

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

METODOLOGIA PARA ANÁLISE DO EFEITO DE LIQUIDAÇÕES MÚLTIPLAS EM MERCADOS ELÉTRICOS DE CURTO-PRAZO NO CONTEXTO DE UMA CRÉSCENTE PENETRAÇÃO RENOVÁVEL

BRUNO PEIXOTO BARBOSA(1);GABRIEL CUNHA(1);JOÃO PEDRO THIMOTHEO BASTOS(1);DAVI M VALLADAO(2)

PSR SOLUCOES E CONSULTORIA EM ENERGIA LTDA.
(1);PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO(2)

RESUMO

O presente trabalho analisa os impactos de um mecanismo de liquidação dupla no mercado elétrico brasileiro, com uma liquidação com base em previsões do dia anterior e outra com base no despacho real -, a partir de uma configuração realista do sistema em 2030. De modo a representar a incerteza na geração renovável, são emulados erros de previsão, introduzindo “choques” nas simulações da operação em tempo real. O sistema é simulado para diferentes estados – demanda e disponibilidade de recursos –, com diversos cenários de previsão e várias materializações para uma mesma previsão. Os resultados são comparados com mecanismos de liquidação única.

PALAVRAS-CHAVE

Desenho de mercados elétricos; Liquidação múltipla; Energia renovável intermitente; Modernização do Setor Elétrico.

1.0 INTRODUÇÃO

A participação cada vez maior de tecnologias renováveis nas matrizes elétricas tem tornado a operação dos sistemas uma tarefa cada vez mais desafiadora. As incertezas inerentes a essas fontes e a variabilidade que tipicamente apresentam elevam a complexidade da tarefa dos operadores, posto que aumentam os requisitos de flexibilidade no sistema para que se faça o equilíbrio entre oferta e demanda a cada instante. Assim, embora existam incertezas quanto ao balanço oferta-demanda que só serão conhecidas em tempo real (em variáveis como disponibilidade de recursos naturais, principalmente solar e eólico, e demanda), a flexibilidade que o sistema tem para variar a geração de outros agentes para acomodar essas incertezas é limitada – visto que os geradores estão sujeitos a restrições operativas, como rampa, tempo de arranque, mínimo tempo ligado, dentre outras. Quanto mais próximo se está do momento da operação, menor a incerteza, mas também menor a flexibilidade para a realização de eventuais ajustes.

Um caminho comumente utilizado para equilibrar esses dois elementos em mercados elétricos mais desenvolvidos é a realização de otimizações do despacho em diversos momentos, à medida que se aproxima do tempo real. A primeira programação do despacho é tipicamente efetuada no dia anterior (*day-ahead*), com o fim principal de conceder maior previsibilidade ao operador na tomada de decisão, especialmente aquelas que requerem certa antecedência. Posteriormente, com a realização das incertezas (*ex-post*, conhecendo medições efetivas da geração renovável, demandas e indisponibilidades, por exemplo) realiza-se uma nova otimização do despacho (*real-time*).

De modo a alinhar os incentivos aos agentes, alguns países realizam a precificação e liquidação da energia elétrica nesses dois momentos – um modelo conhecido como de liquidação dupla, no qual há um mercado *day-ahead* e um mercado *real-time* associados às simulações de despacho. Essencialmente, no mercado *day-ahead*, o operador simula o despacho com base em uma configuração esperada de oferta e demanda para o período que se está modelando, resultando em uma alocação de volumes de energia a cada agente produtor e em um preço ao qual essa energia é transacionada, gerando obrigações financeiras tanto para geradores como para consumidores. Posteriormente, no *real-time*, utilizando como inputs as condições vistas em tempo real, determina-se um novo preço, ao qual serão liquidadas as diferenças entre a geração física e a que foi comprometida na programação do dia anterior. Este modelo de liquidação dupla tem consequências financeiras para os participantes de mercado, o que, por sua vez, tem implicações para a operação física do sistema como um todo: os agentes em geral buscarão melhorar a qualidade das suas previsões no *day-ahead* de modo a reduzir a sua exposição ao preço *real-time*. Uma discussão profunda acerca do tema é apresentada em (1).

Embora o Brasil não implemente um modelo de liquidação dupla atualmente, uma série de outros países adota mecanismos deste tipo. Tendo em consideração que o Brasil está passando por modernizações no seu mercado de

eletricidade, é interessante explorar as consequências deste tipo de implementação – especialmente considerando o aumento da participação das renováveis como solar e eólica na matriz elétrica brasileira e o papel que um modelo de liquidação dupla pode ter em incentivar a eficiência e previsibilidade em mercados de curto-prazo.

