

**Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**

---

# Modelagem e Aplicação via Aumento do Gradiente (*Gradient Boosting*) para Predição de Consumo Elétrico

João Vitor de Moraes Leme<sup>1</sup>Wallace Casaca<sup>2</sup>

Universidade Estadual Paulista (UNESP), Câmpus Experimental de Rosana, SP

## 1 Introdução

A energia elétrica integra um mercado o qual engloba agentes de geração, transmissão, e de consumo e que se tornou altamente competitivo em função da concorrência promovida nos últimos anos, tendo alavancado a participação de diversos investidores e entidades do setor energético. Tendo em mente que esses agentes visam maximizar seus lucros e minimizar suas despesas, uma boa previsão da geração e despacho da carga elétrica passou a ser mandatória para aqueles que interagem nesse mercado [2]. Assim, este trabalho investiga o problema de predição de carga elétrica a partir do estudo e aplicação da técnica *Gradient Boosting*.

## 2 Materiais e Métodos

Para a realização deste trabalho, foi empregada uma base de dados real disponibilizada pela concessionária de energia *ISO New England*, com dados coletados hora-a-hora, no período de 2004 à 2008. A base é constituída das seguintes *features*: *Carga*, *Temperatura*, *Ponto de condensação (água)*, *Hora*, *Dia*, *Dia útil*, *Carga média (dia anterior)*, e *Carga na mesma hora do dia anterior*, *Carga na mesma hora/dia da semana anterior*.

Em seguida, realizou-se a modelagem e a adequação dos dados para aplicação do *Gradient Boosting* [1], que é um método *ensemble* baseado em árvores de regressão que utiliza a estratégia de *boosting* ao invés de *bagging*. Para o referido modelo, utilizando a técnica *Random Search*, foi conduzida uma seleção de parâmetros com validação cruzada ( $k=4$ ) a fim de maximizar sua acurácia, sendo estes (*nestimators*, *maxfeatures*, *maxdepth*, *minsamplesplit*, *minsampleread* e *loss*).

Os resultados foram analisados e comparados a partir das métricas de qualidade Erro Médio Absoluto (*MAE*) e Erro Médio Absoluto em Porcentagem (*MAPE*). O desenvolvimento foi feito na linguagem *Python*, no ambiente *Anaconda/Jupyter Notebook*, onde utilizou-se a biblioteca *Scikit-learn* para a prototipação de todo ferramental.

---

<sup>1</sup>leme-joao@hotmail.com<sup>2</sup>wallace.casaca@unesp.br

### 3 Resultados e Discussão

Após a etapa de modelagem e adequação dos dados, a base original, a qual continha 8 *features*, passou a ter 32, sendo uma destas a variável *target* (Carga Elétrica). Com a divisão da base de dados em conjunto de treino (2004, 2005, 2006 e 2007), e de teste (2008), o modelo de regressão com a configuração padrão dos parâmetros apresentou tais resultados: *MAE*, de 414.25 MW, e *MAPE*, de 2.76%. Já com o modelo treinado com a melhor configuração encontrada pelo *Random Search*, foram obtidos os seguintes resultados: *MAE*, de 304.62 MW, e *MAPE*, de 2.18%. A Figura 1 ilustra o gráfico da predição realizada para a primeira semana de 2008.

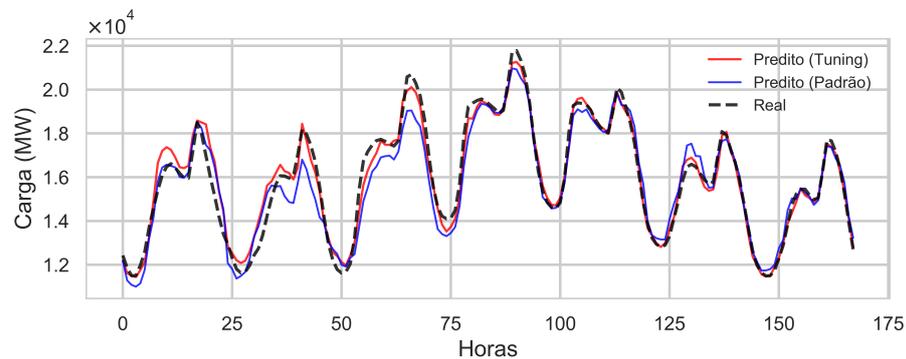


Figura 1: Valor real da carga (em negrito)  $\times$  predição com a configuração padrão (em azul) e com a configuração otimizada (em vermelho) para a primeira semana de 2008.

### 4 Conclusões

Foi possível concluir que o modelo *Gradient Boosting* leva à soluções acuradas na tarefa de predição do consumo elétrico em curtos horizontes de despacho, além da constatação de que é possível maximizar a assertividade a partir da variação dos parâmetros do modelo.

### Agradecimentos

Os autores agradecem à FAPESP (Proc. n 2018/15965-5) pelo amparo à pesquisa.

### Referências

- [1] A. Keprate and R. M. C. Ratnayake, Using Gradient Boosting Regressor to Predict Stress Intensity Factor of a Crack Propagating in Small Bore Piping, *IEEE Int. Conf. on Industrial Engineering and Engineering Management*, p. 1331-1336, 2017.
- [2] F. Martínez-Álvarez et al., A Survey on Data Mining Techniques Applied to Electricity-related Time Series Forecasting, *Energies*, v.8, n.11, p. 13162-13193, 2015.