

Previsão de Carga no Mercado de Energia

Willian Yuji Takano * Eduardo Nobuhiro Asada **

* *Escola de Engenharia de São Carlos, Universidade de São Paulo, SP,
(e-mail: willian.takano@usp.br).*

** *Escola de Engenharia de São Carlos, Universidade de São Paulo,
SP, (e-mail: easada@usp.br).*

Abstract:

Electric load forecasting has an important role to players who trade energy in the Free Energy Market. This study applies the Gated Recurrent Unit network to forecast the Brazilian Southeast/Midwest subsystem electric load and analyzes its performance on the spot price. The input for the model included temperature, electric load, and a business and non-business day classification. The dataset was divided into two groups: training and test. The mean absolute error was 2.05%. The results show that applying Gated Recurrent Unit network to forecast electric loads can help players mitigate the risks associated with the volatility of spot price.

Resumo: A criação do Mercado Livre de Energia tornou a previsão de carga importante para os agentes que comercializam energia neste ambiente. Este estudo tem como objetivo aplicar uma rede *Gated Recurrent Unit* na previsão da carga do subsistema brasileiro Sudeste/Centro-Oeste e analisar o impacto financeiro do erro da previsão no Preço de Liquidação das Diferenças. Utilizou-se como variáveis de entrada dados de temperatura, de carga e uma classificação que indica se o dia é útil ou não. O conjunto de dados foi dividido em um conjunto de treinamento e um de teste. O erro absoluto médio no conjunto de teste foi de 2.05%. Desta maneira, utilizar uma rede *Gated Recurrent Unit* na previsão de carga pode contribuir na mitigação do risco relacionado à volatilidade do preço da energia.

Keywords: Load Forecasting; Spot price; Gated Recurrent Unit

Palavras-chaves: Previsão de Carga; Preço de Liquidação das Diferenças; *Gated Recurrent Unit*

1. INTRODUÇÃO

A previsão de carga é importante para diferentes agentes que atuam no setor elétrico brasileiro. O governo utiliza estudos de previsão de carga do país no planejamento energético, viabilizando a construção de grandes parques geradores de energia que visam suprir o consumo elétrico futuro. As usinas geradoras de energia utilizam a previsão de carga na sua programação diária de operação, no seu calendário de manutenções programadas e para os casos das usinas térmicas, na estimativa da quantidade de combustíveis que devem ser comprados. A previsão de carga também é importante para os agentes que compram e vendem energia no Mercado de Curto Prazo (MCP), como as comercializadoras e os consumidores livres. A carga é uma importante variável que afeta o preço da energia, portanto, a sua previsão permite que esses agentes mitiguem o risco associado à volatilidade do preço da energia no MCP.

Vários métodos de previsão de carga têm sido propostos nas últimas décadas. Pode-se destacar os métodos estatísticos que tratam a carga como uma série temporal. Vemuri et al. (1981) utiliza um modelo auto-regressivo de média móvel (ARMA) e um modelo auto-regressivo (AR) na previsão de carga horária. No entanto, geralmente esses modelos sofrem em apresentar uma boa precisão devido à dificuldade de se incluir variáveis de clima, como a tem-

peratura e umidade Chen et al. (1992). Outro método de destaque é o que utiliza a experiência dos especialistas em identificar as variáveis, as regras e os critérios utilizados em diferentes situações de operação. Rahman and Bhatnagar (1988) apontam que essa abordagem possui como vantagem o fato de não necessitar uma grande quantidade de dados e, por conseguinte, requer menor esforço computacional.

Nos últimos anos, arquiteturas de redes neurais têm sido utilizadas na previsão de séries temporais, como a *feedforward* e a recorrente, por serem capazes de adquirir memória e conseguirem realizar mapeamentos dinâmicos. A primeira rede *feedforward* utilizada na previsão de carga foi proposta por Park et al. (1991), o autor destaca a facilidade que essas redes dispõem em modelar a relação não linear entre a carga e a temperatura. Neste tipo de rede, a memória é obtida ao se adicionar entradas atrasadas no tempo. Contudo, por conta da quantidade de parâmetros que devem ser calculados, o treinamento da rede pode se tornar um processo lento, tornando o uso das redes recorrentes uma melhor alternativa no problema de previsão de séries temporais.

