

**CATEGORIA 1**

# Análise de recursos do vento



## MESO-TO-MICROSCALE COUPLING FOR WIND FLOW MODELING: A CASE STUDY IN SOUTHERN BRAZIL

Bernardo dos Santos Piccoli<sup>1</sup>, Adriane Prisco Petry<sup>1</sup>

<sup>1</sup> Universidade Federal do Rio Grande do Sul, UFRGS

bernardo.piccoli@ufrgs.br, adrianep@mecanica.ufrgs.br

### ABSTRACT

As the wind energy market becomes more competitive and explores regions of significant complexity in terrain and atmospheric phenomena, the need for higher-fidelity flow models also becomes more relevant. This research work explores using a coupled meso-to-microscale approach to predict the freestream wind flow at a region of Southern Brazil. The coupling was performed by using mesoscale conditions as inlet profiles for microscale CFD simulations. The WRF mesoscale model was ran using two different Planetary Boundary Layer parametrizations, the YSU and MYNN parametrizations, for the month of July 2014. The shear profile calculated from mesoscale simulations was compared with the shear profile from on-site measured data. The YSU parametrization performed better both at capturing the overall shear coefficient and at capturing atmospheric stability and its change in magnitude during a typical day. The relative difference between measured and simulated shear was of +3.8% for the YSU parametrization and of -13.8% for the MYNN case. Microscale CFD simulations were ran using a steady RANS approach and the k- $\epsilon$  turbulence model, with the inlet potential temperature profile informed from mesoscale simulations for stable conditions. A comparison to wind speed data measured by the meteorological mast was performed to assess the quality of microscale simulations. For the YSU parametrization, the relative difference in measured wind speed went from 11.6% for standalone mesoscale simulations, to 4.1% when using the coupled meso-to-microscale approach. For MYNN, errors decreased from 20.2% to 4.2%. The proposed coupled approach significantly improved prediction of the wind flow in the region, using realistic profiles from mesoscale simulations and taking advantage of the high-resolution mesh of microscale simulations. For both standalone mesoscale simulations and the coupled meso-to-microscale approach, the YSU parametrization was the one that better captured the flow in the region.

### Keywords:

Wind flow modelling, atmospheric stability, mesoscale, meso-to-microscale coupling

### 1. INTRODUCTION

The Paris Agreement is a legally binding international treaty on climate change adopted by 196 Parties at the UN Climate Change Conference (COP21), in 2015. Amongst its main goals, described in Article 2, is the need to hold the increase in global average temperature to well below 2°C and pursue efforts to limit the increase to 1.5°C above pre-industrial levels (United Nations, 2015).

The Intergovernmental Panel on Climate Change (IPCC) estimates the planet is already 1.1°C warmer than pre-industrial levels, and that a swift response is needed to limit global warming. A reduction of 43% in greenhouse gas (GHG) emissions by 2030 and of 60% by 2035, compared to 2019 levels, is vital to respect the agreement (IPCC, 2023).

One of the most effective ways of reducing GHG emissions is by shifting away from an energy mix based on fossil fuels, to one based on renewable sources, such as wind and solar energy. However, since 2010, the share of renewable energies in the final global energy consumption has increased only slightly, staying around a threshold of about 10%. In order to limit global temperature increase to 1.5°C, a renewable energy share of approximately 66% in the energy mix by 2050 would be necessary - a six-fold increase compared to today (IRENA, 2020).

Such rapid increase can only be met by significant investment in renewable energies. In an ever more competitive market, assumptions about wind energy production during the planning phase of a project need to be more reliable and less uncertain than before, even if projects move towards regions with more complex terrain and challenging atmospheric flow.

Historically, linear models with significant simplifications to flow governing equations have been employed to predict wind conditions. Such models can provide reasonable results at projects with few topographical and ground coverage complexities, and with conditions close to theoretical wind speed vertical profiles. However, it is not expected that this will remain true at sites with complex terrain or complex atmospheric phenomena (Bleeg et al., 2015).

Consequently, there is a growing need for higher fidelity wind flow models. These models should provide adequate and reliable results even in challenging conditions. Higher fidelity models can be classified by the spatial scales they are able to represent. Mesoscale models capture the dynamic processes and features of the atmosphere by modelling or developing parametrizations for the full range of physics, including radiative transfer, cloud processes, boundary layer processes and interactions with the surface (Haupt et al., 2019), at a scale between 10 and 100 km and from hours to days. These features include weather fronts, low-level jets (LLJ) and sea breezes, for example.

Microscale models, on the other hand, are capable of simulating details of flow around complex terrain and ground coverage features, resolving fine scale turbulence and explicitly representing interactions with structures, such as wind turbines. Nonetheless, boundary conditions from microscale models lack the atmospheric physical processes to represent local forcings such as radiation, clouds, precipitation, and surface fluxes, present in mesoscale simulations (Draxl et al., 2021).

Between the limits of the length scales from both models, parameterization or modelling of turbulence is not well represented to simulate realistic ambient turbulence. This range of spatial scales for which existing turbulence models are expected to fail was termed as “terra incognita” (Wyngaard, 2004). The coupling between mesoscale and microscale models is a way of tackling the terra incognita challenge, especially nowadays, when computational power makes it possible to use microscale simulations for larger domains.

Through the insertion of information from mesoscale simulations as boundary conditions to microscale domains, it is possible to take into account the advantages of both models: accounting for broader atmospheric phenomena captured by mesoscale simulations, while using microscale simulations to better represent turbulent fluctuations caused by the wind flow itself, and also by terrain complexities, ground features and obstacles, such as wind turbines or forested patches. This coupling is the focus of this research work.

To perform a more quantitative assessment, an onshore site in the South region of Brazil was assessed. Measurements from a meteorological mast installed on-site were available and a representative measured month was chosen by assessing the available data. The representative month was then simulated by mesoscale models using two different parametrizations for the Planetary Boundary Layer (PBL).

