

Problema de Ofertas Estratégicas de uma Companhia *Price-Maker*: Avaliação da Influência da Previsão de Ofertas dos Demais Agentes

Caio N. Chaves* Tiago G. Cabana** Leonardo Nepomuceno***

* Faculdade de Engenharia de Bauru, Universidade Estadual Paulista,
SP, (e-mail: caio.chaves@unesp.br).

** Faculdade de Engenharia de Bauru, Universidade Estadual Paulista,
SP, (e-mail: tiago.cabana@unesp.br).

*** Faculdade de Engenharia de Bauru, Universidade Estadual
Paulista, SP, (e-mail: leonardo.nepomuceno@unesp.br).

Abstract: This paper uses observed power and price data from an electric power auction as a basis for forecasting these quantities in a future time. The forecast techniques covered include: Rolling Averages, Multiple Linear Regression and Triple Exponential Smoothing Holt-Winters. A notable application of this work is the resolution of the Strategic Offering Model (SOM) problem, where a generating company aims to maximize its profits through optimized offers. For comparison, two simplistic methods of benchmarking were added: Naïve and Simple Average. The results corroborated with the presented theory, because the method related to the smallest relative error between the forecast and the “real” value, also generated a higher profit for the generating company in the auction simulation. The Simple Average method yielded the best results, surpassing the results of robust prediction algorithms such as Holt-Winters.

Resumo: O presente trabalho utiliza dados observados de potência e preço, de um leilão de energia elétrica, como base para previsão dessas grandezas em um tempo futuro. As técnicas de previsão abordadas incluem: Médias Móveis, Regressão Múltipla Linear e Tripla Suavização Exponencial de Holt-Winters. Uma notável aplicação deste trabalho é a resolução de um problema do Cálculo de Ofertas Estratégicas (COE), onde uma companhia geradora visa maximizar seus lucros por meio de ofertas otimizadas. A título de comparação foram adicionados dois métodos simplistas de *benchmarking*: *Naïve* e Média Simples. Os resultados corroboraram com a teoria apresentada, pois o método referente ao menor erro relativo entre a previsão e valor “real”, também gerou um maior lucro para a companhia geradora na simulação do leilão. A Média Simples apresentou os melhores resultados, superando os de algoritmos robustos como Holt-Winters.

Keywords: Time Series; Demand Forecast; Exponential Smoothing; Strategic Offering Model.

Palavras-chaves: Séries Temporais; Previsão De Demanda; Suavização Exponencial; Cálculo De Ofertas Estratégicas.

1. INTRODUÇÃO

Desde o início da década de 90, a comercialização de energia elétrica tem ocorrido através de mercados de eletricidade. Este artigo considera um mercado de eletricidade do dia seguinte do tipo pool, nos chamados leilões de energia elétrica. Neste ambiente, as companhias geradoras fazem ofertas de venda de blocos de potência (MW) e os consumidores e varejistas dão lances de compra de blocos de potência (MW), a preços (\$/MW) especificados de compra e venda. A partir destas informações é que o Operador de Mercado (OM) realiza o cálculo do preço de comercialização de energia, também chamado de preço

de equilíbrio, válido para todo o mercado, enquanto o Operador Independente do Sistema (OIS) é responsável por garantir a qualidade e segurança do sistema (Kardakos et al., 2013).

As companhias geradoras podem ser do tipo *price-maker*, isto é, que são capazes de alterar o preço de equilíbrio do mercado, ou *price-taker*, que não têm poder de influência no preço de equilíbrio de mercado (Conejo et al., 2010). Ambas têm por objetivo maximizar suas receitas líquidas, sendo que para tanto é necessário o cálculo dos blocos de ofertas que serão ofertadas no leilão do dia seguinte. Para a definição destes blocos as companhias geradoras *price-maker* utiliza o problema do Cálculo de Ofertas Estratégicas (COE).

* Ao Conselho Nacional de Pesquisa (CNPq) e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro.

