



Grupo de Estudo de Planejamento de Sistemas Elétricos-GPL

Projeção do consumo de energia elétrica das classes residencial e comercial na área de concessão da CEMIG

**DANILO DE DEUS MOTA(1); THIAGO REZENDE DOS SANTOS(2);
CEMIG(1);UFMG(2);**

RESUMO

Neste trabalho foram realizadas as previsões do consumo de energia elétrica das classes residencial e comercial na área de concessão da Cemig através dos métodos SARIMA e Redes Neurais Artificiais do tipo MLP, além de testar métodos de combinações das previsões obtidas. Foram utilizadas ainda as variáveis número de consumidores e consumo das famílias (IBGE). Para avaliar o desempenho das previsões, retirou-se os últimos 24 meses das séries. Dentre os dois modelos, as redes neurais MLP apresentaram melhor performance para as duas classes, sendo que a combinação das previsões considerando a variância mínima obteve resultados melhores ou praticamente iguais.

PALAVRAS-CHAVE

SARIMA; Redes Neurais MLP; Previsão de consumo; Combinação de previsões

1.0 - INTRODUÇÃO

A previsão do consumo de energia elétrica, dentre outras aplicações, é fundamental para as empresas do setor de energia elétrica, determinando uma expectativa de crescimento da demanda dos seus mercados, a fim de subsidiar o planejamento da expansão e reforço da rede de distribuição, bem como para a compra de energia. A previsão de longo prazo da demanda do mercado é necessária ainda para o devido planejamento da capacidade de produção e transmissão de energia. Esta é uma área de interesse para vários setores ligados à geração, distribuição, transmissão e comercialização de energia, além de instituições ligadas à regulação e operação do sistema elétrico.

O problema deste trabalho é realizar o desenvolvimento e a comparação de modelos utilizados para a previsão do consumo de energia elétrica das classes residencial e comercial na Cemig Distribuição considerando um horizonte de previsão de vinte e quatro meses. O consumo dessas classes representa aproximadamente 48% do consumo do Brasil e 39% do consumo total da CEMIG Distribuição. As séries de consumo mensal foram fornecidas pela CEMIG através da gerência de Planejamento do Mercado, sendo o consumo residencial do período de janeiro de 1996 até março de 2019 e o comercial de junho de 2001 até março de 2019.

Pretende-se neste trabalho realizar previsões por um método de Machine Learning para comparar com o tradicional modelo SARIMA e também para combinar as previsões aproveitando uma possível complementariedade. Com isso, o objetivo é melhorar a performance das previsões que utilizam apenas métodos estatísticos tradicionais.

Assim, foram utilizados para as previsões os métodos SARIMA e Redes Neurais Artificiais (RNA) do tipo MLP

(Multilayer Perceptron). Além disso, foram realizados dois tipos de combinação utilizando as previsões obtidas por esses modelos através dos métodos de combinação média simples e variância mínima simplificado. O número de consumidores das classes e o consumo das famílias (IBGE) foram inseridos como variáveis externas, além de uma variável *dummy* de intervenção devido ao racionamento de energia ocorrido no ano de 2001. A avaliação de desempenho das previsões para comparação dos métodos foi realizada por meio das medidas MAPE (erro percentual absoluto médio) e RMSE (raiz do erro quadrático médio). Foram retirados os 24 últimos meses das séries para serem utilizados como período de validação (abril de 2017 a março de 2019). A implementação e comparação dos modelos foi realizada utilizando o software R.

2.0 - METODOLOGIA

2.1 - Redes Neurais Artificiais

A modelagem por Redes Neurais Artificiais – RNA – é uma técnica computacional que apresenta um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. O funcionamento destas redes é inspirado em uma estrutura física concebida pela natureza: o cérebro humano. Para Braga et al. (1998), as redes neurais são sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais. Na maioria dos modelos, estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede.

Para Haykin (2001), uma rede neural se assemelha ao cérebro em dois aspectos:

- a. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
- b. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Para o autor, um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural, constituído de três elementos básicos:

- a. Um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso;
- b. Um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio;
- c. Uma função de ativação para restringir a amplitude da saída de um neurônio, realizando o processamento do sinal gerado pela combinação linear das entradas e dos pesos das sinapses, para gerar o sinal de saída do neurônio.

