

Previsão de Velocidade do Vento com Redes Convolucionais

Felipe Whitaker

PUC-Rio, Departamento de Engenharia Industrial
Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ
felipewhitaker@aluno.puc-rio.br

Fernando L. Cyrino Oliveira

PUC-Rio, Departamento de Engenharia Industrial

Marley M B R Vellasco

PUC-Rio, Departamento de Engenharia Elétrica

RESUMO

O crescimento da geração por fontes renováveis torna cada vez mais desafiadora a operação do sistema elétrico. Isso porque dependem de recursos intermitentes. Energia eólica, por exemplo, corresponde a 11.8% da oferta de energia no Brasil, com usinas concentradas no norte e no nordeste. Esse trabalho propõe uma metodologia baseada em redes totalmente convolucionais para previsão simultânea de 36 séries de vento, sendo avaliada na previsão multi-passo auto-regressiva de 28 passos (duas semanas). Os resultados ficaram próximos do estado da arte, constatando um erro inferior em metade das comparações feitas no conjunto de teste; mas com um custo computacional ordens de magnitude inferior.

PALAVRAS CHAVE. Energia Eólica. Previsão multi-passo. Redes Convolucionais.

Séries Temporais. Energia Renovável. Aprendizado Profundo.

ABSTRACT

The growth of renewable energy sources is becoming increasingly challenging for the operation of the electrical system. This is because they depend on intermittent resources. For example, wind energy accounts for 11.8% of the energy supply in Brazil, with wind turbines concentrated in the north and northeast. This paper proposes a methodology based on fully convolutional neural networks for simultaneous prediction of 36 wind speed series, evaluated using a multi-step auto-regressive prediction of 28 steps (two weeks). The results were close to state-of-the-art, showing a smaller error in half of the comparisons from the test set; but with orders of magnitude lower computational cost.

KEYWORDS. Wind Energy. Multi-step prediction. Convolutional Neural Networks.

Time Series. Renewable Energy. Deep Learning.

1. Introdução

O crescimento da geração por fontes renováveis, como eólica e solar, intensifica o desafio de operar o sistema elétrico. Isso porque dependem de recursos intermitentes e não estocáveis. Energia eólica, por exemplo, apresenta esse desafio para todas as escalas de tempo: desde segundos, para o sistema de controle da turbina; a minutos e semanas, para a integração da energia eólica na rede elétrica [Giebel et al., 2003].

O médio prazo de previsão de velocidade do vento, intervalo de algumas horas até 10 dias à frente, apresenta um conjunto único de desafios. Isso porque, enquanto previsões de curto prazo dependem fortemente de dados recentes [Bouche et al., 2023] e o longo prazo é influenciado por padrões mais amplos; o médio prazo é um delicado equilíbrio entre ambos extremos. Esse intervalo é particularmente importante para o setor elétrico já que influencia sua tomada de decisão [Möhrle et al., 2022; Cotia et al., 2019], em especial se incertezas na previsão são consideradas [Tuohy et al., 2009; Bouffard e Galiana, 2008]. Adicionalmente, o médio prazo também é crucial para preparação à desastres e planejamento da manutenção.

Atualmente o estado da arte para previsão de variáveis climáticas para o médio prazo são Modelos de Previsão Numérica (*Numerical Weather Prediction*, NWP). No entanto, desenvolvimentos recentes em Aprendizado de Máquina (*Machine Learning*, ML), especialmente Aprendizado Profundo (*Deep Learning*, DL), têm desafiado o pódio por oferecer performance similar por um custo computacional bastante inferior [Schultz et al., 2021; Lam et al., 2023].

Assim, esse trabalho propõe a utilização de técnicas desenvolvidas para previsão de imagens, para previsão de velocidade do vento em uma área pré-definida. Isso é feito considerando cada par latitude e longitude como o pixel de uma imagem com dois canais, as componentes u- e v- do vento [Ronneberger et al., 2015]. A partir disso são aplicados avanços da área de reconhecimento de imagem [Russakovsky et al., 2015] para capturar dependências espaciais e temporais do vento.

