

## COMPARAÇÃO DE PREVISÕES DE CONSUMO DE ENERGIA ELÉTRICA USANDO REDES NEURAIS ARTIFICIAIS E ANÁLISE DE REGRESSÃO

A.2.6. Ciências Exatas e da Terra / Ciência da Computação / Inteligência Artificial e Redes Neurais

**Matheus Braun Magrin<sup>1 4</sup> - braunmagrin@gmail.com**  
**Luiz Angelo Daros de Luca, Me.<sup>2 4</sup> - luizluca@gmail.com**  
**Claudio de Oliveira Magalhães, Dr. Eng.<sup>2 4</sup> - claudiomdo@gmail.com**  
**Gueibi Peres Souza, Prof. Dr.<sup>3</sup> - gpssouza@yahoo.com.br**  
**Manuela Machado<sup>3 4</sup> - manuelamachado.m@gmail.com**  
**Daiane De Bortoli<sup>3 4</sup> - bortoli.daia@gmail.com**

### INTRODUÇÃO

Prever o comportamento de eventos futuros é importante em distintos setores. As previsões são utilizadas, dentre outros, no auxílio à tomada de decisão sobre as ações futuras, que podem envolver questões de segurança e manejo de grandes quantidades de recursos. No setor elétrico nacional, elas são utilizadas como subsídio à tomada de decisão pelas empresas geradoras, transmissoras e distribuidoras de energia, bem como pelos demais agentes, como o Operador Nacional do Sistema Elétrico e a Empresa de Pesquisa Energética, nas mais diversas atividades diárias.

Existem diversos métodos quantitativos que são capazes de realizar previsões, a exemplo de Suavização Exponencial e Regressão Linear. Ainda, a literatura apresenta exemplos do uso de Redes Neurais Artificiais (RNAs) para previsão. Assim, dada a importância das previsões, se faz necessário estudar e comparar técnicas que permitam a obtenção de previsões precisas.

### OBJETIVO

Comparar a capacidade de previsão das Redes Neurais Artificiais em relação a modelos de Análise de Regressão (AR) na previsão do consumo residencial mensal de energia elétrica do estado de Santa Catarina, na área de concessão da Celesc Distribuição S.A.

### MÉTODOS

Foram construídos dois modelos de AR para prever a energia mensal sem tendência dos clientes residenciais da Celesc a partir de 15 variáveis explicativas: 11 binárias para os meses do ano; proporção de dias úteis no mês; proporção de dias com horário de verão (HV) no mês e transformações polinomiais da temperatura ambiente, diária e mensal. Para permitir a extrapolação das RNAs, a energia foi estacionada dividindo seu valor pela média móvel centrada de 24 meses. Os modelos foram construídos com dados do período de Janeiro/01 a Junho/10 e aplicados para prever o período de Julho/10 a Junho/11. Para cada modelo, foi utilizada uma das transformações da temperatura e as demais 13 variáveis.

O primeiro modelo obtido (Reg1) é composto pelas *dummies* de Abril, Maio e Dezembro, a proporção dos dias em HV e a transformação da temperatura mensal. O segundo modelo (Reg2) é composto pelas *dummies* de Junho à Dezembro e a transformação da temperatura diária.

Para a comparação, foram criadas RNAs do tipo *Perceptron* Múltiplas Camadas (MLP) utilizando os mesmos conjuntos de variáveis dos modelos econométricos. O treinamento foi realizado por Levenberg-Marquardt utilizando o erro do conjunto de validação como critério de parada. Para os dois conjuntos de dados foram testadas diferentes combinações de quantidades de camadas e neurônios. A avaliação das RNAs foi realizada através do Erro Quadrado Médio (MSE) e do Erro Percentual Absoluto Médio (MAPE) do conjunto de dados da previsão. Foram escolhidas as duas configurações que apresentaram menor média e variabilidade dos erros.

### RESULTADOS E DISCUSSÃO

As configurações escolhidas (RNA1 e RNA2) possuem a mesma arquitetura: sem camadas ocultas e camada de saída com função de ativação linear. O funcionamento desta arquitetura equivale ao funcionamento da análise de regressão (modelo linear). A tabela 1 apresenta os erros para a predição e previsão dos modelos e particularmente para as RNAs também os erros de treino e validação.