O presente trabalho se propõe a desenvolver uma metodologia para analisar os impactos da adoção de um mecanismo de liquidação múltipla em mercados de curto-prazo – em particular, a liquidação dupla, que possui uma liquidação com base em previsões feitas no dia anterior (*day-ahead market*) e outra com base no despacho em tempo real (*real-time market*). Para representar a incerteza inerente às renováveis, são emulados erros de previsão durante a programação do despacho, através da introdução de “choques” nas simulações da operação em tempo real, calibrados a partir de dados históricos. O sistema é simulado para diferentes estados (níveis de demanda e de disponibilidade de recursos, por exemplo), com diversos cenários de previsão *day-ahead* de geração renovável, bem como várias possíveis materializações em tempo real para um mesmo cenário de previsão. Desta forma, é possível quantificar as consequências de um modelo de liquidação dupla, comparando-o com mecanismos tradicionais de liquidação única. A metodologia desenvolvida é aplicada ao subsistema Nordeste, do sistema elétrico brasileiro, a partir de uma configuração realista em 2030, de modo que as renováveis tenham uma participação relevante.

2.0 MODELOS DE LIQUIDAÇÃO EM MERCADOS ELÉTRICOS

2.1 MODELO DE LIQUIDAÇÃO DUPLA

Mercados que possuem mais de uma liquidação, conhecidos como mercados vinculantes, consistem em otimizar o despacho e formar preços em momentos anteriores ao despacho físico. O modelo *multi-settlement* mais clássico e que será analisado neste trabalho é o de liquidação dupla, com uma liquidação *day-ahead* e outra em tempo real.

Neste modelo de liquidação, a receita obtida por determinada usina é o resultado do somatório entre a receita no *day-ahead* e a receita obtida no *real-time*. A primeira componente seria dada pelo produto entre o preço *day-ahead*, obtido na etapa de programação do despacho (feito com base em previsões de configurações de oferta e demanda) e as quantidades vendidas neste mercado, mostrado na Equação (1). Já a segunda, seria calculada como o produto entre o preço *real-time* (que vem do despacho real) e a diferença entre os volumes efetivamente gerados e o que havia sido comprometido no dia anterior (Equação (2)). Nota-se que este modelo incentiva a qualidade das previsões dos agentes, posto que, assim, evitam exposições a liquidações no mercado *real-time*, como discutido em (2).

$$R_{DA} = p_{DA} \cdot q_{DA} \quad (1)$$

$$R_{RT} = p_{RT} \cdot (q_{RT} - q_{DA}) \quad (2)$$

Onde R_{DA} é a receita no mercado *day-ahead* (MDA), R_{RT} é a receita no mercado *real-time* (MTR), q_{DA} é a quantidade comprometida na MDA, q_{RT} é a quantidade efetivamente gerada, p_{DA} é o preço no MDA e p_{RT} é o preço no MTR.

2.2 MODELOS DE LIQUIDAÇÃO ÚNICA

Os modelos de liquidação múltipla, ainda que comuns em mercados desenvolvidos ou que passaram por reformas mais tardias, não são universalmente adotados, com diversos mercados possuindo liquidação única. Com isso, reduz-se a complexidade da estrutura, embora percam-se alguns benefícios da liquidação em múltiplas etapas.

Um dos modelos mais comuns de liquidação única envolve formação de preços e liquidações das transações apenas *ex-post* (*real-time*), com base exclusivamente nas quantidades reais observadas em determinado período. Neste mecanismo, a programação do despacho *day-ahead* é apenas indicativa e não produz incentivos para que os agentes aprimorem suas previsões de disponibilidade de recursos. Este tipo de liquidação também deixa os agentes mais sujeitos à volatilidade dos preços em tempo real (que podem ser muito diferentes dos que resultariam das previsões *ex-ante*). A receita de um agente neste modelo “*real-time only*” é calculada conforme indicado na Equação (3).

$$R = p_{RT} \cdot q_{RT} \quad (3)$$

Outra categoria de liquidação única, adotada no Brasil, é pré-fixar os preços na programação de despacho. Estes preços *ex-ante* são então multiplicados pelas quantidades observadas durante a operação em tempo real (*ex-post*) para definir os fluxos financeiros resultantes deste mecanismo. Este esquema gera distorções relevantes no mercado ao possibilitar um aumento da incompatibilidade entre os mundos comercial e físico. Isto prejudica diretamente os sinais de preços passados aos agentes e abre espaço para potenciais manipulações dos players em busca de lucros artificiais. A Equação (4) representa o cálculo da receita de um agente neste modelo “*day-ahead only*”.

$$R = p_{DA} \cdot q_{RT} \quad (4)$$

3.0 METODOLOGIA

3.1 FRAMEWORK E ORGANIZAÇÃO DOS CENÁRIOS

O presente trabalho tem como objetivo avaliar os impactos econômicos da adoção dos três tipos de liquidação descritos acima no sistema e nos seus diversos agentes, a partir de diversas métricas para quantificar os riscos e resultados financeiros. No modelo utilizado, admitiu-se que o tipo de liquidação não possui influência sobre a operação do sistema. Em todos os casos, haverá tanto uma programação com um dia de antecedência quanto o despacho em tempo real, de modo que as diferentes liquidações afetam somente o cálculo das receitas, tendo como base os mesmos resultados de despacho. Eventualmente, os diferentes incentivos econômicos percebidos pelos geradores renováveis nesses três cenários poderiam influenciar a qualidade das previsões passadas ao operador, tendo implicações para a operação – neste trabalho, admitiu-se que a previsão é sempre igual à produção esperada.