Por exemplo, no caso do Brasil, a geração eólica atingiu 81.6 TWh em 2022, representando 13% de aumento em relação a 2021. Isso corresponde a 11.8% da oferta de energia, após hidrelétrica (58%) e combustíveis fósseis (15.7%) [Office, 2023]. Sendo comum em sistemas com bastante hidrelétrica, uma cadeia de modelos de otimização é utilizada para otimizar os diferentes horizontes de planejamento [Helseth et al., 2023].

No entanto, ao contrário de água que pode ser armazenada por meses, geração eólica pode variar rapidamente com a variação da velocidade do vento, tornando a inclusão de incerteza para os modelos de curto prazo cada vez mais importante. Maceira et al. [2023], por exemplo, adapta a estrutura atual de reservatórios equivalentes de hidrelétrica para o modelo de médio prazo, DECOMP [CEPEL, 2021]; permitindo incluir geração de outras fontes como eólica e solar; e inclusive considerar suas correlações, como faz Luiz Diniz et al. [2018].

Portanto, esse trabalho propõe a previsão das componentes de velocidade do vento, u- e v-, como se fossem imagens subsequentes de dois canais para apoiar a operação de curto prazo. O modelo utilizado é uma rede totalmente convolucional condicionada no passo anterior para prever o próximo, um passo por vez; além de incluir variáveis de calendário, como hora e mês. O modelo é treinado utilizando o conjunto de reanálise mais recente do Centro Europeu de Previsão de Tempo para o Médio prazo (*European Center for Medium-term Weather Forecast*, ECMWF), ERA5 (*ECMWF's ReAnalysis 5*). Essa proposta foi aplicada no caso brasileiro, considerando três características principais: a crescente influência de geração eólica, a tendência de utilizar cenários para horizontes mais curtos; e a existência do Operador Nacional do Sistema Elétrico (ONS) que frequentemente lida com cenários para diferentes horizontes.

Esse trabalho está organizado da seguinte forma: a seção 2 apresenta os diferentes modelos já aplicados para o desafio de previsão de velocidade do vento; a seção 3 descreve o pré-

processamento dos dados e então brevemente introduz os conceitos necessários para descrever o modelo; a seção 4 detalha a obtenção dos dados e visualizações; a seção 5 apresenta os resultados do treinamento e compara com outros modelos referência; e finalmente a seção 6 conclui o trabalho.

2. Literatura

A previsão de velocidade e direção do vento é objeto de diversos estudos, geralmente aplicados para a área de energia. A tabela 1 traz uma visão geral dos trabalhos existentes.

Tabela 1: Related papers

	Dados	Modelo	Resultado
Nielsen et al. [1998]	-	Propõe uma modificação no modelo de Persistência (<i>Naive</i>), fazendo-o se aproximar da média de longo prazo; melhorando a performance do modelo para prazos mais longos.	Embora simples, demonstra que o modelo é capaz de superar o estado da arte (NWP) no intervalo de até 4 horas et al. [2011]
Brown et al. [1984]	Utiliza dados de sensores de <i>Pacific Northwest, Godnoe Hills</i> e <i>Washington</i> (EUA) de Dezembro de 1981, tomando a média horária.	Avalia os processo autoregressivo com a métrica BIC. Escolhe o modelo AR(2) para previsões de até 3 horas, observando rápida degradação dos cenários.	Prevê velocidade do vento considerando sua autocorrelação, distribuição não Gaussiana e não estacionariedade diurna; posteriormente extrapolando as previsões para a altura da turbina e transformando em geração a partir da curva de potência do gerador.
Bastos et al. [2021]	Dois conjuntos de dados horários das componentes u- e v- do vento, e temperatura do <i>Climate Forecast System Reanalysis</i> (CSFR) foram obtidos através do <i>Research Data Archive</i> (RDA).	Utiliza uma rede neural com duas partes: uma UNet Ronneberger et al. [2015] para extrair as características espaço-temporais; e então uma rede convolucional com camada de saída totalmente conectada para mapear as características para cada um dos pares latitude e longitude, modelando 181 séries próximas.	Os resultados mostraram que variáveis calendário melhoraram consideravelmente a performance dos modelos. Além disso, o trabalho sugere a utilização de um modelo totalmente convolucional, e a utilização de redes recorrentes (RNNs) para modelar esse problema sequencial.

