j, \quad 0 \leq u_j \leq U_j, \quad 0 \leq z_j, \quad \forall j \in J^H \quad (4)$$

$$0 \leq g_j \leq G_j, \quad \forall j \in J^G \quad (5)$$

$$0 \leq r_j \leq \tilde{R}_j(\omega^t), \quad \forall j \in J^R \quad (6)$$

$$a_j^t = \sum_{l \in L} \phi_j a_j^{t-l} + \tilde{\varepsilon}_j(\omega^t), \quad \forall j \in J^H \quad (7)$$

A primeira equação, (1), afirma que o custo futuro do estágio $t - 1$, ou seja, \tilde{B}^t , dados os estados \mathbf{v}^t , $\mathbf{a}^{[t-1]}$ e o evento aleatório ω^t , é definido como a minimização do problema (1)-(7), cuja função objetivo pode ser dividida em duas partes. A primeira parte é o custo imediato na forma de um custo térmico (custo, C_j , vezes a geração, g_j , para todas as térmicas no conjunto J^G), enquanto a segunda parte é o valor esperado do custo futuro \tilde{B}^{t+1} , com $\tilde{B}^{|T|+1} = 0$, onde $|T|$ é o total de etapas. A equação (2) representa o balanço de carga do sistema: D é a demanda, $\rho_j(u_j)$ é a geração hídrica com função do turbinamento, para todas as hidros do conjunto J^H e r_j é a geração de cada renovável no conjunto J^R . A demanda é considerada determinística para simplificar os desenvolvimentos, mas tudo o que segue pode ser facilmente estendido para o caso de demanda estocástica. A equação (3) descreve o balanço de massa de água: o armazenamento no final do estágio, v_j^{t+1} , é igual ao armazenamento no início, v_j^t , menos o turbinamento, u_j , e vertimento, z_j , da usina, mais a soma do turbinamento e vertimento do conjunto de usinas diretamente a montante da usina j , $J^U(j)$, mais a afluência a_j^t . A equação (4) impõe um limite mínimo de zero e máximo de V_j ao armazenamento hidrelétrico; limite mínimo de 0 e máximo de U_j ao fluxo da turbina e limite mínimo de zero ao vertimento. A equação (5) limita a geração térmica entre 0 e uma capacidade máxima G_j e a equação (6) limita a geração renovável entre 0 e o limite estocástico $\tilde{R}_j(\omega^t)$, dependendo do sol e do vento. Por fim, a equação (7) descreve o processo estocástico autorregressivo de vazões (PEREIRA, 1991).

Podemos aplicar o algoritmo SDDP neste problema multiestágio estocástico, para mais detalhes ver (DIAS GARCIA 2022). Em uma descrição de alto nível, o algoritmo SDDP começa amostrando um cenário para cada etapa $t \in T$, em seguida, resolve os subproblemas de cada estágio em ordem cronológica, gerando uma solução viável (uma operação candidata), o que é chamado de passo *forward*. Depois disso, no chamado *backward*, os problemas são resolvidos na ordem inversa do tempo, gerando cortes para melhorar a representação da função de custo futuro (FCF) e, assim, propagando informações do futuro para o presente. Essas etapas são repetidas até que um critério de parada especificado seja atingido. Esse processo também é conhecido como otimização da política operativa (ou treinamento). Para obter detalhes sobre o algoritmo SDDP, o leitor é direcionado a (PEREIRA, 1991). Após a convergência, é comum prosseguir com uma última etapa *forward* em que amostramos cenários $s \in S$, e para cada um deles, resolvemos todos os subproblemas de estágio em ordem cronológica. Esse último procedimento é conhecido como simulação e resulta no que chamamos de solução primal (e dual) para cada variável e restrição. Em outras palavras, terminamos com valores para cada estágio em T e cenário amostrado em S para todas as variáveis de otimização. No caso de volumes, descrevemos esse conjunto de vetores de volumes como $\{\mathbf{v}_{t,s}\}_{t \in T, s \in S}$. Para o caso de preços spot, ou seja, a variável dual associada ao balanço de carga, (2), representaremos como $\Pi = \{\pi_{t,s}\}_{t \in T, s \in S}$, o que significa que temos soluções para cada cenário amostrado $s \in S$ e estágio $t \in T$.

Nesta seção, focamos nossa apresentação no caso de valor esperado por simplicidade. No entanto, tudo o que foi escrito acima, assim como nas próximas seções, se aplica a outras medidas de risco que podem ser representadas no esquema SDDP (DOWSON, 2022). Outra simplificação neste trabalho é considerar a função $\rho(\cdot)$, em (2), como uma função linear, embora modelos não lineares também possam ser usados com aproximações para satisfazer os requisitos do SDDP (FREDO, 2019).

3.0 AGENTES ESTRATÉGICOS

A otimização de um agente independente também pode ser modelada como um problema de otimização estocástica em múltiplos estágios. Foi modelado e primeiramente resolvido com o SDDP em (FLACH, 2010). O modelo (8)-(14) a seguir representa a otimização de um agente individual i e é muito similar ao modelo centralizado (1)-(7).