O procedimento usual na solução de problemas passa inicialmente por uma fase de aprendizagem em que um conjunto de exemplos é apresentado para a rede, a qual extrai automaticamente as características necessárias para representar a informação fornecida (Braga et al., 1998). Diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois tipos principais: aprendizado supervisionado e aprendizado não-supervisionado. O primeiro é o mais comum no treinamento das RNA's e é chamado de aprendizado supervisionado porque a entrada e saída desejadas para a rede são fornecidas por um supervisor externo. O objetivo é ajustar os parâmetros da rede de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos. Neste método a rede deve ser capaz de medir a diferença entre seu comportamento atual e o comportamento de referência e então corrigir os pesos de maneira a reduzir este erro.

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem, cuja função é modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado (Haykin, 2001). Um algoritmo de treinamento supervisionado muito utilizado é o backpropagation, cuja lógica é a seguinte: calcula-se o erro entre o que a rede encontrou e o verificado e, caso esteja acima de uma tolerância determinada, então os valores de todos os pesos são recalculados, começando da última camada e indo até a primeira. Para minimizar o erro, utiliza-se o método do gradiente descendente. Utilizaremos neste

trabalho, uma variação do algoritmo backpropagation, que é o resilient backpropagation, que elimina o problema da derivada próxima de zero fazendo a correção dos pesos através apenas do sinal da primeira derivada.

As arquiteturas neurais podem combinar vários neurônios organizados em camadas como na figura 2, formando as redes neurais denominadas de perceptrons de múltiplas camadas (MLP – multilayer perceptron), que são utilizadas na solução de problemas que envolvem não-linearidade, como é o caso das séries que estamos tratando neste trabalho. Com relação à arquitetura da rede, é necessário definir os seguintes parâmetros: número de camadas da rede, número de nodos em cada camada, tipo de conexão entre os nodos e topologia da rede.

2.2 - Metodologia Box & Jenkins

Segundo Gujarati et al. (2011), nos modelos propostos por Box e Jenkins para modelagem de séries temporais utilizando o modelo ARIMA, a ênfase desses métodos não está na construção dos modelos de uma única equação ou de equações simultâneas, mas na análise probabilística, ou estocástica, das propriedades da própria série temporal. Diferentemente dos modelos de regressão, onde a série é explicada somente pelas variáveis explicativas, os modelos de séries temporais ARIMA permitem que a série temporal seja explicada pelos valores passados (autoregressivos), ou defasados (integração), da própria série e dos termos de erro estocástico (média móvel).

O processo autoregressivo e de médias móveis (ARMA) é utilizado para modelar séries temporais estacionárias, onde o valor em um instante t depende do seu valor nos períodos anteriores e da média móvel dos termos de erro atuais e passados (combinação linear de termos de erro de ruído branco). Se tivermos que diferenciar uma série temporal d vezes para torná-la estacionária e aplicar-lhe o modelo ARMA(p,q), diremos que a série temporal original é ARIMA(p,d,q), ou seja, ela é uma série temporal autorregressiva integrada de médias móveis, em que p denota os números dos termos autorregressivos, d o número de vezes que a série deve ser diferenciada antes de tornar-se estacionária e q o número de termos de média móvel.

Conforme descrito por Morettin & Tolo (2006), a metodologia de Box & Jenkins é um processo iterativo para determinar as ordens do modelo ARIMA, bem como para estimação e validação do mesmo, sendo constituído das seguintes etapas:

- Identificação: após realizar a diferenciação da série original tantas vezes quanto necessário para torná-la estacionária, deve-se descobrir os valores apropriados de p , d e q . Uma das ferramentas utilizadas na identificação são a função de correlação amostral (ACF) e a função de correlação amostral parcial (PACF).
- Estimação: estimar os parâmetros dos termos autorregressivos e dos termos de média móvel incluídos no modelo e verificar a significância dos mesmos. Considera-se também no processo de definição do melhor modelo aqueles com menor valor para o Critério de Informação de Akaike (AIC) e o Critério Bayesiano de Schwarz (BIC).
- Verificação ou Diagnóstico: verificar se o modelo selecionado ajusta-se aos dados analisando se os resíduos estimados com base nesse modelo são ruídos brancos. São utilizados os gráficos da autocorrelação (FAC) e autocorrelação parcial (FACP), além de testes como Ljung-Box (independência) e teste de raiz unitária Dickey-Fuller Aumentado (estacionariedade), dentre outros.
- Previsão: realizam-se as previsões (obtenção dos novos valores da série) e os intervalos de confiança para as mesmas, lembrando de retornar para a variável original desfazendo eventuais transformações.