Continua na próxima página

Tabela 1 – Continua na próxima página

	Dados	Modelo	Resultado
Lam et al. [2023]	Utiliza 39 anos (1979-2017) de dados climáticos do conjunto de reanálise ERA5.	Treina uma rede neural de grafo (GNN) para prever variáveis climáticas em resolução horária para até 10 dias à frente com resolução espacial global de 0.25° graus, otimizando o Erro Médio Quadrático (MSE) ponderado pelo nível vertical.	Demonstra que sistemas de previsão climáticos baseados em aprendizado de máquina (<i>Machine Learning-based Weather Prediction</i> , ou MLWP) são atualmente competitivos contra os modelos tradicionais de previsão numérica. Adicionalmente, mostra que o modelo performou bem para previsão de eventos extremos.

A partir dos estudos apresentados na tabela, pode-se observar que previsões de curto prazo sofrem de rápida deterioração. Além disso, poucos estudos exploram proximidade física entre localidades em seus modelos.

3. Metodologia

Essa seção se divide em quatro partes: primeiro, é apresentado o pré-processamento para os dados; então há uma breve explicação de redes neurais e convolucionais para descrever o modelo utilizado. Finalmente os modelos referência são apresentados.

3.1. Pré-processamento

O presente estudo possui uma etapa de pré-processamento simples voltada apenas para transformar o domínio dos dados para o intervalo $[-1, 1]$, não alterando sua distribuição. Para isso, o conjunto de treinamento é utilizado para estimar os valores mínimo e máximo por localização, trazendo para o intervalo $[0, 1]$; e então reescalando para o intervalo desejado. Esse processo completo é feito para cada par latitude e longitude, seguindo a equação 1:

$$\hat{y}^{h,w} = 2 \cdot \frac{y^{h,w} - m^{h,w}}{M^{h,w} - m^{h,w}} - 1 \quad (1)$$

3.2. Modelagem

Após o pré-processamento dos dados, esses são utilizados para estimação dos parâmetros dos modelos. A atual seção apresenta brevemente Redes Neurais e Convolucionais, e seu processo de aprendizado; então ilustra o modelo escolhido e finalmente apresenta os modelos referência, que serão usados na avaliação.

3.2.1. Redes Neurais e Convolucionais

Redes Neurais Artificiais são pilhas de regressões intercaladas por funções de ativação não lineares, permitindo que o modelo aproxime qualquer função contínua [Hornik et al., 1989]. Como consequência da utilização de funções não lineares na sua construção, não há forma explícita de estimar seus parâmetros. Assim, seu processo de treinamento é baseado no algoritmo de retropropagação, no qual diferentes conjuntos de exemplos são repetidamente apresentados para a rede, resultando em um erro de previsão. A partir desse erro, o gradiente de cada camada é calculado e utilizado para




Figura 1: Arquitetura do Modelo

atualização dos pesos; e então propagado para a camada anterior, até o início da rede [Linnainmaa, 1970].

Por serem extremamente flexíveis, novas formas de organizar esses neurônios foram propostas, com o intuito de restringir o aprendizado e diminuir a quantidade de pesos. Uma dessas alternativas é chamada de Redes Convolucionais. Inicialmente proposta para o processamento de imagens [Russakovsky et al., 2015], essa arquitetura leva em conta a informação de proximidade ao estimar filtros que são arrastados sobre uma entrada. O empilhamento de camadas convolucionais permite o aprendizado de formas cada vez mais complexas [Lecun et al., 1998], como o reconhecimento de linhas horizontais nas camadas iniciais até objetos nas camadas mais profundas.

3.2.2. Modelo

A arquitetura *UNet* foi escolhida pelo seu sucesso de transformação de uma imagem em outra [Ronneberger et al., 2015; Bastos et al., 2021], permitindo a previsão auto-regressiva de ambas componentes de velocidade do vento em uma área geográfica. É importante reparar que a rede é treinada para aprender a variação de um passo para outro, ao invés do valor absoluto.

Além de receber as componentes u - e v - de forma auto-regressiva, o modelo também recebe as informações de hora e mês como dois canais adicionais com valores constantes. Por exemplo, para a hora seis da manhã em Junho, o modelo receberá canais com $6/24 = 0.25$ e $6/12 = 0.5$, respectivamente, para toda a área geográfica.