Results were compared to measurements in an attempt to define the best suited PBL scheme for the site. Boundary conditions for stationary Computational Fluid Dynamics (CFD) simulations, which applied the Reynolds-Average Navier-Stokes (RANS) equations, were derived from both mesoscale models. Therefore, the coupling between mesoscale and microscale happened through the use of mesoscale data as boundary condition for microscale simulations. The coupled results were then compared to measurements, and to the different mesoscale parametrization tests.

The final goals of this research work were to find the most adequate mesoscale parametrization for the PBL at the site, and to highlight the benefits of using mesoscale to microscale coupling onshore, including its significant reduction in prediction errors when compared to measurements and to standalone mesoscale simulations for the freestream wind flow.

## 2. STATE OF THE ART

Several articles have been released in recent years studying the coupling of meso-to-microscale simulations with applications for wind energy. The vast majority of them uses the Weather Research and Forecasting (WRF) Model, which is a state-of-the-art mesoscale numerical weather prediction system developed by the National Center for Atmospheric Research (NCAR). The model can be used for both atmospheric research and operational forecasting applications, at real or idealized scenarios (Skamarock et al., 2008).

The WRF model introduces several parametrizations to describe some key aspects of the atmospheric flow, such as microphysics related to the formation of particles, the impact of radiation and cumulus development, and, perhaps most importantly for wind energy applications, parametrizations concerning the Planetary Boundary Layer in the atmosphere.

Prior to the development of the New European Wind Atlas (NEWA), which is a wind resource assessment tool based on mesoscale simulations from WRF coupled to a microscale linear model, a comprehensive sensitivity assessment was performed by Hahmann et al., 2020, to define the best parameters for mesoscale simulations.

Three nested domains were used to refine spatial resolution until reaching the main areas of interest. The outer domain used a resolution of 27 km, the intermediate domain had a resolution of 9 km, while the inner domain was run with a resolution of 3 km.

Two different PBL schemes were assessed: the Yonsei University scheme (YSU) (Hu; Klein; Xue, 2013) scheme, which uses nonlocal closure, and the Mellor-Yamada-Nakanishi-Niino (MYNN) (Nakanishi; Niino, 2006) scheme, which is parametrized based on local turbulent kinetic energy prediction. Significant differences were observed between both schemes, both onshore and offshore. Differences were related to the ability of each model to capture neutral, stable and unstable flow conditions, as well as the prediction of the wind speed magnitude itself. Overall, the MYNN scheme outperformed YSU in 5 of 8 test cases, when compared to on-site measurements.

Durán et al., 2020, assessed mesoscale to microscale coupling for five onshore locations, also comparing results with on-site measurements. Of the five sites, two were slightly complex with a marked diurnal cycle of wind and temperature, two had flat terrain with stable atmospheric conditions and one presented very complex terrain features.

The coupling approach used average results of wind and potential temperature from the mesoscale simulations as input for microscale simulations performed at steady state. The WRF model was run with version 3.7.1, with one year simulated at each site and three nested domains with horizontal resolution of 9 km, 3 km and 1 km were simulated. The PBL parametrization chosen was the MYNN scheme.

Microscale simulations were performed applying the RANS equations at steady state and the k- $\epsilon$  turbulence closure model. Results highlighted the importance of using boundary conditions informed by mesoscale patterns to correctly account for atmospheric stability, especially in complex terrain. Additionally, boundary conditions from coupled simulations were more suited to reproduce horizontal wind changes caused by horizontal pressure gradients and the Coriolis force, for example, while the analytical boundary conditions were mostly affected by complexity in the terrain, without accounting for other important factors.

The majority of studies demonstrated improved results when the coupled meso-to-microscale approach was applied. The mesoscale simulations are able to capture atmospheric phenomena driven by parameters often neglected in microscale simulations. This information can then be fed into microscale simulations, in the form of boundary conditions, for example. Such boundary conditions reproduce

important atmospheric flow characteristics, too often not considered in the commonly used analytical profiles of CFD simulations. Microscale simulations, however, are necessary to capture the local changes of the flow when interacting with terrain and ground complexities – as well as considering the local effect of buoyancy and the Coriolis effect.

### 3. METHODOLOGY

#### 3.1. Met mast data

The assessed met mast was installed in the northwest region of the state of Rio Grande do Sul, in Brazil. Measurements were performed for a period of three years between August 2013 and April 2016. Anemometers were installed at three different heights: 100 m, 80 m and 60 m. Wind vanes were installed at two heights: 98 m and 78 m. The met mast was also equipped with temperature, pressure and relative humidity sensors.

After the cleaning stage, the overall data coverage for each sensor of interest was calculated. Based on the data coverage, a representative year was chosen to be further assessed, mainly through the investigation of monthly mean wind speed, wind direction and of the shear coefficient,  $\alpha$ , calculated as described in Equation (1):

$$\alpha = \frac{N \sum_i \ln(z_i) \ln(u_i) - \sum_i \ln(z_i) \sum_i \ln(u_i)}{N \sum_i (\ln(z_i))^2 - (\sum_i \ln(z_i))^2} \quad (1)$$

Where the index  $z_i$  represents each measurement height,  $u_i$  the measured wind speed at each height and  $N$  the number of heights (WindFarmer User Guide, 2024).

One month of the selected year was then simulated in the WRF mesoscale model, using two different Planetary Boundary Layer parametrizations. Shear coefficient plays an important role in the choice of the assessed period, since it was the main parameter available from measurements to classify atmospheric stability.

#### 3.2. WRF setup

The mesoscale model was setup using version 4.3.0 of WRF. Table 1 presents the parametrizations for both test cases. More information about parametrizations available in WRF can be found in WRF’s user guides (Skamarock et al., 2008). From here onwards, mesoscale runs will be identified by the PBL parametrization used in each one of them: YSU or MYNN.