Para as séries que apresentam autocorrelação significativa em “lags” sazonais, segundo Morettin & Tolo (2006), há necessidade de se considerar uma sazonalidade estocástica e ajustar um modelo ARIMA Sazonal (SARIMA), que contém uma parte não sazonal com parâmetros (p,d,q) e uma parte sazonal com parâmetros (P,D,Q), sendo que estes parâmetros serão definidos de forma similar aqueles. Além disso, é possível incorporar variáveis externas explicativas, como variáveis macroeconômicas a fim de captar possíveis mudanças no cenário econômico.

3.0 - RESULTADOS

3.1 - Séries de consumo e variáveis explicativas

As séries mensais de consumo de energia das classes residencial e comercial da CEMIG foram fornecidas pela Gerência de Planejamento do Mercado, sendo a primeira de janeiro de 1996 até março de 2019 e a segunda de junho de 2001 a março de 2019. Foram separados os últimos 24 meses para previsão e validação dos modelos (abril de 2017 a março de 2019). Tanto no modelo RNA quanto no modelo ARIMA os dados de entrada foram padronizados subtraindo a média e dividindo pelo desvio padrão (z escore).

Foram testadas para inclusão nos modelos algumas variáveis econômicas, como PIB, consumo das famílias, valor da tarifa de energia, além de outras variáveis como o número de consumidores das classes e o calendário de faturamento da CEMIG. Após analisar a correlação destas variáveis e a significância estatística nos modelos ARIMA, decidiu-se pela utilização do número de consumidores, que reflete o crescimento vegetativo, e do consumo das famílias (IBGE) que representa os impactos econômicos no consumo de energia. O consumo das famílias integra o Produto Interno Bruto (PIB) pela ótica da demanda referindo-se a despesa das famílias em bens de consumo (consumo privado). Utilizou-se a série do número índice de volume trimestral (base: média 1995 = 100) disponível no site do IBGE (sidra.ibge.gov.br). Como a série é trimestral foi necessário fazer um ajuste para obter valores mensais de forma que a soma do trimestre retornasse ao valor original. A correlação de Pearson entre o consumo das famílias e o consumo residencial é de 83,5% (veja figura 1).




Figura 1 – Consumo residencial e consumo das famílias

O número de consumidores foi utilizado como covariável nos modelos para o consumo residencial. Já nos modelos para o consumo comercial, após alguns testes, optou-se por dividir o consumo pelo número de consumidores, utilizando como variável a ser modelada uma nova variável: o consumo médio por consumidor – CPC. Veja na figura 2 abaixo esta nova variável comparada com o consumo das famílias, sendo que a correlação de Pearson entre o consumo das famílias e o consumo médio por consumidor comercial é de 87,7%.




Figura 2 – Consumo médio por consumidor comercial e consumo das famílias

Utilizou-se uma variável *dummy* passo em junho de 2001 no modelo para o consumo residencial devido ao racionamento de energia ocorrido naquele ano e que mudou o comportamento da série de consumo sem alterar o número de consumidores como visto na figura 2. Segundo Morettin & Tolo (2006), por uma intervenção entendemos a ocorrência de algum tipo de evento em dado instante de tempo, conhecido a priori. Como o efeito neste caso é permanente, utilizou-se uma função binária do tipo degrau. A série disponibilizada referente ao consumo comercial iniciou após o período do racionamento.

3.2 Modelo SARIMA

Em uma análise inicial dos gráficos de autocorrelação e autocorrelação parcial das séries, observou-se que as mesmas não eram estacionárias, sendo necessário realizar uma diferenciação na série do consumo residencial e uma diferenciação sazonal (anual) na série da classe comercial. Para identificação e validação do modelo SARIMA considerou-se a metodologia de Box & Jenkins, destacando os critérios e análises: análise dos gráficos ACF e PACF das séries originais e diferenciadas; menores valores para os critérios AIC e BIC; significância dos coeficientes; análise dos resíduos e parcimônia (melhor ajuste e menor número possível de parâmetros).

