

Análise Comparativa de Modelos de Previsão de Geração de Energia Eólica Baseados em Machine Learning

Comparative Analysis of Machine Learning Based Wind Power Forecasting Models

Ana Carolyne G. França
Bacharelado em Sistemas de
Informação,
Instituto Federal de Educação,
Ciência e Tecnologia do
Sudeste de Minas Gerais
Campus Juiz de Fora – MG,
Brasil
anacarolyne.franca@gmail.com

Silvana T. Faceroli
Departamento de Educação e
Tecnologia
Instituto Federal de Educação,
Ciência e Tecnologia do
Sudeste de Minas Gerais
Campus Juiz de Fora – MG,
Brasil
silvana.faceroli@ifsudestemg.edu.br

Paulo Sergio C.
Nascimento
Departamento de Gerência de
Metodologias e Modelos
Energéticos
Operador Nacional do
Sistema Elétrico
Rio de Janeiro, Brasil
pnascimento@ons.org.br

Alberto Sergio Kligerman
Departamento de Gerência de
Metodologias e Modelos
Energéticos
Operador Nacional do
Sistema Elétrico
Rio de Janeiro, Brasil
alberto@ons.org.br

ABSTRACT

Com a crescente expansão da capacidade instalada dos parques eólicos, tornou-se necessário investir na qualidade da previsão de geração de energia eólica para agendamento diário e em tempo real, a fim de reduzir a necessidade de reserva de energia e permitir o melhor uso dos recursos. Nesse sentido, este artigo propõe desenvolver uma análise comparativa entre modelos de previsão de geração de energia de fonte eólica utilizando métodos de redes neurais MLP e NARX e métodos de séries temporais Arima e Arimax, utilizando um conjunto de dados com as informações históricas dos parques eólicos. Verificou-se que as redes MLP e NARX apresentaram melhores resultados, quando comparados os erros das previsões. A partir desses resultados, podemos concluir que as técnicas de Machine Learning testadas nesse trabalho são promissoras para a utilização em previsão de geração de energia eólica.

ABSTRACT

With the increasing expansion of installed capacity of wind

farms, it has become necessary to invest in the quality of wind power forecasting for daily and real-time scheduling, to reduce the need for power reserve and allow better use of resources. In this sense, this paper proposes to develop a comparative analysis between wind power generation forecasting models using MLP and NARX neural network methods and Arima and Arimax time series methods, using a database with the historical information of wind farms. It was found that MLP and NARX networks presented better results when compared the forecast errors. From these results, we can conclude that the Machine Learning techniques tested in this work are promising for use for wind power forecasting.

CCS Concepts

•Theory of computation → Machine learning theory;

Keywords

Machine learning; parques eólicos; rede MLP; rede NARX
Machine learning; wind farms; MLP network; NARX network

1. INTRODUÇÃO

Atualmente, a geração da energia eólica no mundo tem um posicionamento privilegiado dentro das matrizes energéticas, principalmente por se tratar de uma fonte de energia renovável e amplamente disponível, detalhes no atlas da Agência Nacional de Energia Elétrica [3]. Esse tipo de geração de energia possui uma clara vantagem sobre as outras fontes de geração de energia elétrica por ser uma energia

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

limpa e que não causa poluição do ar, da água ou da terra. No entanto, houve inicialmente forte restrição quanto ao seu emprego, devido às dificuldades em se prever suas variações, com a consequente incerteza quanto ao seu planejamento e uso mais eficiente.

Não obstante, no Brasil, o índice de crescimento de energia eólica atualmente supera o de outras fontes de energia, colocando o país entre os 10 maiores produtores do mundo dessa fonte [3]. O país apresenta um grande potencial eólico, sobretudo nas regiões sudeste, nordeste e sul do país e é identificado como tendo um dos maiores potenciais de geração de energia eólica no mundo.

A grande dificuldade dessa fonte de energia é a variabilidade da geração em curtos períodos, aliada à complexidade de prever a condição futura da geração eólica, devido a dependência de variáveis climatológicas de caráter estocástico. Tal situação causa grandes dificuldades para a operação do sistema energético do país, uma vez que a qualidade da previsão afeta diretamente o despacho hidrotérmico, a mitigação de problemas elétricos, a limitação de escoamento de energia entre regiões, entre outros.

Desta forma, torna-se necessário o aperfeiçoamento de técnicas de previsão de geração elétrica de fonte eólica e é de suma importância dispor de bons modelos de previsão desta geração, reduzindo, assim, o custo de operação do Sistema Interligado Nacional (SIN).

1.1 Trabalhos relacionados

Recentemente, técnicas de aprendizagem de máquina têm sido utilizadas para manipular grandes quantidades de dados. Existem algoritmos capazes de extrair comportamentos típicos em conjunto de dados muito grandes e que são muito úteis para previsão de séries temporais [17]. Neste contexto, a utilização de tais técnicas em previsão de geração de energia eólica tem se mostrado bastante promissora, com diversas pesquisas na área.

Em Coelho [7], foi testada uma técnica de aprendizagem de máquina através da aplicação da rede *Long Short Term Memory* (LSTM) na previsão de geração de energia eólica. Esta rede possui a competência de separar acontecimentos recentes e distantes e atribuir valores diferentes para essas ocorrências, além de desconsiderar memórias que possam ser desprezíveis para estimar a próxima saída. Constatou-se uma boa precisão e estabilidade nos resultados atingidos para a geração de energia de fonte eólica.

Em Santos [9], utilizou-se as redes *Radial Basis Function Network* (RBFN) e *Multi-Layer Perceptron* (MLP) para prever futuras potências geradas por um parque eólico a partir de suas potências anteriores. De acordo com os dados apresentados, o método de redes RBFN teve o menor Erro Médio Absoluto.

No trabalho desenvolvido em Hiruma [13], foi implementada a técnica de Redes Neurais Artificiais (RNA) para as previsões de velocidade do vento e de geração elétrica na Usina Eólico-Elétrica de Palmas (PR), que cumpriu plenamente seus objetivos essenciais e realizou previsões satisfatórias para o horizonte de curtíssimo prazo, assim como foi verificado no trabalho desenvolvido em Souza [8], que aplicou, de outro modo, a modelagem Box & Jenkins.

Em Alencar [2], foram usados cinco modelos de previsão: *Seasonal Autoregressive Integrated Moving Average* (SARIMA), SARIMA + Wavelet, Redes Neurais, SARIMA + Redes Neurais e um Modelo Híbrido Proposto (SARIMA +

Redes Neurais 1 + Redes Neurais 2). Dos modelos utilizados, o modelo híbrido proposto foi o que apresentou os melhores resultados com os menores erros na previsão.

1.2 Objetivos

Este trabalho tem como objetivo geral verificar o comportamento de algoritmos de redes neurais artificiais, em especial a rede *Nonlinear autoregressive exogenous* (NARX), para a previsão de geração de energia eólica. Para tanto, será desenvolvida uma análise comparativa entre modelos de previsão de geração de energia de fonte eólica do Sistema Interligado Nacional (SIN) utilizando Redes Neurais *Multi-layer Perceptron* (MLP) e *Nonlinear autoregressive exogenous* (NARX) e os métodos estatísticos *Autoregressive Integrated Moving Average* (ARIMA) e *Autoregressive Integrated Moving Average with Exogenous Variable* (ARIMAX).