Table 1 - Parametrization schemes for the WRF simulations

Parametrization	YSU simulation	MYNN simulation
Microphysics	Thompson	Thompson
Longwave radiation	RRTM	RRTM
Shortwave radiation	Dudhia	Dudhia
Surface layer	Revised MM5 Monin-Obukhov	MYNN
Land-surface layer	Noah	Noah
PBL	YSU	MYNN 2.5
Cumulus	Kain-Fritsch	Kain-Fritsch

Three nested domains were simulated, all of them centered in the mast position. As recommended in WRF best practices, 100 cells were used for each domain with a resolution ratio of 1:3. Final resolutions were of 27 km for the outer domain, 9 km for the middle domain and 3 km for the central domain, from which results were extracted. The final mesh configuration is presented in Figure 1.

36 vertical levels were simulated, following an exponential profile, which is commonly used in WRF to allow more levels to be simulated closer to the ground or inside the PBL - the zone of interest for studies related to wind energy. The center of the bottom cell was located 11.2 m above the ground, while the higher level was located at 14388.9 m above ground level. 10 of the 36 vertical levels were located below 205 m.

Used inputs for the boundaries were the ERA-5 dataset for meteorological data such as wind speed and potential temperature, and the Optimum Interpolation Sea Surface Temperature (OISST) database (Huang et al., 2021), developed by the National Oceanic and Atmospheric Administration, for properties such as land categorization, sea surface temperature and albedo. Time-varying information was inputted in the lateral and bottom boundaries at every 6 hours. Topographical data was obtained from the Shuttle Radar Topography Mission (SRTM) (Farr et al., 2007), developed by NASA.

Simulations were restarted at every 3 days to avoid the accumulation of integration errors. Results were saved at every hour, but the simulation time steps were of 120s for the 27 km domain, 40s for the 9 km domain and 13.3s for the 3 km domain. This follows WRF's best practice, which recommends a time step equal or lower to 6 times the domain resolution in kilometres. For example, if the domain has 3 km, the time step should be of 18s or lower.




Figure 1 - Final WRF nested domains

### 3.3. CFD simulations setup

CFD simulations followed the setup recommended by Bleeg et al., 2015, which accounts for buoyancy, the Coriolis effect and stable stratification of the free atmosphere. The k- $\epsilon$  turbulence model was applied to solve the closure problem of the RANS equations on the Star CCM+ software.

Ground coverage was defined based on the Global Land Cover 2019 database. The aerodynamic length definition for the Project area was based on the Davenport classification, with slight derivations from it to guarantee numerical convergence (Wieringa, 1992). Topographical data was obtained from SRTM at a resolution of 30m.

The edges of the topography map were smoothed to avoid the development of unrealistically flow patterns at the inlet and outlet, which could cause numerical instability and the propagation of unphysical

pressure waves. The non-smoothed region started at least 5 km away from the edges of the domain, as shown in Figure 2, which meant the mast was at least 15 km away from the lateral boundaries.

The horizontal CFD mesh had a resolution of 25 m at the region of interest near the mast, which was then gradually coarsened by factors of 2 until the edges of the domain, where the mesh resolution was of 200 m. The total domain covered an area of 30 km by 30 km. The horizontal view of the mesh, presented in Figure 3, highlights both the elevation map and the coarsening of the mesh from the central point of interest, which is to the left of the image.




Figure 2 - Topography map for CFD simulations




Figure 3 - Elevation map and CFD mesh at ground level

The inlet boundary conditions were composed of profiles of wind speed, potential temperature, kinetic turbulent intensity, and dissipation of kinetic turbulence. At the outlet, pressure and potential temperature profiles were defined.

CFD simulations were performed only when the atmospheric conditions from the mesoscale simulations were deemed stable. The classification of stability was based on the ground heat flux, a parameter calculated by WRF. When the ground heat flux was negative, the atmosphere was considered as statically stable.

The CFD inlet potential temperature profiles were defined based on potential temperature profiles from the mesoscale simulations. WRF results were extracted for the point closest to the CFD domain boundary at the prevalent wind direction of 22.5°.

The remaining conditions of wind speed, kinetic turbulent intensity and dissipation of kinetic turbulence were defined based on well-known empirical correlations, also applied by Blegg et al., 2015 and Barriatto, 2018.

## 4. RESULTS AND DISCUSSIONS

### 4.1. Met mast data

Considering the annual and monthly data coverage, a period from Oct-2013 to Sep-2014 was chosen as a representative year. In this period, data coverage was above 99% for all measured signals.

The shear coefficient for each month is presented in Table 2, alongside the normalized wind speed at 100m. The month of Nov-2013 stands out as the windiest month, followed by Sep-2014, Jul-2014, Jun-2014 and Aug-2014.

Table 2 - Normalized wind speed at 100m and shear coefficient for each month of interest

	Oct-13	Nov-13	Dec-13	Jan-14	Feb-14	Mar-14	Apr-14	May-14	Jun-14	Jul-14	Aug-14	Sep-14
Normalized wind speed at 100m	1.05	1.20	0.95	0.91	1.04	0.97	1.04	0.90	1.15	1.18	1.14	1.20
Shear coefficient	0.23	0.23	0.23	0.21	0.24	0.27	0.22	0.23	0.25	0.33	0.27	0.27

It was also observed that during winter months, the wind blows mainly from northern sectors and at higher wind speeds, especially in June and July. Throughout all months, the hourly wind roses show a strong diurnal cycle, with higher wind speeds during the night and lower wind speeds during the day. From December to May, the wind speed magnitude is lower, and the wind rose is more multidirectional.

Considering the strong atmospheric stratification, the high measured wind speeds, the more unidirectional wind rose and the adequate data coverage, the month of July 2014 was chosen as the most representative month to be simulated in WRF.

### 4.2. WRF simulations

Simulations for the month of July 2014 on the region of the mast were performed for both parametrization setups mentioned in Table 1. The wind rose for each simulation is presented in Figure 4, showing good agreement between them.

WRF results and mast data were filtered to account only for North and Northeast sectors, which are the prevalent directions for the winter months.

