



**Grupo de Estudo de Comercialização, Economia e Regulação do Mercado de Energia Elétrica-
GCR**

**ANÁLISE COMPARATIVA ENTRE MODELOS DE INTELIGÊNCIA COMPUTACIONAL PARA
PREVISÃO DO PREÇO FUTURO NO MERCADO DE ENERGIA BRASILEIRO**

**MATHEUS DE OLIVEIRA MENDONÇA(1); PEDRO HENRIQUE ARAUJO PINTO(2); FELLIPE FERNANDES
GOULART DOS SANTOS(3); DANIEL SILVA DE CASTRO PIRES(3); DOUGLAS ALEXANDRE GOMES
VIEIRA(4); MARCUS VINICIUS DE CASTRO LOBATO(3); GUSTAVO RODRIGUES LACERDA SILVA(5);
RODNEY REZENDE SALDANHA(6); GABRIEL DIAS RESENDE(7); FREDERICO PENA SANTIAGO(8);
GUSTAVO DE LINS E HORTA(9);
ENACOM(1);ENACOM(2);CEMIG
GT(3);ENACOM(4);ENACOM(5);UFMG(6);ENACOM(7);ENACOM(8);ENACOM(9);**

RESUMO

Para a contratação de energia no mercado livre, as empresas que atuam nesse ambiente competitivo precisam realizar previsões de preços de contratos futuros para seu planejamento estratégico e financeiro. Neste trabalho, são realizadas previsões de preços para contratação no mercado livre a partir de implementações de 4 modelos preditivos – SARIMAX, LSTM, GRU e CNN-LSTM. Os modelos foram treinados com dados históricos semanais sobre 5 maturidades da curva *forward* de 2012 a 2016 e usados para predição *one-step ahead* dos preços semanais ao longo dos anos de 2017 e 2018. Os desempenhos dos modelos são comparados quantitativamente através de avaliações das métricas MSE, MAE e RMSSE e seus resultados são analisados qualitativamente.

PALAVRAS-CHAVE

Mercado brasileiro de energia. Predição de preços de energia. Inteligência computacional. Curva *forward*.

1.0 - INTRODUÇÃO

Desde sua criação há quase 20 anos, o mercado livre de energia brasileiro vem evoluindo constantemente e hoje representa cerca de 30% do consumo do Sistema Interligado Nacional. Atualmente, apenas parte dos consumidores podem participar do mercado livre (1), mas há debates liderados pelo MME para a ampliação dessa elegibilidade (2).

Nesse mercado desregulamentado, também chamado de ambiente de contratação livre - ACL, os preços, volumes, períodos e demais condições dos contratos de compra e venda de energia são negociados livremente em operações de balcão. Cabe, portanto, a cada agente, considerando sua percepção do mercado e sua propensão ou aversão ao risco, realizar as transações que lhe são convenientes no momento em que achar oportuno. Porém, dada a reconhecida volatilidade dos preços de curto prazo em mercados de energia (no caso do Brasil o Preço de Liquidação das Diferenças (PLD)) a contratação antecipada para entrega futura é uma das maneiras mais usadas para mitigar essa exposição. Desta forma, a previsão de preços de contratos futuros é

uma atividade importante para o planejamento estratégico e financeiro, e também para gestão de riscos das empresas que atuam nesses ambientes competitivos.

Existem muitas metodologias de definição da curva de preço futuro para a atuação de cada agente no mercado de energia elétrica brasileiro. Alguns agentes desenvolveram modelos buscando capturar uma possível evolução do PLD e suas consequências nos preços de mercado, outros agentes trabalham com o conceito de custo marginal de expansão (CME) e há aqueles que utilizam as duas abordagens. Mais recentemente, um grande número de agentes tem utilizado a plataforma DCIDE como referência para o preço futuro da energia. Existem também modelos estatísticos para previsão de preço, tais como: modelos autorregressivos (AR), autorregressivos com médias móveis (ARIMA), entre outros.

Nesse contexto, a inteligência computacional (IC) pode desempenhar papel fundamental, uma vez que é uma forma de análise de dados que automatiza a construção de modelos analíticos. No campo da inteligência computacional, as redes neurais artificiais (RNAs), por exemplo, são ferramentas de aprendizado que possibilitam a descoberta de padrões em séries temporais, e a previsão de dados a partir do treinamento da rede com as informações disponíveis.

Este trabalho se propõe a utilizar diferentes técnicas de predição de séries temporais para a validação e construção de modelos de projeção do preço futuro de energia, levando em consideração as projeções mensais do PLD publicadas nos decks oficiais da CCEE e as informações históricas de preços contratuais. Os modelos são comparados entre si através de métricas de erro de previsão.