A metodologia propõe analisar as consequências de cada tipo de liquidação em diferentes estados do sistema (por exemplo, trimestres do ano), denominados *seasons*. Isto foi feito para que se possa capturar efeitos sazonais na demanda e disponibilidade de recursos renováveis e foi realizado de modo que os fatores sazonais que afetam o balanço oferta-demanda sejam semelhantes entre os dias de cada período. Para cada *season*, foi simulado um dia de operação do sistema (com resolução horária) em diversos cenários de programação *day-ahead* e, para cada um destes, vários cenários de despacho *real-time*. Os diferentes cenários *day-ahead* diferem entre si na previsão de geração renovável, enquanto os cenários *real-time* representam possibilidades de choques entre a geração renovável prevista e a realizada, emulando erros de previsão. A demanda, esta varia apenas de uma *season* para a outra, tendo sido mantida inalterada entre os diferentes cenários de uma mesma *season*. O mesmo vale para o custo de oportunidade das hidrelétricas, que foi tratado como o custo variável de geração destas centrais para fins de otimização do despacho. As demais variáveis são constantes em todos os cenários, mesmo que de *seasons* diferentes. É importante pontuar que, na prática, a disponibilidade renovável não é a única incerteza entre a programação e o despacho real – falhas em usinas e flutuações na demanda são exemplos de possíveis desvios. Nesta metodologia, estes fatores não foram considerados, mas podem ser analisados em futuros estudos.

Em cada cenário de programação do despacho *day-ahead* e de operação em tempo real, resolve-se um problema de minimização dos custos do despacho das centrais, de modo a atender a demanda da forma mais econômica possível. Dentro de uma mesma *season*, os problemas a serem resolvidos são semelhantes, com variações apenas na disponibilidade de recursos renováveis – como mencionado, entre os diferentes cenários de previsão da geração *day-ahead* (que possuem diferentes valores de expectativa de geração renovável) e os seus respectivos cenários de geração *real-time*, foram introduzidos choques aleatórios, representando erros de previsão. O problema do despacho de mínimo custo, caracterizado como um problema de programação inteira mista (*Mixed Integer Programming*, MIP) foi desenvolvido utilizando a linguagem de programação *Julia*, utilizando o pacote de otimização *JuMP* e resolvido a partir do *solver* de otimização *Xpress*. O problema acomoda as diversas restrições operativas de curto-prazo comuns em sistemas elétricos, como rampas e restrições de *unit commitment*, ainda que grande parte delas tenha sido deixada de lado no estudo de caso que será apresentado, por motivos de simplificação e intuição dos resultados.

3.2 CRIAÇÃO DOS CENÁRIOS RENOVÁVEIS

Como um dos *inputs* do modelo é a geração das renováveis em cada cenário, é necessário calcular dados horários de previsão *day-ahead* da geração de cada usina j para cada um dos cenários $\hat{\omega}_{k,h}$ (denominados $\hat{\xi}_{j,t,k,h}$, onde os índices representam cada central j , em cada hora t do dia, em cada cenário *day-ahead* $\hat{\omega}_{k,h}$, em função da *season* h). Além disso, para cada cenário *day-ahead* $\hat{\omega}_{k,h}$, deve-se calcular valores de desvios entre a geração prevista e a real (variáveis $\xi_{j,t,wk,h}$), para emular os erros de previsão em cada um dos cenários *real-time* $\omega_{w,k,h}$.

Para isso, são utilizados dados históricos de cada renovável j , com dados para 38 anos em resolução horária, obtidos a partir do *software Time Series Lab* (TSL), da PSR. O modelo faz uso de dados climatológicos de bases de reanálise globais para reconstruir o histórico de geração das usinas. A partir destes dados, deve-se determinar uma distribuição de probabilidades para os valores que representariam as previsões *day-ahead* e, conseqüentemente, dos erros de previsão – visto que se sabem os dados reais, e que estes são dados pela soma entre a previsão do cenário *day-ahead* $\hat{\omega}_{k,h}$ (valores $\hat{\xi}_{j,t,k,h}$) e os desvios em cada cenário *real-time* $\omega_{w,k,h}$, daqui em diante referidos como $\delta_{j,t,wk,h}$.