Os modelos de Regressão e as RNAs apresentaram erros (MAPE) na previsão abaixo de 2% para ambos os conjuntos de dados, resultados considerados aceitáveis na área. Os resultados mostram que as RNAs obtiveram erros menores, porém próximos, no horizonte de previsão de 12 meses (12 passos à frente). Em relação a Reg1, a RNA1 reduziu em 0,15 p.p. o MAPE na previsão. Em relação a Reg2, a RNA2 diminuiu o MAPE na previsão em 0,02 p.p.. Nos quatro modelos finais, os valores do MSE também foram similares.

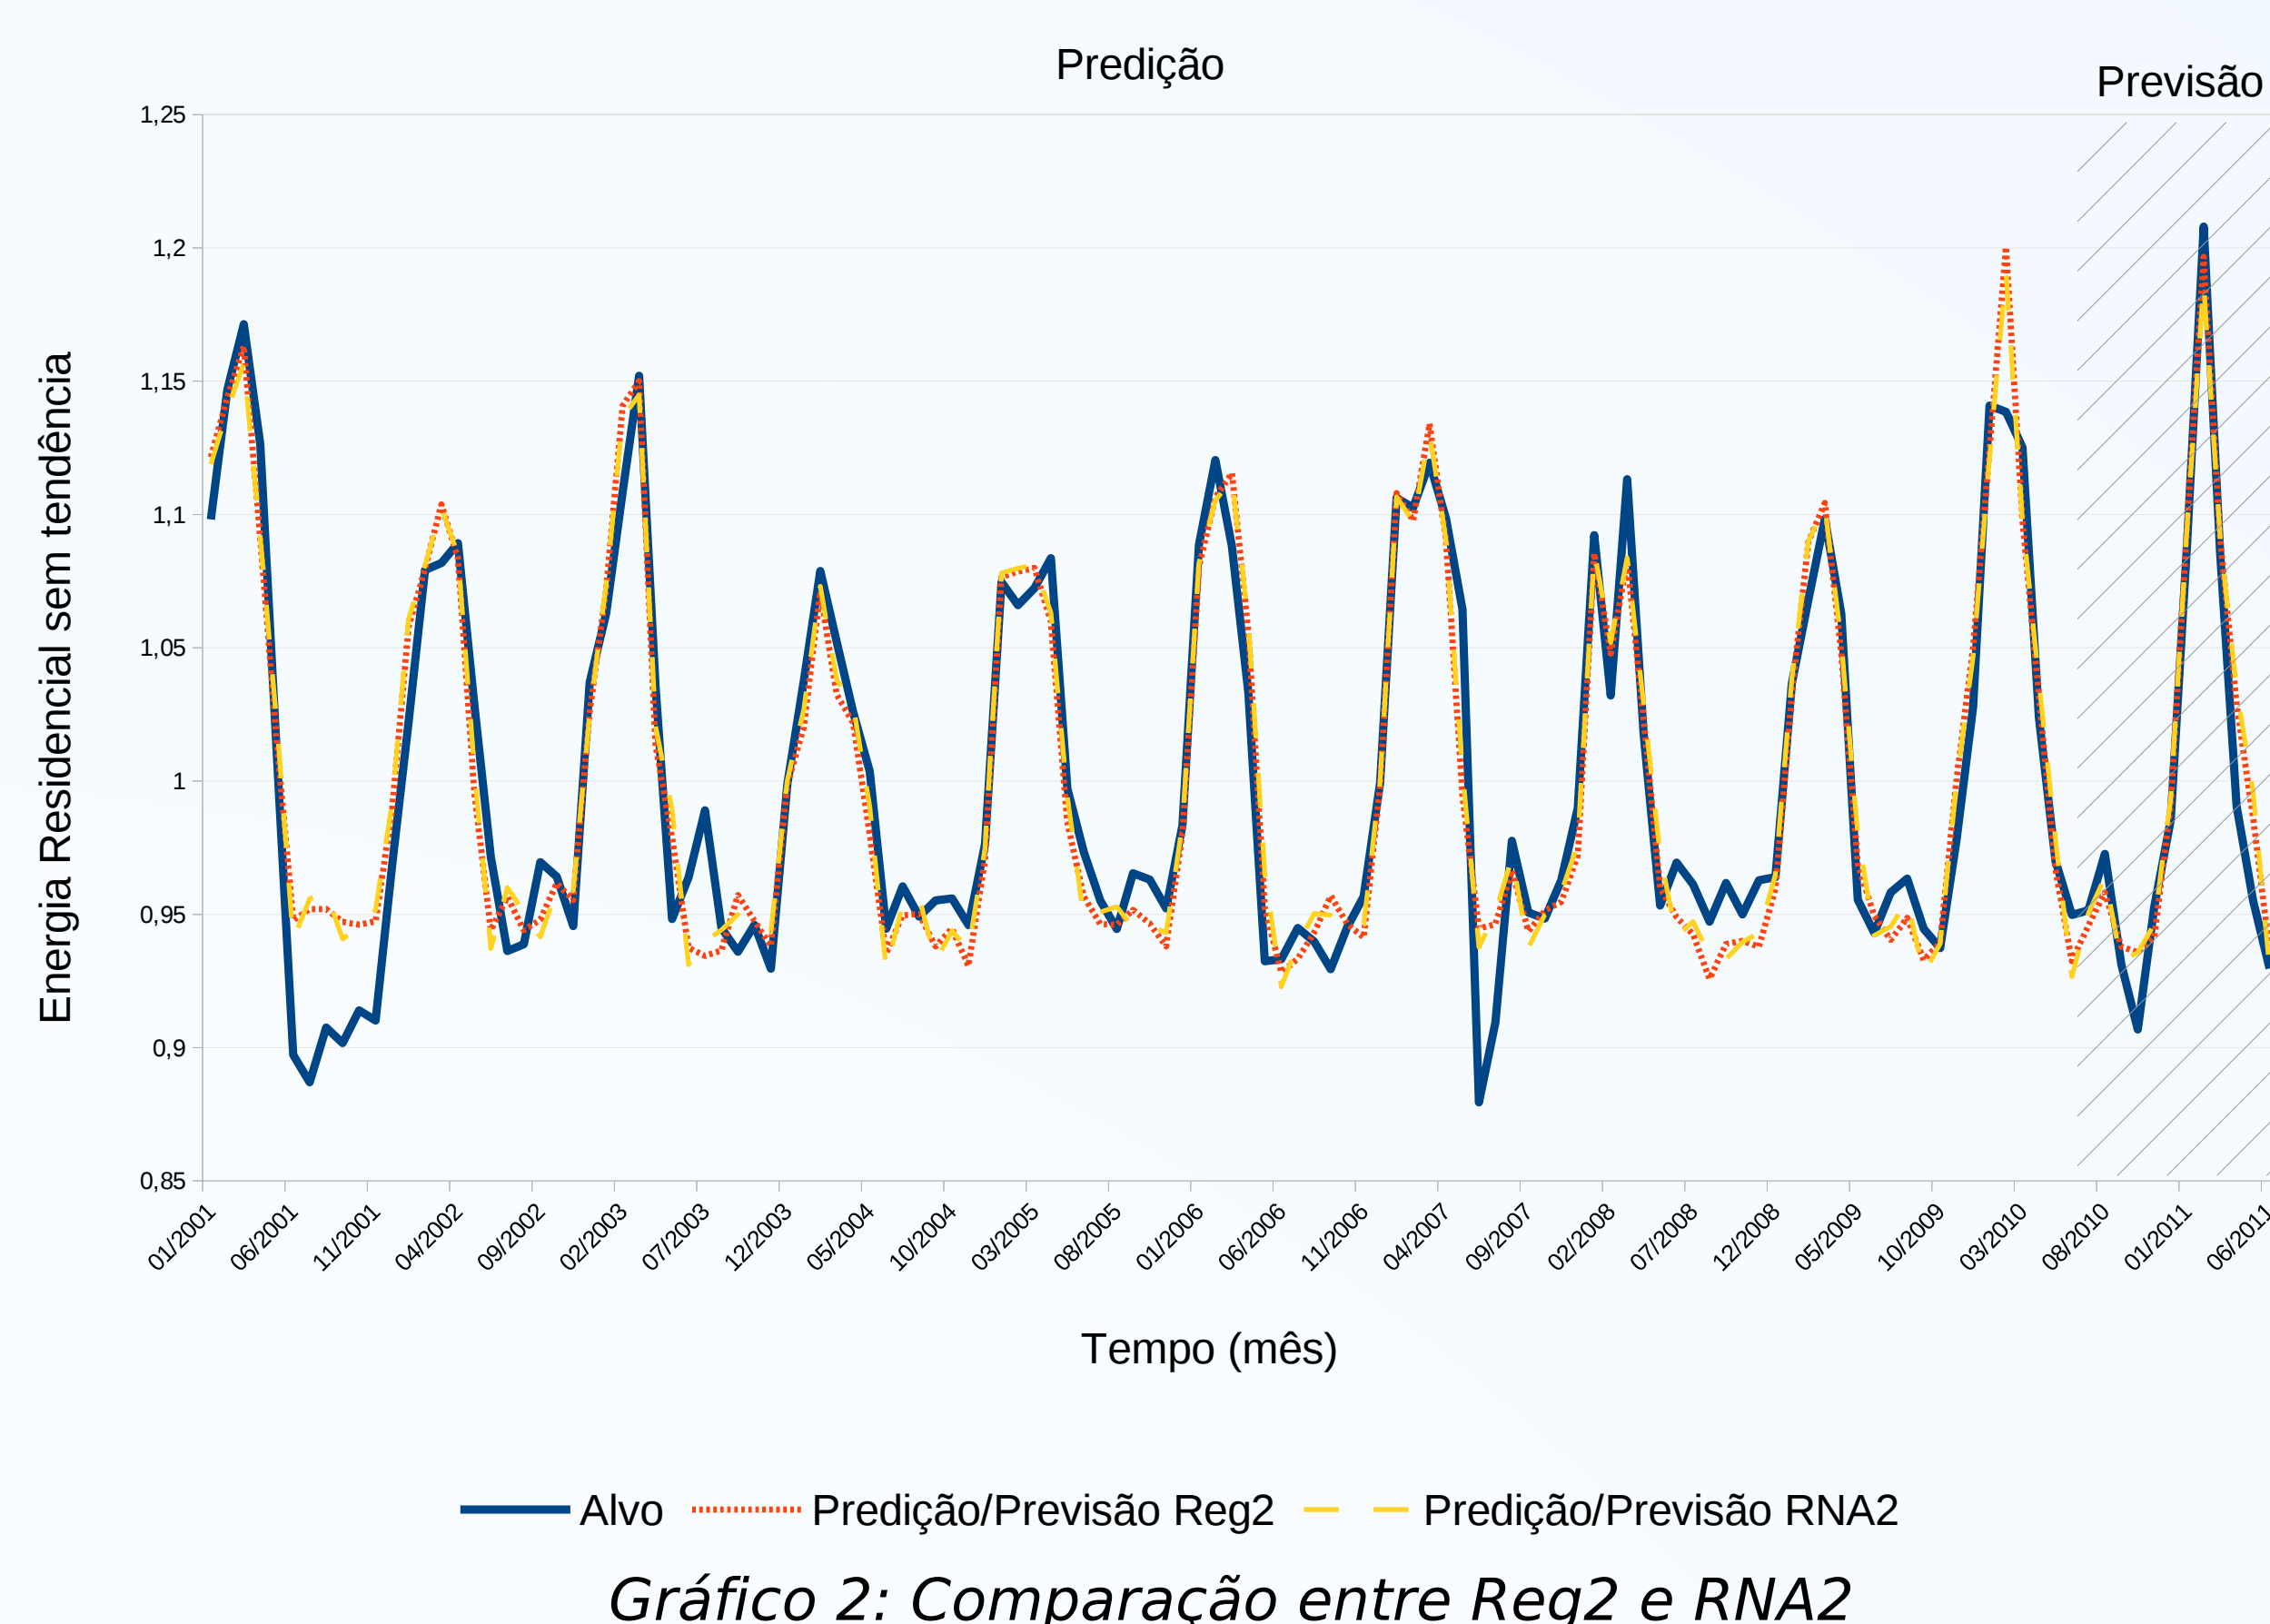
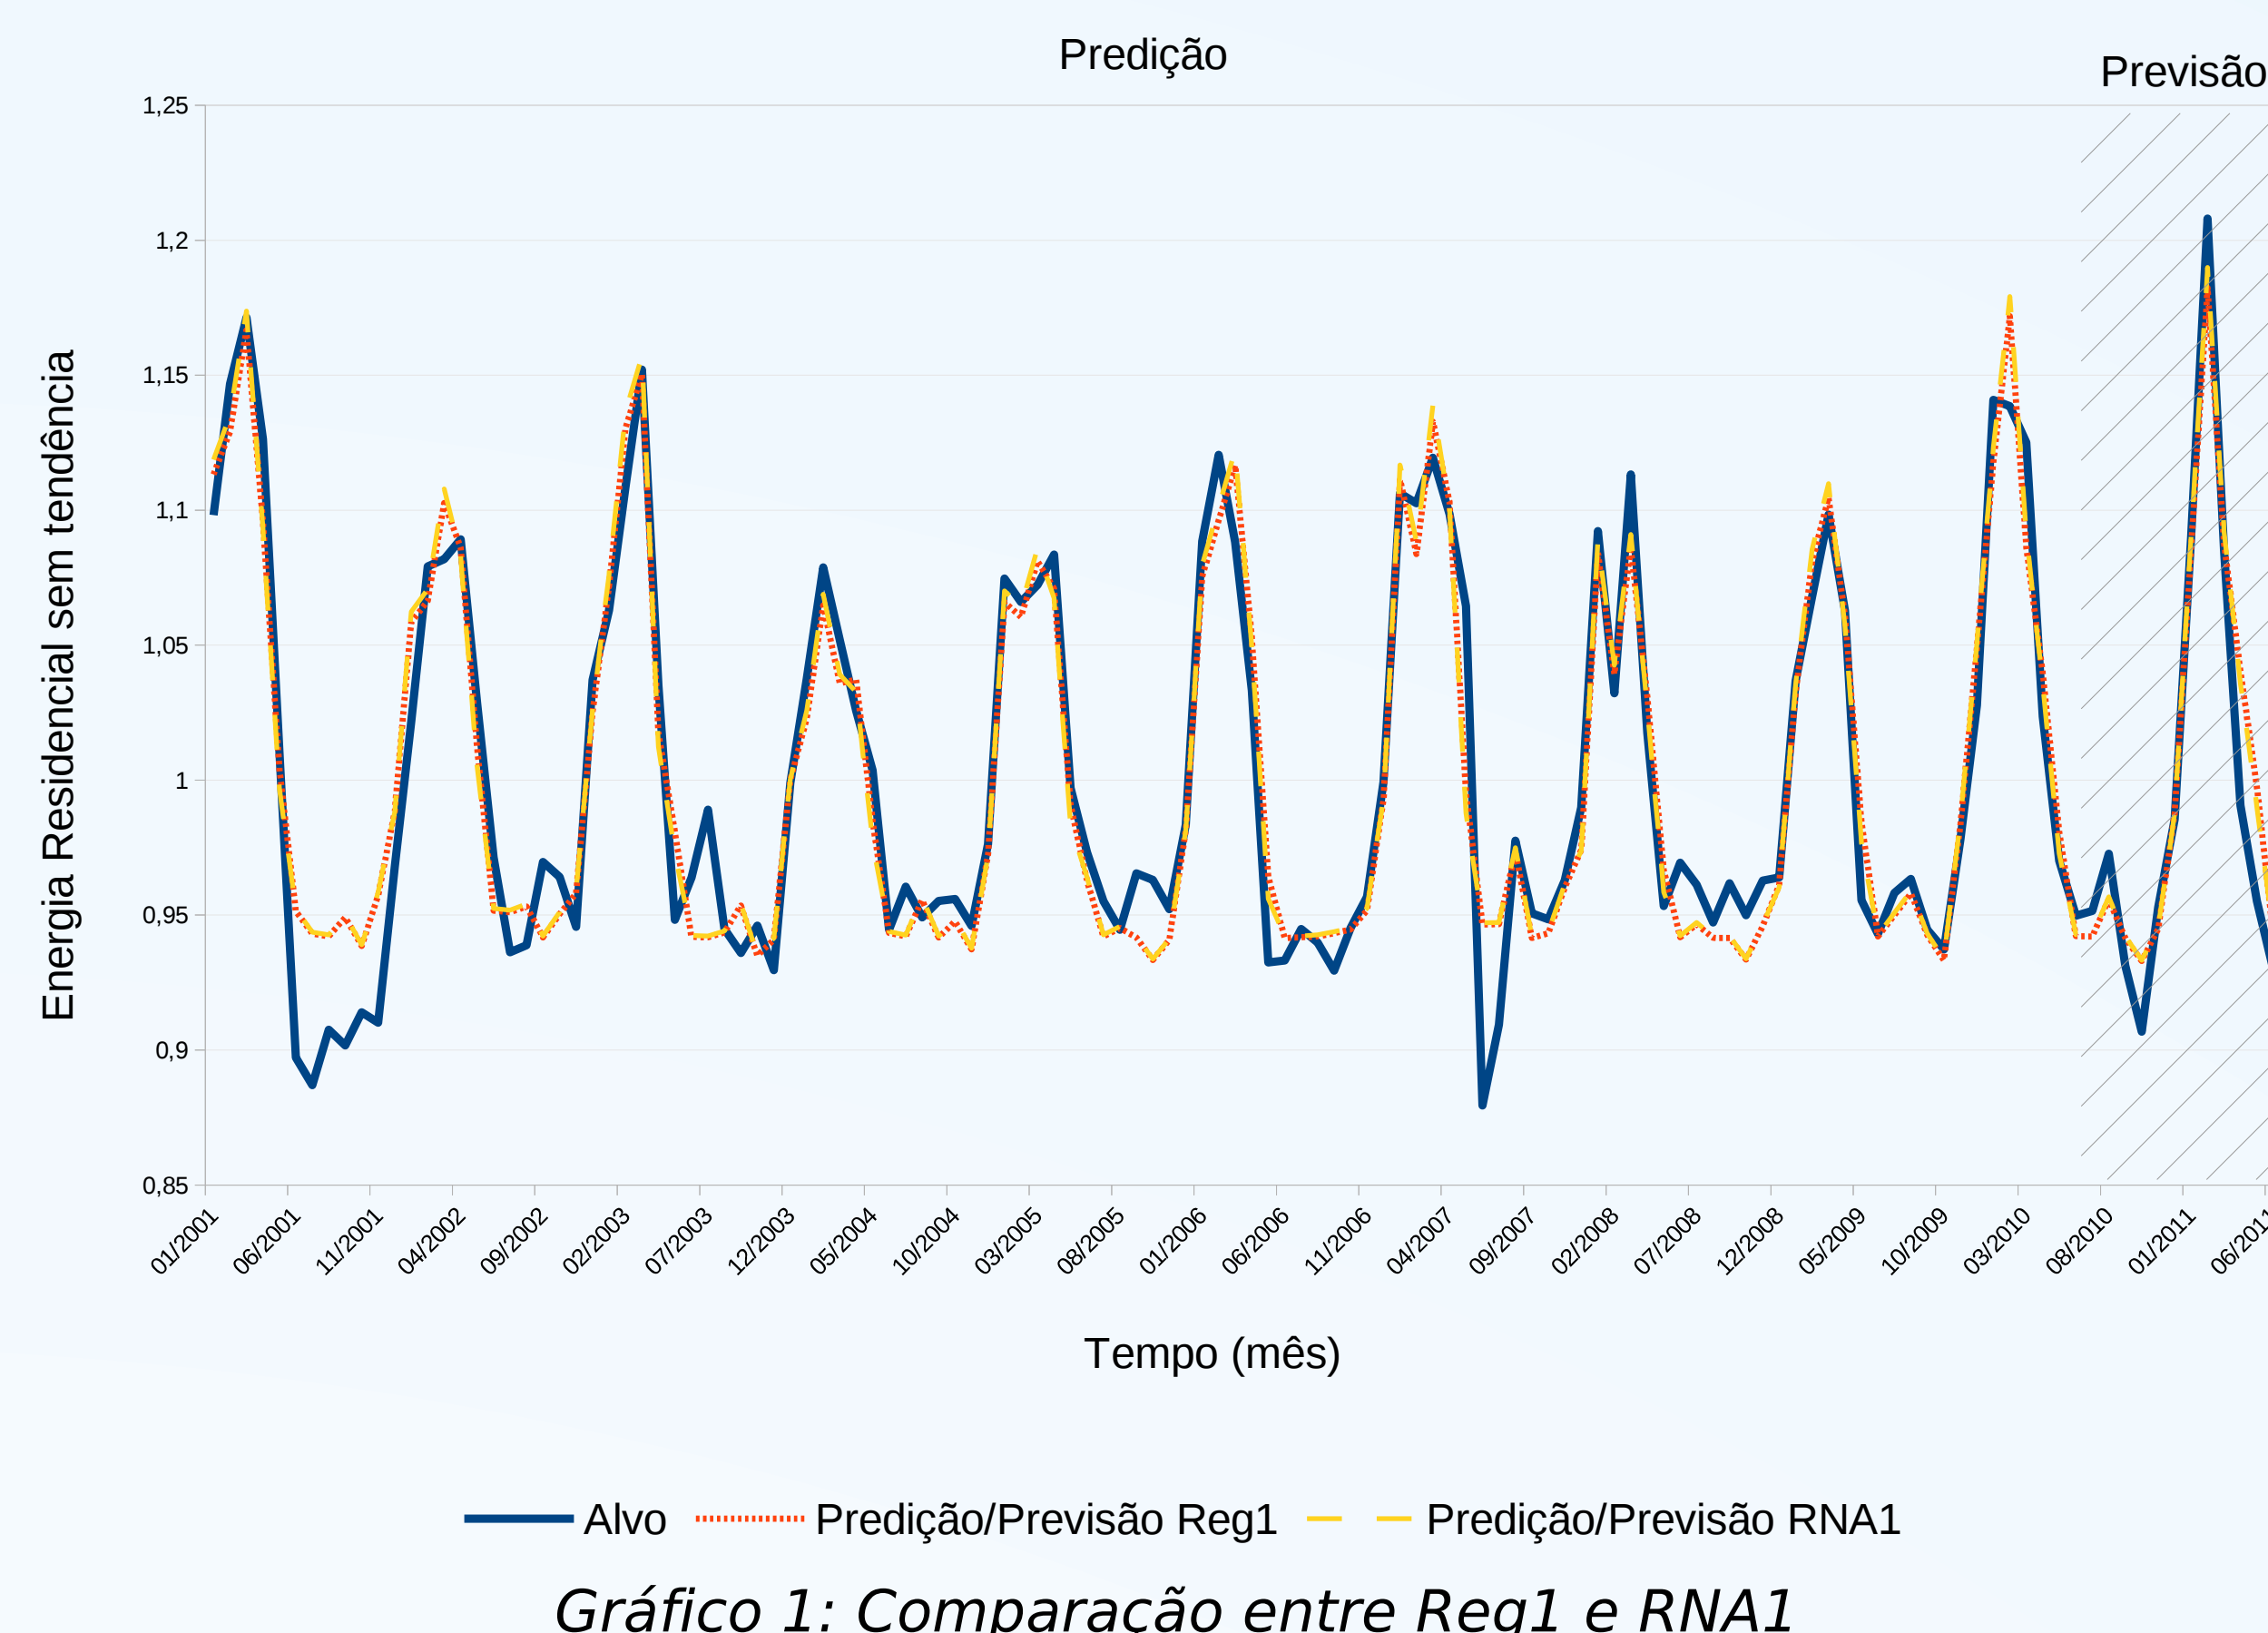
Tabela 1: MSE e MAPE dos modelos