Além desta introdução, as demais seções deste trabalho estão organizadas da seguinte forma: a seção II mostra os trabalhos correlatos em uma revisão bibliográfica acerca do tema; a seção III descreve brevemente os modelos de previsão utilizados; a seção IV contém a metodologia usada para comparação a comparação das diversas abordagens, bem como os dados usados e as métricas avaliadas; a seção V apresenta os resultados obtidos e faz uma discussão a respeito dos mesmos; por fim, a seção VI apresenta as conclusões atingidas por meio do experimento conduzido.

2.0 - REVISÃO BIBLIOGRÁFICA

Nas duas últimas décadas, o mercado de energia elétrica foi se tornando mais competitivo em diversos países, e um dos aspectos mais importantes na competitividade dos agentes participantes desses mercados é a previsão dos preços futuros no curto, médio e longo prazo. Como consequência, inúmeros métodos e estratégias surgiram com o intuito de prever o preço futuro de energia elétrica.

Uma extensa revisão da literatura desses métodos preditivos é detalhadamente apresentada em (3). De maneira geral, os métodos usados podem ser agrupados em relação a algumas características. A Tabela 1 apresenta o resumo dessas classes.

TABELA 1 – Classificação dos métodos de previsão.

Classificação do modelo	Modelo estatístico; IC; Baseado na interação entre agentes
Tipo de previsão	Pontual; Intervalo; Limiar
Horizonte de Previsão	Horário; Diário; Mensal; Anual

Em relação aos modelos estatísticos, diversos modelos paramétricos e não-paramétricos são usados (4). Dentre eles, destacam-se os autorregressivos, suavização exponencial, médias móveis, bem como outros mais simples, como o método do dia similar, que tenta prever o comportamento de um dia futuro baseado em um comportamento similar passado. De maneira geral, os modelos estatísticos não apresentam bom desempenho na presença de eventos extremos, visto que a complexidade desses modelos é reduzida, portando-se bem no caso médio, entretanto (3).

A evolução da ciência de dados e da consequente disseminação da inteligência computacional (IC) culminaram em um maior uso de modelos de IC na predição de preços futuros de energia. A Ref. (5) dispõe de uma rede neural autorregressiva (um tipo de rede recorrente) para a previsão do PLD semanal.

Uma outra abordagem é o uso de modelos híbridos, buscando extrair características relevantes à predição e, indiretamente, controlar a capacidade efetiva dos modelos. (6) (7) fazem uso de modelos híbridos de inteligência computacional. Em (3) é ressaltado que esses modelos, por serem não-lineares e de alta complexidade, tem a capacidade de capturar eventos extremos, mas ao mesmo tempo tendem a sobreajustar a resposta no comportamento médio.

Com relação aos tipos de previsões, as pontuais são maioria na literatura de previsão de preço, apesar de existir uma tendência na linha de predição de séries temporais de abandono desse tipo de previsão em detrimento de previsões probabilísticas, de intervalo e de densidade (8). Com relação à predição por limiar, são pré-estabelecidas faixas de preço (e.g., baixo, médio, alto), transformando o problema de predição de preço em um problema de classificação (9) (10). As previsões de intervalo são realizadas de modo que o valor real do preço futuro esteja contido dentro de um intervalo com uma dada probabilidade (11).

Na literatura internacional, o horizonte de previsão mais comum é o curto-prazo, seja ele a previsão para o dia seguinte ou a hora seguinte. No Brasil, devido às peculiaridades do mercado, o horizonte de previsão mais comum é o semanal (previsão do PLD). Entretanto, (12) usa uma abordagem de otimização da "oferta x demanda" para diferentes cenários futuros hidrológicos como tentativa de prever a liquidez futura do preço contratual.

No que diz respeito às métricas de avaliação, (3) recomenda o uso das métricas *weighted-MAE*, *seasonal MASE* ou *RMSSE* em detrimento de métricas mais tradicionais, como o *RMSE*, visto os trabalhos antigos revisados em seu estudo. A próxima seção irá abordar brevemente os conceitos dessas métricas.

De maneira geral, apesar de existirem diversas metodologias de predição de preço de energia elétrica, ainda há uma carência na maneira de comparação desses métodos de previsão, visto que os horizontes de previsão são distintos, as bases de dados são diferentes e a condução de testes estatísticos é precária, se não inexistente.

