

Previsão de séries temporais de velocidade do vento utilizando Redes Neurais Artificiais e Métodos Estatísticos na região de Arraial do Cabo - RJ

Ricardo Teixeira¹, Diego da Silva¹, Harold de Mello Junior¹, Leonardo Forero¹, Antonio Lima¹, Karla Figueiredo²

¹Departamento de Engenharia Elétrica

²Departamento de Informática e Ciência da Computação

Universidade do Estado do Rio de Janeiro (UERJ)

Rio de Janeiro, Brasil

{[ricardo.mauroct7021](mailto:ricardo.mauroct7021@gmail.com), [lemos.diego.07](mailto:lemos.diego.07@gmail.com), [harold.dias](mailto:harold.dias@gmail.com)}@gmail.com,
leofome@hotmail.com, antoniolima@uerj.br, karla.figueiredo@gmail.com

Resumo— Atualmente diversos países estão engajados no desenvolvimento sustentável. Uma das peças fundamentais para alcançar esse desenvolvimento é a construção de uma matriz energética que contenha fontes renováveis, que preservem o meio ambiente, e elimine as opções relativas aos combustíveis fósseis. Nesse sentido, uma das fontes mais limpas e renováveis é a energia eólica. O Brasil está entre os dez maiores geradores de energia eólica no mundo. Para a implantação e planejamento de tais sistemas são necessários estudos detalhando o comportamento do vento. Logo, este artigo tem como objetivo realizar a análise estatística e previsão de uma série temporal de velocidades de ventos, na localidade de Arraial do Cabo situado no Rio de Janeiro, por meio do método clássico ARIMA e Redes Neurais MLP (*MultiLayer Perceptron*) e LSTM (*Long Short Term Memory*). Os resultados obtidos neste estudo mostram melhor desempenho dos modelos baseados em Redes Neurais sobre o método estatístico, devido às características estocásticas do vento, fenômenos de mesoescala e os outros aspectos climáticos e geográficos da região. Os resultados alcançados indicam que o uso de aprendizado de máquinas (*Machine Learning*) é um caminho promissor. No entanto, é importante investigar se outras variáveis, além da série histórica de velocidades de vento, podem melhorar a previsão desta.

Palavras-chave— geração eólica, séries temporais, métodos de previsão, ARIMA, MLP

I. INTRODUÇÃO

O desenvolvimento sustentável é um tema que vem sendo debatido pela Organização das Nações Unidas (ONU), notadamente após a assinatura do Protocolo de Kyoto (1997), cujo compromisso foi ratificado pelo Brasil no Decreto Legislativo nº 144 de 2002. Desde então, outras convenções, tratados e acordos internacionais sobre clima foram realizados, incluindo a Rio+10, Rio+20, até as mais recentes Conferências Climáticas Mundial, sendo que no Acordo de Paris, o Brasil ratificou a alcançar a parcela de 45% de energias renováveis na composição da matriz energética em 2030 [1]. O Brasil possui elevado potencial eólico, tornando a geração de energia eólica uma das opções mais viáveis para a geração de energia

renovável no Brasil. Porém, mesmo com todo esse potencial, a geração eólica possui dificuldades decorrentes da imprevisibilidade das condições do vento (quanto à velocidade, direção e outros fatores) que demandam estudo e pesquisa. Recentemente atingiu a marca de 15 mil megawatts (MW) de potência instalada (capacidade de geração) de energia eólica, equiparando-se a Itaipu.

Este trabalho tem por finalidade avaliar diferentes modelos baseados em estatística e aprendizado de máquinas visando estudar a previsão do vento horário, que a partir da curva de potência, possibilita a determinação da energia eólica [2].

O restante deste trabalho está distribuído em mais cinco seções. A seção II apresenta alguns fundamentos voltados para a geração de energia eólica. A seção III fundamenta brevemente os princípios relacionados aos três métodos desenvolvidos para a previsão de séries temporais. A seção IV apresenta a metodologia adotada neste trabalho. A seção V exhibe os resultados obtidos e, finalmente, a seção VI encerra o trabalho apresentando conclusões e perspectivas de novos trabalhos.