Duas abordagens básicas têm sido adotadas na literatura para a solução de problemas de COE. A primeira abordagem envolve a formulação do COE por meio de um problema de otimização bi-nível (Baillio et al., 2004; Dai and Qiao, 2015), em que o problema de nível superior é o modelo de autoprodução (AP), que consiste na maximização da receita líquida da companhia, isto é, o resultado da multiplicação da produção da companhia pelo preço de equilíbrio, subtraído os custos. O problema do nível inferior é o Procedimento de Equilíbrio de Mercado (PEM), que é o modelo utilizado pelo OM para determinar o preço de equilíbrio (que é utilizado no problema de nível superior), bem como as potências consumidas e despachadas. Sob determinadas condições é possível escrever o problema bi-nível como um problema de um único nível denominado de problema matemático com restrições de equilíbrio (MPEC, do inglês *Mathematical Problem with Equilibrium Constraints*). Todavia, o MPEC apresenta grandes dificuldades computacionais de processamento devido à presença das restrições de complementariedade (Gabriel et al., 2013).

A segunda abordagem envolve a resolução do COE de algoritmos sequenciais, sendo a primeira etapa um modelo de AP, visando a produção ótima que maximiza o lucro das companhias geradoras, e em uma segunda etapa uma heurística para determinação dos blocos (potência e preço) baseados no resultado do modelo de AP (Cabana and Nepomuceno, 2018; Torre et al., 2004).

Independentemente do tipo de COE, a companhia geradora necessita considerar dados de ofertas das outras companhias e lances das demandas em seus modelos de otimização. Por conta disso as companhias calculam cautelosamente suas ofertas levando em consideração o comportamento dos demais participantes do leilão. Quanto mais próximos forem estes dados daqueles realmente ofertados no futuro pelas companhias e demandas, maior será o lucro alcançado pelas companhias.

Para a escolha desses dados, as companhias podem simplesmente escolher os blocos ofertados no dia anterior, fazer uma média desses valores considerando vários dias ou utilizar um método de previsão. Este trabalho tem por objetivo apresentar e avaliar 5 métodos para a escolha dos blocos de ofertas e lances a serem utilizados pelas companhias geradoras no problema de COE, a partir de um histórico de dados de 10 dias. Serão avaliados 3 métodos de previsão: Regressão Múltipla, Médias Móveis, Holt-Winters e 2 métodos simplistas de *benchmark*: Média dos blocos dos 10 últimos dias e os blocos ofertados no dia anterior.

2. PROBLEMA DO CÁLCULO DE OFERTAS ESTRATÉGICAS

O Problema do COE utilizado neste artigo é similar ao apresentado em Cabana (2019). Este modelo é dividido em 3 etapas, que são apresentadas de modo simplificado na Fig. 1.

A primeira etapa consiste na obtenção das curvas de demanda residual da companhia. Essa curva apresenta o poder de mercado das companhias geradoras do tipo *price-maker*, pois expõe a relação entre o preço de equilíbrio de energia com a cota da companhia aceita no mercado (Torre

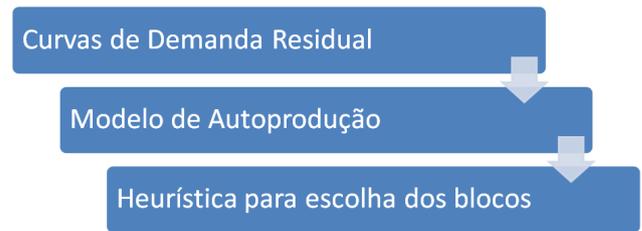


Figura 1. Esquema das etapas do modelo do COE utilizado neste trabalho.

et al., 2002). De um modo geral, esta curva é descendente, pois quanto maior a cota da companhia aceita no mercado, menor será o preço de equilíbrio. Atualmente existem diversos métodos para sua construção, sendo que todos utilizam os dados de lances e ofertas dos consumidores e geradores para sua construção. Neste trabalho usaremos o método proposto em Cabana (2019).