Como objetivos específicos, podemos destacar:

- Oferecer mais suporte ao operador em relação aos efeitos da geração eólica no SIN;
- Analisar o comportamento de redes neurais com realimentação externa para sistemas de previsão de geração de energia eólica;
- Comparar os métodos tradicionais com métodos de machine learning para o caso proposto.

2. MATÉRIAS E MÉTODOS

2.1 Conjunto de dados

Os dados disponíveis para este trabalho são oriundos de uma base de dados real, de uso do Operador Nacional do Sistema Elétrico (ONS). Os dados de geração verificada são obtidos da base histórica de tempo real do Sistema de Supervisão e Controle do ONS (discretização de 4 em 4 segundos) e do Sistema de Medição e Faturamento da Câmara de Comercialização de Energia Elétrica (CCEE) (discretização em intervalos 5 minutos e 1 hora). Os dados observados/medidos da velocidade do vento serão tratados como vento verificado, esses dados são obtidos do Sistema de Supervisão e Controle do ONS (discretização de 4 em 4 segundos) e do Sistema Acompanhamento das Medições Anemométricas da Empresa de Pesquisa Energética (EPE) (discretização em intervalos 10 minutos).

Para compor os dados históricos relativos às séries temporais de velocidade do vento e de geração de fonte eólica, armazenam-se os dados relativos à informação de velocidade do vento verificada e prevista, bem como os dados de geração eólica verificada provenientes das diversas fontes de informação. Como a discretização temporal é diferente, dependendo da origem, todos os dados históricos foram transformados para discretização de 30 minutos, utilizando médias dos intervalos quando a discretização original é menor que 30 minutos e através de interpolação linear quando a discretização original é maior que 30 minutos.

Os dados de geração verificada, obtidos da base histórica de tempo real do ONS, possuem indicadores de qualidade das medidas coletadas e, adicionalmente, valores estimados advindos de estimadores de estado. Assim sendo, esses dados apresentam boa qualidade. Neste contexto, o processo de tratamento causa menor impacto nos dados de geração verificada. Entretanto, em alguns momentos, os estimadores e a própria medida apresentam-se em falha.

Os dados de vento verificado obtidos do sistema de supervisão e controle do ONS possuem, também, indicadores de qualidade das medições. No entanto, por não ser uma medida elétrica, não existem estimadores capazes de reproduzir os valores nos momentos de erros na coleta dos dados. Consequentemente, nesta situação, a aplicação do tratamento é bem mais atuante, uma vez que existem muitos dados comprometidos.

O ONS criou um processo que realiza a identificação dos dados de geração considerados espúrios [16]. Tal processo pode ser resumido nas seguintes etapas:

- Correlacionar dados do ONS com dados da CCEE de 1h;
- Eliminar resultados ruins do Estimador de Estados do ONS;
- Eliminar dados onde: $Ger < 0MW$ ou $Ger > 1.1 \cdot P_{inst}MW$;
- Eliminar dados congelados (ao longo dos dias e das horas);
- Eliminar dados dos dias com menos de 2,5 horas válidas.

O processo de seleção dos dados válidos de vento verificado pode ser resumido da seguinte forma:

- Correlacionar os dados de vento verificado do PI com o vento verificado da EPE e com a geração da CCEE1h;
- Eliminar dados onde: $Ven < 0$ m/s ou $Ven > 30$ m/s;
- Eliminar dados congelados (ao longo dos dias e das horas);
- Eliminar dados dos dias com menos de 2,5 horas válidos.

Maiores detalhes sobre o algoritmo de identificação de dados espúrios podem ser encontrados na Nota Técnica do Operador Nacional do Sistema Elétrico [ONS 2018].

Uma vez que há redundância de informações de geração verificada, do ONS e da CCEE, e de vento verificado, do ONS e da EPE, é possível montar uma série histórica de geração verificada em intervalos de 30 minutos com os melhores dados possíveis. Ainda assim, nem sempre é possível obter os dados medidos para todos intervalos de tempo a partir destas fontes. Para tanto, foram criados alguns processos de reconstrução das informações de geração verificada. Maiores detalhes em [ONS 2018].

As séries de vento previsto, bem como as demais variáveis climatológicas utilizadas, são oriundas do modelo *Global Forecast System* (GFS), do *National Oceanic and Atmospheric Administration* (NOAA), com resolução espacial de 25km e temporal de 1h, estendendo a previsão para o dia corrente e vários dias à frente [15].

Os arquivos oriundos desse modelo numérico são recebidos por quadrícula. Sendo assim é necessário associar cada usina à sua respectiva quadrícula. Há um algoritmo que gera arquivos associando cada usina à sua correspondente quadrícula em relação aos arquivos de vento previsto. A Figura 1 ilustra as quadrículas para o Nordeste e o Sul do Brasil, respectivamente, do modelo GFS. Nestas figuras são

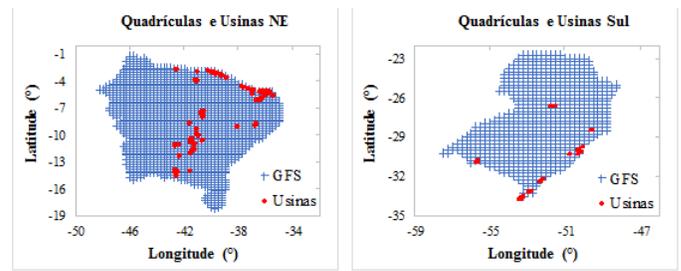


Figure 1: Quadrículas do modelo GFS para Nordeste e Sul

[16]

marcados pontos em vermelho representando exemplos de usinas eólicas consideradas pelo ONS.

A Tabela 1 descreve um resumo dos dados disponíveis, usados neste trabalho, com os atributos e a descrição de cada informação. São utilizados dados de 7 (sete) usinas, sendo uma usina de cada estado brasileiro com capacidade instalada significativa de usinas eólicas.

Table 1: Descrição do conjunto de dados

| Atributo | Descrição |
|----------------------------------|---|
| Código | Diferencia cada usina para associar a sinfomações |
| Latitude ANEEL | Latitude da usina (°) |
| Longitude ANEEL | Longitude da usina (°) |
| Potência instalada ONS | Potência instalada da usina (MW) |
| Geração verifca ONS | Valor observado pelo ONS da geração de 4s em 4s (MW) |
| Geração verifca CCEE | Valor observado pela CCEE da geração de 5min em 5min (MW) |
| MHG | Melhor histórico de geração observada, criado a partir das diversas fontes de 30min em 30min (MW) |
| Geração verifca CCEE 1h | Valor observado pelo CCEE da geração de 1h em 1h (MW) |
| Vento verifca do ONS | Valor observado pelo ONS da velocidade de 4s em 4s (m/s) |
| Vento verifca do EPE | Valor observado pela EPE da velocidade de 10min em 10min (m/s) |
| MHV | Melhor histórico de vento observado, criado a partir das diversas fontes de 30min em 30min (m/s) |
| Velocidade de vento prevista GFS | Valor previsto pelo NOAA da velocidade de 1h em 1h em (m/s) |
| Direção vento prevista GFS | Valor previsto pelo NOAA da direção de 1h em 1h em (°) |
| Temperatura prevista GFS | Valor previsto pelo NOAA da temperatura de 1h em 1h em (K) |
| Umidade prevista GFS | Valor previsto pelo NOAA da umidade de 1h em 1h em (%) |
| Pressão prevista GFS | Valor previsto pelo NOAA da temperatura de 1h em 1h em (Pa) |
| Modelos | Modelos criados com métodos Arima, Arimax, MLP e NARX |

2.2 Métodos de séries temporais

Os métodos de Box-Jenkins [5] para a previsão se baseiam no ajuste de modelos com valores observados da série temporal, de forma que a diferença entre os valores gerados pelos modelos e os valores observados resulte em séries de resíduos de comportamento aleatório em torno de zero.