A calibração das distribuições de probabilidades das previsões *day-ahead* e dos erros de previsão foi feita individualmente para cada usina j e cada *season* h e é composta por duas etapas. A primeira delas é uma regressão diária dos históricos, que consiste em calcular um comportamento diário típico de j dentro da *season*, incorporando também uma certa variação intra-*season* com o passar dos dias. Isto foi feito através de um *fitting* quadrático dos dados diários (média das 24 horas de cada dia), seguindo o modelo mostrado em (5). O objetivo é incorporar o fato de que, mesmo dentro de uma mesma *season* (em que se assume que um comportamento estatístico semelhante), pode haver alguma tendência temporal que precisa ser capturada para que se obtenha um valor característico da geração da usina ao longo da *season* – que será um dos parâmetros no qual se basearão as previsões *day-ahead*.

$$\mu_{j,d_h,y} = \alpha \cdot d^2 + \beta \cdot d + c + \varepsilon_{j,d_h,y} \quad (5)$$

Onde:

$\mu_{j,d_h,y}$ é a geração da usina j no dia d_h da *season* h no ano y (média dos 24 dados horários);
 d representa o número sequencial do dia d_h na *season* h (entre 1 e 90, por exemplo, no primeiro trimestre do ano);
 α, β, c são os parâmetros a serem estimados;
 $\varepsilon_{j,d_h,y}$ é o resíduo da regressão.

É interessante notar que, enquanto o valor estimado pelo modelo $\hat{\mu}_{j,d_h}$ é o mesmo para todos os anos y do histórico (pois a única variável explicativa, para determinada usina j e *season* h , é o dia), o erro de previsão $\hat{\varepsilon}_{j,d_h,y}$ varia entre os anos y . Com isso, $\hat{\mu}_{j,d_h}$ representa um comportamento médio da geração da usina j no dia d_h , enquanto $\hat{\varepsilon}_{j,d_h,y}$ indica o desvio do valor observado em determinado ano y com relação a esta média.

Numa etapa seguinte, busca-se emular o que seria a previsão *day-ahead* para determinada hora t de determinado dia d_h da *season* h . Para tal, considerou-se que esta depende do comportamento típico do dia ($\hat{\mu}_{j,d_h}$) e do desvio com relação à média observado no dia anterior ($\hat{\varepsilon}_{j,(d_h-1),y}$), que é a informação mais recente que se possui, guiando as expectativas para o dia seguinte também. Assim, realizou-se, para cada *season* h , 24 novas regressões (1 para cada hora do dia), tendo como variáveis explicativas os dois parâmetros mencionados, como na expressão a seguir.

$$X_{j,t,d_h,y} = A \cdot \hat{\mu}_{j,d_h} + B \cdot \hat{\varepsilon}_{j,(d_h-1),y} + \delta_{j,t,d_h,y} \quad (6)$$

Onde:

$X_{j,t,d_h,y}$ é a geração histórica da usina renovável j na hora t do dia d_h da *season* h no ano y ;
 A, B são os parâmetros a serem estimados;
 $\delta_{j,t,d_h,y}$ é o resíduo da regressão.

Um dos principais produtos destas regressões horárias são os valores estimados pelo modelo ($\hat{X}_{j,t,d_h,y}$), que podem ser interpretados como as previsões *day-ahead* para a hora t do dia d_h no ano y (ou seja, feita no dia $d_h - 1$ do mesmo ano). Mais do que isso, a regressão fornece uma distribuição para estes valores dentro de uma determinada *season* h , que pode ser construída a partir dos valores previstos para cada dia da *season* ao longo de todos os 38 anos de histórico – reiterando que se assume um comportamento estatístico semelhante entre dias de uma mesma *season*. A Figura 1 mostra, para uma usina eólica no Rio Grande do Norte e uma usina solar em Pernambuco, a distribuição dos valores de previsão *day-ahead* da geração em duas *seasons* (trimestre úmido, de fevereiro a abril, e trimestre seco, de agosto a outubro), representando os valores médios e percentis ao longo do perfil diário.




Figura 1 - Distribuição das previsões *day-ahead* usina solar e usina eólica

Já os resíduos $\hat{\delta}_{j,t,d_h,y}$ representam os próprios erros de previsão *day-ahead* para a hora t do dia d_h no ano y (visto que são definidos como a diferença entre o valor de geração real $X_{j,t,d_h,y}$ e a previsão *ex-ante* $\hat{X}_{j,t,d_h,y}$). Analogamente às previsões, pode-se construir a partir destes valores (dados para todos os dias da *season* ao longo dos 38 anos de histórico) uma distribuição para os desvios dentro de uma *season* h , mostrada na Figura 2 para as mesmas usinas.




Figura 2 - Distribuição dos erros de previsão *day-ahead* para usina solar e usina eólica

Desta forma, cenários de previsão *day-ahead* podem ser obtidos a partir de sorteios aleatórios de valores da distribuição de probabilidades da Figura 1. Já os dados de geração em tempo real podem ser calculados como a soma destes valores de previsão com desvios, também selecionados randomicamente, da distribuição da Figura 2 (desde que, evidentemente, de uma mesma *season* e usina). Estes valores podem ser inseridos como *inputs* nos problemas de otimização do despacho a serem resolvidos e que gerarão os resultados de mercado (preços e quantidades) a serem aplicados nos cálculos de cada tipo de liquidação desejado. Destaca-se que a metodologia desenvolvida pode ser aplicada a qualquer sistema, além de acomodar outros modelos de construção de cenários renováveis mais sofisticados, sendo necessário apenas modificar os dados de entrada de geração solar e eólica.