Esta curva é então utilizada como informação de entrada de um modelo de AP, que definirá a potência ótima gerada por cada unidade de geração da companhia que maximizará os lucros desta. Este trabalho utiliza o modelo de AP apresentado em Torre et al. (2002), de modo que a curva de demanda residual é descrita através de uma programação linear inteira.

Por fim, com a informação da potência ótima que a companhia deseja gerar, a partir de uma heurística, baseada em Xu and Baldick (2007), são determinados os blocos que a companhia deverá ofertar no leilão do dia seguinte.

Deste modo, a alteração dos dados das ofertas das demais companhias e lances dos consumidores na construção da curva de demanda residual irá resultar em uma escolha de blocos a serem ofertados no leilão do dia seguinte diferentes. Quanto mais próximos esses dados considerados forem dos realmente ofertados pelos demais participantes no dia seguinte, maior será o lucro resultante das ofertas calculadas no problema do COE. Estes dados podem ser obtidos através de métodos de previsão de séries temporais. A próxima sessão apresentará os métodos utilizados neste trabalho.

3. MÉTODOS DE PREVISÃO

Previsão de dados é uma tarefa comum em meios empresariais, podendo ser empregada nos mais diversos setores de uma empresa, seja ela ligada a produtos ou serviços. No caso do ambiente de mercado de energia, as companhias geradoras tomam como incertos os dados do dia seguinte, contudo possuem um histórico de dados de ofertas dos demais agentes. A partir deste histórico de ofertas é possível definir os dados para o COE, através dos métodos de previsão de séries temporais. Neste presente trabalho, apresentamos a seguir alguns métodos clássicos de obtenção de dados futuros com base em dados previamente observados.

3.1 Regressão Múltipla Linear

No método de Regressão Múltipla Linear tem-se como objetivo a previsão do valor da variável dependente y , que será o resultado da combinação linear das variáveis

independentes x ligadas ao problema e de seus coeficientes β_n , sendo β_0 o termo independente da equação, como apresentado:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n. \quad (1)$$

Nesta equação, os índices denotam diferentes variáveis independentes, sendo x_1 o valor da primeira variável independente, x_2 o valor da segunda variável independente e assim sucessivamente. Esta linha de raciocínio é seguida até a adição da última variável independente x_n na equação.

Os coeficientes β possuem os mesmos índices, indicando que compõem a combinação linear juntamente com as variáveis independentes. Além disso, β_0 representa o valor da variável dependente y quando as variáveis independentes x assumem valor zero.

3.2 Médias Móveis

Este método usa os n últimos valores da série temporal x_t , como a previsão para o tempo $t+1$ da variável dependente y . Portanto:

$$y_{t+1} = \sum_{i=t-n+1}^t \frac{x_i}{n}. \quad (2)$$

Contudo, a equação (2) é apenas usada quando não existe sazonalidade nos dados. Desta maneira utilizou-se uma técnica de suavização, para uma correção *à priori*, onde é feita a correção da série temporal do efeito da sazonalidade através da divisão dos valores da série temporal pelos seus respectivos fatores sazonais, como mostrado em (3):

$$FS_i = \frac{\mu_i}{\mu_t}, \quad (3)$$

onde:

- μ_i é a média dos valores da série temporal para os períodos i ;
- μ_t é a média dos valores da série temporal toda.

Após realizada esta correção dos dados de cada um dos dias da semana (sazonalidade do problema), utilizou-se a previsão por meio do método de médias móveis para previsão dos dados futuros e, só então, multiplicou-se pelo fator de sazonalidade FS_i para restauração do comportamento sazonal notado anteriormente.

3.3 Holt-Winters (Tripla Suavização Exponencial)

A primeira vez em que suavização exponencial foi apresentada foi no ano de 1959, e desde então tem motivado pesquisadores em uma das linhas mais bem-sucedidas de métodos de previsão.