O modelo final para o consumo residencial foi ARIMA (2,1,1) (1,1,1)₁₂ com as covariáveis consumo das famílias e número de consumidores, além de uma variável *dummy* passo, obtendo os seguintes coeficientes:

Tabela 1 – Coeficientes do modelo SARIMA para o consumo residencial

Coeficiente	Valor	Erro Padrão	Valor z	Valor p
ϕ_1	-0,186	0,086	-2,151	0,031
ϕ_2	-0,185	0,079	-2,335	0,020
θ_1	-0,744	0,065	-11,450	< 0,001
Φ_1	0,191	0,083	2,299	0,021
Θ_1	-0,958	0,132	-7,246	< 0,001
β_1 (Nº de Consumidores)	3,143	0,730	4,305	< 0,001
β_2 (Consumo das Famílias)	0,626	0,187	3,338	< 0,001
β_3 (Racionamento)	-1,523	0,121	-12,611	< 0,001

O modelo foi validado através de uma análise dos resíduos. O gráfico dos resíduos padronizados pelo tempo

apresentou padrão aleatório em torno do zero (média zero e variância constante). Há evidências de independência dos resíduos pela análise dos gráficos ACF e PACF dos resíduos e pela aplicação do teste de Ljung-Box (valor-p maior do que 5%). Com relação à normalidade, o histograma e o QQ-Plot apresentam indícios de um leve desvio da normalidade na calda direita, sendo que o teste de Kolmogorov-Smirnov (valor-p = 0,347) aceitou as evidências de normalidade e o teste de Shapiro-Wilk (que é mais poderoso) rejeitou as evidências de normalidade (valor-p = 0,015). O teste de Dickey-Fuller aumentado apresentou evidências de estacionariedade (valor-p < 0,01).

O modelo final para o consumo médio por consumidor (CPC) comercial foi um $ARIMA(1,0,1)(0,1,1)_{12}$ com a covariável consumo das famílias, obtendo as seguintes estimativas para os coeficientes:

Tabela 2 – Coeficientes do modelo SARIMA para o consumo comercial

Coefficiente	Valor	Erro Padrão	Valor z	Valor p
ϕ_1	0,870	0,075	11,555	< 0,001
θ_1	-0,513	0,136	-3,766	0,000
Θ_1	-0,804	0,069	-11,587	< 0,001
β_1 (Consumo das Famílias)	0,889	0,094	9,421	< 0,001

A análise de resíduos mostra um modelo válido. O gráfico dos resíduos padronizados vs. tempo mostra um padrão aleatório em torno do zero (média zero e variância constante). O gráfico ACF não apresentou picos significativos e o teste Ljung-Box apresenta valor-p bem próximo ou acima do nível de significância de 5% até o lag 12, indicando evidência de independência. Com relação à normalidade, o histograma e o QQ-Plot apresentam indícios de um desvio da normalidade nas caldas, mas os testes de Kolmogorov-Smirnov (valor-p = 0,418) e de Shapiro-Wilk (valor-p = 0,166) mostram evidências de normalidade. Pelo teste de Dickey-Fuller aumentado há evidências de estacionariedade (valor-p menor que 0,01).

3.3 - Redes Neurais Artificiais MLP

A arquitetura da rede neural MLP utilizada para a série residencial possui uma camada oculta com 5 nodos e a rede para a série comercial possui duas camadas ocultas, sendo a primeira com 5 nodos e a segunda com 3 nodos (veja figura 4). Na primeira camada, além das mesmas variáveis explicativas utilizadas nos modelos ARIMA, utilizou-se defasagens de ordem 1, 2, 3, 4, 12 e 24, perfazendo um total de 24 neurônios na camada de entrada para o modelo residencial e 12 para o modelo comercial. O número de nodos das camadas ocultas foi definido de forma empírica, utilizando como referência a medida MAPE para analisar o ajuste da rede aos dados.

Utilizou-se o algoritmo de treinamento supervisionado back-propagation resiliente, uma das adaptações possíveis do algoritmo back-propagation que foram desenvolvidas para acelerar o tempo de treinamento e melhorar seu desempenho na classificação de padrões (Braga, 1998). A função de ativação foi a tangente hiperbólica, que possui características necessárias para a utilização desse algoritmo, que se baseia no método do gradiente descendente (contínua e diferenciável).