II. FUNDAMENTOS DE GERAÇÃO DE ENERGIA RENOVÁVEL: GERAÇÃO EÓLICA

A. Introdução

Conforme as definições de [3], os sistemas eólicos podem ser classificados em pequeno porte (até 10 kW), intermediários (entre 10 e 250 kW) e de grande porte (maiores que 250 kW). Além disso, podem ser sistemas isolados do sistema interligado, necessitando de sistema para armazenamento da energia; sistemas híbridos, nos quais outras fontes de energia atendem uma única carga que necessita de uma unidade de controle e condicionamento de potência; sistemas interligados à rede, que são aqueles de grande porte com aerogeradores conectados ao sistema elétrico; e sistemas *off-shore*, que representa uma nova aplicação em sistemas de grande porte instalados no mar, onde

há a necessidade de estratégias especiais, pois a instabilidade marítima pode movimentar os aerogeradores, assim como cuidados adicionais no transporte dos equipamentos.

B. Relação velocidade/altura

Outro fator que deve ser considerado durante a avaliação da velocidade do vento é a relação que existe entre a mesma e a altura na qual os dados de vento estão sendo coletados [4]. De acordo com [5], a rugosidade do terreno altera a variação da velocidade com a altura devido aos obstáculos. Por isso, áreas urbanas apresentam maior rugosidade do que as rurais e litorâneas.

C. Conversão do potencial eólico em elétrico

A curva de potência da turbina eólica representa a potência elétrica gerada em função da velocidade incidente e depende do tamanho das pás, potência do gerador e de outros detalhes de projeto, de acordo com a Fig. 1.

A avaliação desta curva, de responsabilidade do fabricante, pode ser obtida por medições da velocidade do vento através de um anemômetro instalado próximo à turbina e sua respectiva potência gerada [2].

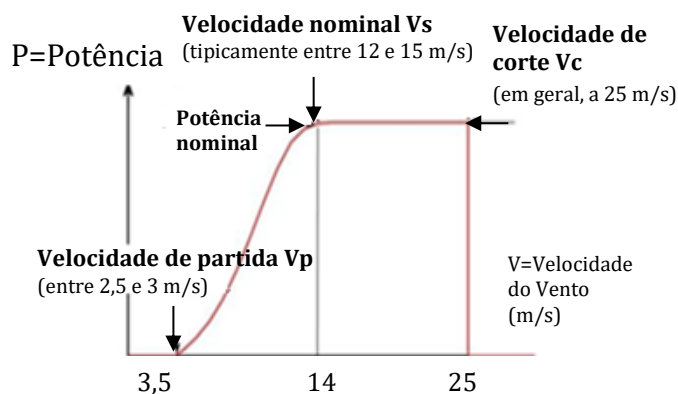


Fig. 1 Curva de potência de um aerogerador (Vargas, 2015 apud Pessanha et al., 2010).

Observam-se três pontos importantes na Fig. 1. A velocidade de partida onde o gerador começa a gerar energia, a velocidade nominal na qual a turbina atinge a produção máxima de potência e a velocidade de corte em que a proteção desliga a turbina.

III. PREVISÃO DE SÉRIES TEMPORAIS

A. Método estatístico (ARIMA)

O modelo autoregressivo integrado de média móvel ou ARIMA (*Autoregressive Integrated Moving Average*), conhecido também como metodologia de Box-Jenkins, é um método estatístico comumente utilizado em previsão de séries

temporais, através da análise de dados históricos com o objetivo de expressar o comportamento futuro baseando-se na variação estocástica do passado [6]. Considerado um método clássico devido a sua generalidade, o ARIMA pode lidar com séries estacionárias ou não-estacionárias, com ou sem elementos sazonais [7].

Este modelo é usualmente representado pela notação $ARIMA(p, d, q)$, onde (p, d, q) é a representação da ordem do modelo. O método possui as seguintes componentes, denominadas de “filtros” [8]:

- Componente de Auto Regressivo (AR).
- Componente de Integração (I).
- Componente de Médias Móveis (MA).

p, d e q são parâmetros que precisam ser estimados por técnicas iterativas, como o método dos mínimos quadrados. O parâmetro p é relacionado ao termo autorregressivo, representando a sua ordem; q é o parâmetro relativo à ordem da parte de médias móveis e d é o parâmetro integrado que representa o número de derivações necessárias para tornar uma série estacionária. Assim, ao atribuir valores como $(1, 0, 0)$ está se utilizando apenas o modelo autorregressivo, enquanto $(0, 1, 0)$, o modelo integrado e $(0, 0, 1)$, o modelo de médias móveis. A definição dos modelos é feita através da análise das condições estacionárias com as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) [8].