Com a arquitetura escolhida, é necessário definir os hiper-parâmetros. Esses foram: profundidade de dois, ou seja, apenas uma conexão residual, que é também o limite de profundidade dada a resolução espacial dos dados, discutido na seção 4; expoente 4 para o cálculo da quantidade de filtros por camada: 16 filtros na primeira camada e 32 na seguinte; tangente hiperbólica como função de ativação nas camadas intermediárias e linear para a camada final, dado que é um problema de regressão. Outros hiper-parâmetros podem ser observados diretamente na implementação disponível ao final do trabalho.

Assim, o modelo treinado possui aproximadamente 39,8 mil parâmetros.

3.3. Treinamento

A etapa posterior ao tratamento dos dados e definição da arquitetura é a definição do treinamento. O modelo apresentado foi treinado para minimizar a média aritmética do Erro Quadrático Médio (MSE) de quatro passos à frente, como feito por Lam et al. [2023]. Além disso, a média aritmética do Erro Absoluto Médio (MAE) para o mesmo horizonte é acompanhada. Tal métrica é apresentada na seção 3.5.

3.4. Modelos Referência

Seguindo os trabalhos apresentados na seção 2, dois modelos referência foram escolhidos: Persistência, também conhecido como *Naive*, um modelo simples que apenas repete a última observação para todo horizonte H ; e o atual estado da arte de previsão numérica do ECMWF, SEAS5, sistema 51.

É importante ressaltar que o modelo de previsão numérica é ordens de magnitude mais custoso computacionalmente do que o modelo apresentado na seção 3.2.2 [Schultz et al., 2021], já que suas previsões são produzidas a partir da solução de um conjunto de equações diferenciais parciais. Além disso, suas previsões não estão restritas à área geográfica escolhida e descrita na seção 4, assim possuindo muito mais informação para suas previsões.

3.5. Avaliação

Após o treinamento, é importante avaliar a performance do modelo. Para isso é usada a média em um horizonte de 14 passos do Erro Médio Absoluto para todos os pares latitude e longitude, como apresentado na equação 2.

$$hMAE = \frac{1}{H \cdot h \cdot w} \sum_{i=0}^H \sum_{\forall h,w} y_i^{h,w} - \hat{y}_i^{h,w} \quad (2)$$

Onde H é o horizonte total; w, h são os pares latitude e longitude; $y_h^{h,w}$ e $\hat{y}_h^{h,w}$ são os valores original e previsto no ponto h, w no passo i .

O $hMAE$ é calculado para cada mês, e então é apresentada a média de todos esses valores.

4. Dados

Esse trabalho utiliza as componentes u- e v- de velocidade do vento do conjunto de reanálise disponibilizado pelo ECMWF através do Climate Data Store (CDS), um repositório online de dados climáticos. É importante ressaltar que a qualidade desses dados de representar o fenômeno real depende de qual área está sendo estudada de Aquino Ferreira et al. [2022]. No entanto, esses conjuntos foram escolhidos pelo seu fácil acesso e por seguirem metodologias próximas, permitindo a comparação dos resultados.

Assim, dois conjuntos de dados foram obtidos, ambos para a mesma área geográfica, definida pelas latitudes -4° até -9° e longitudes -34° até -39° ; para a mesma pressão, 1000 hPa, ou aproximadamente 100 metros acima do nível do mar, correspondendo a altura de uma turbina eólica típica. O primeiro conjunto, nomeado **reanálise**, corresponde ao ERA5 de 2011 até 2023. O segundo conjunto, nomeado **nwp**, corresponde às previsões numéricas, para os últimos 3 anos, de 2020 até 2022, utilizado para avaliar a performance do modelo. Finalmente, o último ano, 2023, é utilizado como conjunto de teste.

Como o conjunto reanálise possui resoluções espaciais e temporais superiores ao de previsão numérica (0.25° e horário, contra 1.00° e 12-horário, respectivamente), foi decidido ajustar o primeiro conjunto ao segundo, ilustrado na seção 4.1, afim de permitir a comparação direta entre os resultados.