$$\tilde{B}^t(\mathbf{v}_i^t, \mathbf{a}_i^{[t-1]}, \omega^t) = \min -\tilde{\Lambda}(e, \omega^t) + \sum_{j \in J_i^G} C_j g_j + E_{\omega^{t+1}} [\tilde{B}^{t+1}(\mathbf{v}_i^{t+1}, \mathbf{a}_i^{[t]}, \omega^{t+1})] \quad (8)$$

$$s. a. \quad e = \sum_{j \in J_i^G} g_j + \sum_{j \in J_i^H} \rho_j(u_j) + \sum_{j \in J_i^R} r_j \quad (9)$$

$$v_j^{t+1} = v_j^t - u_j - z_j + \sum_{n \in J^U(j)} (u_n + z_n) + a_j^t, \quad \forall j \in J_i^H \quad (10)$$

$$0 \leq v_j \leq V_j, \quad 0 \leq u_j \leq U_j, \quad 0 \leq z_j, \quad \forall j \in J_i^H \quad (11)$$

$$0 \leq g_j \leq G_j, \quad \forall j \in J_i^G \quad (12)$$

$$0 \leq r_j \leq \tilde{R}_j(\omega^t), \quad \forall j \in J_i^R \quad (13)$$

$$a_j^t = \sum_{l \in L} \phi_j a_j^{t-l} + \tilde{\varepsilon}_j(\omega^t), \quad \forall j \in J_i^H \quad (14)$$

A fórmula (8) representa uma recursão de Bellman análoga à do despacho centralizado. A principal diferença na função objetivo é que há um novo termo $\tilde{\Lambda}(e, \omega^t)$ para representar a receita do agente no estágio t para um evento aleatório ω^t como função da energia e produzida pelo agente. (9) garante que e é igual à geração total de todos os recursos possuídos por um agente, determinado pelo subscrito i , nos conjuntos J^H , J^G e J^R . Finalmente, (10)-(14) são quase iguais a (3)-(7), mas considerando apenas as usinas de propriedade do agente dado, i .

Um desafio fundamental nesse procedimento é que ele requer que todas as usinas hidrelétricas conectadas pertençam a um único agente. Essa hipótese também é assumida em trabalhos anteriores como (STEEGER, 2017). Lidar com diferentes proprietários na mesma cascata pode ser feito considerando um mercado atacadista de água além do mercado de energia, como feito em (LINO, 2003). Alternativamente, outros projetos de mercado, como 1) *slices*, em que os agentes são proprietários de uma fração da cascata e, conseqüentemente, podem otimizar suas estratégias como se não compartilhassem a cascata, e 2) reservatórios virtuais, em que todas as usinas hidrelétricas de um sistema são agregadas em um único reservatório que é então dividido proporcionalmente entre todos os agentes, para mais detalhes veja (BARROSO, 2021).

No caso de agentes tomadores de preço, sua operação pode ser otimizada considerando a função de receita, conforme em (GJELSVIK, 1999): $\tilde{\Lambda}(e, \omega) = \pi(\omega) e$, onde $\pi(\omega)$ é um cenário de preços spot que pode ser obtido a partir de qualquer modelo, incluindo uma otimização anterior do despacho centralizado do sistema da seção anterior.

Por outro lado, agentes formadores de preço têm a capacidade de afetar os preços spot com suas ofertas de energia. Em outras palavras, π não é mais um dado de entrada exógeno, mas sim uma função da oferta do agente i : e . Nesse caso, as ofertas de preço e quantidade de outros agentes são consideradas variáveis aleatórias dependentes da incerteza ω , e são representadas por $\{(P_j(\omega), Q_j(\omega)), j \in I_{[-i]}\}$. Com essas ofertas, seguimos a mesma lógica de (FLACH, 2010) e (STEEGER, 2017). Portanto, escrevemos o seguinte modelo que expressa um problema de despacho baseado em ofertas simplificado:

$$\pi(e, \omega) \in \arg \min \sum_{j \in I_{-i}} P_j(\omega) q_j \quad (15)$$

$$s. a. \quad \sum_{j \in I} q_j = D \quad : \pi \quad (16)$$

$$0 \leq q_i \leq e \quad (17)$$

$$0 \leq q_j \leq Q_j(\omega), \quad \forall j \in I_{-i} \quad (18)$$

Isso é análogo a um problema de fechamento de mercado (*market clearing*), no qual um operador do sistema seleciona as quantidades ideais de energia para atender à demanda em (16), sob os limites (17)-(18) dados pela oferta atual do agente e pelas ofertas dos outros jogadores. O resultado principal são os preços spot, a variável dual de (16). Agora, simplesmente definimos:

$$\tilde{\Lambda}(e, \omega) = \pi(e, \omega) e \quad (19)$$

Combinando (8)-(14), (19) e (15)-(18), completa-se a definição do problema do agente estratégico, no qual cada subproblema é um problema de otimização binível.

No entanto, a função de receita desse agente estratégico é uma função descontínua não convexa em forma de serra, detalhada em (FLACH, 2010) e (STEEGER, 2017). Portanto, para satisfazer os requisitos de convexidade do SDDP,

seguimos o método proposto em (FLACH, 2010) e representamos a envoltória convexa de $\tilde{\Lambda}(e, \omega)$ em relação a e para um ω fixo:

$$\text{convhull}(\tilde{\Lambda}(e, \omega)) = \max_{\lambda_j \geq 0} \sum_{j \in J^V} \lambda_j E_j^R(\omega) \quad (20)$$

$$\text{s. a.} \\ \sum_j \lambda_j E_j^Q(\omega) = e \quad (21)$$

$$\sum_j \lambda_j = 1 \quad (22)$$

onde cada par $(E_j^Q(\omega), E_j^R(\omega))$ representa um vértice (no conjunto de vértices J^V) da envoltória convexa para o hipografo de $\tilde{\Lambda}(e, \omega)$. Mantemos as referências a ω nos vértices do envoltório convexo para lembrar sua dependência das variáveis aleatórias do problema.