B. Redes Neurais Artificiais (MLP e LSTM)

Redes Neurais Artificiais são métodos alternativos de previsão de séries temporais inspiradas no funcionamento do cérebro humano. São organizadas em camadas de processadores denominados de neurônios artificiais, que realizam o processamento e a transmissão de informações entre redes de neurônios conectados por sinapses.

A estrutura mais básica das redes neurais é o neurônio artificial, que simula as funções do seu equivalente biológico. De acordo com [9], os neurônios são componentes não-lineares, que fornecem saídas contínuas, como ilustrado na Fig. 2, a partir da coleta e processamento de sinais de entrada. A função de ativação determina a resposta de um neurônio e é definida pela Eq. 1:

$$y_k = \varphi(v_{ik}) = \varphi\left(\sum_{j=1}^m w_{kj}x_j \pm b_k\right) \quad (1)$$

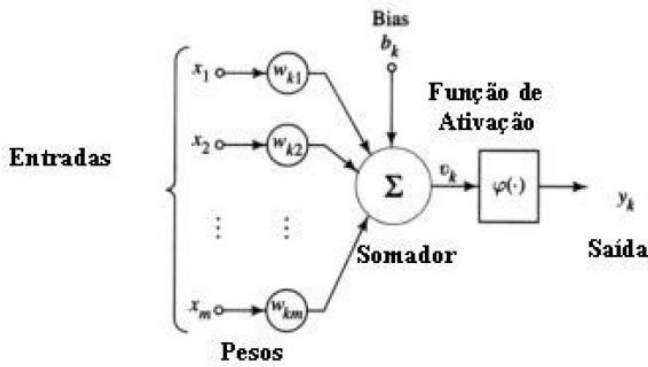


Fig. 2 Modelo de neurônio artificial.

Existem diversas formas de organizar a topologia de uma rede. Particularmente, a MLP é organizada em duas ou mais camadas de neurônios, sendo uma delas (ou mais) intermediárias e uma de saída. A Rede Neural é um aproximador universal de funções e é demonstrado que uma rede MLP, com uma camada escondida e função de ativação não-linear, consegue representar qualquer função [9].

As Redes Neurais Recorrentes são representadas por uma realimentação na arquitetura padrão. O alcance dos valores utilizados para correção dos pesos é restrito, pois a influência da saída nas camadas escondidas, decai exponencialmente à medida em que passa pelas conexões recorrentes da rede. Várias tentativas para resolver esta questão, conhecida como problema de dissipação de gradiente, foram abordadas durante os anos 90, e uma das soluções adotadas foi a criação das redes LSTM.

As redes LSTM foram definidas por [10], como modelos mais complexos da classe de Redes Neurais Recorrentes. A complexidade vem do fato que ela pode armazenar valores por uma quantidade arbitrária de passos de tempo, sendo designada para mitigar o problema da dissipação dos gradientes.

O modelo LSTM substitui os neurônios tradicionais dos perceptrons por blocos (Fig. 3). Esses blocos são formados por células de memórias e por algumas portas de entradas que controlam o fluxo de informações que passa pela célula. Cada célula de memória é auto conectada com unidades lineares denominadas de Carrossel de Erro Constante (CEC), sendo sua ativação considerada o estado da célula.




Fig. 3 Representação de uma célula de memória de uma rede LSTM [11].

Segundo [12], o CEC é o responsável por reduzir o problema de dissipação do gradiente, desde que fluxo anterior de erro local se mantenha constante dentro dele, enquanto uma nova entrada ou sinal externo de erro se apresenta.