4.0 ESTUDO DE CASO

4.1 DESCRIÇÃO DO SISTEMA SIMULADO

A metodologia descrita no Capítulo 3.0 foi, então, aplicada em um estudo de caso do sistema elétrico brasileiro, de modo a avaliar as consequências financeiras da adoção de diferentes mecanismos de liquidação para os agentes que compõem o sistema. Por questões de simplificação e, em especial, de modo a ter uma maior participação de centrais renováveis na configuração simulada, optou-se por direcionar as análises apenas ao subsistema Nordeste, que, como se sabe, possui um elevado potencial para o desenvolvimento de tecnologias renováveis intermitentes, principalmente usinas eólicas. Ainda, o balanço oferta-demanda simulado consiste em uma configuração realista do subsistema para o ano de 2030, para que se observe uma porção ainda maior de solares e eólicas na matriz – e, portanto, potencialmente aumentando as diferenças entre a programação do despacho *day-ahead* e o despacho *real-time*. Neste estudo, foram simuladas duas *seasons*, definidas como os trimestres úmido (fevereiro a abril, *season* 1) e seco (agosto a outubro, *season* 2) deste ano de referência. A simulação foi feita com 38 cenários *day-ahead* de programação do despacho e, para cada um destes, 38 cenários de realização da operação em tempo real.

Com relação ao balanço oferta-demanda, a Figura 3 ilustra as características físicas do subsistema simulado em termos de composição da matriz e evolução da demanda, comparando as cargas média e de ponta previstas com as observadas em 2020. A evolução da oferta foi determinada com base em um exercício de otimização da expansão para todo o sistema brasileiro, utilizando os modelos OptGen e SDDP (3), da PSR.




Figura 3 – Configuração de oferta e demanda estimada para o subsistema Nordeste em 2030

Em termos de modelagem de custos variáveis de geração, destaca-se que as renováveis foram modeladas como centrais de custo variável unitário (CVU) nulo, enquanto as termelétricas tiveram seus custos estimados com base em preços de combustíveis, O&M e parâmetros físicos. No caso das hidrelétricas, os custos de oportunidade foram calculados com base em parâmetros como o fator de produção e o valor da água de cada central individualmente, estimado a partir de uma simulação detalhada do despacho energético do sistema elétrico brasileiro em 2030, utilizando o modelo SDDP. Neste exercício, os custos de oportunidade das usinas foram definidos como os valores médios observados durante cada trimestre, sendo mais altos durante o período seco.

Quanto aos perfis da demanda, estes foram determinados como os perfis diários médios estimados para 2030 em cada *season*. Além disso, somou-se um valor fixo de demanda em cada *season*, para representar exportações para o subsistema Sudeste. Os valores foram calculados como os níveis de exportação médios ao longo de cada trimestre na simulação a partir do SDDP. A Figura 4 ilustra os perfis, com e sem a demanda adicional de exportação.




Figura 4 – Perfil de demanda simulado em cada *season*

4.2 RESULTADOS

Um primeiro *output* válido de ser observado, que vem diretamente do modelo e independe do tipo de liquidação, é o preço de liquidação de diferenças (PLD), que é o preço ao qual a geração é liquidada no mercado de curto-prazo. O PLD é dado pelo custo marginal de operação (CMO), porém com a aplicação de limites horários inferiores e superiores, como definidos na regulação vigente (piso de R\$ 49,77/MWh e teto de R\$ 1197,87/MWh). Particularmente, é interessante que faça distinção entre os preços obtidos durante a programação *ex-ante* do despacho (que, no caso da liquidação dupla, é o chamado DAM, ou *day-ahead market*) e os preços da operação em tempo real (o RTM, *real-time market*). A Figura 5 ilustra o perfil diário do PLD do subsistema Nordeste nos mercados *day-ahead* e *real-time*, mostrando os valores médios e dispersões, exemplificadas por percentis 10 e 90 e por valores máximos e mínimos.