As variáveis consideradas podem ser assim definidas:

- Série temporal (g_t): conjunto de observações discretas ordenadas no tempo e que apresentam uma dependência serial;
- Ruído branco (ϵ_t): sequência de variáveis aleatórias independentes, usualmente com distribuição normal de média zero e variância constante.

Esses métodos podem, para facilitar a compreensão, ser separados em modelos complementares:

- Modelo autorregressivo (AR): o nome autorregressivo se deve ao fato de que g_t no instante t é função dos g' s nos instantes anteriores a t . O primeiro somatório da Equação (1) mostra a componente de um modelo AR de ordem (p);
- Modelo médias móveis (MA): neste modelo g_t uma função soma algébrica ponderada dos ϵ_t que se movem no tempo. O segundo somatório da Equação (1) apresenta um modelo de média móvel de ordem (q).

Estes modelos geralmente são utilizados em séries não estacionárias. Para torná-las estacionárias, deve-se transformar a série. Isso é feito, normalmente, diferenciando a série, o que gera um outro parâmetro do modelo (d). A junção destes modelos é denominada Arima - Autorregressivo Integrado de Médias Móveis.

Dado o exposto, o método Arima é denotado por $Arima(p, d, q)$: onde p está relacionado ao número de componentes autorregressivos; d o número de diferenciações necessárias para tornar a série estacionária; e q é a ordem da média móvel.

Os métodos Arimax - Autorregressivo Integrado de Médias Móveis com Variáveis Exógenas possuem os mesmos parâmetros do método Arima, adicionada a consideração de variáveis exógenas, com e o número de variáveis exógenas consideradas no modelo [4]. O método é explicitado na Equação (1).

$$g_t = k + \sum_i^p \Phi_i g_{t-i} + \sum_j^q \theta_j \epsilon_{t-j} + \sum_k^e \beta_k v_k + \epsilon_t \quad (1)$$

Sendo: g_t geração eólica no tempo t ; k é uma constante; Φ_i é o parâmetro da parte autorregressiva; g_{t-i} é a geração defasada por i passos; θ_j é o parâmetro relacionado a médias móveis; ϵ_{t-j} é o erro no tempo t defasado de j passos; β_k coeficiente do termo das variáveis exógenas; v_k representa as variáveis exógenas; $\epsilon_t \sim N(0, \sigma^2)$, erro normal de média 0 e variância constante; \bar{v} o conjunto de variáveis exógenas.

Através da série temporal original é possível obter uma aproximação que explique o processo gerador da série, através das funções de autocorrelação *Autocorrelation Function* (ACF) e autocorrelação parcial *Partial Autocorrelation Function* (PACF), assim definidas: autocorrelação mede o comprimento e a memória de um processo, ou seja, a extensão para o qual o valor tomado no tempo t depende daquele tomado no tempo $t - i$; autocorrelação parcial: correlação entre duas observações seriais eliminando a dependência dos termos intermediários. Tais funções ajudam na escolha da ordem dos modelos através da significância de um determinado lag. Os lags, por sua vez, são definidos como o número de períodos de tempo que separa os dados. Detalhes pode ser encontrado em [5].

Neste trabalho serão utilizadas séries temporais do vento (módulo e direção), temperatura, umidade e pressão.

2.2.1 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) se constituem em uma técnica de aprendizagem de máquina cuja aplicação prática está se tornando cada vez maior. As RNAs estão sendo amplamente aplicadas e apresentando um comportamento satisfatório em diversas áreas de pesquisas tais como: classificação e reconhecimento de padrões, aproximação de funções, processamento de imagens e de séries temporais, otimização, entre outras [6].

As RNAs são mecanismos paralelos distribuídos e compostos por unidades de processamento, chamados de neurônios artificiais, que calculam determinadas funcionalidades matemáticas (normalmente não lineares). Esta forma de computação não-algorítmica é caracterizada através de sistemas que lembram a estrutura do cérebro humano. Os maiores recursos destes métodos estão em sua capacidade de aprender, generalizar ou extrair regras automaticamente de conjuntos de dados complexos [12].

A seguir são apresentados os métodos de redes neurais utilizados neste trabalho.

2.2.2 Rede Perceptron com múltiplas camadas (MLP)

As redes MLP apresentam uma grande importância na classe de Redes Neurais Artificiais. É uma RNA que corresponde a um processador paralelo, constituído de neurônios (unidades de processamento). Os neurônios são dispostos em uma ou mais camadas interligadas por um grande número de conexões.

As conexões estão associadas a pesos que representam o conhecimento. As redes MLP têm sido aplicadas com sucesso para resolver problemas difíceis, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo *back-propagation*. Este algoritmo é baseado na regra de aprendizagem por correção de erro [11].

2.3 Rede MLP baseada no método Auto Regressivo Não Linear com Entradas Exógenas (NARX)

A rede neural NARX é uma rede dinâmica e recorrente com alto desempenho. É considerada mais robusta do que as redes recorrentes convencionais [10] pois, nesta arquitetura, há a realimentação pelo próprio sistema, conforme mostrado na Figura 2.

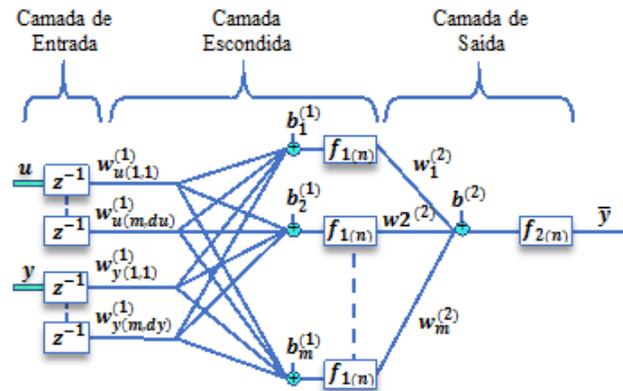


Figure 2: Arquitetura da rede NARX Adaptado de [1]

Como pode-se observar na Figura 2, a arquitetura genérica da rede NARX é formada por uma MLP com realimentação da sua saída y para a entrada, com uma linha de atrasos idêntica à linha de atrasos da entrada. Tal característica aumenta a capacidade de mapeamento não linear da rede.

3. METODOLOGIA PROPOSTA

3.1 Características dos modelos de previsão

Para o desenvolvimento dos modelos utilizados neste trabalho, foram consideradas três métodos:

- Redes neurais MLP: associa as variáveis meteorológicas previstas com a geração verificada de cada usina;
- Redes neurais NARX: associa as variáveis meteorológicas previstas com a geração verificada de cada usina, utilizando também essas variáveis com atraso temporal;
- Séries temporais: método autorregressivo sem e com variável exógena (Arima e Arimax): os modelos fornecem o valor esperado da geração em função do vento previsto e da geração realizada. Esses modelos são utilizados, nesta pesquisa, para comparação com os demais modelos de inteligência artificial apresentados.