Cada bloco contém uma ou mais células de memórias auto conectadas e três unidades multiplicadoras (portões de entrada saída e esquecimento), estes portões têm funções análogas à escrita, leitura, redefinição e operação para as células. Estas unidades multiplicadoras são a razão das células de memória do LSTM serem capazes de guardar e acessar informações por longos períodos de tempo [13]. Graças a essa capacidade, as redes LSTM têm sido bem-sucedidas quando usadas em tarefas que requerem memórias de longo alcance. Essa característica a torna altamente recomendável para o uso em previsão de séries temporais longas, como é o caso do presente trabalho.

IV. METODOLOGIA

A. Análise estatística

Uma série temporal de velocidade do vento horária apresenta variações importantes e não determinísticas que ocorrem ao longo dos dias, meses e anos. A compreensão destas variações, ao longo do tempo, é o maior objetivo destas análises [14] e, para isto, a análise estatística é uma ferramenta muito útil neste estudo. Adicionalmente, é necessário realizar análise detalhada da localidade por um período suficientemente longo, relacionadas ao clima e relevo, por exemplo, para identificar fatores que afetam as variáveis do vento [15].

A Fig. 4 apresenta a decomposição da série temporal em componentes de tendência, sazonais e irregulares usando médias móveis. Esta decomposição foi realizada com a função *decompose* do pacote *stats* do *software* estatístico R [16]. É possível identificar uma tendência crescente com a passagem dos anos, pois, segundo [14], as velocidades do vento variam também a longo prazo, podendo haver uma diferença de até 10% entre o valor médio anual e a média a longo prazo. Através do gráfico de sazonalidade, é observado que a série possui um padrão inerente em seus dados, mostrando períodos com velocidades maiores e outros com velocidades menores. No gráfico de aleatoriedade é apresentado um alto nível de erro.




Fig. 4 Decomposição da série completa nas componentes de uma série temporal (tendência, sazonalidade e erro).

No gráfico *box plot* mostrado na Fig. 5, é possível observar a variação da média anual, reforçando o que é visto no gráfico da tendência da série temporal representando nos gráficos

decompostos. No mesmo é observado a variação da velocidade durante o ano através da caixa interquartílica e a presença de outliers, que são dados considerados atípicos.




Fig. 5 Gráfico *Box Plot* da série completa.

Outra forma de analisar graficamente os dados de velocidade de vento é por meio de histogramas, onde é possível observar na Fig. 6 que a maior incidência durante a série é de velocidades de 1 a 5 m/s.




Fig. 6 Histograma da série completa.

A série também apresenta sazonalidade ao longo do dia, como pode ser observado no gráfico da Fig. 7. A partir dela podem ser analisadas as médias referentes às horas do mês de setembro de 2014, quando a incidência de velocidades é maior. Na figura é possível observar que os ventos de maior intensidade ocorrem aproximadamente no período de 17 às 22 horas, enquanto os ventos com menores intensidade ocorrem no período de 6 às 11 horas. Isto ocorre devido à proximidade do oceano no local, pois é um grande regulador térmico. A umidade do ar, proveniente do mesmo, absorve radiação térmica durante o dia e, durante à noite, esse calor é reemitido para baixo, evitando uma variação brusca de temperatura [17].




Fig. 7 Variação da velocidade média horária em setembro de 2014.

B. Distribuição de Weibull

De acordo com [14], o vento possui característica estocástica, sendo a velocidade uma variável aleatória contínua. A distribuição de Weibull é a melhor forma de apresentar a função densidade de probabilidade de uma distribuição de vento, sendo representada pela equação (2):

$$f(v) = \frac{k}{c} \left(\frac{v}{c}\right)^{k-1} e^{-\left(\frac{v}{c}\right)^k} \quad (2)$$

O fator de escala c está relacionado à média da velocidade do vento no local em um determinado período, e o fator de forma k relacionado à variância da velocidade do vento. Estes parâmetros foram estimados com a função *fitdistr()* do pacote *MASS* do *software* estatístico R, resultando na curva ajustada ao histograma da série na Fig. 8. Esta distribuição pode ser utilizada na avaliação da produção de energia de turbinas eólicas e determinar o aumento na capacidade de geração. Esta análise não foi realizada neste trabalho.




Fig. 8 Distribuição de Weibull série de velocidades de 2006 a 2018.