3.0 - REVISÃO DOS MODELOS USADOS

Dentre os diversos modelos de inteligência computacional existentes na literatura para predição de séries temporais, as redes LSTM, do inglês *Long Short Term Memory*, são as que apresentam melhores desempenhos na predição de preço (7). Desse modo, além da própria rede LSTM, duas variantes dessa arquitetura também são abordadas neste trabalho: CNN-LSTM e GRU. Para fins de comparação com modelos estatísticos, o modelo SARIMAX também é implementado, visto que dentre os modelos estatísticos, é um dos mais robustos. A seguir, é apresentada uma breve descrição de cada um dos métodos de previsão utilizados neste trabalho.

3.1 SARIMAX

O modelo estatístico $SARIMA(p, d, q)(P, D, Q)_s$ (*Seasonal Autoregressive Integrated Moving Average*) é uma combinação de modelos mais simples: um autorregressivo, que relaciona o valor X_t com os próprios valores prévios de X , através de uma combinação linear de ordem p ; e médias móveis, que relaciona o valor X_t com as magnitudes dos termos de erro de valores defasados através de uma combinação linear de ordem q . Esta combinação é ainda adaptada para ser capaz de diferenciar séries a uma ordem d para atingir estacionariedade e ajustar séries com componentes sazonais a partir de seus parâmetros (P, D, Q) e s , onde (P, D, Q) são análogos aos parâmetros (p, d, q) , porém descrevendo comportamento sazonal de ordem s da série.

Chamamos de $SARIMAX(p, d, q)(P, D, Q)_s$ modelos SARIMA que ajustam não apenas à série-resposta, mas também levam em consideração séries de variáveis exógenas como explicativas.

3.2 LSTM

Uma rede LSTM (13) é um caso especial de uma rede neural recorrente (RNN), desenvolvida explicitamente para ser capaz de aprender com essas dependências de longo período e utilizar as informações oferecidas para previsões. Tal capacidade popularizou seu uso para diversos estudos, especialmente para aqueles que apresentam dependência temporal.

Da mesma forma que para RNNs, LSTMs apresentam estruturas similares a cadeias, entretanto seus módulos apresentam estruturas diferentes. Ao invés de serem compostas por apenas uma camada, LSTMs são formadas a partir do conjunto de quatro camadas que interagem de uma maneira singular. A primeira camada sigmóide é denominada *forget gate* e é responsável por analisar as informações referentes ao momento anterior e ao

momento em questão e determinar um valor relativo ao percentual dessas informações que será mantido. A segunda camada sigmóide, chamada *input gate layer*, decide quais valores serão atualizados enquanto a terceira camada, através da função tangente hiperbólica cria um vetor com novos valores candidatos a adentrar no modelo. Os valores dessas duas camadas são multiplicados e adicionados ao conjunto de informações anteriores. Por fim, a quarta camada apresenta duas etapas. Inicialmente aplica-se uma camada sigmóide que decide quais partes das informações prévias serão propagadas. Em seguida, uma camada tangente hiperbólica é aplicada para escalar os valores.

3.3 GRU

A GRU (do inglês *Gated Recurrent Unit*) é uma unidade neural recorrente proposta em (14). Assim como os demais tipos de RNNs, as redes GRU são usualmente empregadas para a modelagem de dados de natureza sequencial, especialmente aqueles que possuem dependências temporais de longo termo. É uma variação do método LSTM tradicional, apresentando resultados comparáveis ou superiores aos do último em uma série de aplicações, dentre elas o processamento de linguagem natural e reconhecimento de fala (15).

As principais diferenças entre a LSTM e a GRU estão ligadas à configuração de suas funções internas. Enquanto a primeira adota um modelo com três portas, a segunda introduz uma arquitetura mais simples com apenas duas. A porta *update* define quais informações devem ser descartadas e as novas a serem adicionadas, ao passo que a segunda porta, a *reset*, determina quais informações do passo anterior devem ser esquecidas.

As simplificações trazidas pelas redes GRU se traduzem em uma menor quantidade de parâmetros se comparadas às redes LSTM. Desta forma, o treinamento da primeira tende a ser menos dispendioso que o da segunda. No contexto de previsão de preços no mercado de energia, o estudo conduzido em (7) demonstrou ligeira superioridade da rede GRU em contraponto à LSTM.

3.4 CNN-LSTM

O modelo CNN-LSTM é uma abordagem híbrida do tipo *encoder/decoder* que faz uso de redes neurais convolucionais (CNNs, *Convolutional Neural Networks*) (16) na etapa de extração de características relevantes que alimentam um modelo LSTM para a predição de uma variável-resposta qualquer.