Assim, o conjunto de treinamento contou com 236.664 ($\approx 365 \cdot 24 / 12 \cdot 9 \cdot 6 \cdot 6$) exemplos, organizados por **tempo, latitude, longitude e componente**.

4.1. Visualização dos Dados

Antes de analisar padrões nos conjuntos de dados, descritos na seção 4, é importante entender algumas características básicas dos dados. Assim, as Figuras 2 e 3 apresentam a diferença entre as resoluções espacial e temporal, respectivamente, entre os conjuntos *reanálise* e *nwp*. Conforme discutido acima, o primeiro conjunto é ajustado ao segundo. Assim, apenas os pontos em laranja são modelados.




Figura 2: Comparação das Resoluções espaciais dos conjuntos de dados




Figura 3: Comparação entre as Resoluções temporais dos conjuntos

Após ajuste à resolução espacial, podemos visualizar um exemplo. A Figura 4 representa as componentes em um instante do tempo. A visualização é feita utilizando a componente u - e v - como os tamanhos alinhados aos eixos horizontal e vertical, respectivamente, e a cor representa o módulo da velocidade. Já a Figura 5 mostra a diferença entre os padrões sazonais.

5. Resultados

A presente seção apresenta os resultados do treinamento e a comparação com modelos referência pela literatura.

5.1. Avaliação do Modelo

Antes de comparar o modelo proposto com as referências, é necessário validar o processo de treinamento. Diversas variações do modelo foram treinadas até a escolha final. Entre eles, as diferenças mais notáveis foram: treinamento para o horizonte de um (otimização apenas para o próximo passo), que resultou em um modelo pouco pior para o horizonte de validação (14 passos); previsão de H passos à frente utilizando a própria previsão do modelo, que não resultou em uma diferença notável; otimização da soma dos logaritmos dos erros quadráticos médios, que não também não alterou muito os resultados; utilização de Normalização por Instância (*InstanceNorm*), o que aumentou a quantidade de parâmetros aprendidos pelo modelo, e piorou muito os resultados; utilização de normalização L2 com diferentes valores para λ , que piorou pouco os resultados; e inclusão de uma etapa de pré-processamento na qual cada par latitude e longitude é dividido pelo seu desvio padrão, que alterou pouco os resultados.

A Figura 6 apresenta as curvas de perda e $hMAE$, métrica apresentado na seção 3.5, ou média aritmética para no horizonte H do erro absoluto médio, dos hiper-parâmetros escolhidos; para o treinamento do mesmo modelo com pontos iniciais (*seeds*) diferentes. Com isso foi escolhido o melhor modelo, ou seja, o que atingiu o menor $hMAE$ no conjunto de validação.

Finalmente, a Figura 7 mostra que o modelo aprendeu a dinâmica 12-horária da série, e se aproxima da média histórica, demonstrando aprendizado.

5.2. Comparativo com Referências

Após validação do treinamento, pode-se comparar com os modelos referência. Afim de ilustrar a performance e comparar visualmente, escolheu-se o mês de Fevereiro de 2023 nas coordenadas $(-5.0, -39.0)$. A Figura 8 trás a previsão de cada um dos modelos e o $hMAE$ na legenda.




Figura 4: Velocidades de Vento instantânea na resolução espacial de *nwp*




Figura 5: Variação Intra-diária por Componente por Estação




Figura 6: Gráfico de Perda e hMAE




Figura 7: Validação do Aprendizado comparando padrões do conjunto de treinamento contra previsão, componente u-

Velocidade por Componente de 2023-02-01 00:00:00 em (-5.0, -39.0)




Figura 8: Exemplo de série prevista

É fácil observar que o modelo aprendeu o padrão 12-horário e acompanha bem a série, com erro inferior ao modelo numérico em ambas componentes.

Finalmente, foram calculados o $hMAE$ de 28 passos (duas semanas) para cada um dos modelos. A tabela 2 apresenta a média do $hMAE$ para todos os meses de todo conjunto de teste, 2023. É importante ressaltar que os resultados do modelo numérico (nwp) foram produzidos utilizando a média do membros (cenários).