Figura 3 – Estruturas das redes MLP

3.4 - Comparação dos Resultados

A avaliação de desempenho das previsões para comparação dos métodos foi realizada por meio das medidas MAPE (erro percentual absoluto médio) e RMSE (raiz do erro quadrático médio), que foram calculadas inicialmente para o intervalo de treinamento (dentro da amostra), cujos resultados se encontram na tabela 3.

Tabela 3 – Resultados para ajuste dentro da amostra

Classe	Método	MAPE	RMSE
Residencial	SARIMA	2,82	4.232.334
	MLP	2,08	1.235.843
Comercial	SARIMA	2,72	3.701
	MLP	1,42	1.229

No ajuste dentro da amostra, como descrito na tabela 3, os modelos apresentaram bons ajustes com valores pequenos para o MAPE, sendo que as redes neurais MLP obtiveram melhor desempenho considerando as duas medidas utilizadas. Sendo assim, a utilização de redes neurais para a previsão de séries de consumo de energia das classes estudadas mostrou-se adequada. Como o objetivo era comparar os modelos ARIMA e MLP, foram utilizadas as mesmas variáveis em ambos, mas em trabalhos futuros pode-se buscar melhorar a performance das redes neurais com a inclusão de outras variáveis como o valor da tarifa de energia, o calendário de faturamento, volume de vendas e variáveis meteorológicas.

3.4.1 - Pesos das combinações das previsões

Após o processo de definição dos modelos ARIMA e RNA, foram calculados os pesos para realizar dois tipos de combinação utilizando as previsões encontradas. Para Teixeira (2005), “na prática, formar combinações de duas ou mais previsões é preferível a aproximar um valor real por uma única previsão, pois o desempenho pode ser melhor que as previsões individuais”. Assim, foram utilizados os seguintes métodos de combinação de previsões: método da média simples (pesos iguais a 0,5 para os dois modelos) e o método da variância mínima simplificado, pelo qual os pesos são inversamente proporcionais à variância dos erros de predição dos modelos no período de treinamento (os resultados para os pesos estão na tabela 4). O melhor desempenho das redes neurais MLP refletiu-se nos valores dos pesos obtidos pois estas apresentaram menor variância.

Tabela 4 – Resultados para os pesos do método de combinação da variância mínima

Classe	Peso SARIMA	Peso MLP
Residencial	0,36	0,64
Comercial	0,21	0,79

3.4.2 - Consumo Residencial

Os resultados para as medidas de desempenho das previsões para o período de validação (abril de 2018 a março de 2019) estão listados na tabela 5.

Tabela 5 – Resultados de previsões da classe residencial para 24 meses

Método	MAPE	RMSE
SARIMA	3,70	43.703
MLP	3,21	31.460

Variância Mínima	3,11	33.267
Média Simples	3,22	34.917

Os modelos apresentaram bons resultados na previsão no período de validação com valores de MAPE entre 3,11% e 3,70%, o que é confirmado pela análise dos gráficos das previsões que podem ser vistos na figura 4, onde percebe-se um bom ajuste dos preditos aos dados reais. O melhor resultado foi obtido pela combinação através do método da variância mínima mas com resultado bem próximo ao da rede MLP. Esta última superou todas os outros quando considerado o RMSE. Estes resultados corroboram a adequação da utilização de redes neurais para a previsão do consumo residencial, bem como da combinação utilizando a variância para encontrar os pesos.