Apesar de desenvolvidos e mais utilizados para problemas com *inputs* de estrutura espacial, como imagens e vídeos, as CNNs apresentam grande capacidade de adaptação a outros problemas. Por isso, quando se trata de dados com dependência temporal cujo objetivo é previsão h passos à frente, essas redes são aliadas a modelos LSTM, sendo utilizadas para seleção de variáveis consideradas como regressores importantes.

Após selecionadas as variáveis consideradas significativas para auxílio da previsão da série em estudo, ajusta-se uma rede LSTM, com arquitetura similar à apresentada anteriormente, porém com uma entrada multivariada.

4.0 - DEFINIÇÃO DO EXPERIMENTO REALIZADO

A definição de preços contratuais no mercado de energia brasileiro é uma tarefa complexa. Embora o PLD sirva como uma referência oficial da projeção do preço *spot* da energia, o seu uso para avaliação de contratos de longo prazo é insuficiente, visto que outras variáveis – balanço energético do sistema, projeções de tarifas, custos marginais de expansão – passam a ser mais importantes para a contratação de energia à medida que o tempo de contratação se alonga. Desta forma, um grande número de agentes faz uso de um *pool* de preços para definir a uma estimativa da curva *forward*. Neste trabalho, iremos adotar os preços desse *pool* como referência para o preço de mercado futuro.

As estimativas de preços fornecidas pela curva *forward*, em suas diferentes maturidades, são usadas como variáveis-resposta dos modelos preditivos analisados. As maturidades representam o preço de contratos de compra ou venda de energia com entrega durante o período de um ano. Assim, o preço para a maturidade $A + n$ representa o preço de um contrato de energia que deverá ser entregue durante todo o ano n .

As séries históricas de preço compreendem dados semanais coletados em um período de sete anos (2012-2018), totalizando 358 observações para cinco maturidades usualmente utilizadas no setor elétrico brasileiro: $A + n, n \in [0,4]$.

Além destes preços, utilizaremos as projeções mensais de PLD realizados na época que cada curva *forward* foi construída. Cabe destacar aqui, que as projeções de PLD foram feitas de forma mensal e não foram atualizadas semanalmente.

A Figura 1 apresenta as curvas de maturidade $A + n, n \in [0,4]$, do preço juntamente com as projeções correspondentes do PLD entre 2012 e 2018. Pode-se notar uma forte relação entres os preços de mercado e o PLD, principalmente para maturidades menores. Também é possível observar uma menor variabilidade dos preços para maturidades maiores.

Os dados foram divididos em dois grupos: um conjunto de treino com as primeiras 261 observações (referente ao período de 2012 a 2016) e um conjunto de teste com 97 observações (jan/2017-nov/2018). Os experimentos com cada um dos modelos se deram da seguinte forma: o conjunto de treino é usado para o ajuste do modelo e uma predição é feita para a primeira semana do conjunto de teste. A partir do momento que a predição de uma semana é realizada, o valor real do dado é incorporado ao conjunto de treinamento para a predição da semana posterior. Esse procedimento se repete ao longo de todos os dados semanais de preço dentro do conjunto de validação.

Para modelos SARIMAX, foi necessário realizar predições *one-step ahead* também para as séries explicativas a fim de usá-las como argumentos obrigatórios nas predições SARIMAX. As predições de séries explicativas foram realizadas a partir de modelos SARIMA, tanto para preços futuros quanto para PLD. Quanto aos modelos GRU, LSTM e CNN-LSTM, o uso de variáveis exógenas é realizado apenas com valores passados destas, e, portanto, não é necessário realizar o procedimento supracitado, que obviamente adiciona incertezas ao processo de predição dos preços futuros.