Figura 5 – Distribuição dos preços nos mercados *day-ahead* e *real-time* em cada *season*

Neste exercício, os preços do DAM são influenciados essencialmente pela demanda (que, como mencionado, é mantida constante entre os diversos cenários de uma mesma *season*) e pela disponibilidade de recursos renováveis, além do custo de oportunidade das usinas hidrelétricas (fator que, no subsistema Nordeste em particular, tem peso menor do que os demais fatores). Na *season 1*, que possui uma demanda menor que a *season 2*, porém com uma disponibilidade de recursos eólicos bastante reduzida (como exemplificado na Figura 1 pela central eólica do RN), observam-se preços mais elevados no fim de tarde e ao longo da noite. Porém, a demanda mais baixa e a alta disponibilidade de usinas solares durante o dia, faz com que os preços permaneçam bem próximos do piso regulatório em quase todos os cenários neste trimestre, formando a chamada “curva do pato”. Já na *season 2*, nota-se um perfil mais “bem-comportado” dos preços, com variações menos pronunciadas ao longo do dia. Isto se deve ao fato de que as centrais solares, com a maior demanda, não são suficientes para reduzir substancialmente os preços durante o dia, enquanto a maior produção eólica evita a subida dos preços em momentos em que não há irradiação solar. No mercado em tempo real, os movimentos são bastante semelhantes, porém agora com uma dispersão consideravelmente maior, o que é consequência principalmente da maior dispersão dos cenários renováveis (que são construídos a partir da soma da previsão *day-ahead* com o erro, resultando numa distribuição com maior variabilidade que ambas as componentes individualmente). A maior estabilidade dos preços na *season 2* é ilustrada também através da Tabela 1, que apresenta um comparativo entre variabilidade da demanda líquida do sistema (demanda descontada da geração renovável) e dos preços, medida através dos desvios-padrões destas variáveis divididos pelas suas respectivas médias. Este índice foi calculado para dois conjuntos de dados: (i) somente cenários *day-ahead* e (ii) somente os cenários *real-time* associados a um dado cenário *day-ahead* (e, posteriormente, tirando a média dos valores obtidos para cada cenário *day-ahead*). A Tabela mostra que, na *season 1*, os preços são mais voláteis, em particular com variações na geração renovável provocando variações ainda maiores no PLD (representado por um σ/μ maior no caso dos preços do que na demanda líquida) – relação que se inverte na *season 2*, com preços bem menos variáveis.

Tabela 1 – Variabilidade da demanda líquida e dos preços

σ/μ	Season 1		Season 2	
	Dem. Líq.	Preço	Dem. Líq.	Preço
DAM	0.430	0.732	0.574	0.344
RTM DAM (média)	0.423	0.745	0.567	0.421

Uma análise interessante, que é de particular relevância para a avaliação das receitas dos agentes em cada tipo de liquidação, é o estudo da interdependência entre o preço e geração renovável, que pode ser mensurada por meio do coeficiente de correlação entre essas duas variáveis. O cálculo do índice de correlação é feito separadamente para a geração eólica e solar do sistema e os resultados para diversas combinações de preço e quantidade – associadas aos diferentes tipos de liquidação considerados; ver Equações (1), (2), (3) e (4) – são mostrados na Tabela 2. Como esperado, as correlações são sempre negativas, posto que a tendência é que aumentos na geração renovável (a custo zero) provoquem baixas nos preços (e vice-versa). Especificamente no caso do par que associa os erros de previsão às diferenças de preços entre RTM e DAM (última linha da tabela), nota-se que as usinas solares apresentam correlação negativa, mas muito próxima de zero. Isso indica que os erros de previsão solares tendem a ter pouco impacto nos preços, o que aproximaria os resultados da liquidação dupla à liquidação *day-ahead only*. Isto porque, no limite, os erros de previsão seriam liquidados exatamente ao preço do DAM (caso não houvesse impacto algum nos preços), o que levaria a resultados idênticos ao modelo de liquidação única semelhante ao que é atualmente adotado no Brasil, que multiplica a geração real pelos preços calculados *ex-ante*. Esta particularidade no caso das solares é analisada em mais detalhe mais à frente, com resultados financeiros.

Tabela 2 – Tabela de correlações entre geração e preços

ρ Geração, Preço			Season 1		Season 2	
Liquidação associada	Geração	Preço	Solares	Eólicas	Solares	Eólicas
<i>Real-time only</i>	RTM	RTM	-0.469	-0.459	-0.426	-0.483
<i>Day-ahead only</i>	RTM	DAM	-0.586	-0.234	-0.479	-0.266
<i>Multi-settlement</i>	DAM	DAM	-0.590	-0.367	-0.479	-0.432
<i>Multi-settlement</i>	RTM-DAM	RTM	-0.098	-0.357	-0.032	-0.442
-	RTM-DAM	RTM-DAM	-0.074	-0.538	-0.007	-0.564

A forte correlação (negativa) entre preços e geração renovável é ilustrada na Figura 6, que compara os preços médios do mercado *real-time* com as gerações solar e eólica médias e, em especial, com a demanda líquida média. No caso desta última, constata-se uma evidente correlação com os preços, que tendem a seguir o mesmo perfil desta variável.