As redes neurais recorrentes possuem como característica a existência de retroalimentação, ou seja, as saídas passadas da rede são consideradas como dados de entrada, isso faz com que a rede guarde informações dos dados sequenciais de uma série temporal. A rede neural recorrente mais simples é chamada de rede de Elman, no entanto, Bengio

et al. (1994) aponta a dificuldade de treinar esse tipo de rede devido ao problema da dissipação do gradiente. Os tipos mais modernos das redes recorrentes, como a *Long Short-Term Memory* (LSTM) e a *Gated Recurrent Unit* (GRU), possuem mecanismos internos chamados de *gates* que regulam o fluxo de informações e evitam esse problema.

Assim, o presente trabalho tem como objetivos propor uma rede neural recorrente GRU na previsão da carga diária média do subsistema Sudeste/Centro-Oeste e analisar o impacto financeiro do erro da previsão no Preço de Liquidação das Diferenças (PLD). Este trabalho está dividido em cinco seções. A primeira seção é destinada a introdução do trabalho. A seção dois descreve brevemente o MCP e o processo do cálculo do PLD, além de mostrar a sua volatilidade a partir dos dados históricos. A seção três apresenta a metodologia utilizada no estudo, abordando as variáveis de entrada que foram consideradas, o processo de pré-processamento que foi realizado, a arquitetura da rede proposta e o procedimento que foi feito para verificar o impacto no PLD. A seção quatro exibe o desempenho da rede no conjunto de teste e os estudos efetuados no preço da energia de três semanas distintas. E por fim, é feito a conclusão do trabalho na seção cinco.

2. MERCADO DE CURTO PRAZO

O Mercado de Curto Prazo é o mercado aonde os agentes devem comprar ou vender energia para ter o seu balanço energético equilibrado. Cada agente que atua no Ambiente de Contratação Livre (ACL) deve ter a sua geração somado aos seus contratos de compra de energia equivalente ao seu consumo somado aos seus contratos de venda de energia. Caso haja uma diferença, o agente deve liquidá-la no MCP ao valor do PLD.

O PLD é calculado semanalmente pela Câmara de Comercialização de Energia Elétrica (CCEE) utilizando os modelos computacionais *Newave* e *Decomp*. O modelo *Newave* analisa o sistema elétrico brasileiro no médio prazo com um horizonte de estudo de cinco anos e com etapas mensais. Em contrapartida, o modelo *Decomp* analisa o curto prazo com um horizonte de estudo de dois meses, sendo que as etapas são semanais no primeiro mês e mensal no segundo. Esses modelos buscam encontrar a solução ótima de despacho das usinas que compõem o Sistema Interligado Nacional (SIN).

A solução ótima encontrada busca minimizar o custo total da operação do sistema, que é formado por duas parcelas: o custo imediato, referente às decisões que estão sendo tomadas no momento, e o custo futuro, referente às decisões que serão tomadas no futuro. A energia gerada por fonte hidráulica tem custo nulo, uma vez que a água proveniente das chuvas não tem custo, no entanto, a energia gerada por fonte térmica possui custo não nulo que depende da sua fonte de geração de calor. Como exemplo, se num determinado momento, somente a água estocada no reservatório for utilizada para atender a demanda, o custo imediato seria nulo, mas o custo futuro poderá ser elevado caso a precipitação futura não seja suficiente, fazendo com que a demanda futura seja suprida por geração térmica.

Para resolver o problema de otimização do despacho das usinas, os modelos *Newave* e *Decomp* utilizam como dados de entrada variáveis que modelam o sistema, como os níveis dos reservatórios, previsão de carga, manutenções das usinas, restrições elétricas e hidráulicas e entre outras. A complexidade em se resolver esse problema torna o PLD extremamente volátil, como mostra a Figura 1.




Figura 1. Volatilidade do PLD.

A Figura 1 exibe os dados do PLD mensal do submercado Sudeste/Centro-Oeste desde 2003 a 2019. Observa-se que a sua volatilidade acarreta em risco financeiro aos agentes que liquidam a diferença do seu balanço energético no MCP. Mecanismos de mitigação desse risco geralmente envolvem métodos de previsão de séries temporais que buscam prever as variáveis que afetam o preço da energia, como as vazões naturais dos rios, níveis dos reservatórios e a carga.