A técnica de previsão utilizando suavização exponencial é basicamente a ponderação de observações passadas, com seus pesos de decaindo exponencial conforme as observações são ultrapassadas no tempo. Em outras palavras, quanto mais recente é o dado observado maior é o peso associado a ele na ponderação.

Este algoritmo proporciona uma previsão de dados de maneira rápida, confiável e para uma ampla gama de

séries temporais, fato esse de grande importância para as aplicações industriais.

A ideia por trás deste método é aplicar a suavização exponencial aos componentes sazonais, assim como ao *nível* e à *tendência* da série. O método é apresentado em (4) a (7):

$$\hat{y}_{x+m} = l_x + mb_x + s_{x-L+1(m-1)/L}, \quad (4)$$

em que:

$$l_x = \alpha(y_x - s_{x-L}) + (1 - \alpha)(l_{x-1} + b_{x-1}) \quad (5)$$

$$b_x = \beta(l_x - l_{x-1}) + (1 - \beta)b_{x-1} \quad (6)$$

$$s_x = \gamma(y_x - l_x) + (1 - \gamma)s_{x-L}. \quad (7)$$

onde:

- \hat{y} : dado previsto de acordo com o método Holt-Winters;
- l (nível): é o valor ou faixa típica de valores que a variável pode assumir, se não for observado comportamento crescente ou decrescente no longo prazo;
- b (tendência): é o comportamento de longo prazo da série;
- s (sazonalidade): componente de sazonalidade para cada valor previsto;
- α, β, γ : constantes de suavização de nível, tendência e sazonalidade, respectivamente;
- L : corresponde ao número de períodos x em um ciclo sazonal;
- m : refere-se ao período anterior.

4. MÉTODOS SIMPLISTAS DE BENCHMARK

Foram implementados dois métodos simplistas de *benchmark* neste trabalho. Devido à rudimentariedade dos métodos, não foi possível levar em consideração o comportamento singular de sazonalidade dos dados.

4.1 Naïve

No método *Naïve* (ingênuo, em inglês), a previsão de um dado futuro, y_{x+1} , é simplesmente feita pela repetição do último valor observado y_x , sendo matematicamente representado por:

$$\hat{y}_{x+1} = y_x \quad (8)$$

4.2 Média Simples

Um método menos rudimentar que o citado em 4.1 é o de Média Simples. Toma-se todos os n valores observados, calcula-se a média aritmética e assume-se que o próximo dado da série temporal a ser previsto, y_{x+1} , será justamente este valor médio calculado.

$$\hat{y}_{x+1} = \frac{1}{n} \sum_{i=1}^n y_i. \quad (9)$$

5. METODOLOGIA

Inicialmente, foram extraídos dados de blocos de ofertas de 5 unidades geradoras e lances de 17 unidades de demandas, de potência e preço, para 24 horas utilizados em Cabana (2019). A partir desses dados, foram gerados, de modo aleatório dentro de uma faixa pré-estabelecida de $\pm 5\%$ sobre os dados iniciais, dados para 10 dias de comercialização de energia elétrica. Neste trabalho, supõe-se a situação que a companhia geradora que deseja resolver o COE, deseja calcular as ofertas para uma próxima segunda-feira, possuindo os dados das últimas duas semanas entre segunda e sexta-feira.

Esta análise só é possível devido ao comportamento característico da potência consumida/despachada. Durante os dias analisados nota-se uma grande semelhança se comparada essa grandeza entre dias distintos (Taylor and McSharry, 2007).

Para efeito de comparação e validação da metodologia proposta, foi realizado novamente o processo de geração aleatória de dados para um 11^o dia, podendo representar os dados de potência e preço “reais” para aquele período. A Fig. 2 apresenta os dados de potência dos blocos de lance da unidade 13, nela pode-se notar a sazonalidade de 10 dias, de modo que o perfil de potência para os demais dias permanece semelhante ao ilustrado.