Figura 6 – Relação entre preços e demanda líquida no mercado *real-time* em cada *season*

Voltando as análises agora para os resultados financeiros, como comentado, estes são avaliados para três tipos de liquidação: (i) liquidação múltipla (*multi-settlement*), em particular, liquidação dupla (as receitas são calculadas com base nas Equações (1) e (2)); (ii) liquidação única com preços calculados no mercado de tempo real, isto é, *RTM only* (receitas calculadas segundo a Equação (3)); e (iii) liquidação única com preços calculados no mercado *day-ahead*, isto é, *DAM only* (receitas calculadas segundo a Equação (4)). As análises financeiras foram realizadas para duas usinas selecionadas: solar em PE e eólica no RN, as mesmas utilizadas para ilustrar as distribuições dos perfis de previsão de geração *day-ahead* e erros de previsão, na Figura 1 e na Figura 2). A Figura 7 traz uma representação gráfica das receitas diárias destas centrais em cada uma das *seasons*, considerando os diferentes tipos de liquidação comentados, medidas em R\$ por MW instalado. Ilustra-se a dispersão destes montantes nos cenários de operação simulados, por meio de mediana, quartis e percentis, além do valor médio e do $CVaR_{95\%}$. Ressalta-se que os eixos das duas usinas estão em diferentes escalas, para facilitar a visualização, posto que a central eólica, além de possuir fatores de capacidade mais elevados que a solar, também gera justamente nos períodos de maior preço (principalmente na parte da noite), fazendo com que obtenha receitas significativamente superiores. Similarmente, além do nível médio, observa-se que a variabilidade das receitas da eólica também é superior à da solar.




Figura 7 – *Boxplot* das receitas de usinas renováveis selecionadas em cada tipo de liquidação

No que tange aos diferentes tipos de liquidação, nota-se que, em geral, a liquidação *RTM only* resulta numa maior dispersão entre os cenários, o que ocorre de forma pronunciada no caso da usina solar. Isto se deve à maior dispersão tanto de geração (visto que a distribuição da geração em tempo real resulta da soma entre a da previsão *day-ahead* e a do erro de previsão) e preço, ilustrada na Figura 5. Em particular, neste tipo de liquidação, nota-se uma amplitude significativa nos quantis superiores da distribuição de receitas da central fotovoltaica, principalmente na *season 1*. Isto se dá por conta de os preços médios durante as horas de maior irradiação solar estarem sempre muito próximos ao piso regulatório, o que dá pouca margem para flutuações negativas – ao passo que variações positivas mais bruscas ocorrem no RTM em alguns poucos cenários. Porém, de modo geral, percebe-se uma dispersão pequena nas receitas da usina solar durante o período úmido. Já no período seco, que possui preços ao longo do dia e tarde um pouco mais elevados e com uma maior volatilidade, a central fotovoltaica possui resultados mais positivos e também com maior incerteza. No caso da eólica, que possui perfil de geração mais bem distribuído ao longo do dia, a amplitude das dispersões de receitas em cada *season* é semelhante (e até um pouco maior na *season 1*, por conta da variabilidade dos preços na parte da noite e na madrugada). Porém, a maior incidência de ventos no período seco faz com que os níveis de receita sejam superiores na *season 2*.

Outra forma intuitiva de analisar a receita média é através da métrica de preço capturado (\bar{p}). Essencialmente, essa métrica consiste em dividir a receita média da usina pela sua geração média. Desta forma, obtém-se um valor em R\$/MWh, representando o preço médio ao qual a usina vendeu a sua energia ao longo de todos os cenários, representado na mostrado na Figura 8 para cada usina e *season*, com base nas diferentes liquidações.




Figura 8 – Preço capturado médio de usinas renováveis selecionadas em cada liquidação

Nota-se que, ao passo que a usina solar captura preços bem mais altos na *season* seca, por conta dos preços mais elevados durante o dia, os resultados para a eólica são bastante semelhantes entre os trimestres. Isto se deve ao fato de que, apesar de a energia ser mais cara durante o dia na *season 2* do que na 1, esta relação se inverte nos períodos em que não há sol, levando o valor capturado pela eólica a níveis parecidos. Com relação às diferenças entre cada tipo de liquidação, no caso da solar, percebe-se que ela possui uma vantagem na liquidação *RTM only* com relação às demais. Isto está diretamente ligado ao fato de este modelo liquidar toda a geração ao preço do mercado *real-time*, cuja distribuição de preços apresenta alguns cenários com valores bem altos, enquanto os cenários mais negativos estão limitados pelo preço piso – enquanto os preços *day-ahead* possuem uma dispersão menor, estando frequentemente bem próximos ao limite mínimo. Além disso, como já introduzido na Tabela 2, variações na geração solar tendem a ter pouco impacto nos preços. Desta forma, os resultados do modelo de liquidação dupla, para esta usina, acabam sendo bem semelhantes ao da liquidação *DAM only*, como ilustrado pelos

preços capturados por esta tecnologia. Já no caso da eólica, nota-se que esta também se beneficia dos cenários de *spikes* de preços no mercado em tempo real e do fato de desvios negativos estarem limitados ao PLD piso. Porém, na comparação entre as liquidações *DAM only* e *multi-settlement*, tem-se que a liquidação dupla acaba por provocar resultados piores para esta central. Isto se dá por conta da correlação bastante negativa entre os erros de previsão (geração realizada menos geração prevista) e os preços no RTM, significando que os desvios a serem liquidados neste mercado tendem a ser altamente penalizados – a usina acaba comprando eventuais desvios negativos a preços mais elevados e vendendo desvios positivos a preços menores, em comparação com a liquidação *DAM only*.