Como um dos principais mecanismos para mitigar o poder de mercado, também devemos ser capazes de representar contratos futuros (KELMAN, 2001). Isso não foi descrito nos modelos anteriores do MSO resolvidos pelo SDDP. No entanto, é simples modificar a função de receita para considerar dois termos adicionais da seguinte forma:

$$\tilde{\Lambda}(e, \omega) = P^F Q^F - \pi(e, \omega) Q^F + \pi(e, \omega) e \quad (23)$$

o primeiro termo é a receita fixa do contrato futuro, o segundo representa a energia que deve ser entregue devido ao contrato, e o terceiro é a receita previamente representada do mercado spot. As constantes preço *forward*, P^F , e quantidade *forward*, Q^F , são dados de entrada, i.e., não são variáveis de decisão nos problemas de otimização. Essa função também não é convexa, mas podemos representar seu fecho convexo no problema de otimização da mesma forma que o caso anteriormente descrito sem contratos.

Finalmente, ressaltamos que tanto em (FLACH, 2010) quanto em (STEEGER, 2017), a função de receita não é estocástica, uma vez que considera apenas ofertas das térmicas na forma de capacidades instaladas e custos operacionais. Contudo, neste trabalho, os preços ou preços e quantidades são processos estocásticos que representam condições de mercado ou ofertas de outros agentes, de forma que tem dependência temporal. Tal dependências impede o uso tradicional do SDDP para resolver esse problema multiestágio estocástico, mesmo em sua forma convexificada. Portanto, tais processos estocásticos com dependências temporais serão representados como cadeias de Markov e utilizaremos o SDDP Markoviano de (GJELSVIK, 1999).

4.0 MÚLTIPLOS AGENTES

Agora vamos combinar as metodologias descritas nas seções anteriores para descrever um novo algoritmo de simulação que aproxima a interação entre vários agentes formadores de preço e possíveis agentes tomadores de preço. Todas as interações entre agentes serão em termos de ofertas de preço e quantidade, como em um mercado competitivo de energia real.

Primeiro, observamos que podemos obter uma hipótese inicial sobre as ofertas de vários agentes a partir de uma simulação da operação centralizada do sistema de energia. Conforme descrito na Seção 2.0, os resultados de uma simulação do sistema de energia incluem soluções de variáveis primais e duais para cada t e s . Ao coletar as decisões de geração de todas as usinas de um agente, i , em um determinado estágio e cenário, temos a oferta de quantidade, enquanto a parte do preço da oferta é fornecida pelo preço spot correspondente. Denotamos o conjunto de ofertas de preço e quantidade de um agente i como $(\mathcal{P}_i, \mathcal{Q}_i) = \{P_{\{i,t,s\}}, Q_{\{i,t,s\}}\}_{\{t \in T, s \in S\}}$, o que significa que há um par de preço e quantidade para cada cenário amostrado, $s \in S$, e estágio, $t \in T$. Nomearemos o procedimento de resolução de um despacho centralizado e obtenção tanto dos preços spot, $\Pi = \{\pi_{\{s,t\}}\}_{\{t \in T, s \in S\}}$, quanto das ofertas para todos os agentes, $(\mathcal{P}, \mathcal{Q})$, como *CentralizedOperation* $(\mathcal{A}, \mathcal{R})$. As entradas $(\mathcal{A}, \mathcal{R})$ representam cenários de vazões, \mathcal{A} , e geração de fontes renováveis, \mathcal{R} , que são amostras das variáveis aleatórias para todos os estágios. Como as ofertas e os preços spot, $(\mathcal{P}, \mathcal{Q}, \Pi)$ são obtidos de um procedimento que depende de vazões e geração renovável, $(\mathcal{A}, \mathcal{R})$, todos esses devem ser considerados como variáveis aleatórias dependentes.

A auto-otimização de agentes estratégicos requer ofertas de todos os outros agentes, como descrito na Seção 3.0. Também destacamos que todas as ofertas de preço e quantidade de outros agentes podem ser vistas como variáveis aleatórias dependentes do tempo, caso provenham de agentes não puramente térmicos tomadores de preço. Portanto, a resolução desse problema estocástico multiestágio exigirá o SDDP Markoviano para lidar com a dependência temporal das variáveis aleatórias. Podemos estimar uma cadeia de Markov com base em dados de vazões, geração renovável, preço spot e ofertas, $(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$, que são todas as variáveis aleatórias associadas à otimização do agente estratégico. A estimação da cadeia de Markov resulta em probabilidades de transição entre os estados de Markov para cada estágio. A coleção de probabilidades de transição entre todos os estados de Markov para todos os estágios será denotada como \mathcal{M} . Esse processo que recebe a tupla $(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$ e retorna \mathcal{M} será denotado como *EstimateMarkovChain* $(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$.

Enquanto isso, a otimização estratégica de um agente, i , como uma função das vazões, \mathcal{A} , geração renovável, \mathcal{R} , ofertas de outros agentes, $(\mathcal{P}_{-i}, \mathcal{Q}_{-i})$ e as probabilidades de transição de Markov, \mathcal{M} , será rotulada como $StrategicBid(\mathcal{A}, \mathcal{R}, \mathcal{P}_{-i}, \mathcal{Q}_{-i}, \mathcal{M})$. Analogamente à etapa de simulação de $CentralizedOperation(\mathcal{A}, \mathcal{R})$, o $StrategicBid(\cdot)$ retornará uma oferta atualizada, $(\mathcal{P}_i, \mathcal{Q}_i)$, para o agente otimizado, i : as quantidades serão as soluções primais da oferta de energia e , e os preços serão obtidos calculando o preço correspondente em (15)-(18).