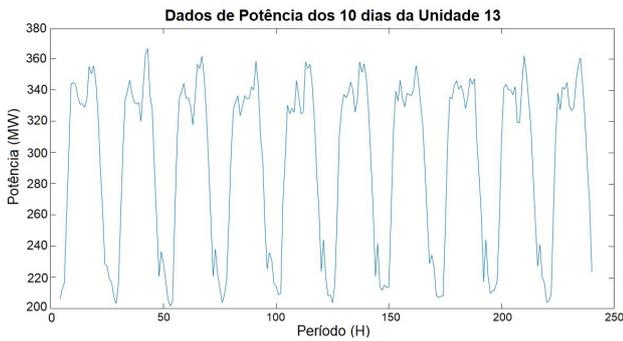


Figura 2. Dados de potência da unidade 13 para os últimos 10 dias.

A partir dos dados de 10 dias foi feita a previsão dos lances/ofertas para o 11^o dia utilizando 3 métodos de previsão e 2 métodos simplistas. O primeiro método de previsão utilizado foi o de Regressão Múltipla.

Esta situação dispõe de dados de 22 unidades (17 de demanda e 5 geradoras), durante 10 dias por 24 horas. Entretanto, optou-se por elaborar 22 modelos de regressão com 3 coeficientes (linear, dia e hora), do que um único modelo com 4 coeficientes (linear, unidade, dia, hora). Desta forma, espera-se que os dados previstos fossem mais precisos. Os Coeficientes da Regressão Múltipla calculados para cada unidade são apresentadas na Tabela 1.

O segundo método de previsão escolhido foi o de Médias Móveis. Neste caso, como os dados possuem uma sazonalidade, primeiro retirou-se a componente sazonal da série, como citado na Seção 3.2. Realizada a correção à priori, cada unidade foi então representada por um conjunto de 240 dados de entradas, referente às 24 horas dos 10 dias observados, agora sem uma característica sazonal aparente.

Tabela 1. Coeficientes β de cada unidade geradora.

Unidade	β_1	β_2	β_3
1	68.3370	0.0301	0.0033
2	69.5329	-0.0106	0.0027
3	70.7625	0.0088	0.0217
4	67.4061	0.0163	-0.0102
5	72.1660	-0.0008	0.0081
6	69.9378	0.0415	-0.0161
7	74.3545	0.0124	-0.0040
8	69.6828	-0.0120	0.0264
9	64.8536	0.0036	-0.0055
10	80.7923	0.0239	0.0063
11	73.3674	-0.0027	-0.0106
12	65.2299	-0.0162	-0.0033
13	74.5222	0.0209	0.0041
14	71.6114	-0.0330	-0.0079
15	79.1686	-0.0258	-0.0117
16	78.8263	-0.0272	-0.0111
17	74.1614	-0.0165	-0.0105
18	53.0802	0.0085	0.0091
19	53.1391	0.0076	0.0031
20	82.8931	0.0244	-0.0055
21	82.8875	0.0492	-0.0115
22	104.1878	0.0182	0.0167

Decidiu-se utilizar $n = 50$, isto é, considerar 50 dados observados para a previsão do próximo valor desejado. Este valor adotado para n foi determinado por um processo de tentativa e erro, pois verificou-se que ainda que fosse utilizada uma quantidade maior que 50 observações para os cálculos, o valor do erro relativo não diminuiu como era de se esperar. Após realizada a previsão dos valores de potência e preço para o 11^o dia, aplicou-se o fator sazonal no resultado para que não houvesse a interferência no comportamento dos dados originais.

O terceiro método de previsão aplicado foi o método de Tripla Suavização Exponencial de Holt-Winters. Neste caso estudado, como os dados dos 10 dias são semelhantes, não existe uma tendência para a previsão. Desta forma o parâmetro β , referente à tendência da série temporal, foi considerado nulo. Em contrapartida, os dados apresentam alta sazonalidade. Após diversas simulações, os melhores resultados obtidos foram a partir da adoção dos parâmetros de sazonalidade e nível, respectivamente $\gamma = 0.792$ e $\alpha = 0.193$. Verificou-se também que o parâmetro de nível não exerce forte influência sobre os dados previstos, se comparado ao parâmetro de sazonalidade, por exemplo.