5.0 CONCLUSÃO

Este trabalho apresentou uma metodologia para avaliação dos impactos da adoção de um mecanismo de liquidação dupla em mercados elétricos de curto-prazo, em comparação com mecanismos de liquidação única, emulando erros de previsão de geração renovável na programação *day-ahead* do despacho. Algumas das conclusões obtidas são:

- Com a maior participação renovável, os perfis de preços em 2030 no Nordeste são altamente dependentes da disponibilidade de recursos solares e eólicos, com correlação negativa entre geração renovável e preços.
- Erros de previsão tendem a prejudicar os geradores no caso de liquidação dupla (principalmente a eólica, no estudo de caso apresentado), reforçando que este mecanismo incentiva a qualidade das previsões.
- Por outro lado, liquidações que utilizam dados de geração realizada e preço *ex-ante* levam a uma incompatibilidade entre a programação do despacho e a operação, não penalizando erros de previsão.
- A liquidação com base em preços e quantidades do mercado *real-time* acarreta resultados financeiros mais voláteis para as usinas geradoras, sendo motivação para a adoção de uma etapa *ex-ante* do mercado.
- As consequências financeiras da adoção de diferentes modelos de liquidação dependem do *interplay* entre uma série de variáveis e podem ser heterogêneas entre distintos sistemas e mercados, justificando análises detalhadas caso a caso – em particular considerando incertezas em variáveis além da geração renovável.

REFERÊNCIAS BIBLIOGRÁFICAS

- (1) INSTITUTO DE INVESTIGACIÓN TECNOLÓGICA (IIT) (2018). Estudio para la modernización del despacho y el mercado spot de energía eléctrica - despacho vinculante y mercados intradiarios.
- (2) PSR CONSULTORIA; “Propostas de metodologias para a formação de preços por oferta no Brasil. Entregável 1: Avaliação conceitual e estratégias de desenho”; Rio de Janeiro: PSR; 2020.
- (3) PÉREIRA, M.V.F., PINTO, L.M.V.G.; “Stochastic optimization of a hydroelectric system: a decomposition approach”; Water Resources Research; 1985.

DADOS BIOGRÁFICOS



Graduado em Engenharia de Produção pela PUC-Rio, com ênfase em Análise de Riscos. Desde 2019, trabalha na PSR Consultoria, onde atua na área de estudos de mercados elétricos internacionais, desenvolvendo projetos de análise, desenho e modelagem de mercado, projeção de preços, diligência e planejamento estratégico para agentes do setor. É profundo conhecedor de metodologias de despacho econômico e de planejamento energético geração-transmissão, incluindo as ferramentas da PSR SDDP e OPTGEN, bem como de modelagem de cenários de geração renovável (como o TSL, também da PSR). Possui ampla experiência profissional com clientes de diversos países, em especial na América Latina.

(2) GABRIEL CUNHA

Gabriel Cunha é doutor em economia pela FGV, mestre em planejamento energético pela UFRJ, e engenheiro químico pela USP. Ingressou na PSR em 2011, onde atua como gerente de projetos em temas associados à análise de mercados elétricos internacionais, fundamentos econômicos de sistemas de energia, e desenho de mercado.

(3) JOÃO PEDRO THIMOTHEO BASTOS

João Pedro Bastos é engenheiro de produção graduado cum laude pela UFRJ, e atualmente é mestrando em Engenharia Elétrica na PUC-Rio. Desde 2014, trabalha na consultoria PSR, onde é atualmente gerente de projetos na área internacional da empresa, desenvolvendo projetos voltados à análise de mercados elétricos internacionais, modelagem de mercado, projeção de preços de energia e formulação de políticas no setor. Tem sido instrutor em cursos sobre desenho de mercados de eletricidade, leilões de energia e modelagem de sistemas elétricos. É autor ou coautor de livros e artigos técnicos publicados nacional e internacionalmente.

(4) DAVI M VALLADAO

Davi Valladão é professor do Departamento de Engenharia Industrial da Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio). Seus interesses de pesquisa são ciência de dados, otimização sob incerteza e análise de risco. Davi tem doutorado em Sistemas de Apoio à Decisão (2011) no Departamento de Engenharia Elétrica da PUC-Rio. Como parte de seu programa de doutorado, ele foi pesquisador visitante do departamento Operations Research and Financial Engineering (ORFE) da Universidade de Princeton. Além disso, Davi tem mestrado em Ciências Atuariais e Finanças (2008) e bacharelado em Engenharia Elétrica e Industrial (2006), também pela PUC-Rio.