C. Configurações do método estatísticos (ARIMA)

Para o método ARIMA, a função *auto.arima*, do *software* estatístico R, foi utilizada. Esta realiza a normalização da série temporal e estima os parâmetros p , d e q . Os dados foram separados em conjuntos de treino e teste, que consistia no período de janeiro de 2007 a dezembro de 2017 para o conjunto de treino, e para o teste os dados referentes ao ano de 2018.

D. Configurações dos modelos baseados em Redes Neurais (MLP e LSTM)

Nas redes neurais os dados foram apresentados em forma de “janela”, com n valores anteriores ao valor a ser previsto na posição $n+1$ [9], onde o tamanho da mesma constitui um parâmetro a ser ajustado na identificação da rede, visando o melhor desempenho na previsão. A previsão realizada foi *single step* uma hora a frente.

Na etapa de treino o algoritmo *backpropagation* foi o método de treinamento supervisionado utilizado. Os dados foram separados em conjuntos: 70% dos dados da série temporal (77.146 amostras) foram usados para ajuste do modelo (treinamento), um subconjunto com 20% destes dados (19.286 amostras) foram usados para validação. E os 30% dos dados restantes da série (8.760 amostras) foram utilizados no conjunto de teste.

A função de parada antecipada (*early stopping*) foi utilizada. O objetivo dessa função é identificar quando as medidas de erro de validação se estabilizam ou voltam a aumentar, pois nesse momento ela deverá interromper o treinamento.

Na rede LSTM foram adotados critérios semelhantes aos da MLP. Uma vez que a LSTM lida melhor com séries de grande extensão, separando e distinguindo fatos recentes dos mais antigos [9], a utilização da hora como entrada se torna desnecessária, logo não é inserida na entrada da rede.

Todas as simulações das redes neurais foram realizadas em códigos desenvolvidos em linguagem Python (versão 3.7) utilizando máquina com processador Intel Xeon. O tempo de treinamento da rede LSTM foi de 527 s.

V. RESULTADOS

A. ARIMA

Para esta etapa de previsão da série, foi necessário o ajuste dos parâmetros (p, d, q) no modelo ARIMA, usando a função *auto.arima* do *software* estatístico R, que realiza a estimação dos parâmetros com métodos iterativos de modo a otimizar a previsão da série. Os parâmetros identificados pelo método foram (5, 1, 0). Analisando os gráficos na Fig. 9, pode-se notar a grande diferença entre os valores reais e previstos, confirmada pelos erros da Tabela I.

TABELA I. Previsão do Modelo ARIMA.

ARIMA	MAPE (%)	RMSE (m/s)
Treinamento	27,54	1,05
Teste	69,01	3,47




Fig. 9 Gráfico de comparação entre valores reais e previstos no ano de 2018.

B. MLP

Para a previsão usando redes neurais, primeiramente foi usada a rede MLP, considerando experimentos com diversas parametrizações, a fim de identificar o tamanho da rede capaz de promover o melhor aprendizado e generalização.

O melhor resultado foi obtido através de 2 camadas escondidas, com 4 e 9 neurônios em cada uma, respectivamente, usando como funções de ativação a tangente hiperbólica, tamanho de janela de 168 entradas de amostras normalizadas de velocidade do vento (quantidade de horas por semana) mais 1 entrada referente a hora alvo da previsão, com 100 épocas de treinamento.

A Tabela II apresenta o melhor resultado obtido das simulações realizadas. A característica estocástica da série impõe um desafio à previsão, porém com resultados melhores do que os obtidos com o ARIMA.

TABELA II. Previsão do Modelo MLP.

MLP	MAPE (%)	RMSE (m/s)
Treinamento	29,13	0,97
Teste	28,31	1,17

A Fig. 10 apresenta o gráfico dos valores reais e previstos pela Rede Neural MLP para o ano de 2018.