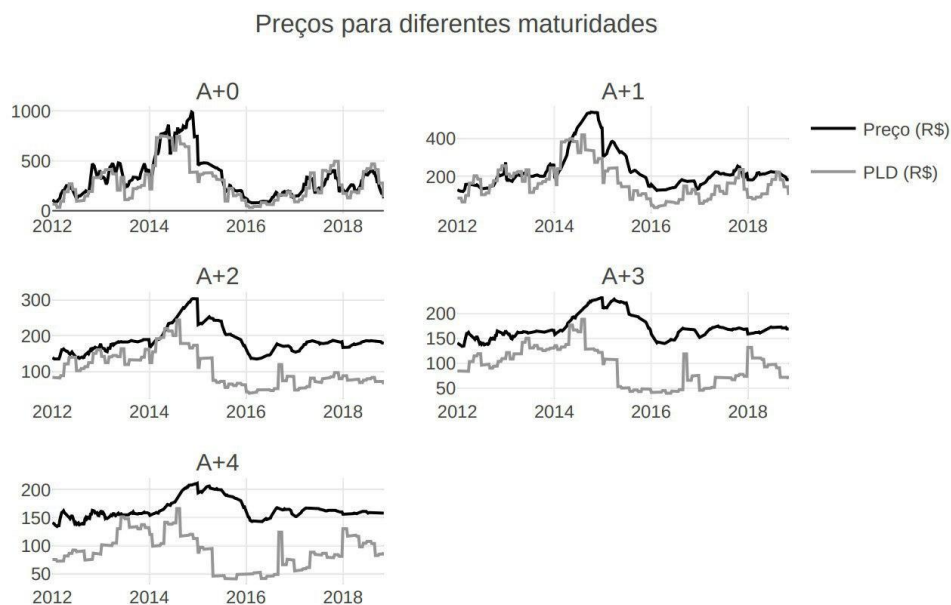


FIGURA 1 – Dados de preço futuro e PLD para diferentes maturidades.

Neste estudo utilizaremos as métricas clássicas MSE e MAE e RMSSE, proposta por (3), para avaliação dos desempenhos dos modelos. Explicamos sucintamente abaixo o significado das métricas selecionadas.

Mean Squared Error (MSE): definida como a média dos quadrados dos resíduos, é sempre não-negativa e mede o desvio entre os valores reais observados e os estimados. Seu valor é, portanto, melhor quanto mais se aproxima de zero.

Mean Absolute Error (MAE): medida linear do desvio entre valores observados e estimados. Assim como o MSE, o estimador ideal produz MAE igual a zero. Esta métrica é especialmente interessante porque é mais robusta a *outliers* que MSE.

Root Mean Square Standardized Error (RMSSE): é uma medida de qualidade de previsão sobre a variabilidade dos dados. Quanto mais próxima do valor unitário, melhor a previsão da variabilidade. Valores de RMSSE menores que 1 indicam que a variabilidade dos dados está sendo superestimada, e, de modo inverso, se RMSSE é maior que 1, a variabilidade dos dados está sendo subestimada.

4.1 SELEÇÃO DE VARIÁVEIS EXPLICATIVAS

As séries disponíveis para análise foram os preços futuros e PLDs estimados para 5 maturidades diferentes, totalizando 10 séries, das quais as PLDs são puramente explicativas. Para cada maturidade do preço futuro, é possível utilizar combinações entre as 9 outras séries de forma a melhor explicar o comportamento da maturidade em questão. Portanto, neste cenário são 512 possíveis combinações entre variáveis explicativas para cada maturidade a ser prevista - 2560 no total. Os modelos GRU, LSTM e CNN-LSTM são capazes de abstrair as importâncias das variáveis explicativas e ponderá-las de acordo com suas influências. Estes modelos foram, portanto, treinados com todas as variáveis à disposição.

Os modelos SARIMAX demandam que as variáveis exógenas sejam selecionadas explicitamente e, como seus ajustes e previsões *one-step ahead* para o horizonte definido (97 pontos) podem exigir horas para cada combinação, torna-se inviável o teste de todos os casos para a seleção do melhor resultado. Utilizou-se, então, as matrizes de correlação e correlação parcial como guias para a seleção das combinações a serem consideradas.

As Figuras 2 e 3 demonstram as correlações e correlações parciais, respectivamente, entre as séries Preço Futuro x Preço Futuro e entre Preço Futuro x PLD para as 5 maturidades. Comparando ambas as figuras, percebe-se que as correlações parciais entre Preço Futuro x Preço Futuro discriminam um padrão melhor que as correlações (maturidades adjacentes se destacam consideravelmente nas correlações parciais). Desta forma, decidiu-se testar apenas séries Preço Futuro de maturidades adjacentes às que devem ser previstas.

Como as correlações e correlações parciais entre Preço Futuro x PLD não formam padrões claros entre as variáveis, foram selecionados os PLDs de mesmas maturidades que as de preços futuros a serem previstas e os PLDs das maturidades que apresentam a maior correlação com cada Preço Futuro a ser prevista. Ao prever a Preço Futuro $A + 0$, por exemplo, foram consideradas as variáveis explicativas Preço Futuro $A + 1$, PLD $A + 0$ e PLD $A + 1$.