3.2 Modelo de séries temporais

Para o desenvolvimento dos modelos utilizando os métodos Arima e Arimax, mostrado nas seções posteriores, foi utilizada a linguagem R na versão 3.5.2.

Quando observada a série temporal na sua ordem natural, tem-se seus valores seguidos pelas horas e pelos dias, respectivamente, conforme ilustração à esquerda da Figura 3. Entretanto, quando é modelada a série temporal desta forma, os modelos apresentam bom desempenho apenas para poucas horas à frente. Todavia, quando estamos fazendo previsões para o dia seguinte e temos históricos observados até o final do dia anterior, estamos realizando previsões para dois dias à frente. Nesta situação, essa modelagem não gera bons resultados.

Como algumas características físicas dos ventos ocorrem em horários específicos, como é o caso dos ventos alísios no Nordeste, uma modelagem da série temporal de cada intervalo em separado acarreta benefícios nos resultados das previsões. A ilustração à direita da Figura 3 mostra essa situação.



Figure 3: Esquema da série temporal para previsões.

3.3 Modelo utilizando Redes MLP

Para desenvolvimento do algoritmo de previsão, foi usado o software Matlab versão 2013. Foram realizados dois exemplos, ajustando 48 redes neurais, uma para cada intervalo do dia. No primeiro exemplo, foi considerada apenas a velocidade do vento previsto como entrada e, no segundo exemplo, foram utilizadas as variáveis meteorológicas velocidade e direção do vento, temperatura, pressão e umidade, previstas pelo modelo GFS. Na saída da rede, foi usada a geração verificada.

Para os testes, os dados foram separados em 70% para treinamento, 20% para validação e 10% para o teste, de acordo com as análises feitas. Além disso, uma outra parte dos dados foi considerada para simulação de previsões futuras. A

Figura 4 ilustra o esquema de uma rede neural do tipo MLP no Matlab.

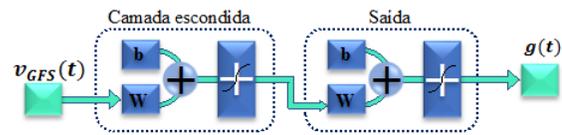


Figure 4: Exemplo de rede MLP no Matlab.

3.4 Modelo utilizando redes NARX

Similarmente ao modelo com MLP, no desenvolvimento do modelo de previsão com a rede NARX foi usado o software Matlab versão 2013, novamente ajustando 48 redes neurais, uma para cada intervalo do dia. Como entrada da rede foram utilizadas as variáveis meteorológicas previstas pelo modelo GFS. Como saída da rede, foi utilizada a geração verificada. Por se tratar de uma rede com realimentação, a entrada também leva em consideração a geração verificada com defasagem no tempo.

Os conjuntos de dados foram separados conforme o modelo com redes MLP, 70% para treinamento, 20% para validação e 10% para o teste. A mesma quantidade de dados foi considerada para simulação de previsões futuras. A Figura 5 ilustra o esquema de uma rede neural do tipo NARX no Matlab.

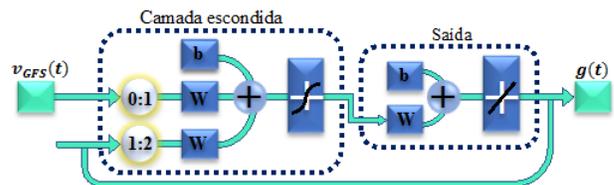


Figure 5: Esquema da NARX no Matlab

Na rede NARX foi considerado 1 (um) atraso temporal nas variáveis de entrada, tanto no exemplo com apenas a velocidade do vento quanto no exemplo com a velocidade e direção do vento, temperatura, umidade e pressão, valores previstos pelo modelo GFS. e dois atrasos na geração verificada para a realimentação da rede. Ou seja, no tempo t deseja-se realizar a previsão $g(t+1)$, para isso utiliza-se $v_{GFS}(t)$, $v_{GFS}(t+1)$, $g(t)$ e $g(t-1)$. Em ambos os modelos, com MLP e com NARX, foram utilizadas: função de treinamento traingdx (*gradient descent with momentum and adaptive learning rate backpropagation*); função de transferência tansig (*tan-sigmoid*); número máximo de 500 (quinhentas) épocas; função de desempenho mse (*mean squared normalized error*); 1 (uma) camada escondida com 12 (doze) neurônios na rede MLP e 20 (vinte) neurônios na rede NARX. Esses parâmetros foram escolhidos após diversas simulações para análise do processo.

4. RESULTADOS E DISCUSSÕES

Esta seção tem por objetivo descrever alguns resultados obtidos pelo uso dos modelos de previsão de geração eólica apresentados. O desempenho do modelo está relacionado à qualidade dos dados verificados, que são essenciais para um

bom ajuste. O fator preponderante, no entanto, é a qualidade de previsão de vento. Por mais bem calibradas que estejam as funções Vento x Potência, previsões meteorológicas distantes da realidade acarretam um resultado ruim na previsão de geração eólica. Primeiramente, os testes foram feitos utilizando apenas o vento previsto como variável de entrada. Em seguida, também foram feitas análises utilizando mais variáveis meteorológicas e o vento verificado como entrada do sistema.

Previamente à criação dos modelos, foi necessária uma investigação das séries temporais. Vale salientar algumas conclusões importantes.

As previsões de vento do modelo GFS apresentam desvios em relação ao vento que de fato ocorre. A Figura 6 apresenta um BoxPlot com os desvios de cada intervalo para uma determinada usina. Observa-se, no entanto, comportamento de desvio típico, ou seja, a previsão de vento apresenta, em quase todos as usinas eólicas, um viés em relação ao vento verificado, o que felizmente propicia um tratamento vantajoso para a previsão de geração de fonte eólica. Cada região apresenta um viés característico para cada intervalo do dia, conforme pode ser visto na Figura 6. Esta é então outra razão para uma modelagem por intervalo, o que acarreta resultados melhores na previsão.

4.1 Métricas utilizadas para avaliação dos desvios de previsão

Várias métricas podem ser utilizadas para avaliação de desempenho dos modelos de previsão, tais como: ME (*mean error*); MAE (*mean absolute error*); MSE (*mean squared error*); MAPE (*mean absolute percentage error*); RMSE (*root mean square error*); NMAPE (*normalized absolute percentage error*). Todas as métricas apresentam características positivas e negativas, conforme descrito em [ONS 2018]. O ME denota se o modelo de previsão que possui algum viés na sua previsão e, devido esse valor ser muito baixo nos modelos apresentados, não serão utilizados neste trabalho. O MAE, o MSE e o RMSE acarretam uma informação de quanto se erra da grandeza prevista, entretanto, como estamos interessados em comparar erros de geração (em MW) de usinas com diferentes capacidades, saber esses valores de forma absoluta não é relevante para as comparações. O uso dessas métricas seriam interessantes para grandezas naturais, como velocidade do vento (m/s) por exemplo. Considerando as análises em questão, optou-se pela utilização da métrica do MAPE, com a normalização pelo valor da grandeza verificada, e da métrica do NMAPE, com a normalização pela potência instalada da usina, mostradas nas equações (2) e (3) respectivamente.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \left(\frac{P_{verif}^i - P_{prev}^i}{P_{verif}^i} \right) \right| \cdot 100 \quad (2)$$

$$NMAPE = \frac{1}{N \cdot P_{inst}^{tot}} \sum_{i=1}^N \left| (P_{verif}^i - P_{prev}^i) \right| \cdot 100 \quad (3)$$

A métrica do MAPE é muito útil na análise de desvios de previsão [ONS 2018]. Entretanto, deve-se ter cuidado com seu uso, uma vez que é um somatório de frações onde o denominador é a geração verificada. O inconveniente disso é que muitas vezes a usina eólica pode apresentar geração muito baixa ou zerada, levando à superestimação do desvio. Por-

tanto, o uso do MAPE para usinas individuais ou pequenos conjuntos não é indicado [ONS 2018].