Finalmente, podemos obter preços spot atualizados, Π , ao fechar o mercado para cada estágio e cenário, dadas as ofertas de todos os agentes, $(\mathcal{P}, \mathcal{Q})$. Denominaremos esse procedimento como $ClearMarket(\mathcal{P}, \mathcal{Q})$.

O algoritmo de simulação completo é baseado no método de diagonalização amplamente utilizado na literatura de mercados competitivos de hidroeletricidade (VILLAR, 2003), (ALMEIDA, 2013), (CRUZ, 2016), (WU, 2020) entre outros. Recorreremos aos procedimentos definidos acima para inicializar e , em seguida, atualizar iterativamente as ofertas de um agente formador de preço por vez, enquanto as ofertas dos outros agentes são fixos. O processo é interrompido quando as mudanças nessas ofertas estiverem dentro de uma determinada tolerância fornecida. O principal objetivo é simular o mercado de energia de forma baseada em agentes. Se a convergência for estritamente alcançada, poderíamos ter alcançado um equilíbrio de Nash. No entanto, tal equilíbrio pode nem mesmo existir nesse contexto.

O Algoritmo 1 a seguir descreve o método proposto. O algoritmo começa calculando ofertas, $(\mathcal{P}, \mathcal{Q})$, para todos os agentes tomadores de preço e formadores de preço com o procedimento $CentralizedOperation(\mathcal{A}, \mathcal{R})$. As ofertas dos agentes tomadores de preço serão congeladas a partir desse ponto, pois supomos que eles acreditam que suas ofertas ótimas são seus custos de oportunidade (GJELSVIK, 1999). Em seguida, uma primeira estimativa do processo de Markov é feita com o procedimento $EstimateMarkovChain(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$. Depois disso, haverá um loop por todos os agentes formadores de preço, $i \in I^*$. Para cada agente i , novas ofertas, $(\mathcal{P}_i, \mathcal{Q}_i)$, serão obtidas pelo procedimento $StrategicBid(\mathcal{A}, \mathcal{R}, \mathcal{P}_{-i}, \mathcal{Q}_{-i}, \mathcal{M})$. Em seguida, os preços spot e a estimativa do processo de Markov serão atualizados por chamadas a $ClearMarket(\mathcal{P}, \mathcal{Q})$ e $EstimateMarkovChain(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$. Por fim, se algum critério de convergência for atingido, o algoritmo é interrompido; caso contrário, ele continua para uma nova rodada de atualizações de ofertas dos agentes formadores de preço. O critério de convergência considerado neste trabalho é garantir que a variação absoluta máxima das ofertas de preço e quantidade de todos os agentes varie menos que um pequeno valor dado: 1% de seus valores na operação centralizada.

```

 $(\mathcal{P}, \mathcal{Q}, \Pi) \leftarrow CentralizedOperation(\mathcal{A}, \mathcal{R})$ 
 $\mathcal{M} \leftarrow EstimateMarkovChain(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$ 
while no convergence do
  for  $i \in I^*$  do
    |  $(\mathcal{P}_i, \mathcal{Q}_i) \leftarrow StrategicBid(\mathcal{A}, \mathcal{R}, \mathcal{P}_{-i}, \mathcal{Q}_{-i}, \mathcal{M})$ 
  end
   $\Pi \leftarrow ClearMarket(\mathcal{P}, \mathcal{Q})$ 
   $\mathcal{M} \leftarrow EstimateMarkovChain(\mathcal{A}, \mathcal{R}, \mathcal{P}, \mathcal{Q}, \Pi)$ 
end

```

Algoritmo 1. Simulador de mercado.

5.0 ESTUDOS DE CASO

Agora, aplicamos o procedimento de simulação da Seção 4.0 em várias configurações. Começamos com uma análise de sensibilidade em uma representação do subsistema Sudeste brasileiro, que corresponde a cerca de 55% dos recursos hidroelétricos brasileiros e cerca de 50% da capacidade instalada total do sistema. Vamos analisar diversos esquemas de concentração de mercado e contratação. Em um segundo estudo de caso, consideraremos uma base de dados desenvolvida a partir do sistema brasileiro completo. Aplicaremos a metodologia proposta para contrastar os resultados de simulações com e sem contratos. Foram feitas várias simplificações em ambos os sistemas de energia, incluindo a não consideração de muitas restrições térmicas, hidráulicas e outras políticas, a fim de manter a análise direta e demonstrar as capacidades do procedimento de simulação proposto sem distrair o leitor.

5.1 SIMULAÇÕES NO SISTEMA SUDESTE BRASILEIRO

Este sistema foi construído a partir de dados reais, considerando o cenário de expansão do sistema brasileiro para 2025 e contém 46 usinas térmicas que foram mantidas o mais próximo possível das originais e 21 usinas hidrelétricas com uma topologia simplificada do sistema. Note que isso já é mais do que os 13 reservatórios agregados considerados no modelo oficial. A capacidade instalada de geração hidrelétrica representa 70% da capacidade instalada total desse sistema. Vamos considerar 3 proprietários de usinas hidrelétricas: um agente preço tomador e dois agentes formadores de preços. As 21 usinas hidrelétricas são divididas em 3 grupos de 7 usinas. Um grupo para cada um dos dois agentes preços formadores e o terceiro grupo para o agente preço tomador. Todas as usinas

térmicas são consideradas agentes individuais tomadores de preço. Consideramos um único bloco de carga por simplicidade. As seguintes simulações foram realizadas em um horizonte de 60 estágios mensais. Consideramos 1000 cenários amostrados. As simulações de grande escala foram realizadas em um cluster PSRCloud de 8 servidores, cada um com 64 núcleos e 128 GB de RAM. Cada simulação levou aproximadamente 3 horas.