Por fim, os dois métodos simplistas utilizados foram o cálculo da média dos valores dos blocos (potência e preço) dos últimos 10 dias e simplesmente repetir o bloco de ofertas do 10^o dia, isto é, da última sexta-feira gerada.

Vale ressaltar que os blocos previstos são compostos por um par de dados (Potência [MW]/Preço [\$/MW]). A partir dos dados previstos através de cada um dos 5 métodos propostos, foi feito o cálculo do erro relativo entre os dados previsto de potência e preço, com os dados simulados para o 11^o dia (referência). Os resultados obtidos são apresentados na seção a seguir.

A partir dos blocos previstos por cada um dos 5 métodos, é utilizado o método de COE apresentado na seção 2, onde foram levantadas 5 curvas de demanda residual, uma para cada tipo de método. Estas curvas foram aplicadas

em um modelo de autoprodução, e segundo o resultado deste modelo, isto é, a potência de geração ótima de cada companhia, junto a heurística, são escolhidos os blocos que serão ofertados no leilão.

A última análise a ser feita é o lucro alcançado pela companhia a partir de cada método. Foram simulados 5 leilões, em que os blocos ofertados pela companhia geradora foram aqueles calculados pelo COE a partir das informações de cada método de previsão, e os blocos das demais unidades geradores e unidades de demanda são os dados “reais” do 11º dia. A partir desta simulação foi possível calcular a receita líquida obtida pela companhia a partir de cada um dos métodos de previsão.

6. RESULTADOS E DISCUSSÕES

A partir dos 5 métodos de previsão apresentados, foram previstos os blocos de potência e preço para as 24 horas das 22 unidades da segunda-feira por vir. A Fig. 3 apresenta a previsão de uma das 22 unidades, assim como o valor “real” para o mesmo período, para efeito de comparação e análise. Visualmente é possível notar que 4 dos 5 métodos possuem um perfil de previsão semelhantes aos dados observados, exceto pelo método de Regressão Múltipla Linear, o qual apresentava um perfil de previsão na forma de um segmento de reta.

De forma semelhante, nota-se o comportamento dos preços associados a estes blocos, agora justificado pela lei de oferta e procura proveniente do âmbito econômico convencional. Entretanto, é possível constatar uma maior suavidade entre os pontos se comparado ao perfil de dados de potência gerada/consumida.

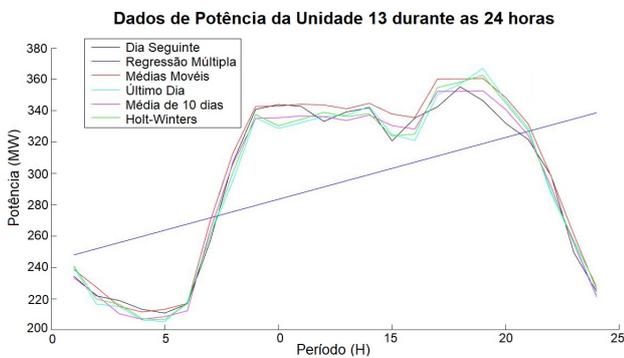


Figura 3. Resultado das previsões de dados de potência para a Unidade 13.

A Tab. 2 apresenta os erros relativos entre os métodos previstos e o valor real considerado, assim como a receita obtida pela companhia geradora. Vale ressaltar que os erros apresentados nesta tabela são as médias dos erros percentuais de cada método, pois cada método prevê 24 valores de 22 unidades, resultando em 528 dados, sendo assim realizado o cálculo da média desses erros.

Como já observado na Fig. 3, os erros do método de regressão, em relação a potência, são muito superiores aos demais métodos, que ficam em torno de 2%. Isto acontece, pois conforme exposto anteriormente, o perfil de potência consumido é extremamente não linear, não podendo ser aproximado a uma reta.