Exemplificando, no índice MAPE um mesmo desvio absoluto leva a considerações de desvio percentual bem distantes, dependendo do valor verificado. Um desvio de 2 unidades pode ter MAPEs totalmente distintos: Se $\left| \frac{verif_1 - prev_1}{verif_1} \right| = \left| \frac{4-2}{4} \right| = 50\%$ e se $\left| \frac{verif_2 - prev_2}{verif_2} \right| = \left| \frac{2-4}{2} \right| = 100\%$. Porém, para avaliação de desvios de um conjunto agregado maior de usinas, como por exemplo a avaliação de desvios por ponto de conexão, por estado, ou para uma região, seu uso pode ser aceito.

Para o NMAPE, esse inconveniente não ocorre, dado que em ambas situações a referência é a mesma. Em Hodge, et al. [14] podem ser encontradas comparações de previsões de alguns operadores de rede mundiais utilizando essa métrica. No cálculo do NMAPE tomando como referência, hipoteticamente, o valor 4, tem-se o mesmo erro, ou seja, se $\frac{1}{4} |verif_1 - prev_1| = \frac{1}{4} |4 - 2| = 50\%$ ou se $Erro_2 = \frac{1}{4} |verif_2 - prev_2| = \frac{1}{4} |2 - 4| = 50\%$. Como pode ser observado, os índices que apresentam maior concordância são os do NMAPE.

4.2 Previsões com modelo utilizando Arimax e Arima

A seguir serão apresentados os resultados dos modelos de séries temporais dos métodos de Box - Jenkins. Estes modelos servirão como base para comparação com os modelos com redes neurais, propostos neste trabalho, por serem técnicas bastante difundidas na área.

O período histórico considerado para calibração dos modelos estende-se de janeiro/2017 a dezembro/2018. O período para testes de avaliação do desempenho vai de janeiro/2019 a fevereiro/2019. Esses horizontes são válidos para todas as simulações que serão apresentadas adiante.

O gráfico superior da Figura 7 ilustra a curva Vento x Potência para os dados observados de geração e velocidade do vento. Na parte inferior desta figura, é apresentado o gráfico de geração com o vento GFS e a dispersão entre a geração prevista pelo modelo com o Arimax e o vento previsto pelo GFS.

Como pode ser observado na Figura 7, na dispersão em azul, as dispersões dos gráficos inferiores deveriam ter a mesma forma. Em resumo, o formato dessas dispersões deveria seguir uma função logística. No entanto, devido aos erros de previsão, sua forma é relativamente distorcida.

Os métodos da classe Arimax apresentam uma limitação, pois são métodos lineares e, como se nota na Figura 7, há regiões da curva que apresentam características não lineares. Esses métodos geralmente são utilizados para prever séries temporais mensais, porém o interesse neste trabalho é utilizar em dados com discretização semi-horária ou diária. Por serem conhecidos na literatura, oferecem a possibilidade de comparação com os modelos propostos.

A Figura 8 ilustra o erro, a autocorrelação (ACF) e a autocorrelação parcial (PACF) da série do erro entre a geração verificada e a previsão de 48 horas à frente, utilizando o modelo Arimax. Neste caso, como pode ser constatado, não existe nenhum lag com valor da PACF significativo, portanto os resíduos são decorrelatados linearmente no tempo, indicando que todo o comportamento linear da série de erro já foi abstraído com o modelo. É considerada uma previsão sempre para as 10 horas da manhã.

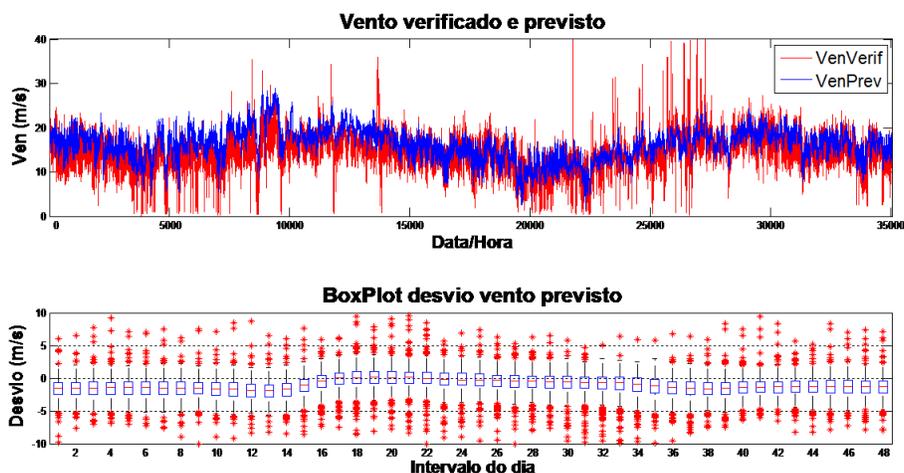


Figure 6: Desvios do vento previsto por intervalo.

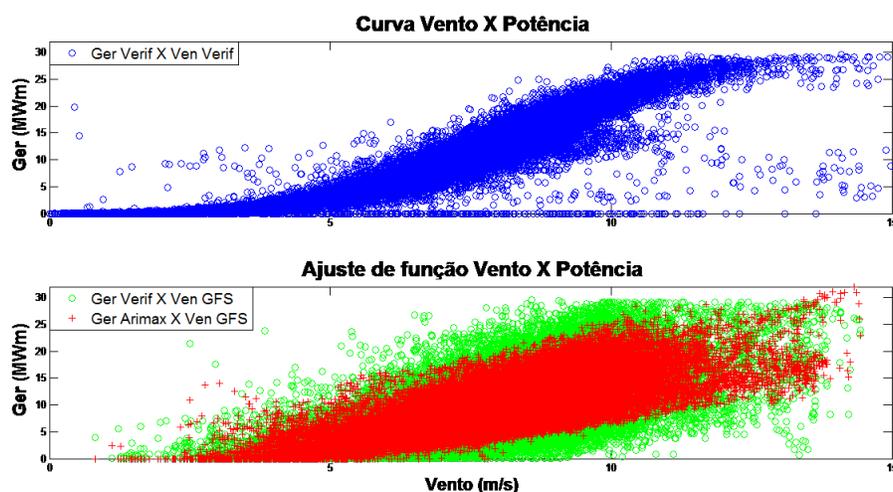


Figure 7: Curva Vento x Potência com dados originais, vento previsto GFS e previsão com Arimax.

O gráfico superior da Figura 9 ilustra a aplicação do modelo com Arimax para o conjunto de treinamento, validação, teste e simulação. Os modelos não foram calibrados novamente em cada dia de previsão do período de teste de simulação. O gráfico intermediário da Figura 9 apresenta o erro em MW dos mesmos conjuntos de dados. O gráfico inferior da Figura 9 amplifica a parte final do gráfico superior, com os resultados para o teste simulação.