The shear coefficient was calculated for each hour of the day for the met mast wind speed measurements and for the WRF simulations. For the mast, the anemometers installed at 60m, 80m and 100m were used for the calculation. For the WRF runs, horizontal wind speed from the levels closest to the



measurement heights were used: 64.3m, 80.4m and 104.6m. The selected cell from WRF was also the one nearest to the met mast location. For the mast, 10-minute recordings were first resampled to hourly timestamps, and then averaged through the month. Only wind speeds higher than 3 m/s at the selected heights were considered for shear calculation.

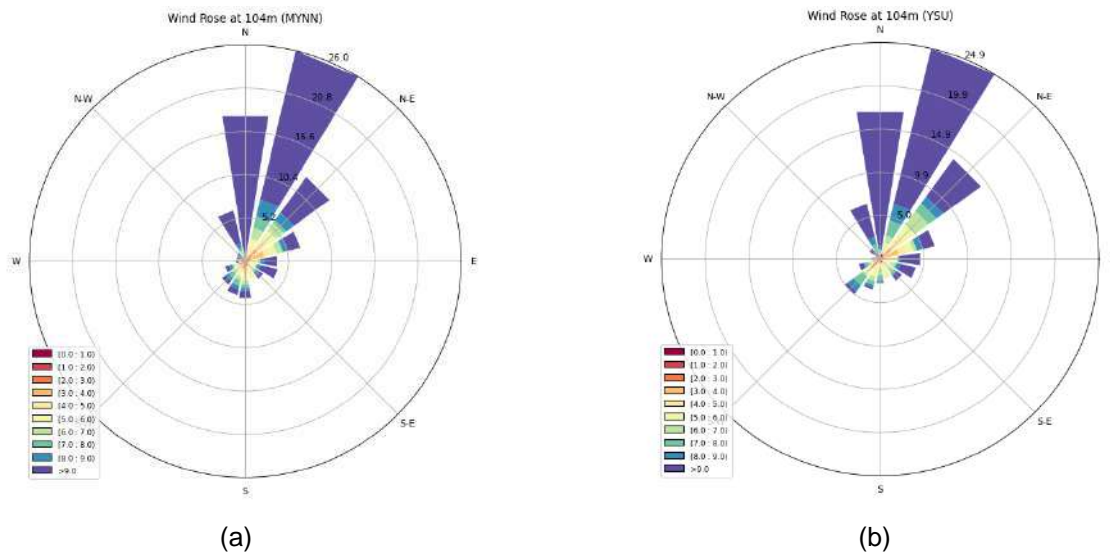


Figure 4 - Wind Rose at (a) WRF simulations with MYNN parametrization, (b) WRF simulations with YSU parametrization

A classification between stable, unstable or neutral flow was performed based on the study of (Durán et al., 2019), where shear coefficients higher than 0.2 are considered representative of a strongly statically stratified atmosphere, while values lower than 0.1 represent unstable conditions. Shear coefficients between 0.1 and 0.2 are deemed as typically neutral.

The measured shear coefficients were well in line with the typical evolution of the atmospheric boundary layer: during the night, while there are less heat exchanges between the atmosphere and the ground, shear coefficients were higher, as the atmosphere presents an elevated degree of static stability. Convection between the “layers” in the atmosphere is less pronounced, which represents a more significant increase in wind speed with the increase in height above the ground.

As the day progresses, the heat of the Sun warms the ground and facilitates convective exchanges between layers and the development of stronger turbulence, decreasing the shear coefficient and the difference in wind speed between measurement heights. Since July is a winter month in the southern hemisphere, this heating process takes longer to start and is only observed close to noon at the met mast location.

As presented in Table 3, the WRF simulations are also able to capture this strong stability and its decay during the daytime. The same trend is observed when using shear or heat flux to quantify atmospheric stability. The magnitude of shear, however, is not as strong as for measurements, especially for the MYNN simulations and during the first morning hours. In general, the YSU simulations present a lower discrepancy compared to the mast measurements, with an average difference of +3.8% for the shear coefficient. This difference is of -13.8% for the MYNN parametrization. In general terms, the YSU parametrization seems to be the most adequate choice for standalone mesoscale simulations at the site.

Table 3 - Shear coefficient and stability classification for mast measurement and WRF simulations per hour of day

Hour of the day	Shear from mast	Stability classification (mast)	Shear from MYNN simulation	Stability classification (MYNN)	Shear from YSU simulation	Stability classification (YSU)
0	0.42	stable	0.35	stable	0.38	stable
1	0.42	stable	0.33	stable	0.39	stable
2	0.49	stable	0.29	stable	0.39	stable
3	0.46	stable	0.30	stable	0.36	stable
4	0.47	stable	0.32	stable	0.36	stable
5	0.46	stable	0.31	stable	0.36	stable
6	0.48	stable	0.32	stable	0.36	stable
7	0.55	stable	0.31	stable	0.41	stable
8	0.58	stable	0.30	stable	0.38	stable
9	0.41	stable	0.32	stable	0.38	stable
10	0.20	stable	0.22	stable	0.17	neutral
11	0.08	unstable	0.18	neutral	0.12	neutral
12	0.04	unstable	0.16	neutral	0.12	unstable
13	0.07	unstable	0.14	neutral	0.11	unstable
14	0.08	unstable	0.16	neutral	0.15	unstable
15	0.05	unstable	0.17	neutral	0.13	neutral
16	0.14	unstable	0.20	neutral	0.16	neutral
17	0.24	stable	0.26	stable	0.33	stable
18	0.31	stable	0.29	stable	0.39	stable
19	0.29	stable	0.30	stable	0.38	stable
20	0.33	stable	0.34	stable	0.39	stable
21	0.34	stable	0.31	stable	0.37	stable
22	0.36	stable	0.36	stable	0.38	stable
23	0.38	stable	0.36	stable	0.38	stable
Average	0.32		0.27		0.31	

### 4.3. CFD simulations

As described in Section 3.3, microscale CFD simulations were performed by applying the RANS methodology with  $k-\epsilon$  as the turbulence model. Only stable conditions were investigated using microscale simulations, since they were the prevalent conditions at the site during the assessed period, and also the one with highest wind speeds.