3. PREVISÃO DA CARGA DO SUBSISTEMA SUDESTE/CENTRO-OESTE

Esta seção apresenta a metodologia utilizada para solucionar o problema de previsão da carga do subsistema Sudeste/Centro-Oeste e o procedimento feito para analisar o impacto do desempenho da rede no preço da energia. Para tanto, realizou-se quatro etapas. Na primeira, coletou-se os dados das variáveis de entrada da rede. Na segunda, realizou-se o pré-processamento dos dados coletados na etapa anterior. Na terceira, foi feito o treinamento da rede proposta. E por último, verificou-se o desempenho da rede no conjunto de teste e foram feitas simulações com o modelo *Decomp* para verificar o novo PLD.

3.1 Conjunto de Dados

Considerou-se três variáveis de entrada para a rede, a própria carga do subsistema Sudeste/Centro-Oeste, a temperatura média diária dos três principais centros consumidores da região (São Paulo-SP, Rio de Janeiro-RJ e Belo Horizonte-MG) e um índice que classifica o dia em útil ou não. Essa classificação foi realizada pelo fato da carga apresentar comportamento diferente nesses dois casos. Em geral, a carga apresenta picos mais elevados nos dias úteis do que nos dias de fim de semana e feriados. Desta forma, foi atribuído o valor 1 nos dias úteis e 2 caso contrário.

Os dados da carga foram retirados do Informativo Preliminar da Operação (IPDO) que é publicado diariamente

pelo Operador Nacional do Sistema ONS (2019) e os dados de temperatura foram disponibilizados pelo Instituto Nacional de Meteorologia INMET (2019).

A Figura 2 mostra o conjunto de dados da carga e da temperatura, e correspondem as medições realizadas entre os dias 1 de Janeiro de 2013 a 30 de Setembro de 2019.




Figura 2. Carga e Temperatura

Observa-se que existe uma forte correlação entre a temperatura e a carga, o consumo de energia tende a ser maior em dias quentes devido à intensificação do uso de eletrodomésticos como ar-condicionado, ventilador e geladeira. Assim sendo, verifica-se que ambas as variáveis possuem sazonalidade, na qual o seu comportamento é repetido com valores maiores durante o verão e menores durante o inverno.

3.2 Pré-Processamento dos Dados

O pré-processamento dos dados é um passo importante de se realizar antes de iniciar o treinamento da rede. No presente estudo, é utilizado a normalização min-max que realiza uma transformação linear sobre os valores originais de um atributo, conforme a Equação 1.

$$x' = \frac{x - x^{min}}{x^{max} - x^{min}} \quad (1)$$

Após a normalização, o domínio dos atributos foi transformado para um intervalo que varia de zero a um, mantendo o relacionamento entre os valores originais. Esse processo de normalização é feito individualmente em cada atributo e visa melhorar o desempenho do treinamento da rede, diminuindo o tempo necessário para a convergência.

3.3 Arquitetura da Rede GRU

A unidade de célula GRU proposta por Cho et al. (2014) pode ser considerada como uma simplificação da LSTM proposta por Hochreiter and Schmidhuber (1997). Esses tipos de células possuem mecanismos internos chamados de *gates* que resolvem o problema da dissipação do gradiente que ocorre quando as redes recorrentes mais simples são treinadas. A Figura 3 exibe a estrutura de uma célula GRU.




Figura 3. Adaptado de Chung et al. (2014)

A estrutura interna de uma célula GRU possui dois *gates*, *reset* (r_t) e *update* (z_t), que permitem a célula armazenar informações passadas por meio da atualização do seu estado h_t . O estado atual h_t é igual a sua saída num mesmo instante e é computado por

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (2)$$

O *update gate* z_t determina a porção do estado anterior h_{t-1} e do estado candidato $\tilde{h}_t$ que são considerados no estado atual da célula h_t , e é calculado por

$$z_t = \sigma(W_z[h_{t-1}, x_t]) \quad (3)$$

onde,

- σ : função de ativação sigmóide
- W_z : respectiva matriz de pesos
- x_t : vetor dados de entrada
- $[h_{t-1}, x_t]$: concatenação dos vetores