Embora o modelo utilizando o método Arimax não necessite desta divisão dos dados para sua calibração, essa foi mantida para posteriores comparações com os modelos com redes neurais.

Para fins de comparação dos modelos, serão analisados os dados referentes ao período para testes de avaliação de desempenho, que vai de janeiro/2019 a fevereiro/2019. A Tabela 2 descreve o NMAPE para o modelo com Arimax de todas as usinas consideradas, utilizando os dados deste período.

O modelo com Arimax utiliza uma ponderação entre o

Table 2: NMAPE do Arimax de todos os conjuntos para as usinas consideradas

| Usinas | U1 | U2 | U3 | U4 | U5 | U6 | U7 |
|-----------|------|------|------|------|------|------|-----|
| NMAPE (%) | 11.0 | 17.9 | 10.7 | 18.0 | 20.0 | 23.0 | 6.5 |

passado da série com os parâmetros de explicação da série com a própria série e a variável exógena vento previsto. Para se ter uma noção do impacto dessa variável exógena, foi ajustado um simples modelo com método Arima, ignorando a variável exógena. Sendo assim, realizaram-se as previsões apenas com o que pode ser explicado com o passado da série. A Tabela 3 descreve o NMAPE para o modelo com Arima de todas as usinas consideradas, usando os dados do período para teste de avaliação de desempenho.

4.3 Previsões com redes MLP

A seguir, serão apresentados os resultados do modelo com

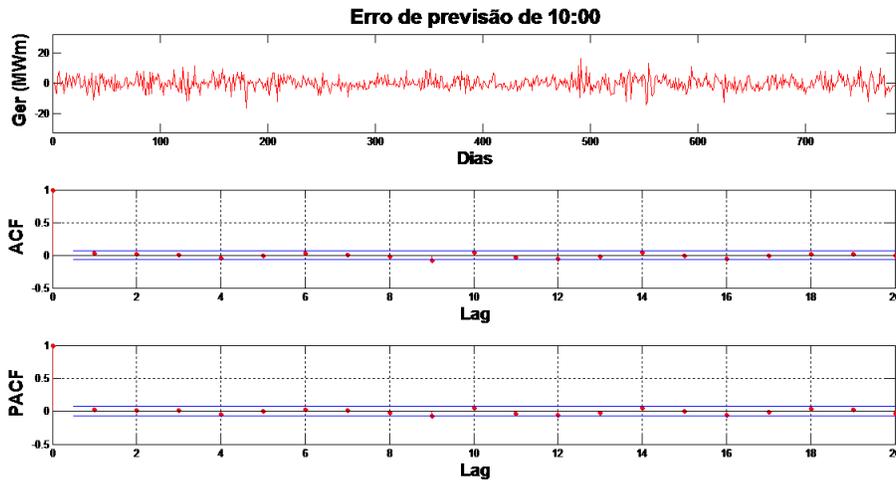


Figure 8: Erro de previsão do intervalo das 10 horas, do modelo com Arimax função de autocorrelação e função de autocorrelação parcial.

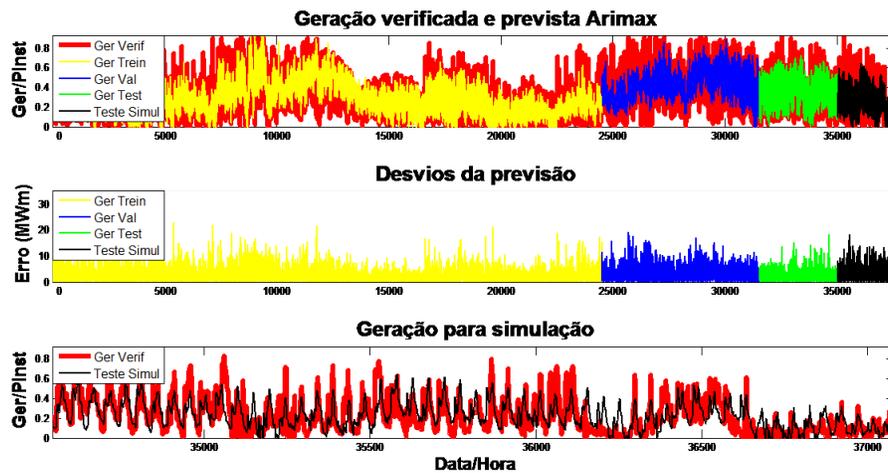


Figure 9: Aplicação do modelo com Arimax para o conjunto de treinamento, validação, teste e simulação.

Table 3: NMAPE do Arima de todos os conjuntos para as usinas consideradas

| Usinas | U1 | U2 | U3 | U4 | U5 | U6 | U7 |
|-----------|------|------|------|------|------|------|-----|
| NMAPE (%) | 12.9 | 21.0 | 13.4 | 19.5 | 22.4 | 23.1 | 6.9 |

redes MLP, que ajusta uma função de transferência entre o histórico da geração observada e o histórico das previsões de vento do modelo GFS para dois dias à frente. A Figura 10 ilustra os resultados da aplicação da rede MLP para o conjunto de treinamento, validação e teste, bem como um período adicional utilizado para a simulação dos modelos criados.

A Tabela 4 exibe o NMAPE de todas as usinas consideradas, usando os dados do período para teste de avaliação de desempenho. Para o levantamento das métricas de desem-

penho, foi rodado o modelo 10 vezes pegando a média dos 8 melhores ajustes. Conforme pode ser observado, os desvios variam muito de uma usina para outra. Entretanto, essa variação também é causada pela normalização pela potência instalada, que é diferente para cada usina.

Table 4: NMAPE da rede MLP de todos os conjuntos das usinas consideradas

| Usinas | U1 | U2 | U3 | U4 | U5 | U6 | U7 |
|-----------|-----|------|-----|------|------|------|-----|
| NMAPE (%) | 9.8 | 16.0 | 8.9 | 14.7 | 17.7 | 20.2 | 5.4 |

Neste modelo, quando se observa a função de autocorrelação e autocorrelação parcial dos resíduos, mostrados na Figura 11, percebe-se um pequeno valor da PACF no lag 1. Isso indica que o modelo com redes MLP ainda não conseguiu extrair todas as características modeláveis da série

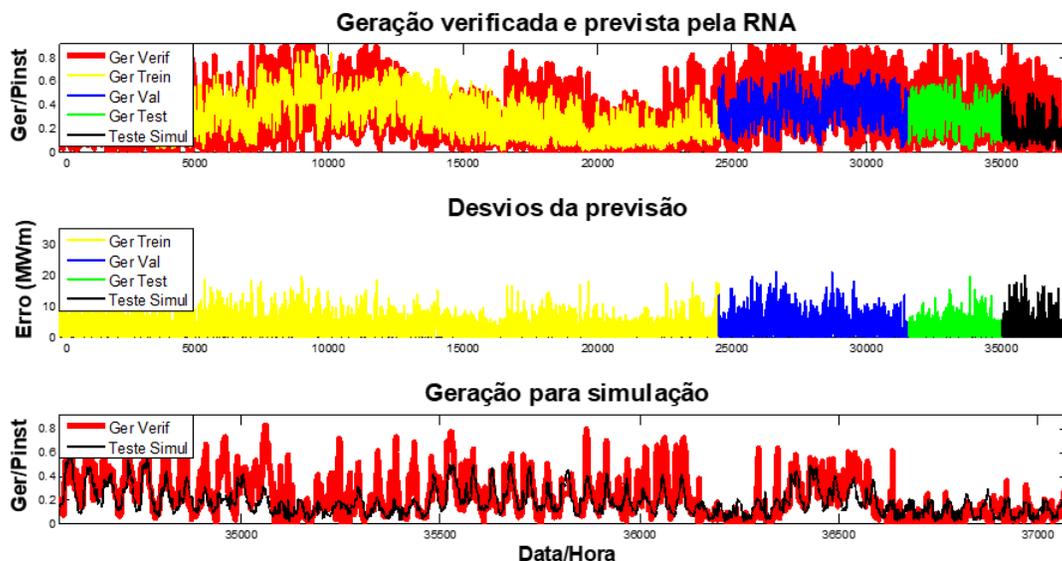


Figure 10: Aplicação da rede MLP para o conjunto de treinamento, validação, teste e simulação.

temporal.