No geral, as previsões do SARIMAX realizadas utilizando esta metodologia de seleção de variáveis exógenas produzem resultados com erros quadráticos médios menores que as combinações de subconjuntos destas. Nas raras exceções, as diferenças dos erros encontrados são de magnitudes de ordem muito baixa, não excedendo a unidade. Nestas condições, consideramos que a perda de desempenho não é suficiente para justificar a possível generalidade do modelo que pode-se perder não utilizando variáveis explicativas fortemente relacionadas.




FIGURA 2 – Matrizes de correlação.




FIGURA 3 – Matrizes de correlação parcial.

5.0 - RESULTADOS E DISCUSSÃO

A Tabela 2 dispõe as avaliações das métricas MSE, MAE e RMSSE para as previsões de cada maturidade por cada modelo. Assim como a variabilidade dos dados decresce com a maturidade, as métricas MSE e MAE refletem este fenômeno, decrescendo monotonicamente também de acordo com as maturidades. Percebe-se que os modelos GRU e SARIMAX se destacam nas métricas MSE e MAE para todas as previsões, ou seja, se aproximam mais das médias dos valores observados do que os modelos LSTM e CNN-LSTM.

Os desempenhos avaliados por RMSSE foram mais variados. Para as maturidades $A + 0$ e $A + 4$ modelos SARIMAX se destacam; nas previsões de $A + 2$ e $A + 3$ são os modelos CNN-LSTM que apresentam melhores resultados; e em $A + 1$ o LSTM se mostrou melhor. É interessante observar que os modelos SARIMAX geram RMSSE maiores que 1 em todos os casos e os modelos de IC geram RMSSE sempre menores que 1. Esta avaliação é coerente com as visualizações disponíveis na Figura 4, onde percebe-se que os modelos de IC estimam valores mais ruidosos em torno dos valores observados, superestimando a variância dos dados, o que é típico de casos de *overfitting*. Em contrapartida, os modelos SARIMAX produzem valores pouco variantes, sendo um indicativo de *underfitting*.

As séries previstas por modelos SARIMAX e GRU são suaves, enquanto as estimadas através dos modelos LSTM e CNN-LSTM apresentam comportamentos com variações bruscas ao redor dos dados observados. Os comportamentos das séries previstas neste horizonte favorecem a suavidade do GRU e do SARIMAX, como MSE e MAE apontam, mas os desempenhos RMSSE destes modelos indicam que suas estimativas sobre as variabilidades dos dados podem ser bastante falhas.

TABELA 2 – Performance dos modelos para cada maturidade. Os resultados são exibidos na ordem (SARIMAX, GRU, LSTM, CNN-LSTM).

	A + 0	A + 1	A + 2	A + 3	A + 4
MSE	(865,99, 789,08 , 3078,94, 1527,13)	(50,73, 50,10 , 242,41, 143,32)	(5,58, 5,39 , 16,23, 17,96)	(2,12 , 2,69, 5,67, 7,26)	(1,16 , 1,72, 3,02, 3,89)
MAE	(22,43, 21,29 , 41,84, 31,30)	(4,88 , 5,04, 12,00, 9,18)	(1,56, 1,49 , 3,15, 3,35)	(1,04 , 1,14, 1,97, 2,00)	(0,82 , 0,99, 1,36, 1,48)
RMSSE	(1,08 , 0,28, 0,54, 0,39)	(1,58, 0,37, 0,80 , 0,62)	(2,17, 0,42, 0,74, 0,77)	(1,82, 0,37, 0,54, 0,61)	(1,01 , 0,22, 0,30, 0,34)