O estado candidato da célula $\tilde{h}_t$ depende do estado anterior e de um *gate* chamado de *reset*, conforme a seguinte equação

$$\tilde{h}_t = \tanh(W_{\tilde{h}}[r_t * h_{t-1}, x_t]) \quad (4)$$

O *reset gate* calcula a relevância do estado anterior, e de maneira análoga ao *update gate* é dado por

$$r_t = \sigma(W_r[h_{t-1}, x_t]) \quad (5)$$

Este trabalho utilizou três vetores de entrada na primeira camada e que correspondem aos dados de carga, temperatura e o índice que classifica o dia em útil ou não. Utilizou-se somente uma camada escondida composta por sessenta unidades de células GRU, essa quantidade foi determinada após treinar a rede com diversas topologias diferentes e foi a que obteve o menor erro absoluto médio no conjunto de teste. Na camada de saída, utilizou-se um único neurônio. A Figura 4 exibe a arquitetura utilizada.




Figura 4. Arquitetura da rede.

Os vetores x_1 , x_2 e x_3 possuem dimensão sete e abrigam os dados de entrada. Escolheu-se o número de sete dias por ser geralmente o intervalo de tempo que o comportamento das variáveis se repetem. As saídas das células GRU formam as entradas do único neurônio que compõe a última camada da rede, e a saída deste neurônio é a carga prevista.

3.4 Análise do Impacto no PLD

Para verificar o impacto da performance da rede proposta no PLD, utilizou-se somente o modelo *Decomp*. O modelo *Decomp* possui um bloco de carga no qual é declarado a previsão de carga para os próximos dois meses, sendo que o primeiro mês é dividido em estágios semanais e o segundo é composto por um único estágio mensal.

Após o treinamento da rede, previu-se a carga dos estágios semanais do primeiro mês e verificou-se o erro cometido pela rede. Em seguida, o erro foi adicionado ao bloco de carga do modelo *Decomp* e o mesmo foi executado novamente. Por fim, comparou-se o novo PLD obtido com o oficial divulgado pela CCEE.

Este processo foi realizado em três casos distintos, no PLD da primeira semana dos meses de Julho, Agosto e Setembro. Escolheu-se esses meses por não estarem contidos no conjunto de treinamento.

4. RESULTADO E CASOS DE ESTUDO

O conjunto total possui 7389 dados que são referentes às três variáveis de entrada e aos 2463 dias. Dividiu-se o conjunto total na seguinte proporção: 80% dos dados foram utilizados no treinamento da rede e 20% na validação da sua performance. Para o treinamento da rede, utilizou-se o algoritmo de otimização *Adaptive Moment Estimation* (ADAM) proposto por Kingma and Ba (2014), que é baseado no método do gradiente.

Após o treinamento da rede, verificou-se que o seu erro absoluto médio foi de 2.05% no conjunto de teste. Para verificar a significância da temperatura no desempenho da rede, a mesma foi treinada desconsiderando essa variável, e o erro absoluto médio aumentou para 6.56%.

As subseções a seguir apresentam os estudos realizados no preço de três semanas distintas.

4.1 Primeira Semana de Julho

O bloco de previsão de carga do modelo *Decomp* da primeira semana de Julho de 2019 contém cinco estágios semanais que se referem ao período de 29 de Junho a 2 de Agosto. A Figura 5 mostra a carga diária média que foi prevista pela rede e a observada.




Figura 5. Carga Diária Média de Julho.

O erro absoluto médio da rede foi de 1,25%, resultando em uma superestimação no valor da carga em alguns dias das quatro primeiras semanas operativas. No entanto, após a execução do modelo *Decomp*, constatou-se que o impacto no PLD foi de apenas R\$ 0,91/MWh indo de R\$ 170,94/MWh para R\$ 171,85/MWh, que representa uma variação de 0,53%.

4.2 Primeira Semana de Agosto

Para o preço da primeira semana de Agosto de 2019, o bloco de previsão de carga do modelo *Decomp* possui seis estágios semanais que representam o período de 27 de Julho a 6 de Setembro. A Figura 6 mostra a carga diária média que foi prevista pela rede e a observada.