The coupling between mesoscale and microscale simulations was made by using the potential temperature profiles from WRF as inlet boundary conditions for the CFD simulations. The remaining inlet conditions of wind speed, turbulent kinetic energy and dissipation of turbulent kinetic energy were defined by using well-known empirical correlations and by assuring the boundary conditions were horizontally homogeneous.

Horizontally homogenous conditions are important to assure numerical convergence and the non-propagation of unphysical gravity and pressure waves. Residuals for continuity, momentum in all three directions, energy, turbulent kinetic energy and dissipation of turbulent kinetic energy were defined to be below the threshold of  $1 \cdot 10^{-3}$ .

From here onwards, microscale simulations will be identified by the name of their associated mesoscale parametrization, with the suffix CFD.

Figure 5 presents the wind speed profile at the position of the mast when the flow is considered stable for the standalone mesoscale simulations, as well as for the CFD simulations. The wind speeds at the measurement heights of the met mast are also highlighted.

Table 4 presents the relative difference between measured wind speeds at the meteorological mast and simulated wind speeds, both from microscale and mesoscale simulations, when the flow is considered stable. For simulated values, a cubic spline interpolation was used to calculate the horizontal wind speed at the specific measurement heights. From here onwards, the terms “relative differences” and “errors” will be used interchangeably, since the differences between simulated results and the measured reference data are a way of quantifying the accuracy of numerical simulations.

As previously mentioned, atmospheric conditions were deemed stable for the mesoscale simulations when the heat flux at the ground was negative. Since microscale simulations were derived using potential temperature profiles from WRF, the flow classification remains the same for CFD.

For the mast, wind speed was classified as stable when the shear coefficient calculated using wind speed measurements at 60 m, 80 m and 100 m was above 0.2, since the heat flux at the ground could not be calculated based on measured data. Sensitivity studies with the potential temperature profiles from WRF showed little difference between both classifications.

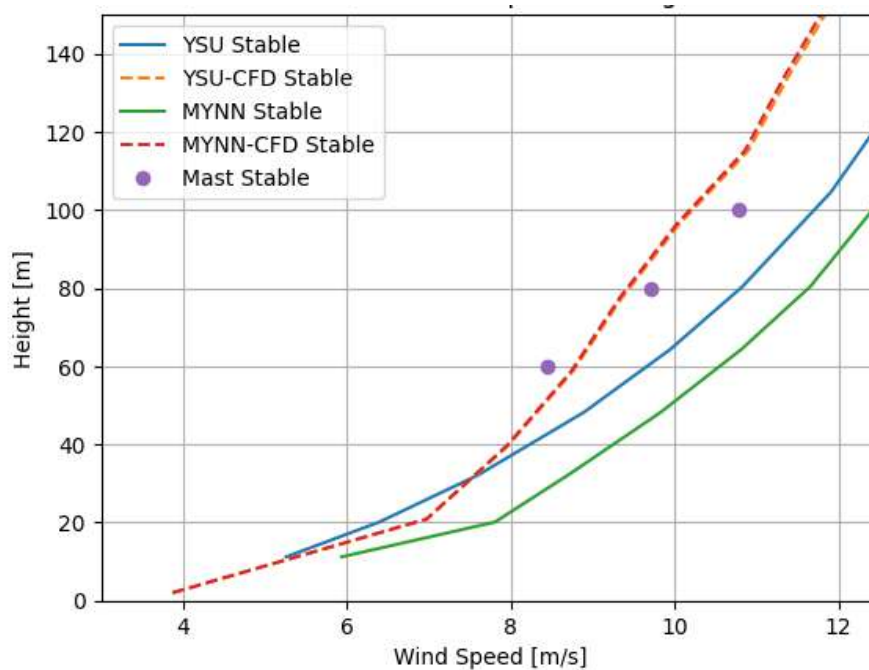


Figure 5 – Simulated and measured wind speed profiles for stable conditions at the mast location

Table 4 - Relative difference between measured and simulated data at measurement heights

Height [m]	Relative difference to measured wind speed [%]			
	YSU – CFD	YSU standalone	MYNN – CFD	MYNN standalone
60	4.3	14.7	4.1	25.2
80	-2.8	11.3	-3.1	19.9
100	-5.2	8.8	-5.5	15.4
Absolute average	4.1	11.6	4.2	20.2

A significant decrease in errors can be observed going from mesoscale to microscale simulations, which highlights two main points: the importance of a finer mesh resolution, characteristic of microscale simulations, to predict wind speeds at specific locations; and the robustness of the applied meso-to-microscale technique in capturing the wind flow at the region of interest. The wind speed distribution at the microscale domain is presented in Figure 6 for the YSU-CFD simulations.




Figure 6 - Wind speed distribution at the microscale domain (YSU-CFD)

It can also be observed that differences between both microscale simulations are quite small, not reaching more than 0.3% for any height. Differences between the mesoscale simulations, however, can reach more than 10%.

One possible explanation for this decrease in differences is the ability of inlet conditions to evolve throughout the simulation domain in microscale simulations, according to changes in terrain and ground coverage, before reaching the region of interest. Another reason could be the way the coupling technique was employed, since the potential temperature profiles are quite similar for YSU and MYNN, even though wind speeds may differ between both parametrizations.

In general, the YSU simulations have yielded lower errors when compared to measured data than MYNN simulations, both for standalone mesoscale results and the coupled approach. Therefore, the YSU parametrization is considered to be the most adequate to perform standalone mesoscale simulations at this area, to provide inlet boundary conditions for microscale CFD assessments and to capture the significant atmospheric stability observed on-site.

## 5. CONCLUSIONS

This study aimed at applying a coupled approach to model the freestream atmospheric flow at a region in Southern Brazil. The coupling used mesoscale simulations to inform inlet conditions of a microscale domain that was simulated through the use of RANS equations and a  $k-\epsilon$  turbulence model.

