

Estudo de um Modelo de Regressão Não Linear para a Previsibilidade de Carga Elétrica

Matheus de Paula & Wallace Casaca & Marilaine Colnago

Departamento de Engenharia de Energia - UNESP Campus de Rosana

matheus.paula@unesp.br



Resumo

A geração de energia elétrica no mundo contemporâneo tem enfrentado grandes desafios para suprir a demanda necessária por parte de seus centros consumidores. Nesse contexto, o uso da matemática aliada à metodologias computacionais tem se tornado fundamental, possibilitando às concessionárias e distribuidoras de energia tecer uma análise mais apurada de seus dados, além de uma performance mais adequada da previsão da demanda por eletricidade. Assim, o objetivo desse estudo é explorar um modelo de regressão não linear, sendo este baseado em Árvores de Decisão (AD's) e no esquema de agrupamento de dados chamado *Bagging* (*Bootstrap Aggregating*) a fim de atacar o problema de previsibilidade da carga elétrica.

Introdução

Para que se evite racionamentos de energia como o ocorrido no início dos anos 2000 no Brasil, uma predição de carga efetiva e um planejamento energético mais assertivo são fatores cruciais na atual conjuntura nacional, uma vez que uma baixa oferta de energia pode acarretar em prejuízos econômicos para diversos setores, além do aumento do custo da energia. Desta forma, o presente trabalho tem como objetivos:

1. Predizer a carga elétrica demandada com o uso de um modelo preditivo de regressão baseado em AD's + estratégia de agrupamento do tipo *Bagging*.
2. Dar suporte às estratégias de planejamento energético futuras quanto à segurança na geração e distribuição da energia elétrica por parte das provedoras e concessionárias de energia.
3. Analisar a viabilidade de um modelo preditivo de *Aprendizado de Máquina* (AM) no cenário energético.

Materiais e Métodos

O material de estudo e metodologia explorada nesta pesquisa foram as seguintes:

1. Plataforma de programação: MATLAB (R2017a), a qual inclui *toolboxes* específicas de análise e exploração de dados.
2. Base de dados: *ISO New England* (provedora americana de energia), cujos dados tabulados são: *Carga*, *Temperatura*, *Ponto de condensação (água)*, *Hora*, *Dia*, *Dia útil*, *Carga média (dia anterior)*, *Carga na mesma hora do dia anterior*, *Carga na mesma hora/dia da semana anterior*. Os dados contemplam o período de 2004 à 2008.
3. Modelo preditivo: Árvores de Decisão + *Bagging* [1].
4. Métricas de validação: Erro Médio Absoluto (MAE) e de Percentual Médio Absoluto (MAPE).

Resultados

A base de dados foi dividida entre treino/validação (anos de 2004-2007) e período de teste (ano de 2008). Em seguida, considerou-se 15 subintervalos (“janelas” de tempo) no ano teste de 2008 para a análise dos resultados. Assim, o subintervalo de menor MAPE apresentou um *score* de 1.31%, e o de maior, *score* de 3.89% (vide Figura 1). A árvore foi configurada com um tamanho mínimo de $k = 20$ folhas, além de um número $m = 20$ árvores de regressão, o que resultou em um melhor controle de performance e estabilidade. A métrica de

análise interna de desempenho foi a validação cruzada ($k = 8$) [2]. Os *scores* obtidos pelo modelo de regressão estudado foram: MAPE (em %): 2.23, e MAE (em KWh): 305.85.

