



Análise da Aderência do Modelo de Redes Neurais Artificiais para Previsão de Demanda de Potência Ativa Utilizando a Função de Autocorrelação

Sofia Moreira de Andrade Lopes¹

Departamento de Engenharia Elétrica e de Computação

Escola de Engenharia de São Carlos, USP, São Carlos, SP

Rogério Andrade Flauzino²

Departamento de Engenharia Elétrica e de Computação

Escola de Engenharia de São Carlos, USP, São Carlos, SP

Resumo. A previsão de demanda de potência ativa têm grande valor para a operação de diversos ramos do setor de energia, sendo que diversos métodos já foram aplicados para a previsão desta série temporal. Todavia, o modelo de previsão utilizado nem sempre é capaz de extrair de maneira ótima as características determinísticas da série. Para garantir um bom desempenho, a série deve ser decomposta e, posteriormente, a aderência do modelo deve ser avaliada para garantir resultados precisos e com baixo risco associado. Este trabalho utilizou a função de autocorrelação para avaliar a aderência do modelo de redes neurais na previsão da série de demanda, comparando a previsão para uma série pura e outra decomposta. Os resultados indicam a necessidade da decomposição para melhorar a aderência do modelo ao sistema e validam a utilização da função de autocorrelação para esta análise.

Palavras-chave. Redes Neurais Artificiais, Previsão de Demanda, Função de Autocorrelação, Séries Temporais

1 Introdução

A previsão de demanda de potência ativa possui grande importância prática em situações técnicas, como no planejamento da operação do sistema de distribuição, em situações de corte e realocação de carga, ou no planejamento da expansão física do sistema, como a construção de novas centrais geradoras, sendo uma útil ferramenta para diversos ramos do setor energético. Além disso, os dados de previsão influenciam o mercado de energia, afetando os níveis dos preços e as transações de compra e venda. Por estes motivos, é vital que a previsão de demanda obtenha resultados com o bons níveis de precisão, que indicam um menor risco associado à sua utilização.

¹sofia.moreira.lopes@usp.br

²raflauzino@usp.br

Tendo em vista a importância do tema, diversos estudos abordaram a previsão de demanda de potência ativa utilizando métodos variados de previsão de séries temporais. Dentre os métodos clássicos podem ser citados os modelos ARIMA [6], os métodos de regressão [5], entre outros. Além disso, muitos estudos optaram pelos métodos de sistemas inteligentes, como as redes neurais artificiais (RNA) [2] e as máquinas de vetores de suporte (SVM) [4]. Dentre os estudos presentes na literatura, as RNA se sobressaem, normalmente apresentando os melhores resultados de previsão. Contudo, muitas vezes o problema de previsão pode ser simplesmente solucionado por meio de métodos lineares de estimação, sem a necessidade do uso de métodos complexos como as RNAs [1]. Esta situação é verificada quando se decompõe uma série temporal, e a componente residual da série apresenta comportamento puramente estocástico, não podendo ser prevista. Neste caso, basta utilizar um modelo linear simples para realizar a previsão da parte determinística da série, que seria a componente média [1].

Desta forma, infere-se que a escolha do modelo de previsão mais apropriado deve priorizar a simplicidade e a acurácia. Por este motivo, o presente trabalho visa analisar a aderência do modelo de RNAs no problema de previsão de demanda de potência ativa, utilizando a função de autocorrelação (FAC) como método de avaliação. Será feita uma análise comparativa da previsão utilizando uma série temporal sem tratamento prévio e uma série temporal residual, de forma a abordar o problema tratado em [1] sobre a necessidade de decomposição da série previamente à previsão. O diferencial do presente trabalho está no uso da FAC para avaliar a aderência dos modelos aplicados para a previsão. Assim, pretende-se facilitar futuras pesquisas da área, principalmente as que utilizam técnicas de sistemas inteligentes, como as RNA e os sistemas de inferência fuzzy.

O restante do artigo é dividido como se segue: A seção 2 detalha os métodos implementados para a obtenção dos resultados; A seção 3 expõe de forma clara os resultados encontrados e as análises e discussões sobre eles; Por último, são apresentadas as considerações finais sobre o trabalho e ideias para estudos futuros na seção 4.