Previsões para diferentes maturidades

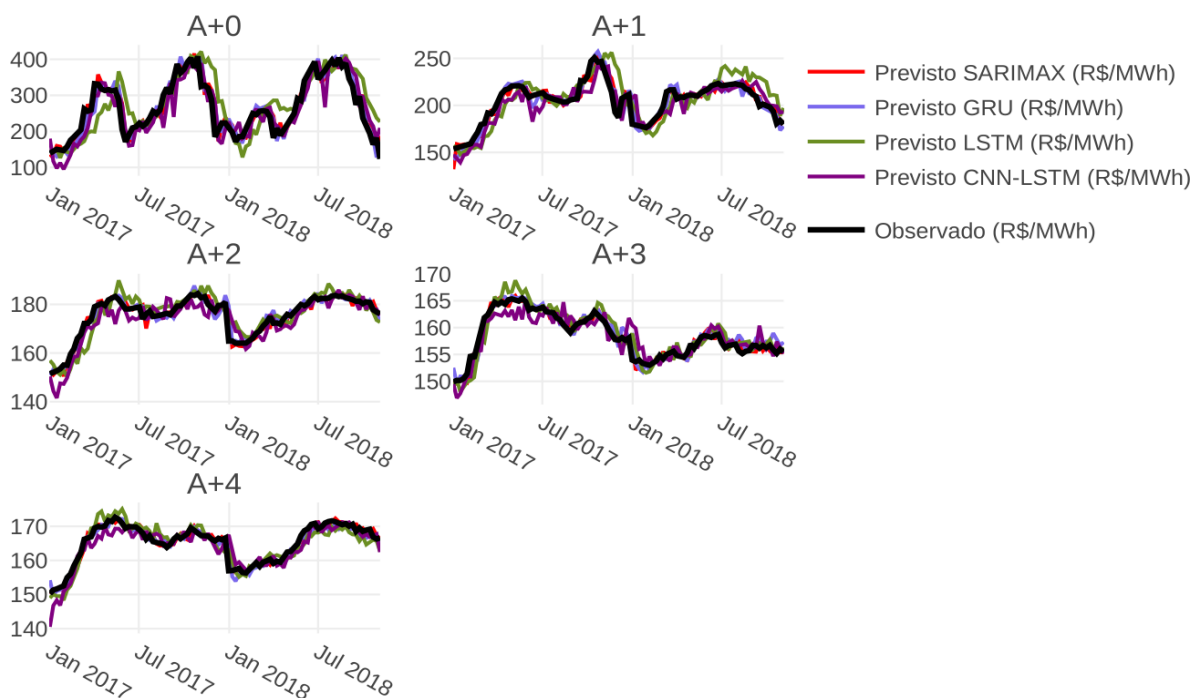


FIGURA 4 – Resultado das previsões para os diferentes modelos organizados pela maturidade.

6.0 - CONCLUSÃO

Foram realizadas previsões *one-step ahead* semanais sobre as séries preços futuros de maturidades de 0 a 4. Além das séries temporais de preços futuros, as séries de PLD para as mesmas maturidades também estavam disponíveis para uso como variáveis explicativas. Os modelos utilizados para as previsões foram SARIMAX, GRU, LSTM e CNN-LSTM e as métricas utilizadas para comparar os desempenhos dos modelos foram MSE, MAE e RMSSE.

Em termos de MSE e MAE, os modelos GRU e SARIMAX demonstraram superioridade em todas as séries, sendo que o GRU obtém melhores resultados MSE em 3 maturidades e o SARIMAX se destaca em 3 maturidades para a métrica MAE.

Os valores de RMSSE avaliados demonstram que o SARIMAX sempre subestima a variabilidade dos dados, enquanto GRU, LSTM e CNN-LSTM sempre a superestimam. Os melhores resultados em RMSSE variam entre os modelos SARIMAX ($A + 0$, $A + 4$), LSTM ($A + 1$) e CNN-LSTM ($A + 2$, $A + 3$). Com desempenhos MSE e MAE bastante equilibrados entre SARIMAX e GRU, as avaliações RMSSE apontam um desequilíbrio entre estes, onde SARIMAX apresenta dois melhores valores e dois piores, enquanto GRU apresenta 3 piores valores e nem um melhor.

As altas variâncias das estimativas dos modelos de IC – em especial LSTM e CNN-LSTM - são perceptíveis visualmente e implicam que tais modelos tenham baixos vieses. Acredita-se que estas altas variâncias sejam consequências das altas complexidades dos modelos para um número reduzido de dados. De fato, estes modelos abstraem milhares de parâmetros e possuímos apenas centenas de dados temporais, o que invariavelmente causa *overfitting*. Acredita-se que a simplificação dos modelos possa causar melhoras em seus resultados.

Os modelos SARIMAX apresentam comportamentos opostos aos dos outros com respeito às variâncias, que são subestimadas em todas as séries. Enquanto em $A + 0$ e $A + 4$ os resultados são próximos do ideal, em $A + 2$ o modelo produz o pior RMSSE avaliado para todos os casos, o que indica que o modelo ajustado reage mal a dados que não variam suavemente.

Nota-se que nenhum dos modelos testados foi capaz de prever grandes variações nos preços futuros. Os modelos SARIMAX, apesar de serem os mais simples analisados, apresentam os comportamentos mais equilibrados com relação às métricas e consistentes ao longo das maturidades. Sua aplicação prática não deve diferir da metodologia utilizada neste trabalho, podendo atingir melhores resultados se forem realizadas previsões de variáveis exógenas mais precisas.