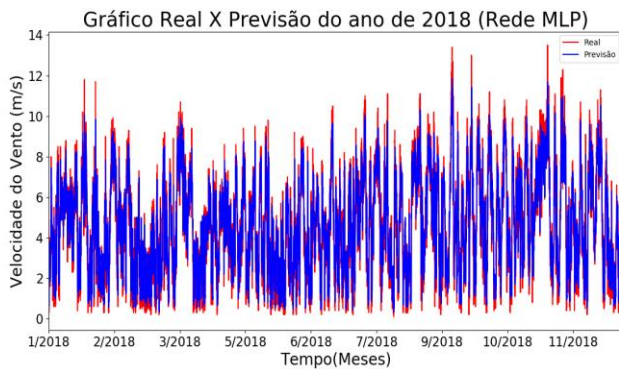


Fig. 10 Gráfico de comparação entre valores reais e previstos para o ano de 2018 (MLP).

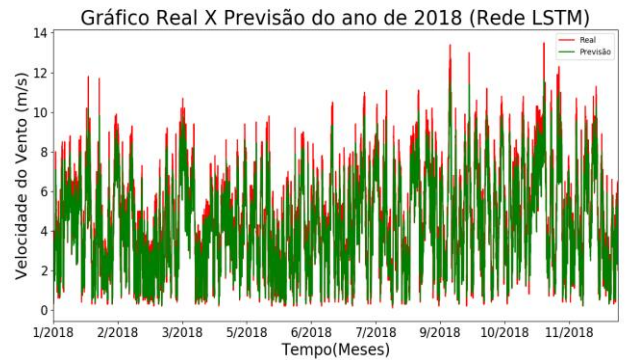


Fig. 11 Gráfico de comparação entre valores reais e previstos para o ano de 2018 (LSTM).

C. LSTM

Para a LSTM, a metodologia aplicada foi semelhante a que foi aplicada a Rede Neural MLP, avaliando resultados de diversos ensaios com diferentes configurações. O melhor resultado obtido foi com uma configuração de 2 camadas escondidas com 15 e 5 neurônios, função de ativação sigmóide, 24 amostras por janela como entrada e com 100 épocas de treinamento.

A Tabela III mostra o melhor resultado obtido com a rede LSTM. Pode-se constatar que entre os três métodos adotados, a rede LSTM foi a que apresentou melhores resultados.

TABELA 3 Previsão do Modelo LSTM.

LSTM	MAPE (%)	RMSE (m/s)
Treinamento	28,16	0,97
Teste	27,43	1,18

O gráfico da Fig. 11 apresenta os valores reais e previstos por LSTM para o ano de 2018.

VI. CONCLUSÃO

Neste trabalho foram analisadas séries temporais de velocidade do vento, através de modelos estatísticos e baseados em Redes Neurais, para determinação de viabilidade técnica de instalação de uma usina eólica em Arraial do Cabo no Estado do Rio de Janeiro. Sendo os modelos ARIMA e as Redes Neurais MLP e LSTM escolhidos para este estudo. Como a localidade escolhida está em uma área de escala regional (mesoescala), pois se encontra dentro de uma região de tamanho médio (entre 1 e 1000 Km) e com fenômenos na ordem de 1 em 1 hora [19], verifica-se que para este tipo de cenário a dinâmica atmosférica aumenta [20] e grandezas como pressão e temperatura têm grande influência no comportamento do vento. Então, em estudos posteriores, é necessário que estas variáveis possam se consideradas para melhorar os resultados dos modelos de previsão de séries de velocidade de vento nesta região, principalmente dos baseados em Redes Neurais, que obtiveram erros menores do que o método clássico ARIMA.

Adicionalmente, a análise estatística dos dados, realizada com a distribuição de Weibull (conforme seção 4), mostrou que a maior probabilidade de velocidades de vento situa-se entre 3 a 5 m/s. Vale ressaltar que os anemômetros usados para os registros de velocidade do vento estão posicionados a apenas 7 metros do solo e, desta forma, estão sujeitos a diversos fatores que diminuem sua intensidade, como a rugosidade do terreno local. Então, com a devida correção dos valores para alturas compatíveis às das turbinas eólicas, pode-se considerar que a intensidade do vento ficará acima da faixa identificada.

Esses níveis de velocidade tornam viáveis a instalação de uma usina eólica no local em estudo, observando as características dos aerogeradores, porém com ressalvas de que estudos mais aprofundados sobre a localidade, como seu clima e relevo, são necessários.