5.1.1 CONCENTRACAO DE MERCADO

Nesta seção, apresentamos 5 simulações com diferentes concentrações de mercado. Adaptamos as usinas hidrelétricas para obter diferentes bases de dados representados por tuplas (participação1 %, participação2 %), onde participação1 e participação2 representam as parcelas percentuais do sistema hidrelétrico pertencentes a cada um dos dois agentes formadores de preço. A parte restante do sistema hidrelétrico é alocada ao agente hidroelétrico tomador de preço.

Na Figura 1 (a), mostramos os preços spot médios em função da concentração de mercado em um gráfico de barras. Adicionamos a primeira barra com o preço spot do despacho centralizado. Como esperado, os preços spot aumentam rapidamente à medida que a concentração em agentes formadores de preço aumenta. A figura também mostra o valor médio de energia vendida, que é a receita total do agente dividida pela energia total gerada pelo agente, conhecida como preço capturado. Apresentamos os resultados em formas normalizadas para que possamos comparar os resultados de agentes de tamanhos diferentes. A Figura 1(b) mostra resultados adicionais com os níveis médios de reservatório dos agentes formadores de preço ao longo do período de estudo e a média de vertimento.

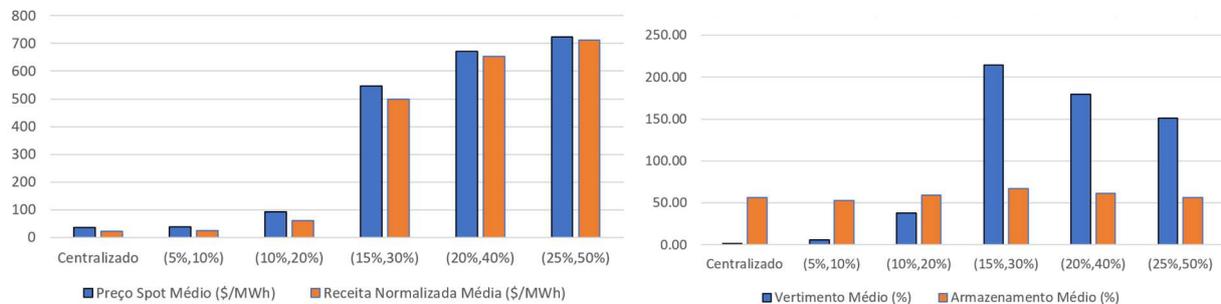


Figura 1. (a) e (b) Resultados de simulação do Sudeste do Brasil sem contratos.

A Figura 2 apresenta um perfil típico de convergência do método iterativo proposto. Esses perfis foram obtidos a partir do estudo de caso com participações dos formadores de preço de (25%, 50%) e sem contratos. A Figura 2 (a) mostra as médias dos preços spot para 12 iterações consecutivas, sendo o último valor aquele relatado na Figura 1 (a). A Figura 2 (b) mostra tanto as diferenças absolutas médias quanto as diferenças relativas médias entre duas iterações consecutivas. Primeiro, as diferenças absolutas (ou relativas) são calculadas para cada estágio e cenário, e depois são tiradas as médias.

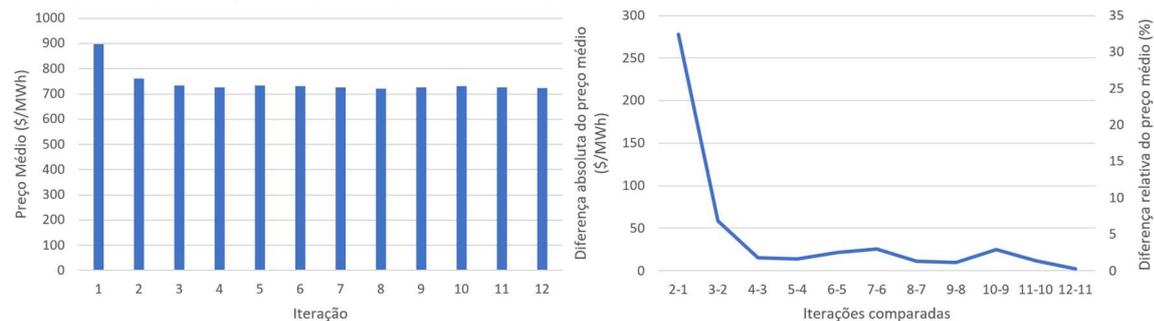


Figura 2. Convergência do caso (25%, 50%), sem contratos. (a) Preço por iteração, (b) Comparação entre iterações.

5.1.2 CONTRATOS

Nesta seção, repetimos as análises anteriores, mas com contratos. Para determinar as quantidades mensais de contrato, utilizamos os valores médios de geração do despacho centralizado e os preços médios spot do despacho centralizado. Isso estimulará os agentes a produzir energia e reduzir os preços spot, uma vez que ter déficit no contrato junto com preços spot elevados levará o agente a ter despesas devido ao segundo termo em (23).

As Figuras 3 (a) e 3 (b) contêm as mesmas métricas apresentadas na seção anterior, mas para os casos em que os agentes estão contratados em 75% e 100%, respectivamente. Nos estudos de caso, podemos claramente observar que os contratos eliminaram completamente o poder de mercado, e os preços spot resultantes estão muito próximos

dos obtidos no despacho centralizado. Ao mesmo tempo, as receitas capturadas e os níveis de reservatório também se aproximaram dos valores do despacho centralizado.