Mesoscale simulations were performed with the WRF model, which is based on several parametrizations to estimate how different elements of the atmosphere interact, such as the heat flux between the air and the ground, the formation of clouds and droplets, air humidity and the impact of long and shortwave radiation. For wind energy applications, the most important parametrization is the Planetary Boundary Layer parametrization. Several options are available, and two of the most used ones were investigated in this work: the YSU and the MYNN parametrization.

Simulations were run for the month of July 2014. The choice of the period was defined after careful assessment of the wind speed and wind direction data available from a meteorological mast in the region of study. The month presented high data coverage, strong winds and high atmospheric stability, which are both interesting phenomena to be modelled and also relevant for wind energy production.

Before the CFD model setup, mesoscale standalone results were compared to measured data. The wind speed distributions across the simulated domain were quite in agreement between both PBL parametrizations, and so were the wind rose, the horizontal wind speed and potential temperature profiles at the mast location.

A typical daily cycle of the atmospheric flow was also estimated based on the measured and simulated shear coefficient. For the measurement mast, strong stability could be observed during the nighttime and unstable flow patterns occurred during the afternoon, which is expected for this region and time of year. Mesoscale simulations were able to capture the same trend, although not with the same intensity. Overall, the relative difference between simulated and measured shear was of +3.8% for the YSU parametrization and of -13.8% for the MYNN parametrization, which seems to indicate the YSU PBL parametrization to be the one that better captures the flow and the strong atmospheric stability at the region during the assessed period.

Microscale simulations are important to capture local fluctuations in the flow due to changes in topography and ground coverage. These changes cannot be properly estimated by mesoscale simulations, due to its coarser horizontal resolution. The CFD model mesh had a resolution of 25 m in the region of interest, using non-structured polyhedral elements. The numerical setup accounted for the Coriolis effect and the impact of buoyancy on the flow and applied the meso-to-microscale coupling approach by taking into consideration the temperature profile coming from WRF.

To reduce the use of computational resources, only inlet boundary conditions deemed as stable at the prevalent wind direction were simulated using a microscale model. These were also the most frequent conditions at the region being assessed, and the ones with higher measured wind speeds. For the coupling, mesoscale conditions being fed into the CFD model were classified as stable or unstable based on the heat flux at the ground, and not based on the shear coefficient.

Results of microscale simulations were also similar in wind speed and turbulent intensity distributions for both cases, using the YSU or MYNN potential temperature profiles as inlet boundary conditions. The simulated wind speed profiles were much closer to each other for microscale simulations than for the standalone mesoscale ones, which can be verified by the relative errors when comparing simulated results to measured data.

For YSU, the relative difference went from 11.6% for standalone mesoscale simulations to 4.1% for the coupled approach. For MYNN, the relative difference went from 20.2% for standalone results to 4.2% for the coupled approach. These relative differences consider the average of differences at all heights where wind speed measurements were available for the met mast.

The YSU parametrization continued to outperform MYNN, which makes it the most suitable option to capture the strong atmospheric stability cycles at the region being studied. The reduction in errors when compared to measured data highlights the relevance of using microscale models with fine mesh resolutions to model the wind flow, as well as the robustness of the coupling approach being applied.

## ACKNOWLEDGMENTS

The authors wish to thank Hidropan Distribuição de Energia S.A. for making the measured data available for this study.

## REFERENCES

Barriatto, L. **Efeitos da estabilidade atmosférica na modelagem do escoamento para aplicações no setor de energia eólica**. Universidade Federal do Rio Grande do Sul. 2018.

Bleeg, J. et al. **Modeling stable thermal stratification and its impact on wind flow over topography.** *Wind Energy*, v. 18, n. 2, p. 369–383, fev. 2015.

Draxl, C. et al. **Coupling Mesoscale Budget Components to Large-Eddy Simulations for Wind-Energy Applications.** *Boundary-Layer Meteorology*, v. 179, n. 1, p. 73–98, abr. 2021.

Durán, P.; Meibner, C.; Casso, P. **A new meso-microscale coupled modelling framework for wind resource assessment: A validation study.** *Renewable Energy*, v. 160, p. 538–554, nov. 2020.

Farr, T. G. et al. **The Shuttle Radar Topography Mission.** *Reviews of Geophysics*, v. 45, n. 2, p. 2005RG000183, jun. 2007.

Hahmann, A. N. et al. **The making of the New European Wind Atlas – Part 1: Model sensitivity.** *Geoscientific Model Development*, v. 13, n. 10, p. 5053–5078, 27 out. 2020.

Hu, X.-M.; Klein, P. M.; Xue, M. **Evaluation of the updated YSU planetary boundary layer scheme within WRF for wind resource and air quality assessments: impact of vertical mixing on wind and O<sub>3</sub>.** *Journal of Geophysical Research: Atmospheres*, v. 118, n. 18, p. 10,490-10,505, 27 set. 2013.

Huang, B. et al. **Improvements of the Daily Optimum Interpolation Sea Surface Temperature (DOISST) Version 2.1.** *Journal of Climate*, v. 34, n. 8, p. 2923–2939, abr. 2021.

IPCC. **Climate Change 2023: Synthesis Report.** Intergovernmental Panel on Climate Change (IPCC), 2023.

IRENA. **Global Renewables Outlook: Energy transformation 2050.** International Renewable Energy Agency (IRENA), Abu Dhabi, 2020.

Nakanishi, M.; Niino, H. **An Improved Mellor–Yamada Level-3 Model: Its Numerical Stability and Application to a Regional Prediction of Advection Fog.** *Boundary-Layer Meteorology*, v. 119, n. 2, p. 397–407, maio 2006.

Skamarock, W. C. et al. **A Description of the Advanced Research WRF Version 3.** v. Note NCAR/TN-475+STR, p. 113, 2008.

United Nations. **Paris Agreement.** United Nations Framework Convention on Climate Change, Paris, 2015.

Wieringa, J. **Updating the Davenport roughness classification.** 1992.