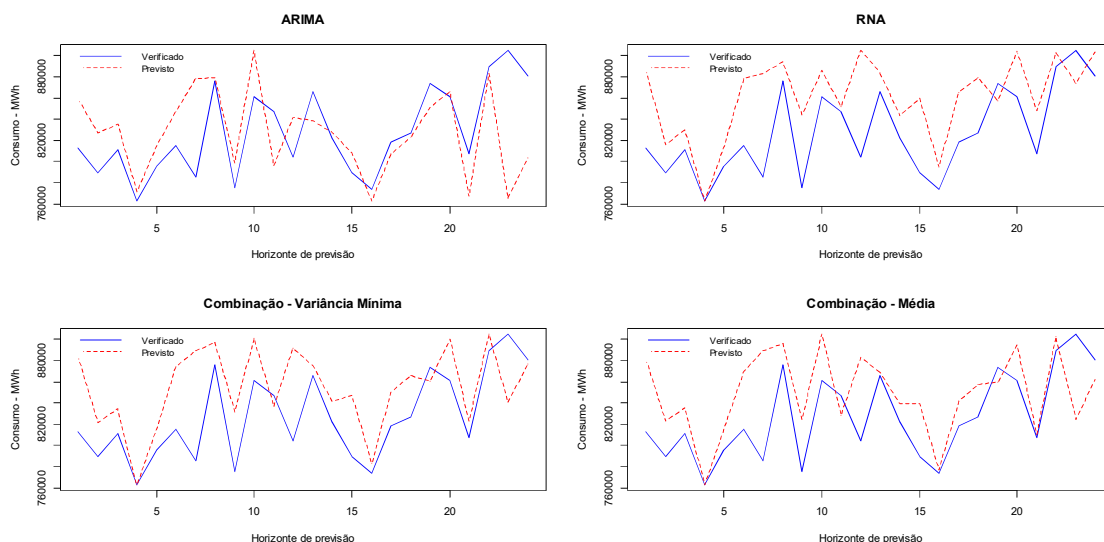


Figura 4 – Previsões ARIMA e RNA e combinações para a classe residencial - 24 passos

3.4.2 Consumo Comercial

Os resultados das medidas de erro referentes às previsões realizadas com horizonte de 24 passos à frente para a classe comercial pode ser vistos na tabela 5.

Tabela 6 – Resultados de previsões da classe comercial para 24 meses

Método	MAPE	RMSE
SARIMA	2,54	23,28
MLP	2,26	22,27
Variância Mínima	2,27	22,12
Média Simples	2,31	22,23

A comparação de cada previsão com os valores reais estão na figura 5. Os modelos apresentaram bons resultados na previsão no período de validação com valores de MAPE entre 2,26% e 2,54% e com desempenho muito próximo. Como na classe residencial, o modelo MLP e a combinação por variância mínima apresentaram os melhores resultados, corroborando a adequação da utilização destes métodos para a previsão também do consumo comercial.

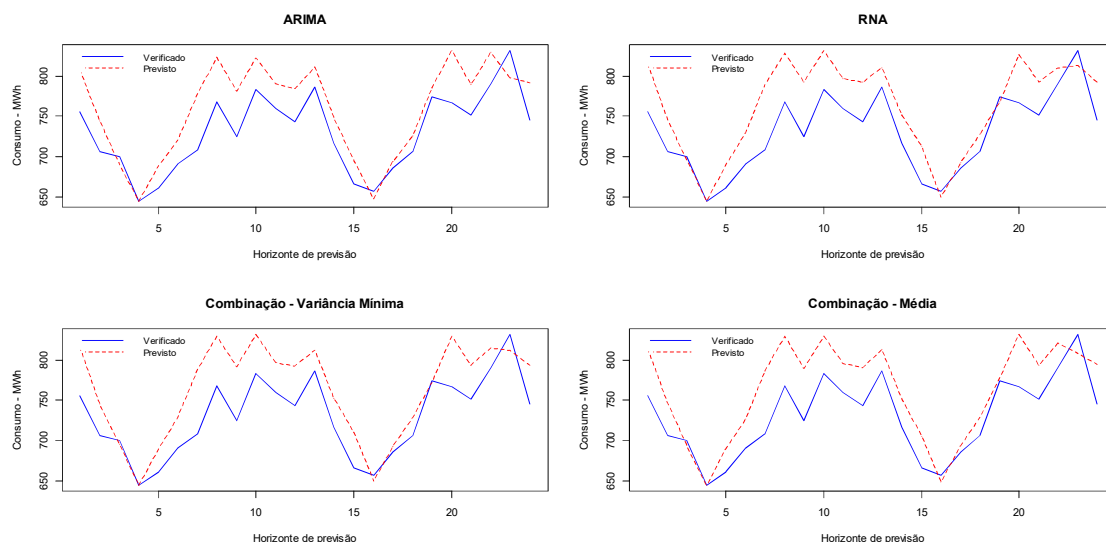


Figura 5 – Previsões ARIMA e RNA e combinações para a classe comercial - 24 passos

4.0 - CONCLUSÃO

Os modelos apresentaram bons resultados, tanto dos ajustes dentro da amostra, quanto da previsão no período de validação, observados na análise dos gráficos e pelos valores do MAPE encontrados, além de não apresentarem resultados discrepantes.