MSE ( $\times 10^{-4}$ ) MAPE (%)	Predição	Treino	Validação	Previsão
<b>Reg1</b>	4,50 1,63	n/a	n/a	5,23 1,76
<b>RNA1</b>	4,64 1,62	3,96 1,56	7,27 1,86	4,14 1,61
<b>Reg2</b>	5,04 1,72	n/a	n/a	3,29 1,46
<b>RNA2</b>	4,96 1,74	4,62 1,66	6,27 2,04	4,28 1,44

Os resultados obtidos mostram desempenho ligeiramente superior das RNAs. Isso é devido a separação dos dados em conjuntos de treino e validação, que ocasionalmente produziu melhores resultados.

### CONCLUSÕES

O processo de construção dos modelos de AR seleciona variáveis com relações lineares com a variável dependente. Ao utilizar estes dados na busca de uma arquitetura de RNA, a melhor configuração obtida foi equivalente a um modelo de AR. O uso das RNAs não se mostrou interessante, quando aplicado sobre o mesmo conjunto de dados de um modelo de AR. As discrepâncias nos erros são devidas às pequenas diferenças nos conjuntos de dados usados na construção dos modelos e pela característica iterativa do treinamento.



<sup>1</sup> Departamento de Informática e Estatística - INE/CTC/UFSC

<sup>2</sup> IDESTI - Instituto de Capacitação, Pesquisa e Desenv. Inst. em Gestão Social de TI

<sup>3</sup> Departamento de Economia e Relações Internacionais - CNM/CSE/UFSC

<sup>4</sup> Laboratório de Sistemas do Conhecimento - LSC/INE/CTC/UFSC