2 Método de redes neurais artificiais para a previsão de séries temporais

2.1 Decomposição da série temporal

A série de demanda de potência ativa utilizada foi obtida a partir de um alimentador de uma subestação localizada no estado de São Paulo, Brasil. A série é composta por 17520 medições, obtidas entre o período de 01 de Agosto de 2017 e 31 de Julho de 2018, sendo que para cada dia, foram efetuadas 48 medições, com intervalos de tempo iguais de 30 minutos.

Para o tratamento da série, primeiramente normalizou-se seus valores entre os limites de -1 e 1. Posteriormente, seguindo a metodologia proposta por [1], a série original foi dividida em duas: uma série média e uma série residual. Para a construção da primeira, utilizou-se o conceito de *dia típico*. Considerando a influência de fatores externos, como a ocorrência de feriados, a estação climática, entre outros, obteve-se 28 modelos de dias

típicos, como *Terça-feira de verão* e *Domingo de inverno*, por exemplo. Em seguida, obteve-se a série residual de demanda, pela extração da série média a partir da série original. A série residual encontrada apresentou características determinísticas, verificadas no teste de hipótese proposto por [1], desta forma, a previsão desta série é justificada.

2.2 Função de Autocorrelação

A autocorrelação mensura o nível de relação linear entre os elementos de uma série temporal, considerando o atraso temporal (*lag*) entre estes elementos. Desta forma, pode-se calcular o coeficiente de autocorrelação para cada valor de *lag* como, por exemplo, para o *lag* 1, encontra-se o coeficiente r_1 que mede a relação entre o instante y_t e y_{t-1} . De forma genérica, para medir a relação para um *lag* k , utiliza-se a expressão dada na Eq. (1).

$$r_k = \frac{\sum_{t=k+1}^N (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^N (y_t - \bar{y})^2} \quad (1)$$

Sendo que N é o número total de elementos da série temporal e \bar{y} é o valor médio dos elementos da série. A função de autocorrelação (FAC) é formada pelos coeficientes de autocorrelação calculados para consecutivos valores de *lags*. A partir da análise dos coeficientes da FAC pode-se obter informações significativas sobre o comportamento da série temporal, como a presença de componentes sazonais, cíclicas e tendências.

Neste trabalho, deseja-se utilizar a FAC para análise da série composta pelos erros de previsão. Este estudo se baseou na hipótese de que um método de previsão com boa aderência, deve extrair de forma ótima os aspectos determinísticos da série e, por isso, a série de erros de previsão deve se comportar simplesmente como um ruído, ou seja, como uma parcela totalmente aleatória que não pode ser prevista. Desta forma, espera-se que a análise da FAC para a série de erros de previsão tenha o comportamento similar ao encontrado para a análise da FAC para uma série de ruído branco [3].

Para uma série de ruído branco os coeficientes de autocorrelação tendem à zero, ou seja, os elementos não apresentam relações entre si. A característica mais marcante da análise da FAC de um ruído branco é que pelo menos 95% dos coeficientes de autocorrelação estarão dentro dos limites de confiança, que podem ser calculados por $\alpha = \pm \frac{2}{\sqrt{N}}$, representando que a série se trata de um ruído e é predominantemente estocástica [3].

2.3 Redes neurais artificiais para previsão de séries temporais

Neste trabalho, o método para previsão de curtíssimo prazo utilizado foi a rede neural perceptron multicamadas (PMC) com configuração de *time delay neural network* (TDNN). Nesta configuração, apresentada na Figura 1, a rede PMC atua como uma RNA dinâmica, devido ao atraso temporal inserido em sua camada de entrada. Assim, ao realizar a previsão das amostras futuras, com base nas np amostras passadas, a rede considera a dependência temporal existente entre elas.

Para a seleção da topologia da TDNN, utilizou-se o método de validação cruzada, no qual topologias distintas foram submetidas aos processos de treinamento e teste e a com




Figura 1: Estrutura de RNA utilizada

melhor desempenho global foi escolhida como vencedora. Para a execução destes processos utilizou-se, respectivamente, 80% e 20% das amostras do conjunto original. Os parâmetros considerados na construção das topologias foram: número de camadas escondidas (entre 1 e 2); número de neurônios permitidos em cada camada (entre 1 e 10) ; valor de np , ou seja, número de amostras passadas consideradas para previsão (entre 1 e 48).

O indicador utilizado para avaliar o desempenho das redes, tanto na etapa de treinamento, quanto na de teste, foi o do erro médio absoluto (*mean absolute error*, MAE). Além deste indicador, considerando a proposta da pesquisa, obteve-se a série de erros de previsão, gerada a partir da diferença entre os valores esperados para demanda e os valores previstos pela rede (sempre analisados para as fases de teste). Após a construção desta série, aplicou-se a FAC para avaliar a aderência do modelo construído.