**WindFarmer User Guide.** Accessed 16<sup>th</sup> June 2024, website at <<https://myworkspace.dnv.com/download/public/renewables/windfarmer/manuals/latest/CalcRef/WindAnalysis/Shear/Shear.html#power-law-extrapolation>>.

Wyngaard, J. C. **Toward Numerical Modeling in the “Terra Incognita”.** *Journal of the Atmospheric Sciences*, v. 61, n. 14, p. 1816–1826, jul. 2004.

## **Investigação da sinergia operacional entre geração fotovoltaica e eólica**

### **Estudo de caso no Ceará**

Davi Faula dos Santos<sup>1</sup>, Wadaed Uturbey<sup>2</sup>

Departamento de Engenharia Elétrica - Universidade Federal de Minas Gerais

davif1@ufmg.br<sup>1</sup>, wadaed@ufmg.br<sup>2</sup>

#### **RESUMO**

Este estudo tem como objetivo propor uma metodologia para avaliar a complementaridade intra-horária entre usinas solares fotovoltaicas e eólicas, contribuindo com a validação do uso da hibridização como estratégia para mitigar rampas na geração de energia. Ilustra-se a aplicação da metodologia com usinas situadas no estado do Ceará. Utilizando dados medidos e simulados foram analisadas diferentes proporções entre energia solar e eólica, avaliando o impacto de cada configuração. Os resultados indicam que uma combinação específica dessas fontes permite reduzir as rampas de geração, contribuindo com o aumento da robustez operacional do sistema, proporcionando assim uma potencial redução de investimentos em soluções alternativas para tratamento de rampas de geração. Esses resultados oferecem constatações relevantes para o planejamento e implementação de usinas hibridizadas, destacando seu potencial para otimizar a integração de fontes renováveis na matriz energética do país.

#### **Palavras-chaves:**

Rampas de Geração, Usinas Híbridas, Energia Solar, Energia Eólica.

#### **ABSTRACT**

This study aims to propose a methodology for evaluating intra-hourly complementarity between solar photovoltaic and wind power plants, contributing to the validation of hybridization as a strategy to mitigate ramps in energy generation. The application of the methodology is illustrated with plants located in the state of Ceará. Using both measured and simulated data, different proportions between solar and wind energy are analyzed, and the impact of each configuration analyzed. The results indicate that a specific combination of these sources can reduce generation ramps, contributing to increased operational robustness of the system, thus potentially reducing investments in alternative solutions for ramp management. These findings provide relevant insights for the planning and implementation of hybrid plants, highlighting their potential to optimize the integration of renewable sources into the country's energy matrix.

#### **Keywords:**

Generation Ramps, Hybrid Power Plants, Solar Energy, Wind Energy.

## 1. INTRODUÇÃO

O Brasil possui um vasto potencial natural para a geração de energia renovável. A existência de muitos rios de planalto é propícia para a geração de energia hidrelétrica, a ampla incidência solar em boa parte do território favorece a geração de energia solar, enquanto os ventos favoráveis, especialmente no nordeste brasileiro, impulsionam a geração de energia eólica, além disso, a grande disponibilidade de terrenos ajuda a viabilizar a realização de grandes projetos. Essas condições, aliadas a um cenário regulatório favorável, criaram um ambiente propício para a implementação e desenvolvimento de projetos de fontes renováveis de energia.

Entre esses projetos, os que envolvem fontes solares e eólicas se destacam no mercado, apresentando um crescimento significativo nos últimos anos e tornando-se cada vez mais competitivos em relação às fontes de energia convencionais. De acordo com dados do planejamento eletroenergético divulgado pelo ONS para o horizonte de 2024-2028 (ONS, 2024), é prevista a continuidade do crescimento das fontes mencionadas. A capacidade instalada de geração fotovoltaica, em usinas operadas de maneira centralizada, que em julho de 2024 encontrava-se em 13,8 GW, é prevista para crescer significativamente em um período de 4 anos, atingindo 22,3 GW. De maneira semelhante, é esperado que a capacidade de geração de energia eólica também tenha um notável aumento para o mesmo período, passando de 30,8 GW para 34,8 GW.

Paralelamente a essas previsões de crescimento e considerando os impactos que uma rede baseada fortemente em fontes intermitentes causa, é necessário um esforço na busca de sistemas mais integrados e eficientes. Nesse contexto, a associação de usinas eólicas com plantas fotovoltaicas tem se tornado uma estratégia cobiçada por investidores do setor devido às características complementares de geração que elas podem apresentar, em especial no nordeste brasileiro, conforme considerado e evidenciado por estudos, como (Campos, 2020) e (Gonçalves, Costa, Martins, & Pereira, 2020).

A complementaridade dessas fontes de energia permite uma geração mais resiliente e constante. Enquanto a geração de energia solar opera somente durante o dia, a geração eólica no Nordeste tende a ser mais forte à noite (Pessanha, Almeida, & Melo, 2021), resultando em uma distribuição mais uniforme de geração ao longo do dia. Entretanto, apesar de, geralmente, serem complementares e propiciarem benefícios, as usinas híbridas eólico-solares fotovoltaicas ainda enfrentam alguns desafios operativos comuns à geração a partir de fontes variáveis. Além do problema da incerteza na geração, que pode resultar em momentos de baixa ou nenhuma produção de energia, há desafios operacionais críticos, como as rampas rápidas de geração, caracterizadas por variações bruscas na produção de energia em um intervalo curto de tempo.

Essas variações repentinas representam uma complicação para a operação segura do sistema elétrico, pois demandam respostas rápidas e precisas para garantir a estabilidade. Na geração eólica, variações abruptas podem ocorrer quando a velocidade dos ventos ultrapassa ou fica aquém da faixa de operação das turbinas, na geração solar, essas variações podem ocorrer quando nuvens passageiras sombreiam os módulos do parque gerador. Em sistemas com grande penetração de fontes eólica e solar, essa vulnerabilidade pode impactar negativamente a estabilidade do sistema, e impõe desafios para a regulação da frequência do sistema elétrico, aumentando a complexidade operacional e, em determinados casos,



podendo acarretar prejuízos financeiros para os proprietários das usinas (da Rocha, et al., 2020; Diaz, 2019; Ackermann, et al., 2013). Devido a essas e outras razões, em países com uma participação significativa de fontes variáveis, foram implementadas medidas regulatórias para impor limites máximos às oscilações na produção de energia, com exemplos notáveis, como México, China e Alemanha (Diaz, 2019).