Acredita-se, portanto, que estudos no sentido de melhor refinamento das variáveis exógenas a serem utilizadas para cada maturidade de preço, e suas previsões devam ser realizados. Por fim, ressaltamos que os desempenhos dos métodos de IC não os qualificam como inaptos para o problema em questão, mas indicam que as complexidades inerentes aos seus desenhos possuem efeitos negativos em seus desempenhos. Tais efeitos também devem ser estudados mais a fundo para que possam ser minimizados, produzindo resultados possivelmente superiores aos SARIMAX relatados neste trabalho, como por exemplo, a previsão de variações mais abruptas nos preços futuros de energia.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Brasil, MME (2018). Portaria 514/2018: Regulamenta o disposto no artigo 15, parágrafo 3º, da lei 9.074, de 07.07.1995, com o objetivo de diminuir os limites de carga para contratação de energia elétrica por parte dos consumidores
- (2) Brasil, MME (2019). Portaria 187/2019: Institui Grupo de Trabalho que desenvolva propostas de Modernização do Setor Elétrico
- (3) WERON, R. "Electricity price forecasting: A review of the state-of-the-art with a look into the future". In: International Journal of Forecasting, 2014.
- (4) WERON, R., MISIOREK, A. "Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models". In: International Journal of Forecasting, 2008.
- (5) NASCIMENTO, F.B.D., OLIVI, L.R., LIMA, L.H.L. "Multi-step forecasting of the Brazilian energy market price using autoregressive neural networks". In: SBSE 2018 - 7th Brazilian Electrical Systems Symposium, 2018.

- (6) KUO, P.H., HUANG, C.J. "An electricity price forecasting model by hybrid structured deep neural networks". In: Sustainability (Switzerland), 2018.
- (7) UGURLU, U., OKSUZ, I., TAS, O. "Electricity price forecasting using recurrent neural networks". In: Energies, 2018.
- (8) DE GOOIJER, J.G., HYNDMAN, R.J. "25 years of time series forecasting". In: International journal of forecasting v.22, pp. 443-473, 2006.
- (9) RESTON FILHO, J.C., AFFONSO, C.M., OLIVEIRA, R.C.L. "Pricing Analysis in the Brazilian Energy Market: a Decision Tree Approach". In: IEEE Bucharest Power Tech Conference. June, 2009.
- (10) ZAREIPOUR, H., JANJANI, A., LEUNG, H., MOTAMEDI, A., SCHELLENBERG, A. "Classification of future electricity market prices". In: IEEE Transactions on Power Systems, 2011.
- (11) MISIOREK, A., TRUECK, S., WERON, R. "Point and interval forecasting of spot electricity prices: Linear vs. non-linear time series models". In: Studies in Nonlinear Dynamics & Econometrics v.10, 2006.
- (12) CAVALIERE, M., OLIVEIRA, S. "PREVISÃO DE PREÇOS FUTUROS DE ENERGIA ELÉTRICA NA CONTRATAÇÃO LIVRE – UMA ABORDAGEM DE EQUILÍBRIO DE MERCADO SOB INCERTEZAS". In: XXIV SNPTTE SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA, 2017.
- (13) HOCHREITER, S., SCHMIDHUBER, J. "Long short-term memory". In: Neural computation v.9, pp. 1735-1780, 1997.
- (14) CHO, K., van MERRIENBOER, B., GÜLÇEHRE, Ç., BOUGARES, F., SCHWENK, H., BENGIO, Y. "Learning Phrase Representations using {RNN} Encoder-Decoder for Statistical Machine Translation". In: CoRR, 2014.
- (15) CHUNG, J.G., HYNDMAN, R.J. "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling". In: CoRR, 2014.
- (16) LECUN, Y., BOTTOU, L., BENGIO, Y., HAFFNER, P. et al. "Gradient-based learning applied to document recognition". In: Proceedings of the IEEE v.86, pp. 2278-2324, 1998.

8.0 - DADOS BIOGRÁFICOS



Matheus Mendonça é graduado em engenharia elétrica pela UFMG (2017) e foi aluno intercambista na Universidade de Strathclyde/Reino Unido pelo mesmo curso durante 2014. Já trabalhou em projetos de iniciação científica no OptMA Lab da UFMG e foi integrante da equipe de engenharia da Gaia Solutions on Demand. Em 2018 iniciou o mestrado na UFMG na área de otimização e, atualmente, é pesquisador associado da ENACOM e professor de ciência de dados na COTEMIG. Possui como interesse as áreas de otimização e aprendizado de máquinas.