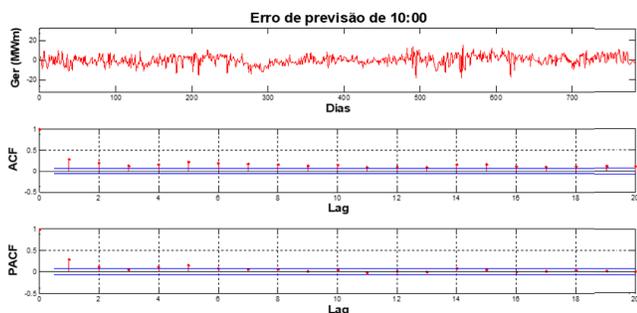


Figure 11: Erro de previsão do modelo com MLP, função de autocorrelação e função de autocorrelação parcial

As características, expostas na Figura 11, impulsionaram a pesquisa para um outro tipo de rede, mais avançada, capaz de extrair as informações do passado da série, bem como da variável exógena vento previsto do modelo GFS.

4.4 Previsões com redes NARX

A Figura 12 mostra os resultados da aplicação da rede NARX para o mesmo conjunto de treinamento, validação e teste, bem como um período adicional utilizado para a simulação dos modelos criados, e para as mesmas condições utilizadas no modelo com redes MLP.

A seguir, na Tabela 5, são apresentados os erros obtidos para o modelo com redes NARX para todas as usinas, usando os dados do período para teste de avaliação de desempenho. Para o levantamento das métricas de desempenho, foi rodado o modelo 10 vezes pegando a média dos 8 melhores ajustes.

Pode-se observar, que os erros dos modelos com redes MLP e NARX são muito próximos, superior em alguns casos

Table 5: NMAPE da rede NARX de todos os conjuntos para as usinas consideradas

| Usinas | U1 | U2 | U3 | U4 | U5 | U6 | U7 |
|-----------|-----|------|-----|------|------|------|-----|
| NMAPE (%) | 9.8 | 16.0 | 8.9 | 14.7 | 17.7 | 20.2 | 5.4 |

e inferior em outros. No entanto, conforme pode ser observado na Figura 13, em nenhum lag há valor significativo da ACF e da PACF, indicando que foi possível extrair todas as características modeláveis da série temporal utilizando o modelo com redes do tipo NARX.

4.5 Comparação e análises dos modelos utilizando apenas o vento como entrada do sistema

A fim de fornecer um maior entendimento de cada um dos modelos, foi calculado o NMAPE dos resultados apresentados de todos os modelos testados, utilizando o vento como variável de entrada. A Figura 15 mostra os resultados obtidos.

Conforme podem ser observados nas simulações, os desvios apresentados para o teste da simulação com o modelo utilizando o método Arima são significativamente mais elevados que os apresentados para o modelo com Arimax. Tal situação já era esperada, dado que informação do vento previsto tem maior poder explicativo que o passado da série. Isso ocorre devido à grande variabilidade desta série temporal e sua grande dificuldade preditiva. Desta forma, para previsão eólica o modelo com Arimax seria mais indicado do que modelos com Arima simples.

O modelo com redes MLP, mesmo sem utilizar o passado da série para prever, consegue desempenho superior aos modelos com Arima e Arimax. Apesar do modelo com Arimax considerar a variável exógena vento previsto, a representação no modelo é feita de forma linear, conforme Equação (1), no entanto a relação entre a geração e o vento é não linear, principalmente nas extremidades da dispersão, conforme pode

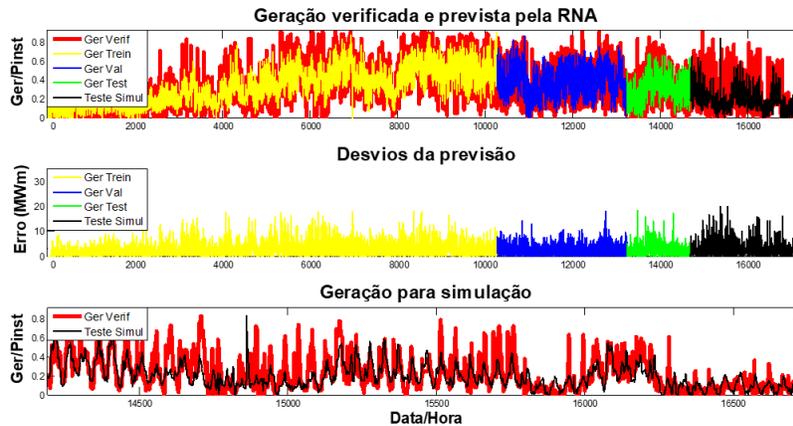


Figure 12: Aplicação da rede NARX para o conjunto de treinamento, validação, teste e simulação

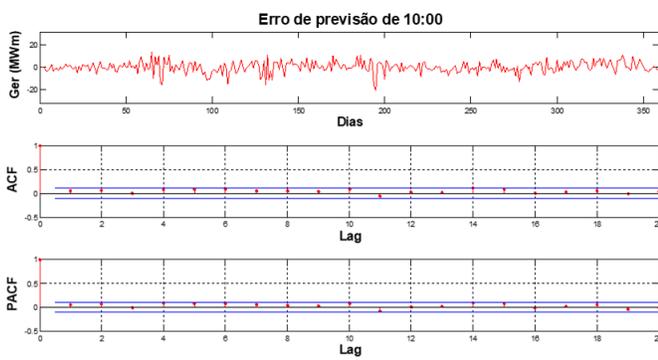


Figure 13: Erro de previsão do modelo com NARX, função de autocorrelação e função de autocorrelação parcial

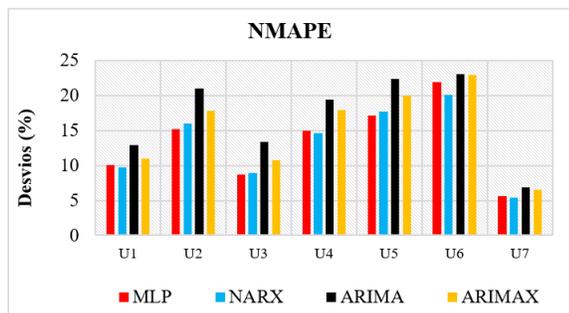


Figure 14: NMAPE dos modelos considerados de todos os conjuntos de dados para as usinas analisadas

ser visto na Figura 7. Todavia, o modelo com redes MLP consegue capturar a não linearidade presente nas grandezas envolvidas, e assim obtém ganhos mais significativos mesmo sem considerar o passado recente da série temporal.