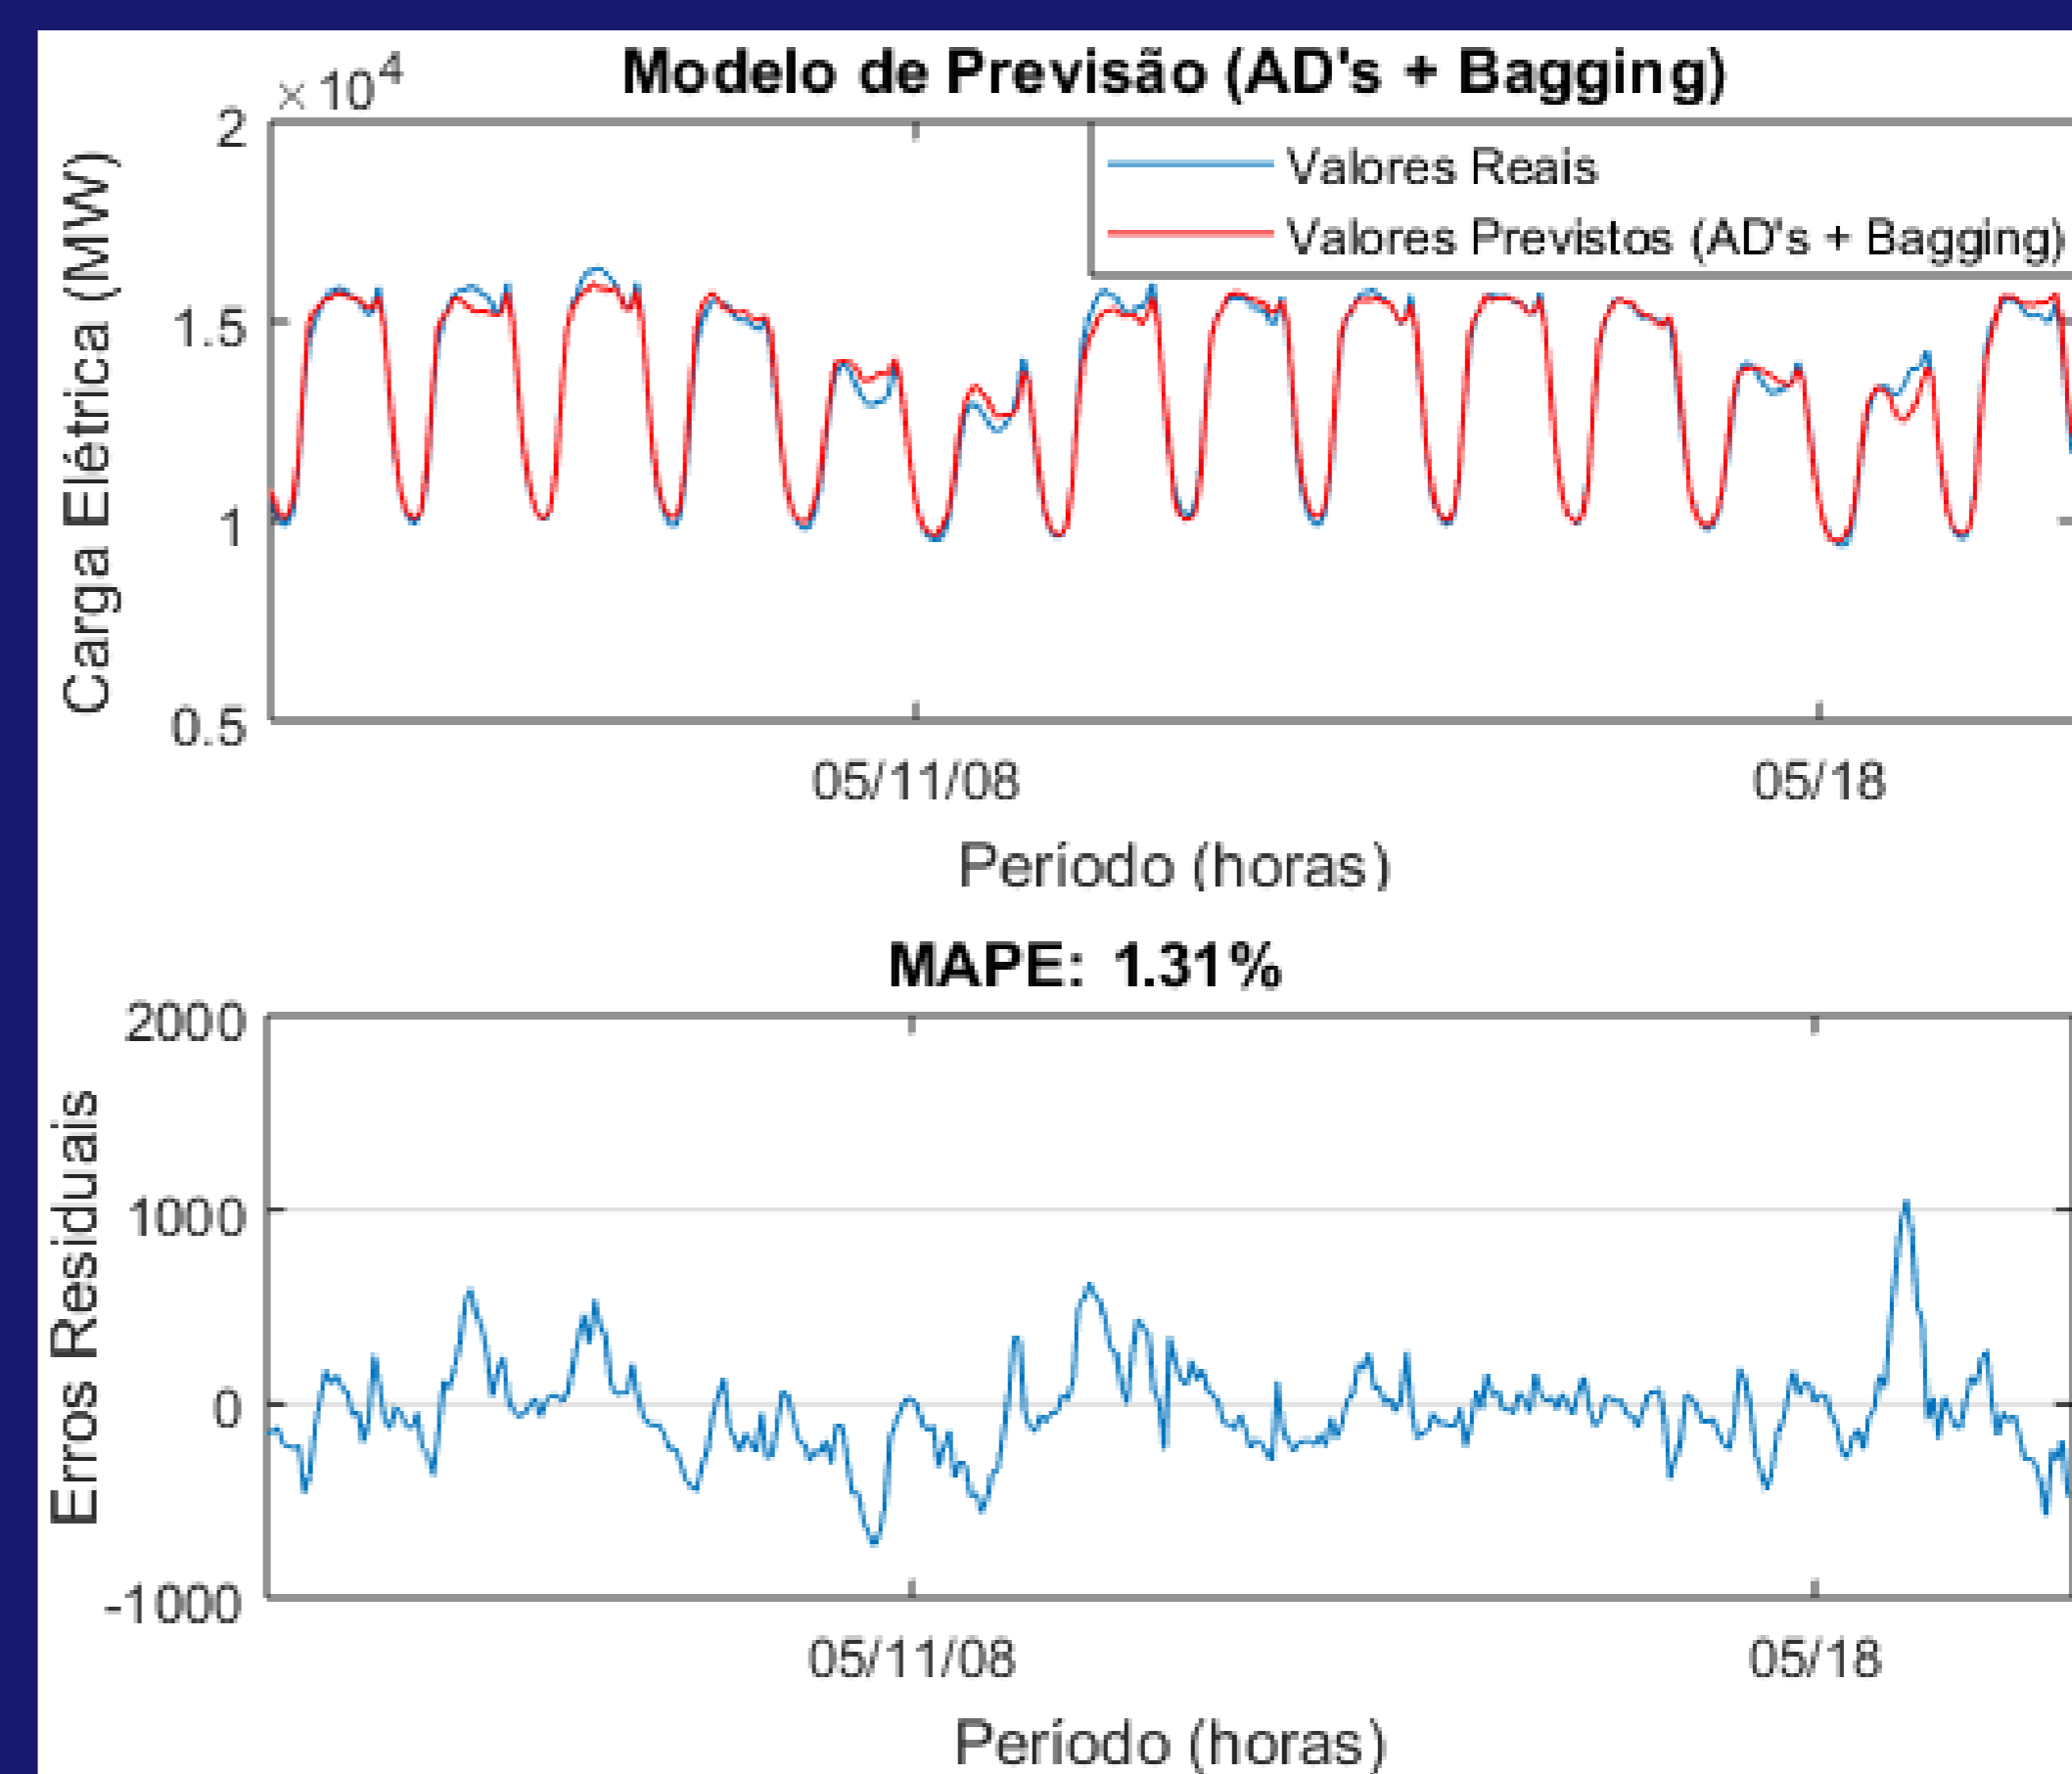


Figura 1: Carga e do erro residual no intervalo de menor MAPE.