6. Conclusões

Este trabalho propôs a utilização de uma rede totalmente convolucional para a previsão de séries das componentes u - e v - da velocidade do vento no nordeste brasileiro. O modelo foi treinado para minimizar o erro quadrático médio (MSE) de um horizonte de 48 horas (4 passos à frente) de forma auto-regressiva.

A metodologia proposta foi então comparada com outros dois modelos referência na literatura: Persistência (*Naive*) e o modelo de previsão numérica, o estado da arte. A proposta obteve um resultado melhor no conjunto de teste na previsão 28 passos à frente (duas semanas) em metade das comparações. Esse resultado é positivo, visto que a metodologia proposta possui um custo computacional bastante inferior ao estado da arte, além de possuir acesso a menos informação.

Como próximos passos, sugerimos incluir geração de cenários, já que são cruciais para a tomada de decisão no sistema elétrico [Tuohy et al., 2009; Bouffard e Galiana, 2008].

Referências

Bastos, B. Q., Cyrino Oliveira, F. L., e Milidiú, R. L. (2021). U-convolutional model for spatio-temporal wind speed forecasting. *International Journal of Forecasting*, 37(2):949–970. ISSN 0169-2070. URL <https://www.sciencedirect.com/science/article/pii/S0169207020301618>.

2023	proposta	persistência	nwp
Janeiro	(0.877, 0.904)	(0.985, 1.563)	(0.787, 1.059)
Fevereiro	(0.861, 0.956)	(1.094, 1.808)	(0.964, 1.029)
Março	(0.984, 0.974)	(1.331, 1.579)	(0.990, 1.212)
Abril	(1.262, 0.998)	(1.336, 1.43)	(1.036, 0.956)
Maio	(1.005, 1.551)	(1.339, 1.567)	(0.904, 1.315)
Junho	(0.839, 1.127)	(1.618, 1.856)	(0.878, 0.989)
Julho	(0.941, 1.788)	(1.321, 2.218)	(0.878, 1.395)
Agosto	(0.874, 1.17)	(1.717, 1.639)	(0.924, 1.205)
Setembro	(0.938, 1.901)	(1.172, 3.015)	(0.963, 0.896)
Outubro	(0.787, 1.171)	(1.687, 2.334)	(0.796, 1.03)
Novembro	(0.742, 1.487)	(1.274, 2.516)	(0.817, 1.085)
Dezembro	(0.711, 1.200)	(1.06, 1.872)	(0.813, 1.184)

Tabela 2: Média do $hMAE$ da previsão de 28 passos (duas semanas) para todos os meses do conjunto de teste por componente, ordenado (u-, v-)

- Bouche, D., Flamary, R., d'Alché Buc, F., Plougonven, R., Clausel, M., Badosa, J., e Drobinski, P. (2023). Wind power predictions from nowcasts to 4-hour forecasts: A learning approach with variable selection. *Renewable Energy*, 211:938–947. ISSN 0960-1481. URL <https://www.sciencedirect.com/science/article/pii/S0960148123006201>.
- Bouffard, F. e Galiana, F. D. (2008). Stochastic security for operations planning with significant wind power generation. *IEEE Transactions on Power Systems*, 23(2):306–316.
- Brown, B. G., Katz, R. W., e Murphy, A. H. (1984). Time series models to simulate and forecast wind speed and wind power. *Journal of Climate and Applied Meteorology*, 23(8):1184–1195. URL [https://doi.org/10.1175/1520-0450\(1984\)023<1184:tsmtsa>2.0.co;2](https://doi.org/10.1175/1520-0450(1984)023<1184:tsmtsa>2.0.co;2).
- CEPEL (2021). Cepel. URL <https://www.cepel.br/wp-content/uploads/2022/05/DECOMP\%5FManualReferencia\%5FOut2021.pdf>. Accessed at 2024/02/05 from <https://www.cepel.br/produtos/documentacao-tecnica/>.
- Cotia, B. P., Borges, C. L., e Diniz, A. L. (2019). Optimization of wind power generation to minimize operation costs in the daily scheduling of hydrothermal systems. *International Journal of Electrical Power & Energy Systems*, 113:539–548. ISSN 0142-0615. URL <https://www.sciencedirect.com/science/article/pii/S0142061519301024>.
- de Aquino Ferreira, S. C., Cyrino Oliveira, F. L., e Maçaira, P. M. (2022). Validation of the representativeness of wind speed time series obtained from reanalysis data for brazilian territory. *Energy*, 258:124746. ISSN 0360-5442. URL <https://www.sciencedirect.com/science/article/pii/S0360544222016498>.
- et al., G. G. (2011). The state-of-the-art in short-term prediction of wind power a literature overview, 2nd edition document type deliverable.
- Giebel, G., Kariniotakis, G., e Brownsword, R. (2003). The state-of-the-art in short term prediction of wind power from a danish perspective. In *4th International Workshop on large scale integration of wind power and transmission networks for offshore wind farms*, Billund, Denmark. URL <https://minesparis-psl.hal.science/hal-00529986>.