Uma importante análise a ser feita é a relação inversamente proporcional entre a receita da companhia geradora e o erro apresentado por um determinado método, de modo que se ordenarmos de modo crescente os erros dos métodos, ordenaremos de modo decrescente em relação a receita. Para os 4 melhores métodos a receita da companhia é em torno de \$600.000, de modo que a diferença do melhor método (média dos 10 elementos) para o segundo método (Holt-Winters) e para o último (Regressão Múltipla), são respectivamente de \$642,20 e \$36.830,01. Por mais que a diferença de receita do melhor método para o segundo melhor, seja de um valor relativamente baixo, ao relembramos que esta é uma diferença diária, em um ano a companhia deixará de ganhar \$234.403,00. Ao analisarmos ao pior método, esse valor chega a \$13.442.953,65.

Além disso é possível observar também que todos os erros de preços permaneceram baixos, de modo que o melhor método em relação aos erros de preço foi o de Regressão Múltipla. Deste modo é possível observar que, para a receita, a previsão dos valores de potência dos blocos dos demais participantes, tem maior influência do que o preço. Vale ressaltar que o método de Holt-Winters possui o 2º pior erro de preços (1,70%), todavia os valores utilizados pelas constantes para previsão de potência foram os mesmos para previsão de preço, de modo caso fossem utilizados outros valores, possivelmente o erro seria menor.

A última análise a ser feita são pelos motivos de o melhor método ser a média dos 10 dias anteriores. Alguns fatores são importantes serem destacados, que influenciaram este resultado. Primeiro ponto, todos os dados foram gerados com uma faixa de 5% em relação a um banco de dados iniciais. Todavia, na realidade, não é possível estabelecer uma faixa fixa para a oferta de blocos.

Outro ponto que vale salientar é a ausência de tendência na série de dados observados. Ao analisarmos as ofertas de 10 dias no mercado como, por exemplo, em uma época de mudança de estação, existe um acréscimo na potência consumida, por conta do ligamento de aparelhos domésticos relacionados à regulação de temperatura. Dados com característica de tendência acentuada provavelmente fariam com que os erros de métodos simplistas fossem maiores, valorizando a robustez do método de Tripla Suavização Exponencial de Holt-Winters, por ser capaz levar em conta esse tipo de característica.

7. CONSIDERAÇÕES FINAIS

Este trabalho avaliou cinco métodos para prever os blocos de ofertas enviados pelas demais empresas geradoras, bem como os blocos de ofertas enviados pelos consumidores em um mercado de energia no dia seguinte. Esses dados são fundamentais para um cálculo confiável de problemas de

Tabela 2. Erros de Previsão.

Método de Previsão	Erro de Potência	Erro de Preço	Receita Líquida
Regressão Múltipla	11,75%	0,17%	\$566.205,99
Médias Móveis	2,04%	0,42%	\$600.584,70
<i>Naïve</i>	2,07%	1,26%	\$600.019,30
Média Aritmética	1,50%	0,39%	\$603.036,00
Holt-Winters	2,00%	1,20%	\$602.393,80

ofertas estratégicas. Observamos que a escolha do método mais adequado ao problema implica em uma receita maior para a empresa, o que é extremamente importante, uma vez que esta empresa visa maximizar seus lucros.

Entre os métodos avaliados, o que apresentou melhor desempenho na previsão dos dados foi o método da média aritmética simples. Isso se deve ao fato de o banco de dados utilizado apresentar uma situação específica de consumo de energia, onde não se verifica tendência de consumo, seja com aumento ou diminuição da demanda. Nesse caso, não há variação significativa envolvendo ofertas e lances para blocos de quantidade/preço no leilão de energia.