3 Resultados e discussões

Com base nos métodos da Seção 2, realizou-se a previsão da série temporal, por meio de duas RNAs, uma para a previsão da série original e outra pra a previsão da série residual. A Figura 2 apresenta a comparação entre os valores previstos pelas melhores topologias das redes e os valores esperados para a série original e para a série residual.

Para a rede da série original, a melhor topologia foi a com 6 neurônios na primeira camada escondida e 3 na segunda, considerando um $np = 48$. Para esta topologia, o valor do erro observado na fase de teste foi de $MAE = 0,0262$. Para a rede da série residual, o menor erro encontrado foi o de $MAE = 0,0391$, para a topologia com 7 e 11 neurônios na primeira e segunda camadas escondidas, respectivamente, e $np = 8$.

Após a obtenção dos resultados acima, foi possível construir as séries de erro de previsão para as duas redes e verificar a aderência do modelo, avaliando a FAC para ambas as séries de erro. Tendo em vista que o número de elementos da série de erros é igual para as duas redes, pode-se calcular os valores dos limites de confiança da FAC ($\pm\alpha$) de forma que:

$$\alpha = \pm \frac{2}{\sqrt{N}} \Rightarrow \alpha = \pm \frac{2}{\sqrt{3437}} \Rightarrow \alpha = \pm 0.0341$$

A aderência dos modelos foi analisada em relação à estes limites, avaliando a porcentagem de coeficientes (β) da FAC que os excedeu. Mesmo para a melhor topologia, a série de erros obtida a partir da previsão da rede da série original apresenta um valor de $\beta = 7,3\%$,




Figura 2: Previsão de demanda utilizando a série temporal original. Legenda: Linha pontilhada (- -) representa os valores previstos; Linha cheia (-) representa os valores esperados.

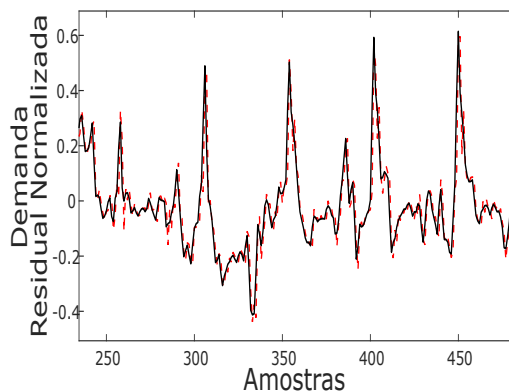


Figura 3: Previsão de demanda utilizando a série temporal residual. Legenda: Linha pontilhada (- -) representa os valores previstos; Linha cheia (-) representa os valores esperados.

o que indica que a série de erros para esta rede não se comporta como um ruído. A análise dos coeficientes da FAC para esta série indicam a presença de tendência (coeficientes da FAC decaem com o aumento do lag) e sazonalidade (presença de picos periódicos), o que não é desejável e demonstra que o modelo deixou de prever tais aspectos da série original. Para análise da FAC da série de erros obtida a partir da rede da série residual, observa-se que 4,6% dos pontos estão fora dos limites de confiança. Desta forma, pode-se inferir que a série de erros apresenta um comportamento semelhante ao de um ruído branco, o que é desejável e indica que o modelo apresentou um bom nível de aderência ao sistema, conseguindo prever a maior parte de suas características determinísticas.

Além das considerações feitas anteriormente, é interessante observar na Figura 4 o comportamento das redes em função do número de dados de entrada (np). Avaliando o gráfico da evolução do erro na Figura 4, infere-se que, para este indicador, a rede de

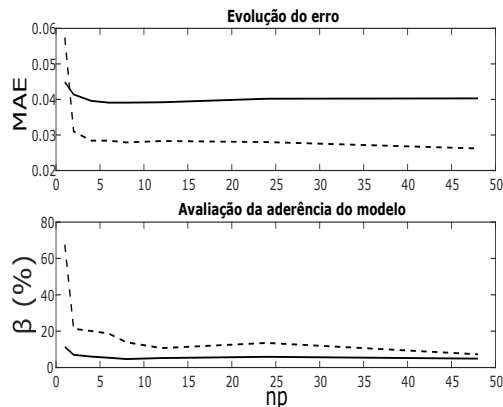


Figura 4: Evolução do erro MAE para as redes TDNN e evolução do nível de aderência dos modelos em relação ao aumento de np (Linha pontilhada (- -) evolução para a rede da série original; linha cheia (-) evolução para a rede da série residual).