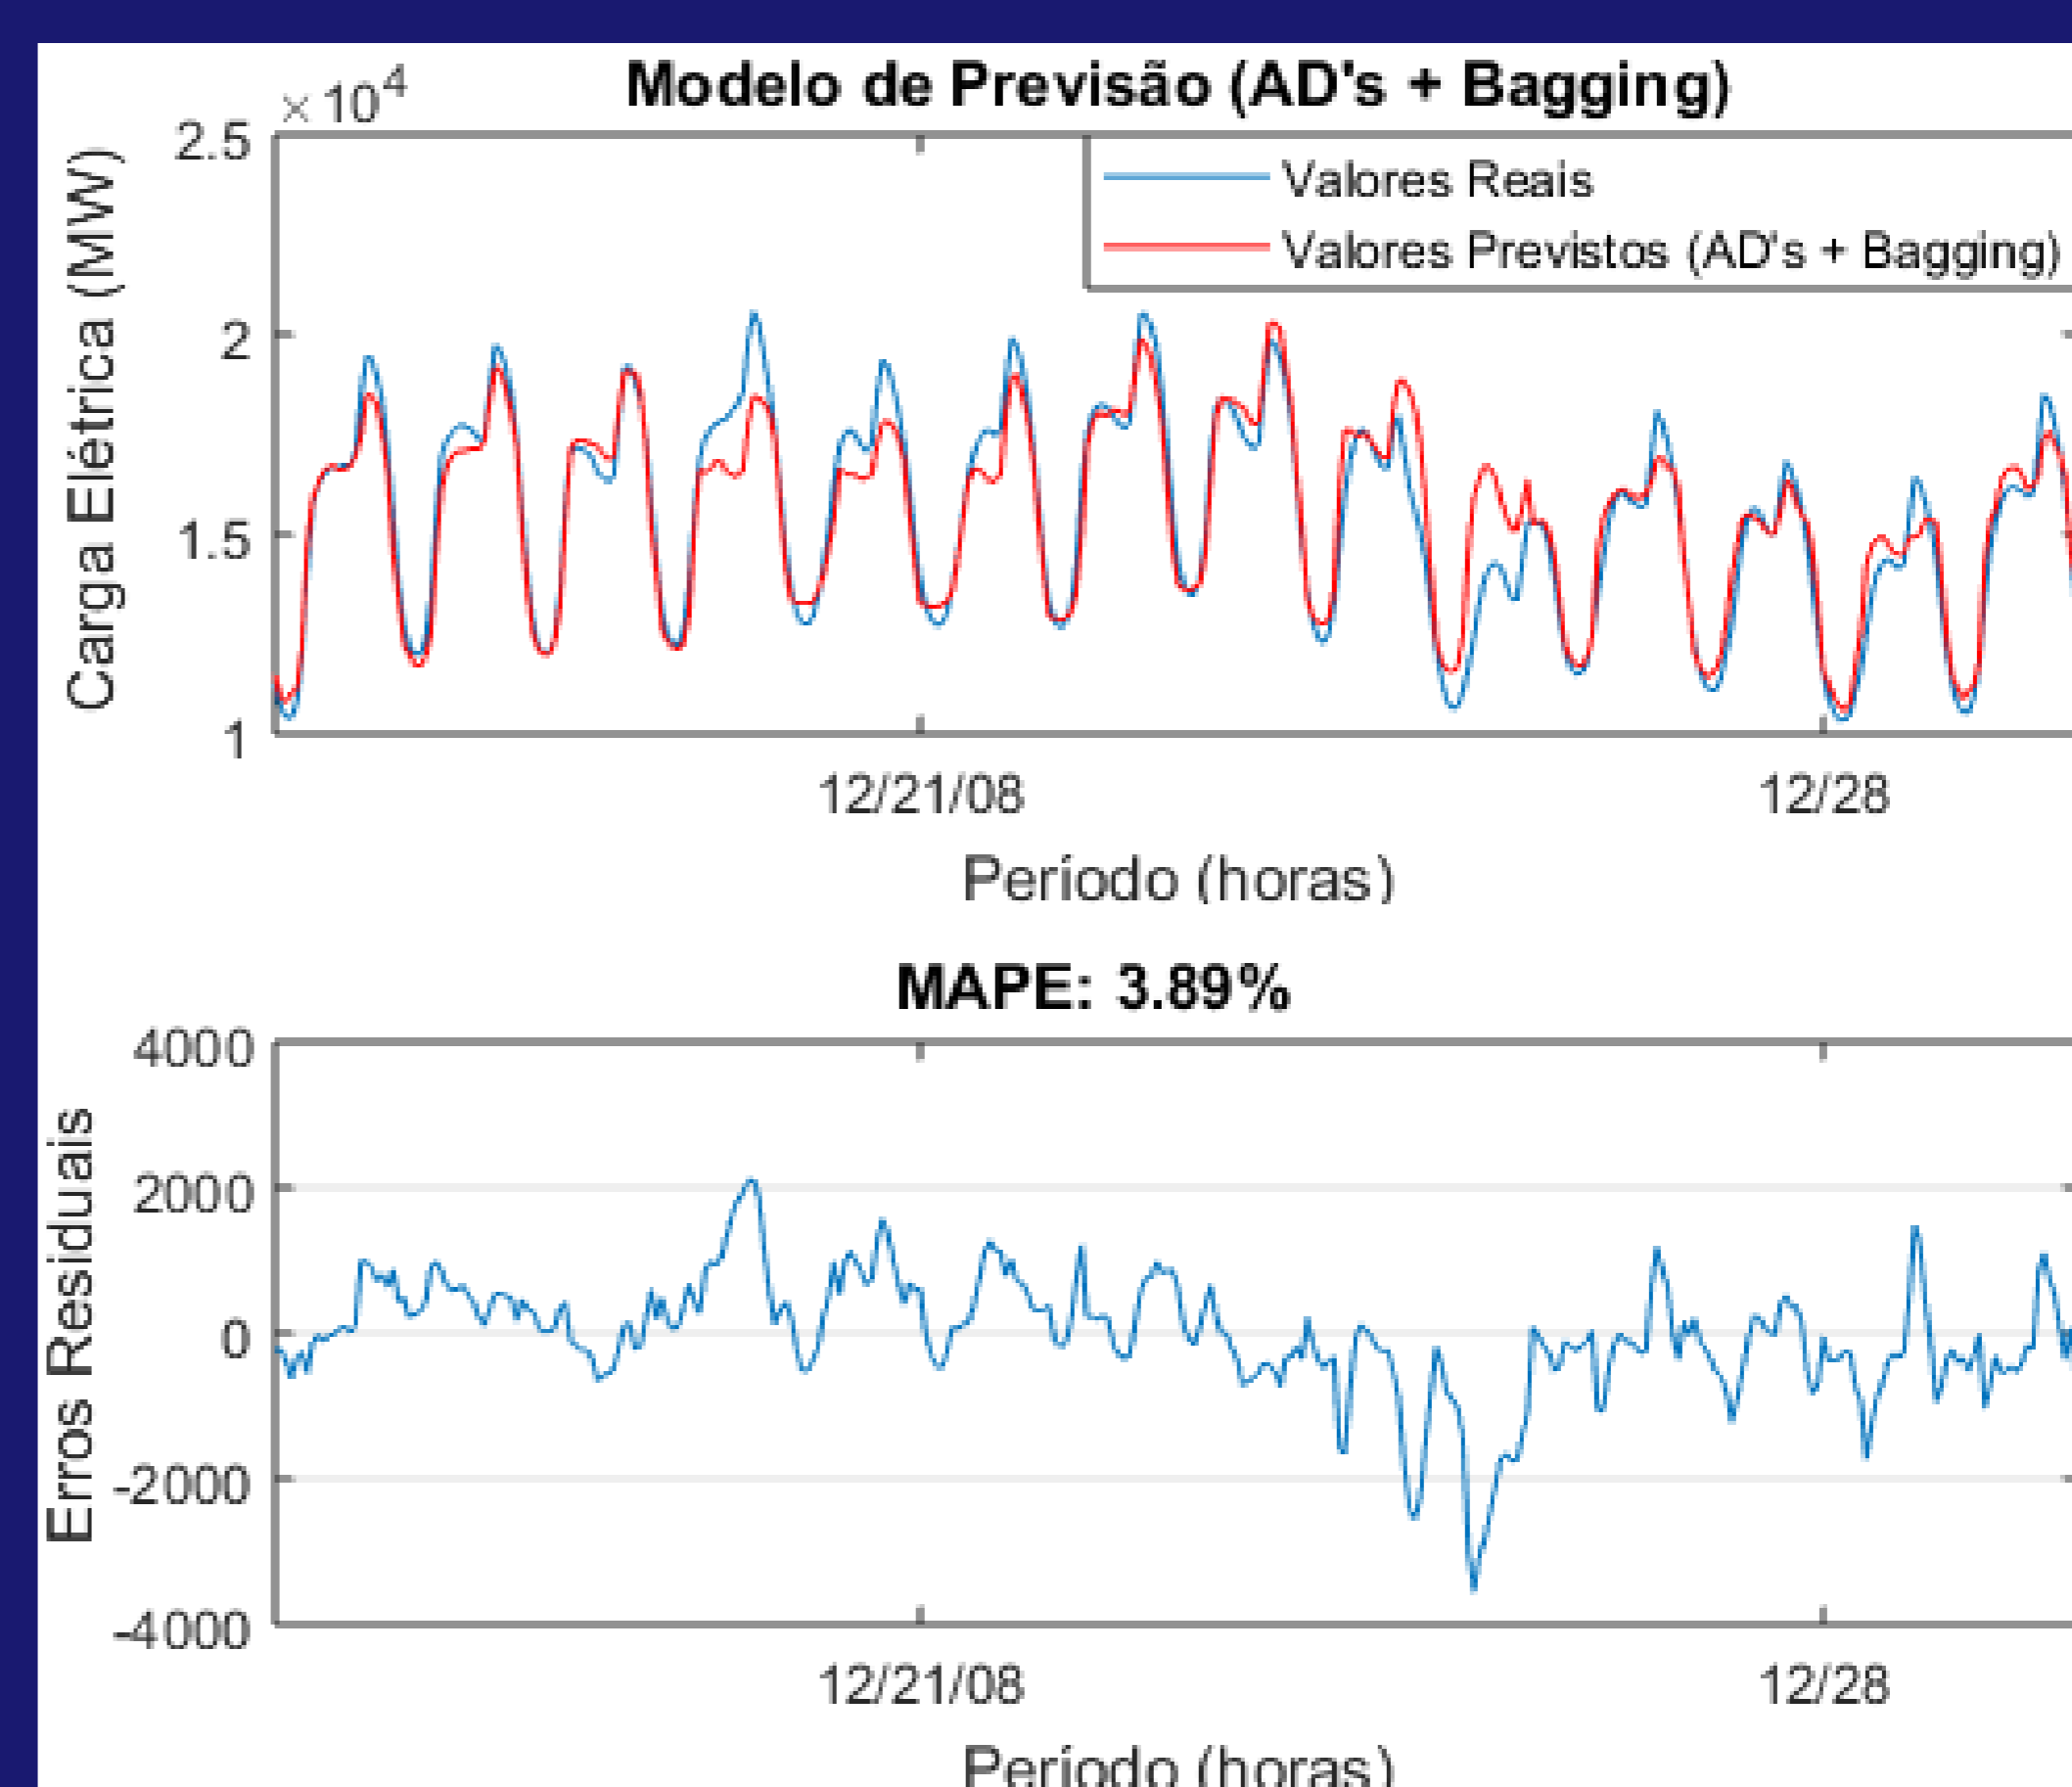


Figura 2: Carga e do erro residual no intervalo de maior MAPE.

Conclusão

O modelo de regressão estudado nesta iniciação científica (Árvores de Decisão com agrupamento *Bagging*) apresentou uma alta taxa de assertividade para o problema de predição investigado. Mesmo nos períodos da série temporal considerados demasiadamente “sobreajustados” (fenômeno este quase sempre presente em aplicações dessa área), o modelo estudado se comportou de maneira bastante preciso, demonstrando que técnicas de regressão não lineares podem ser utilizadas com sucesso na tarefa de predição de carga elétrica.

Referências

- [1] L. Breiman. Bagging predictors. *Machine learning*, v. 24, n. 2, p. 123-140, 1996.
- [2] A. Krogh and J. Vedelsby. Neural Network Ensembles, Cross Validation, and Active Learning, *Proc. of the 7th Int. Conf. on Neural Information Processing Systems*, p. 231-238, 1995.

Agradecimentos

Os autores agradecem à FAPESP pelo amparo à pesquisa.