Figura 6. Carga Diária Média de Agosto.

Este caso foi o que apresentou o menor erro absoluto médio (1,07%). A rede superestimou o valor da carga na terceira semana operativa, mas de maneira geral, conseguiu prever a sua sazonalidade. O impacto deste erro fez com que o

PLD variasse de R\$ 225,00/MWh para R\$ 225,21/MWh, uma variação de 0,09%.

4.3 Primeira Semana de Setembro

O último caso de estudo corresponde ao preço da primeira semana de Setembro de 2019. Neste caso, o bloco de previsão de carga do modelo *Decomp* possui cinco estágios semanais que representam o período de 31 de Agosto a 4 de Outubro. A Figura 7 mostra a carga diária média que foi prevista pela rede e a observada.




Figura 7. Carga Diária Média de Setembro.

Por fim, o último caso de estudo apresentou o pior erro absoluto médio (1,89%), fazendo o PLD variar de R\$ 200,69/MWh para R\$ 201,50/MWh, um aumento de 0,4%. No entanto, apesar deste caso apresentar o maior erro absoluto médio na previsão da carga, não foi o que apresentou o maior impacto no PLD, que aconteceu no caso da primeira semana de Julho.

5. CONCLUSÃO

O desenvolvimento do presente estudo possibilitou uma análise de como uma rede neural recorrente do tipo GRU pode ser utilizada na previsão da carga do subsistema Sudeste/Centro-Oeste. De modo geral, a rede conseguiu prever o comportamento da carga com erro absoluto médio de 2,05% no conjunto de teste. Também foi investigado a importância da variável de entrada temperatura na performance da rede, quando esta foi desconsiderada, o seu erro absoluto médio aumentou para 6,56%. Este estudo, também se propôs analisar o impacto do erro da rede no PLD, verificou-se que a rede pode auxiliar os agentes que comercializam energia no Mercado Livre na mitigação do risco relacionado a volatilidade do PLD, uma vez que o impacto nos três cenários estudados foi pequeno.

A fim de melhorar os resultados obtidos, outros tipos de redes recorrentes podem ser testados e avaliados, como por exemplo, redes LSTMs. Além disso, pode-se considerar a influência dos outros três subsistemas (Sul, Nordeste e Norte) utilizando a carga deles como variáveis de entrada. Outro ponto que pode ser considerado é utilizar dados de carga horária, tornando o conjunto de dados maior, auxiliando no desempenho da rede.

REFERÊNCIAS

- Bengio, Y., Simard, P., and Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166. doi:10.1109/72.279181.
- Chen, S., Yu, D.C., and Moghaddamjo, A.R. (1992). Weather sensitive short-term load forecasting using non-fully connected artificial neural network. *IEEE Transactions on Power Systems*, 7(3), 1098–1105. doi:10.1109/59.207323.
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y. (2014). Learning phrase representations using rnn encoder-decoder for statistical machine translation.
- Chung, J., Gulcehre, C., Cho, K., and Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. doi:10.1162/neco.1997.9.8.1735.
- INMET (2019). Banco de dados meteorológicos para ensino e pesquisa. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em 10 de out. de 2019.
- Kingma, D.P. and Ba, J. (2014). Adam: A method for stochastic optimization.
- ONS (2019). Informativo preliminar diário da operação. Disponível em: <<http://www.ons.org.br/paginas/conhecimento/acervo-digital/documentos-e-publicacoes?categoria=IPDO>>. Acesso em 10 de out. de 2019.
- Park, D.C., El-Sharkawi, M.A., Marks, R.J., Atlas, L.E., and Damborg, M.J. (1991). Electric load forecasting using an artificial neural network. *IEEE Transactions on Power Systems*, 6(2), 442–449. doi:10.1109/59.76685.
- Rahman, S. and Bhatnagar, R. (1988). An expert system based algorithm for short term load forecast. *IEEE Transactions on Power Systems*, 3(2), 392–399. doi:10.1109/59.192889.
- Vemuri, S., Huang, W.L., and Nelson, D.J. (1981). On-line algorithms for forecasting hourly loads of an electric utility. *IEEE Transactions on Power Apparatus and Systems*, PAS-100(8), 3775–3784. doi:10.1109/TPAS.1981.317020.