Vale ressaltar que, embora o método de média tenha apresentado os melhores resultados, os demais métodos investigados, com exceção da regressão múltipla linear, também apresentaram bons resultados, uma vez que não houve grande disparidade entre os lucros obtidos e os erros calculados são pequenos. O método de regressão linear acaba não tendo um bom desempenho pois o perfil de consumo de energia não pode ser aproximado a uma reta. Um método de regressão não linear ou simplesmente o método de regressão quadrática provavelmente alcançará melhores resultados, contudo sua complexidade também aumenta.

Trabalhos futuros incluem a implementação de um lote de dados mais complexo, onde é usado um número maior de dias, e pode ser observada uma tendência no consumo de energia, representando a situação das mudanças de estação, por exemplo. Outro trabalho futuro inclui a comparação dos métodos apresentados com os métodos estocásticos, abordando as incertezas no COE. Finalmente, alguns trabalhos futuros também serão necessários para explorar a implementação de métodos que possam representar a sazonalidade dos dados durante a semana, considerando as diferenças no consumo de energia nos finais de semana.

REFERÊNCIAS

- Baillo, A., Ventosa, M., Rivier, M., and Ramos, A. (2004). Optimal offering strategies for generation companies operating in electricity spot markets. *IEEE Transactions on Power Systems*, 19(2), 745–753. doi:10.1109/TPWRS.2003.821429.
- Cabana, T.G. (2019). *Novo Método de Construção da Curva Cota-Preço para Companhias Geradoras do tipo Price-Maker via Modelos de Otimização*. Dissertação de mestrado, Universidade Estadual Paulista - UNESP.
- Cabana, T.G. and Nepomuceno, L. (2018). Novo Método de Construção da Curva Cota-Preço para Companhias Price-Makers no Mercado do Dia Seguinte. In *IEEE/IAS Inter. Conf. on Ind. Applic.*, 8.
- Conejo, A.J., Carrión, M., and Morales, J.M. (2010). *Decision Making Under Uncertainty in Electricity Markets*, volume 153 of *International Series in Operations Research & Management Science*. Springer US, Boston, MA. URL <http://link.springer.com/10.1007/978-1-4419-7421-1>.
- Dai, T. and Qiao, W. (2015). Optimal Bidding Strategy of a Strategic Wind Power Producer in the Short-Term Market. *IEEE Trans. on Sust. Energy*, 6(3), 707–719. doi:10.1109/TSTE.2015.2406322.
- Gabriel, S.A., Conejo, A.J., Fuller, J.D., Hobbs, B.F., and Ruiz, C. (2013). *Complementarity Modeling in Energy Markets*, volume 180 of *International Series in Operations Research & Management Science*. Springer New York, New York, NY. URL <http://link.springer.com/10.1007/978-1-4419-6123-5>.
- Kardakos, E.G., Simoglou, C.K., and Bakirtzis, A.G. (2013). Short-Term Electricity Market Simulation for Pool-Based Multi-Period Auctions. *IEEE Trans. on Power Syst.*, 28(3), 2526–2535. doi:10.1109/TPWRS.2012.2226759.
- Taylor, J.W. and McSharry, P.E. (2007). Short-term load forecasting methods: An evaluation based on european data. *IEEE Transactions on Power Systems*, 22(4), 2213–2219.
- Torre, S.d.l., Arroyo, J.M., Conejo, A.J., and Contreras, J. (2002). Price maker self-scheduling in a pool-based electricity market: a mixed-integer LP approach. *IEEE Trans. on Power Syst.*, 17(4), 1037–1042. doi:10.1109/TPWRS.2002.804945.
- Torre, S.d.l., Contreras, J., and Conejo, A.J. (2004). Finding multiperiod Nash equilibria in pool-based electricity markets. *IEEE Trans. on Power Syst.*, 19(1), 643–651. doi:10.1109/TPWRS.2003.820703.
- Xu, L. and Baldick, R. (2007). Transmission-Constrained Residual Demand Derivative in Electricity Markets. *IEEE Trans. on Power Syst.*, 22(4), 1563–1573. doi:10.1109/TPWRS.2007.907511.