- Helseth, A., Melo, A. C. G., Ploussard, Q. M., Mo, B., Maceira, M. E. P., Botterud, A., e Voisin, N. (2023). Hydropower scheduling toolchains: Comparing experiences in brazil, norway, and USA and implications for synergistic research. *Journal of Water Resources Planning and Management*, 149(7). URL <https://doi.org/10.1061/jwrmd5.wreng-5911>.
- Hornik, K., Stinchcombe, M., e White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5):359–366. ISSN 08936080.
- Lam, R., Sanchez-Gonzalez, A., Willson, M., Wirsberger, P., Fortunato, M., Alet, F., Ravuri, S., Ewalds, T., Eaton-Rosen, Z., Hu, W., Merose, A., Hoyer, S., Holland, G., Vinyals, O., Stott, J., Pritzel, A., Mohamed, S., e Battaglia, P. (2023). Learning skillful medium-range global weather forecasting. *Science*, 382(6677):1416–1421. URL <https://www.science.org/doi/abs/10.1126/science.adi2336>.
- Lecun, Y., Bottou, L., Bengio, Y., e Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- Linnainmaa, S. (1970). The representation of the cumulative rounding error of an algorithm as a Taylor expansion of the local rounding errors.
- Luiz Diniz, A., Da Serra Costa, F., Elvira Maceira, M., Norbiato dos Santos, T., Dos Santos, L. C. B., e Neves Cabral, R. (2018). Short/mid-term hydrothermal dispatch and spot pricing for large-scale systems-the case of brazil. In *2018 Power Systems Computation Conference (PSCC)*, p. 1–7.
- Maceira, M. E. P., Melo, A. C. G., Pessanha, J. F. M., Cruz, C. B., Almeida, V. A., e Justino, T. C. (2023). Combining monthly wind and inflow uncertainties in the stochastic dual dynamic programming. *Energy Systems*. URL <https://doi.org/10.1007/s12667-023-00580-5>.
- Möhrlen, C., Bessa, R. J., e Fleischhut, N. (2022). A decision-making experiment under wind power forecast uncertainty. *Meteorological Applications*, 29(3):e2077. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/met.2077>.
- Nielsen, T. S., Joensen, A., Madsen, H., Landberg, L., e Giebel, G. (1998). A new reference for wind power forecasting. *Wind Energy*, 1(1):29–34. URL <https://onlinelibrary.wiley.com/doi/abs/10.1002/%28SICI%291099-1824%28199809%291%3A1%3C29%3A%3AAID-WE10%3E3.0.CO%3B2-B>.
- Office, E. R. (2023). Brazilian Energy Balance: summary report 2023 - reference year 2022. Report, Energy Research Office – Brazil, Esplanada dos Ministérios - Bloco U. Ministério de Minas e Energia - Sala 744 - 7º andar, 70065-900 Brasília – DF. URL <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-748/topico-687/BEN2023.pdf>.
- Ronneberger, O., Fischer, P., e Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., e Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3):211–252. ISSN 15731405.

- Schultz, M. G., Betancourt, C., Gong, B., Kleinert, F., Langguth, M., Leufen, L. H., Mozaffari, A., e Stadtler, S. (2021). Can deep learning beat numerical weather prediction? *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379 (2194):20200097. URL <https://doi.org/10.1098/rsta.2020.0097>.
- Tuohy, A., Meibom, P., Denny, E., e O'Malley, M. (2009). Unit commitment for systems with significant wind penetration. *IEEE Transactions on Power Systems*, 24(2):592–601.