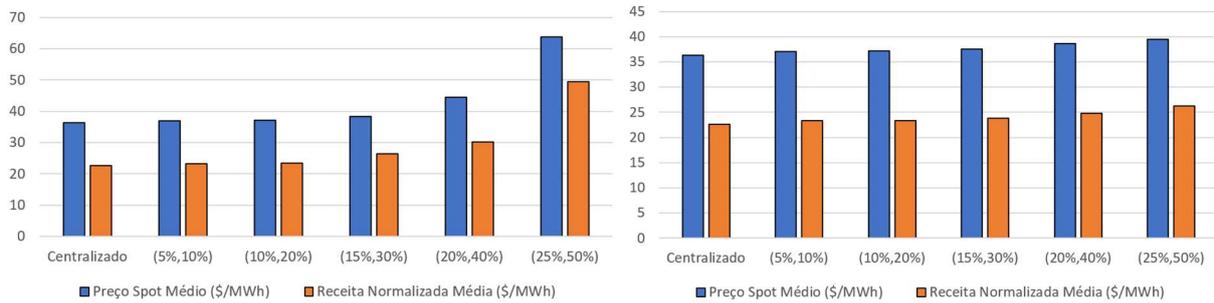


Figura 3. (a) Nível de contratação de 75%, (b) Nível de contratação de 100%.

5.2 ESTUDOS NO SISTEMA BRASIL

Esta base de dados foi criada a partir dos dados originais do sistema brasileiro e contém 137 usinas térmicas representando 18% da capacidade instalada, 364 usinas de energia renovável (eólica e solar) representando 19% da capacidade instalada e 32 usinas hidrelétricas representando os 63% restantes da capacidade instalada. Aqui, melhoramos a precisão da curva de duração da carga e consideramos 5 blocos de carga em vez de apenas um para considerar as horas de demanda de pico. Assim como nos estudos anteriores, consideramos 5 anos (60 estágios mensais), 1000 cenários e a mesma configuração de cluster PSRCloud.

Neste estudo, consideramos uma aproximação da concentração de mercado real no sistema. Representamos 3 agentes formadores de preço, com respectivamente 32%, 9% e 7% dos recursos energéticos representando os 3 maiores proprietários de usinas de energia do país. Enquanto isso, os 55% restantes dos recursos são distribuídos entre um quarto agente, agora tomador de preço, puramente hidrelétrico e mais um agente tomador de preços para cada usina térmica restante. Aqui assumimos que os agentes menores se comportam como tomadores de preço devido ao seu tamanho comparativamente reduzido. Cada simulação levou aproximadamente 11 horas.

Primeiro, simulamos a operação centralizada, o mercado baseado em ofertas sem contratos, e depois consideramos agentes com diferentes níveis de contratação no mercado baseado em ofertas. Em particular, analisamos os casos de: 25%, 50%, 75% e 100% de nível de contratação. Os principais resultados de cada uma das 6 simulações são representados na Figura 4.

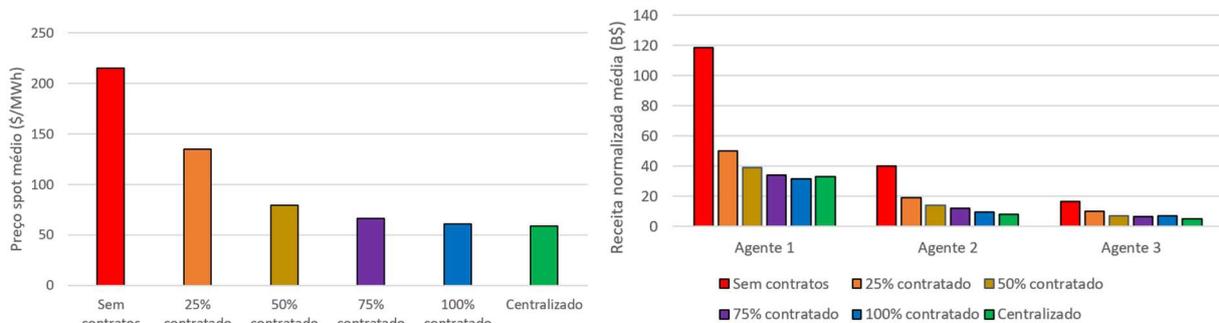


Figura 4. (a) e (b) Resultado para a simulação do sistema do Brasil com diferentes níveis de contratação.

A Figura 4 (a) mostra o preço spot em cada uma das 6 condições mencionadas acima. Podemos claramente observar a progressão dos preços spot mais altos quando não há contratos no mercado baseado em ofertas, permitindo que os agentes exerçam seu poder de mercado, até o caso de contratação total, em que o preço spot médio é muito próximo ao obtido na operação centralizada do sistema. Dado o número de recursos alocados para os agentes formadores de preço, 45%, observamos que um nível de contratação de 75% já é muito eficaz na redução da diferença em relação à operação centralizada. Isso corrobora com o que vimos nas simulações do sistema do sudeste. Em particular, contratação em 75% também foi muito eficaz em conter o poder de mercado no caso em que o primeiro agente formador de preço tinha 15% dos recursos e o segundo agente formador de preço tinha 30% dos recursos, resultando em 45% nas mãos dos agentes formadores de preço. Finalmente, observamos que mesmo níveis de contratação muito baixos (25%) fazem diferença nos preços médios spot finais comparados ao caso sem contratos.