AGRADECIMENTOS

Este trabalho recebeu suporte da Intel Corporation. Os autores também agradecem o apoio financeiro do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), da Coordenação de Aperfeiçoamento do Ensino Superior Educação Pessoal (CAPES) e da Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ).

REFERÊNCIAS

- [1] “Nações Unidas Brasil” 2018. [Online]. Disponível em: <https://nacoesunidas.org/conferencia-da-onu-sobre-clima-comeca-na-polonia-com-foco-em-neutralidade-de-carbono/>. [Acesso em: 01-Set-2019].
- [2] Vargas, S. A. Previsão da Distribuição da Densidade de Probabilidade da Geração de Energia Eólica usando técnicas não paramétricas. [s.l.] PUC-Rio Pontifícia Universidade Católica do Rio de Janeiro, Tese de Doutorado, 2016.
- [3] ANEEL, Atlas da Energia Eólica do Brasil, 2 Edição, 2005
- [4] Braz, C.A., Rodriguez, S, R.L., Siqueira, H.V., (2017) Geração de energia elétrica por meio de fontes de energias renováveis: uma revisão sistemática da literatura sobre energia eólica, v. 13, n. 1.
- [5] Rodrigues, L.B., Perobelli, F.F.C., Vasconcelos, S., (2017). Geração de energia eólica no Brasil: um investimento viável? Brazilian Journal of Business Economics, v. 17, n. 2.
- [6] Babai, M. Z. et al. Forecasting and inventory performance in a two-stage supply chain with ARIMA(0,1,1) demand: Theory and empirical analysis. International Journal of Production Economics, [s.l.], v. 143, n. 2, p.463-471, jun. 2013. Elsevier BV.
- [7] Maddala, G.S. Introdução à econometria. 3a. ed. Rio de Janeiro: LTC, 2003.
- [8] Morettin, P.A.; Toloí, C. M. C. Análise de séries Temporais. 3. ed. São Paulo: Blucher, 2018.
- [9] Haykin, S. Redes Neurais - Princípios e prática 2a Edição. Porto Alegre: Bookman, 2001.
- [10] S. Hochreiter and J. Schmidhuber. Long short-term memory. Neural Computation, 9(8):1735–1780, 1997.
- [11] C. Olah, “Understanding LSTM Networks,” 2015. Disponível em: <https://ai.google/research/pubs/pub45500/>. [Acesso em: 01-Set-2019].
- [12] E. López, C. Valle, H. Allende, E. Gil, and H. Madsen, “Wind Power Forecasting Based on Echo State Networks and Long Short-Term Memory,” Energies, vol. 11, no. 3, p. 526, Feb. 2018.
- [13] A. Graves. Supervised Sequence Labelling with Recurrent Neural Networks, vol. 385. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012.
- [14] Custódio, R. D. S. Energia Eólica para produção de energia elétrica. Rio de Janeiro: ELETROBRAS, 2009.
- [15] Kumaraswamy, B. G.; Keshavan, B. K.; Jangamshetti, S. H. A statistical analysis of wind speed data in west central part of Karnataka based on Weibull distribution function. 2009 IEEE Electrical Power and Energy Conference, EPEC 2009, p. 1–4, 2009.
- [16] R Core Team, R: A Language and Environment for Statistical Computing, R Foundation for Statistical Computing, Vienna, Austria, 2019.
- [17] Cavalcanti, I. F. A.; Ferreira, N. J., da Silva, M. G. A. J.; Dias, M. A. F. S. Tempo e clima no Brasil. 1. ed. São Paulo: Oficina de Texto, 2009.
- [18] Nelson, D. M. Q. Uso de redes neurais recorrentes para previsão de séries temporais financeiras. [s.l.] UFMG Universidade Federal de Minas Gerais, Dissertação de Mestrado, 2017.
- [19] Kelly, P.; Silva, D. O. Análise e previsão de curto prazo do vento através da modelagem estatística em áreas de potencial eólico no Nordeste do Brasil. [s.l.] Universidade Federal de Campina Grande, 2017.
- [20] Lamdberg, L. Short-term prediction of the power production from wind farms. Journal of Wind Engineering and Industrial Aerodynamics, v. 80, n. 1-2, p. 207-220, 1999.