As variáveis exógenas utilizadas mostraram-se adequadas para a previsão destas séries, sendo necessária uma boa previsão de seus valores futuros para o cálculo dos valores previstos. Para estudos futuros, há que se analisar a inclusão do fator climatológico, que é responsável por vários pontos atípicos (como no início de 2019), mas o obstáculo são as previsões destas variáveis no médio e longo prazo. Poderão ser incluídas também outras variáveis como o valor da tarifa de energia, o calendário de faturamento e volume de vendas, dentre outras.

Na comparação entre os modelos SARIMA e RNA, o segundo apresentou melhor desempenho para as séries de consumo das duas classes consideradas, ainda que com resultados próximos. As combinações das previsões pelo método da variância mínima também obteve bons resultados. Conclui-se, portanto, que as redes neurais podem ser utilizadas para melhorar o desempenho das previsões realizadas por métodos estatísticos tradicionais, como o SARIMA, de forma complementar através de combinações ou mesmo em substituição. Além disso, são métodos flexíveis e de fácil atualização.

Para aprofundar esta análise com foco nas combinações e na comparação de métodos estatísticos e de Aprendizado de Máquina, pode-se também desenvolver outros tipos de modelos de previsão como Holt-Winters, modelos lineares dinâmicos, médias móveis, X-12-ARIMA, árvores de decisão, dentre outros.

5.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) BRAGA, A. P., CARVALHO, A. P. L. F., LUDEMIR, T. B. Fundamentos de redes neurais artificiais. Rio de Janeiro: DCC/I, COPPE/Sistemas, NCE/UFRJ, 1998. 246p.
- (2) GUJARATI, D. N., PORTER, D. C. Econometria básica. 5. ed. Porto Alegre: AMGH, 2011. 924p.

(3) MORETTIN, P. A.; TOLOI, C. M. C. Análise de séries temporais. 2. ed. São Paulo: Edgar Blucher Ltda., 2006. 531 p.

(4) HAYKIN, S. Redes Neurais: Princípios e Prática. 2.ed. Porto Alegre, Bookman, 2001.

(5) TEIXEIRA, D. F. Combinação de Previsões para série de Telefonia Celular. 2005. 109f. Dissertação (Mestrado em Estatística) – Universidade Federal de Minas Gerais. Belo Horizonte, 2005.

6.0 - DADOS BIOGRÁFICOS



Danilo de Deus Mota é mestre em Educação Tecnológica pelo Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG (2015) e bacharel em Matemática Computacional (2006) e em Estatística (2019) pela Universidade Federal de Minas Gerais - UFMG. Licenciou-se no ano de 2011 em Matemática pelo CEFET/MG através do Programa Especial de Formação de Docentes. Foi professor concursado de Matemática na Escola Municipal Osório Aleixo da Silva (Betim-MG) nos anos de 2012 e 2013. Desde 2013 trabalha na Gerência de Planejamento do Mercado na CEMIG, sendo atualmente Analista de Planejamento do Mercado de Energia atuando nas áreas de Inteligência de Mercado e Big Data aplicados ao setor de energia. Desenvolve atividades como: análise dos dados de mercado, no que se refere à estrutura, conteúdo e regulação setorial; obtenção e consolidação de informações para relatórios corporativos; elaboração de projeções de mercado para definição de estratégias empresariais, estimativas econômico-financeiras, compra e venda de energia e planejamento do sistema elétrico.

Thiago Rezende dos Santos é Doutor em Estatística pela UFMG, onde defendeu a tese intitulada Inferência, Previsão e Suavização em Modelos Estruturais Gaussianos e Não Gaussianos. Foi professor dos departamentos de matemática e estatística da Universidade Federal de Ouro Preto e, atualmente, é professor do departamento de estatística Universidade Federal de Minas Gerais. Ele publicou artigos em revistas da área de Estatística, como the International Statistical Review, Journal of Time Series Analysis, IEEE Transactions on Reliability, Brazilian Journal of Probability and Statistics, Journal of Applied Statistics e etc. Proferiu um minicurso sobre modelos de espaço de estados abordagens clássica e Bayesiana durante XIII ESTE (Escola de Séries Temporais e Econometria). Foi conferencista convidado para a XV ESTE que aconteceu em Teresópolis, RJ. Trabalha com vários colaboradores, principalmente, em análise de series temporais, econometria, modelos lineares/data mining aplicados a dados de saúde e educação e confiabilidade.