A Figura 4 (b) apresenta a receita global, incluindo custos de operação e contrato, receita spot e de contrato ao longo do horizonte de 5 anos para cada um dos 3 agentes formadores de preço. No geral, a figura reproduz informações já verificadas na Figura 4 (a) com receitas excessivas para todos os agentes nos casos do mercado baseado em

ofertas sem contratos. Notavelmente, o caso de contratação total leva a receitas muito semelhantes às do despacho centralizado. Novamente, 75% parece ser um valor interessante, pois deixa o sistema muito próximo da versão centralizada em termos de remuneração dos agentes.

6.0 CONCLUSÃO

Com base na literatura sobre mercados de energia hidrotérmica de longo prazo, combinamos três elementos-chave para desenvolver um simulador de mercado novo e eficaz, a saber: 1) o algoritmo SDDP aplicado ao despacho hidrotérmico centralizado para inicializar o processo e servir de referência, 2) um modelo estocástico de oferta estratégica considerando múltiplos estágios para obter decisões de agentes formadores de preço e 3) um método iterativo baseado em diagonalização para simular as interações entre os agentes no mercado. Em contraste com a literatura existente sobre o assunto, com nosso novo algoritmo, pudemos considerar em conjunto vários reservatórios (32), vários estágios (60) e cenários (1000), e vários agentes formadores de preço (3). Portanto, um estudo de caso realista de grande escala com base no sistema de energia brasileiro (um dos maiores do mundo) pôde ser abordado e *insights* relevantes puderam ser obtidos.

Mais especificamente, realizamos com sucesso várias simulações de sistemas de energia em grande escala. Em uma primeira análise de sensibilidade no sistema do sudeste brasileiro, pudemos observar como a variação da concentração de poder de mercado pode levar a situações em que o poder de mercado é claramente prejudicial ao sistema. Na análise subsequente, mostramos como os contratos podem ser usados para mitigar o poder de mercado, levando a situações muito mais razoáveis mesmo em um nível de contratação de 75%, e, no caso de contratação total, o poder de mercado é completamente erradicado. No estudo final, simulamos um sistema de energia com base nos dados reais do Brasil, incluindo todos os geradores mais importantes do sistema. Representamos três grandes agentes estratégicos em proporções realistas, dados seus portfólios atuais. Os resultados demonstram que, na configuração atual de concentração de mercado brasileiro, ele é suscetível ao poder de mercado. Por fim, mostramos que os contratos podem de fato ser uma ferramenta muito importante para mitigar o poder de mercado e melhorar o desenho do mercado em direção à solução para a maximização da riqueza social.

Destacamos que uma ferramenta como essa pode ser extremamente útil para monitorar mercados. Simular um sistema de energia é o primeiro passo para entender o que está acontecendo atualmente no sistema. Além disso, desenvolvedores de políticas e *designers* de mercado podem se beneficiar de tal ferramenta para experimentar com desenhos alternativos e encontrar novas soluções. Em termos algorítmicos, o método é adequado para computação paralela e pode ser facilmente estendido para considerar outros detalhes físicos e regulatórios. Não obstante, demonstramos que um problema do mundo real formulado como um problema estocástico multiestágio pode ser resolvido sob suposições razoáveis e fornecer *insights* relevantes para tomadores de decisão e reguladores.

7.0 AGRADECIMENTOS

Os autores agradecem a Luiz Augusto Barroso e Sergio Granville pelas muitas conversas que levaram ao desenvolvimento deste trabalho. Os autores agradecem ao P&D ANEEL PD-00403-0050/2020 financiado pela Engie Brasil Energia S.A. que propiciou o desenvolvimento deste trabalho. Este trabalho foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001.

8.0 BIBLIOGRAFIA

IEA. Hydropower. <https://www.iea.org/reports/hydropower>, June 2022.

PEREIRA, M. V. F.; PINTO, L. M. V. G.. Multi-stage stochastic optimization applied to energy planning. *Mathematical Programming*, 52(1-3):359–375, 1991.

GJELSVIK, A.; BELSNES, M. M.; HAUGSTAD, A.. An algorithm for stochastic medium-term hydrothermal scheduling under spot price uncertainty. In: *Proceedings Of 13th Power Systems Computation Conference*, 1999.

STEEGER, G.; BARROSO, L. A.; REBENNACK, S.. Optimal Bidding Strategies for Hydro-Electric Producers: A Literature Survey. *IEEE Transactions on Power Systems*, 29(4):1758–1766, 2014.

GROSS, G.; FINLAY, D.. Generation supply bidding in perfectly competitive electricity markets. *Computational & Mathematical Organization Theory*, 6(1):83–98, 2000.

FLACH, B.; BARROSO, L.; PEREIRA, M.. Long-term optimal allocation of hydro generation for a price-maker company in a competitive market: latest developments and a stochastic dual dynamic programming approach. *IET generation, transmission & distribution*, 4(2):299–314, 2010.