Finalmente, comparando os erros obtidos pelos métodos MLP e NARX, verifica-se que são muito próximos, superior para algumas usinas e inferior para outras. Sendo assim, a escolha de um modelo ou outro dependerá do desempenho para cada parque eólico. Tal situação indica que um possível

modelo combinado com redes MLP e NARX poderiam ter resultados ainda melhores.

4.6 Comparação e análises dos modelos acrescentando outras variáveis meteorológicas

Com o objetivo de ampliar as análises em relação às variáveis de entrada, foram feitas novas simulações acrescentando uma maior variedade de variáveis exógenas: vento (magnitude e direção), temperatura, umidade e pressão, valores previstos pelo modelo GFS. A Figura 15 ilustra o gráfico dos desvios para aplicação do modelo com MLP e NARX, considerando os históricos para calibração de março/2018 a dezembro/2018. O início desse histórico é em 2018 e não em 2017 conforme as demais simulações. Isso deve-se ao fato de não se possuir as informações de todas as variáveis meteorológicas para o período anterior. Todavia, o período de avaliação de desempenho é o mesmo, de janeiro/2019 a fevereiro/2019. Apesar de os períodos serem diferentes dos resultados anteriores, os resultados são comparáveis, dado que as simulações dos testes anteriores foram realizadas para o horizonte de janeiro/2017 a dezembro/2018 e os desempenhos são muito similares.

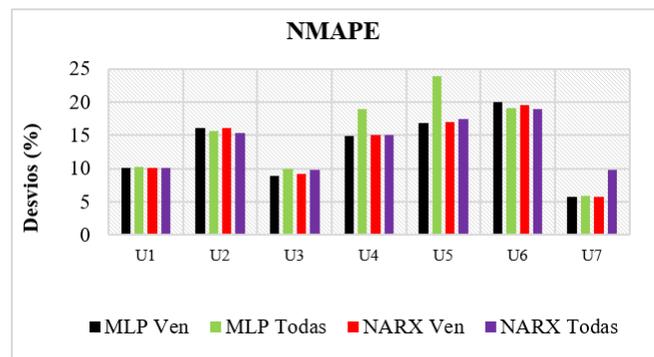


Figure 15: NMAPE dos modelos MLP e NARX com e sem as demais variáveis meteorológicas

Conforme pode ser observado, a adição de novas variáveis não acarretou melhorias para todas as usinas, indicando que simplesmente o vento previsto é uma informação de grande

importância na previsão da geração eólica. Porém, essa conclusão pode ser alterada à medida em que há um aumento do período e uma maior qualidade nos históricos considerados para estimação dos modelos.

5. CONCLUSÕES

Este trabalho propôs uma comparação entre os métodos de séries temporais (Arima e Arimax) e redes neurais (MLP e NARX) para previsão de geração de energia eólica. O aumento da demanda de energia eólica no Brasil é crescente e essa fonte de energia tem se mostrado muito promissora por ser não deletéria ao meio ambiente. No entanto, sua produção depende de condições climatológicas, apresentando uma característica estocástica. Nesse sentido, o desenvolvimento de algoritmos inteligentes que tragam suporte para o sistema de geração eólica é extremamente importante. Esta pesquisa mostrou que as técnicas utilizando redes neurais artificiais são promissoras e trouxe a utilização de redes NARX como uma proposta pertinente em previsão de geração de energia eólica.

As simulações realizadas, com os dados disponíveis, mostraram que os resultados com algoritmos baseados em redes neurais apresentam erros menores em comparação com as tradicionais técnicas de séries temporais Arima e Arimax. A rede NARX apresentou resultados ainda mais satisfatórios que a rede MLP devido a sua característica de realimentação do sistema com dados previstos, o que aumenta sua capacidade de mapeamento não linear.

A partir dos resultados demonstrados neste trabalho, sugere-se como trabalhos futuros o desenvolvimento de algoritmos híbridos utilizando técnicas de redes neurais artificiais. Além disso, as simulações mostraram que algoritmos com realimentação do sistema com dados previstos, como a rede NARX, melhora o desempenho da previsão devido às características estocásticas próprias do sistema de geração eólica.

6. REFERENCES

- [1] L. M. Aguilar-Lobo, J. R. Loo-Yau, J. E. Rayas-Sánchez, S. Ortega-Cisneros, P. Moreno, and J. Reynoso-Hernández. Application of the narx neural network as a digital predistortion technique for linearizing microwave power amplifiers. *Microwave and Optical Technology Letters*, 57(9):2137–2142, 2015.
- [2] D. B. d. Alencar. *Modelo híbrido baseado em séries temporais e redes neurais para previsão da geração de energia eólica*. PhD thesis, Universidade Federal do Pará, 2018.
- [3] A. N. ANEEL. Atlas de energia elétrica do brasil 3. ed. In <http://www2.aneel.gov.br/arquivos/PDF/atlas3ed.pdf>, 2008.
- [4] C. Bennett, R. Stewart, and J. Lu. Autoregressive with exogenous variables and neural network short-term load forecast models for residential low voltage distribution networks. *Energies*, 7(5):2938–2960, 2014.
- [5] J. G. M. R. G. C. . L. G. M. Box, G. E. *Time Series Analysis: Forecasting and Control*. Wiley, 2015.
- [6] C. A. P. . L. T. B. Braga, A. d. *Redes Neurais Artificiais: Teoria e Aplicações*. LTC Editora, 2007.
- [7] I. Coelho. Estudo sobre a aplicação de redes neurais recorrentes para previsão da geração eólica e do preço de liquidação das diferenças. In *Repositório Institucional da UFSC*, 2018.
- [8] I. M. M. de Souza. Um estudo comparativo para previsão da cotação de ações da bm&fbovespa utilizando redes neurais artificiais. In *Escola Politécnica de Pernambuco - Universidade de Pernambuco*, 2012.
- [9] P. H. C. dos Santos. Previsão de geração de potência eólica utilizando redes neurais artificiais. In *Escola Politécnica de Pernambuco: Poli*, 2014.
- [10] Hang Xie, Hao Tang, and Yu-He Liao. Time series prediction based on narx neural networks: An advanced approach. In *2009 International Conference on Machine Learning and Cybernetics*, volume 3, pages 1275–1279, July 2009.
- [11] S. Haykin. *Redes Neurais Princípios e Prática*. Bookman, 2001.
- [12] S. Haykin. *Redes Neurais Princípios e Prática*. Bookman, 2007.
- [13] F. S. Hiruma. Previsão da geração de energia eólica com redes neurais artificiais. Master’s thesis, Universidade Federal do Paraná, 2016.
- [14] B.-M. Hodge, D. Lew, M. Milligan, E. Gómez-Lázaro, X. Larsén, G. Giebel, H. Holttinen, S. Sillanpää, R. Scharff, L. Söder, and D. Flynn. Wind power forecasting error distributions: An international comparison. In *Proceedings of 11th International Workshop on Large-Scale Integration of Wind Power into Power Systems*, 2012.
- [15] NOAA. National oceanic and atmospheric administration. global forecast system (gfs). In <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-forecast-system-gfs>, 2019.
- [16] ONS. Modelos de previsão de geração eólica. In <https://sintegre.ons.org.br/sites/6/27/48>, 2018.
- [17] A. S. Weigend. *Time series prediction: forecasting the future and understanding the past*. Routledge, 2018.