previsão utilizando a série original atingiu melhores resultados, ou seja, níveis inferiores de erro. Todavia, com base nos resultados anteriores, observa-se que ambas as redes obtêm erros aceitáveis para a previsão. Outro aspecto que merece destaque, é o de que, ao contrário do esperado, o aumento no valor de np não resulta em melhora significativa no nível do erro, de forma que observa-se um comportamento de saturação a partir de $np = 6$. Como busca-se sempre encontrar o modelo mais simples que melhor se adapte ao problema, indica-se o uso da rede com o menor número de entradas possíveis.

Em contraste ao encontrado na análise do erro, a rede de previsão para a série residual apresenta resultados melhores na análise de aderência do modelo. Mesmo para valores baixos de np , a FAC da série de erros obtida para o modelo da série residual já se aproxima do comportamento da FAC da série de ruído branco, apresentando $\beta = 11,4\%$ para $np = 1$, enquanto a série de erros para o modelo da série original apresenta $\beta = 67,6\%$. Para todos os valores de np avaliados, a rede da série original não apresentou resultados cuja análise da FAC da série de erros retorna-se um β inferior à 5% , ou seja, em nenhum dos casos o modelo da rede conseguiu representar todas as características determinísticas do sistema.

O resumo dos resultados é apresentado na Tabela 3. Considerando a tabela e as análises feitas anteriormente, recomenda-se o uso do modelo que utiliza a série temporal residual, pois este modelo é mais simples e se adaptou melhor ao problema proposto.

Tabela 1: Resumo dos resultados

RNA	Melhor Topologia	np	MAE	β
Série original	[6, 3]	48	0,0262	7,3%
Série residual	[7, 11]	8	0,0391	4,6%

4 Conclusões

Este estudo propôs a análise da aderência de dois modelos de redes neurais do tipo TDNN na previsão de duas séries de demanda de potência ativa, uma decomposta e a outra com dados originais. Ambos os modelos de previsão apresentaram baixos níveis de erro, sendo que o modelo para a série original apresentou os menores valores de MAE. Todavia, o modelo para a série decomposta (residual) era mais simples (com menos entradas) e apresentou um grau maior de aderência ao problema de previsão, sendo que a série composta pelos erros de previsão deste modelo se comportou como uma série de ruídos.

Desta forma, observa-se a importância de realizar a decomposição da série antes da previsão e conclui-se que a análise do erro para seleção do modelo deve ser acompanhada por uma análise da aderência. Pois, mesmo a rede para a série original tendo apresentado melhores valores de erro, sua previsão deixou de captar certas características determinísticas da série, apresentando um nível de aprendizado inferior.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro à pesquisa por meio de uma bolsa de mestrado e ao Departamento de Engenharia Elétrica e de Computação da Universidade de São Paulo.

Referências

- [1] L. Aguirre, D. D. Rodrigues, S. T. Lima and C. Martinez, Dynamical prediction and pattern mapping in short-term load forecasting. *International Journal of Electrical Power and Energy Systems*, vol. 30, (2008), DOI: 10.1016/j.ijepes.2007.11.001.
- [2] Y. Hsu, T. Tung, H. Yeh and C. Lu, Two-Stage Artificial Neural Network Model for Short-Term Load Forecasting, *IFAC-PapersOnLine*, vol. 28, (2018), DOI: 10.1016/j.ifacol.2018.11.783.
- [3] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 2nd edition, Australia, (2018).
- [4] S. Maldonado, G. González and S. Crone, Automatic Time Series Analysis for Electric Load Forecasting via Support Vector Regression, *Applied Soft Computing Journal*, vol. 83, (2019), DOI: 10.1016/j.asoc.2019.105616.
- [5] I. A. Samuel, A. Emmanuel, I. A. Odigwe and F. C. Felly-Njoku, A Comparative Study of Regression Analysis and Artificial Neural Network Methods for Medium-Term Load Forecasting, *Indian Journal of Science and Technology*, vol. 10, (2017), DOI: 10.17485/ijst/2017/v10i10/86243.
- [6] S. Singh and R. Singh, ARIMA Based Short Term Load Forecasting for Punjab Region, *International Journal of Science and Research (IJSR)*, vol. 4, (2013).