- STEEGER, G.; REBENNACK, S.. Dynamic convexification within nested Benders decomposition using Lagrangian relaxation: An application to the strategic bidding problem. *European Journal of Operational Research*, 257(2):669–686, 2017.
- BARROSO, L. A.; CARNEIRO, R. D.; GRANVILLE, S.; PEREIRA, M. V.; FAMPA, M.. Nash equilibrium in strategic bidding: a binary expansion approach. *Power Systems, IEEE Transactions on*, 21(2):629, 2006.
- SCOTT, T. J.; READ, E. G.. Modelling hydro reservoir operation in a deregulated electricity market. *International Transactions in Operational Research*, 3(3-4):243–253, 1996.
- KELMAN, R.; BARROSO, L. A. N.; PEREIRA, M. V. F.. Market power assessment and mitigation in hydrothermal systems. *Power Systems, IEEE Transactions on*, 16(3):354–359, 2001.
- VILLAR, J.; RUDNICK, H.. Hydrothermal market simulator using game theory: assessment of market power. *Power Systems, IEEE Transactions on*, 18(1):91–98, 2003.
- MOLINA, J. P.; ZOLEZZI, J. M.; CONTRERAS, J.; RUDNICK, H.; REVECO, M. J.. Nash-cournot equilibria in hydrothermal electricity markets. *IEEE Transactions on Power Systems*, 26(3):1089–1101, 2010.
- STEEGER, G.; REBENNACK, S.. Strategic bidding for multiple price-maker hydroelectric producers. *IIE Transactions*, 47(9):1013–1031, 2015.
- LÖSCHENBRAND, M.; WEI, W.; LIU, F.. Hydro-thermal power market equilibrium with price-making hydropower producers. *Energy*, 164:377–389, 2018.
- WU, X.; CHENG, C.; MIAO, S.; LI, G.; LI, S.. Long-Term Market Competition Analysis for Hydropower Stations using SSDP-Games. *Journal of Water Resources Planning and Management*, 146(6):04020037, 2020.
- BUSHNELL, J.. A Mixed Complementarity Model of Hydrothermal Electricity Competition in the Western United States. *Operations Research*, 51(1):80–93, 2003.
- ALMEIDA, K. C.; CONEJO, A. J.. Medium-Term Power Dispatch in Predominantly Hydro Systems: An Equilibrium Approach. *IEEE Transactions on Power Systems*, 28(3):2384–2394, 2013.
- CRUZ, M.; FINARDI, E.; MATOS, V. D.; LUNA, J.. Strategic bidding for price-maker producers in predominantly hydroelectric systems. *Electric Power Systems Research*, 140:435–444, 2016.
- DIAS GARCIA, J. The Effectiveness of Bilevel Optimization in Large-Scale Power Systems Problems: A Bilevel Optimization Toolbox, a Framework for Application-Driven Learning, and a Market Simulator. Tese de Doutorado. PUC-Rio, Dezembro, 2022.
- DOWSON, O.; MORTON, D. P.; PAGNONCELLI, B. K.. Incorporating convex risk measures into multistage stochastic programming algorithms. *Annals of Operations Research*, p. 1–25, 2022.
- FREDO, G. L. M.; FINARDI, E. C.; DE MATOS, V. L.. Assessing solution quality and computational performance in the longterm generation scheduling problem considering different hydro production function approaches. *Renewable energy*, 131:45–54, 2019.
- LINO, P.; BARROSO, L. A. N.; PEREIRA, M. V.; KELMAN, R.; FAMPA, M. H.. Bid-based dispatch of hydrothermal systems in competitive markets. *Annals of Operations Research*, 120(1-4):81–97, 2003.
- BARROSO, L.; GRANVILLE, S.; JACKSON, P.; PEREIRA, M.; READ, E.. Overview of virtual models for reservoir management in competitive markets. In: PROCEEDINGS 4TH IEEE/CIGRÉ INTERNATIONAL WORKSHOP ON HYDRO SCHEDULING IN COMPETITIVE MARKETS, BERGEN, NORWAY, 2012

DADOS BIOGRÁFICOS

(1) JOAQUIM DIAS GARCIA



Joaquim Dias Garcia ingressou na PSR em 2015. Ele divide seu tempo entre: pesquisa e desenvolvimento de metodologias avançadas em otimização estocástica, modelos de equilíbrio e técnicas de reinforcement learning para aplicações de grande porte em mercados de energia; desenvolvimento de novos sistemas computacionais; e contribuições para o ecossistema JuMP, do qual é um dos 5 core developers, na linguagem Julia. Ele tem doutorado em pesquisa operacional e graduação em engenharia elétrica e em matemática pela PUC-Rio, Brasil. Também cursou um ano na UC Santa Barbara, onde trabalhou com sistemas dinâmicos e controle.

(2) ALEXANDRE STREET DE AGUIAR

Alexandre Street, professor do departamento de engenharia elétrica da PUC-Rio, é fundador do LAMPS PUC-Rio, onde desenvolve diversos projetos de P&D com empresas do setor de energia, e do LAMPS Company, startup encubada na PUC-Rio com o objetivo de produtizar os resultados dos projetos de P&D e consultoria. É autor de inúmeros artigos científicos na área de planejamento, operação e comercialização de energia renovável. É senior member do IEEE, pesquisador 1 do CNPq, e tem sido editor das principais revistas científicas de energia, como IEEE transactions on power systems e IEEE transactions on energy markets, policy and regulation.

(3) GABRIEL ROCHA DE ALMEIDA CUNHA

Gabriel Cunha é doutor em economia pela FGV, mestre em planejamento energético pela UFRJ, e engenheiro pela USP e pela École Polytechnique. Trabalha na PSR desde 2011, onde lidera a equipe responsáveis por análise de mercados internacionais, desenho de mercado, e modelagem matemática e econômica aplicada a sistemas de energia.

(4) MARIO VEIGA FERRAZ PEREIRA

Mario Veiga Pereira é engenheiro eletricitista com doutorado em otimização. Ele fundou a PSR em 1987 e foi o principal conselheiro presidencial na gestão da crise energética de 2001 e no desenho das novas regras do mercado da eletricidade em 2004. Algumas de suas recentes atividades incluem o desenvolvimento de modelos computacionais, reforma de mercados de eletricidade, estudos de integração de geração renovável em vários países. Seu algoritmo SDDP é uma referência mundial e é aplicado em dezenas de países. É Fellow do IEEE; membro eleito da Academia Brasileira de Ciências e das Academias Nacionais de Engenharia do Brasil e dos Estados Unidos.