Com base nos pontos delineados, este estudo visa explorar a associação sinérgica das tecnologias solar fotovoltaica e eólica, centrando-se na avaliação de como a complementaridade entre essas fontes pode influenciar as rampas rápidas de geração. Reduzir a intensidade dessas variações não apenas melhora a qualidade da energia gerada, mas também pode viabilizar soluções, menos complexas e mais econômicas, para garantir maior resiliência da geração. Sob essa perspectiva, as usinas hibridizadas emergem como uma alternativa promissora para uma implementação eficiente tanto do ponto de vista técnico quanto financeiro ao mesmo tempo que preservam os benefícios das fontes renováveis. Este artigo é dividido em 4 seções principais, introdução, estado da arte, metodologia, um estudo de caso e as considerações finais quanto aos potenciais resultados da associação de fontes renováveis.

## **2. ESTADO DA ARTE**

Esta sessão traz uma contextualização sobre os assuntos previamente apresentados, promovendo uma discussão crítica acerca de conceitos e metodologias.

### **2.1. Energia Solar Fotovoltaica**

No contexto brasileiro, a energia solar fotovoltaica está ganhando destaque tanto na geração centralizada quanto na distribuída, cuja potência instalada proveniente dessa fonte representará mais de 19% da matriz elétrica nacional em 2024, e expectativas de alcançar mais de 24% até 2028 (ONS, 2024). O Nordeste do Brasil se posiciona como uma região especialmente privilegiada, com sua alta incidência solar ao longo do ano e menor variabilidade sazonal, conforme revelado pelo Atlas Solar Brasileiro (Pereira, Martins, De Abreu, & Ruther, 2006). Essas características tornam a região um polo promissor para o desenvolvimento de parques solares.

No entanto, é importante considerar os efeitos colaterais da alta penetração da energia solar fotovoltaica neste subsistema, como a variabilidade na geração de energia e os impactos na qualidade da energia e na estabilidade do sistema elétrico. Além disso, devem ser avaliadas as políticas e regulamentações necessárias para garantir a integração eficiente e sustentável dessas fontes de energia renovável.

### **2.2. Energia Eólica**

Por décadas, o desenvolvimento dessa fonte renovável foi limitado pela predominância de combustíveis fósseis e pela competitividade das hidrelétricas e termelétricas (Farias & Sellitto, 2013), todavia com o aumento da preocupação global com sustentabilidade e as melhorias tecnológicas as turbinas eólicas de grande porte ganharam destaque no cenário mundial.

No início dos anos 2000, o governo brasileiro investiu em programas como o Proinfa, que impulsionaram a indústria de geração eólica no país ao longo dos anos. Em 2019, cerca de 90% dos projetos de geração

eólica no país estavam concentrados na região Nordeste do País, beneficiando-se de ventos consistentes e de alta intensidade (Bezerra, 2019). Estudos do Instituto Nacional de Pesquisas Espaciais (INPE) indicam que o potencial eólico na região pode atingir até 880 GW em terra e 1,3 TW offshore, sublinhando a riqueza dos recursos disponíveis. Assim como para a geração solar fotovoltaica, a energia eólica tem caráter intermitente. Logo, evidencia-se também a necessidade de elaborar soluções técnicas para a integração dessa fonte no sistema, garantindo a estabilidade e eficiência do fornecimento de energia.

### **2.3. Tipologias de usinas híbridas**

A EPE (Empresa de Pesquisa Energética) publicou em 2018 um estudo sobre usinas híbridas, destacando a estratégia de combinação de fontes para melhorar a eficiência e confiabilidade do fornecimento de energia, o documento categoriza usinas em adjacentes, associadas, híbridas e portfólios comerciais. Usinas adjacentes compartilham proximidade geográfica e infraestrutura, enquanto as associadas otimizam o desempenho através de interconexões, por sua vez usinas híbridas integram diferentes fontes energéticas em um único processo, e portfólios comerciais envolvem a gestão e diversificação de várias usinas para otimizar recursos e investimentos.

Embora cada uma das categorias possa ter aplicações relevantes em diferentes contextos, a associação de usinas parece ser o caminho mais simples e viável para combinar fontes de energia. Em cenários onde se pretende hibridizar plantas já construídas, a implementação de usinas híbridas seria excessivamente complexa, requerendo mudanças significativas nos sistemas existentes, pois as fontes precisam compartilhar o mesmo conversor. Ademais, a incapacidade de identificar a origem específica da energia pode ocultar o mau desempenho de uma das fontes, dificultando a detecção e a correção de problemas. Portanto, a geração associada é uma abordagem vantajosa para combinar fontes, permitindo aproveitar os benefícios da complementaridade de diferentes fontes sob um único contrato e aumentando a utilização dos sistemas de transmissão.

### **2.4. Proporção entre as fontes eólica e solar**

Em um sistema associado de geração solar fotovoltaica e eólica é importante validar que, de maneira global, as fontes consigam produzir energia de forma complementar, melhorando o uso do sistema e identificando as proporções que trarão os melhores resultados.


Em um projeto, determinar a proporção ideal entre essas fontes pode exigir a consideração de diversos fatores, como a região onde o sistema será instalado, o nível de ociosidade da rede, se uma das usinas já está construída, a disponibilidade de recursos solares e eólicos, a demanda de energia e os custos associados. Diferentes estudos oferecem metodologias variadas para dimensionar sistemas híbridos, por exemplo, em (Nascimento, Campos, & Ruther, 2018) é levado em consideração uma usina eólica já existente e a capacidade ociosa da subestação é usada para dimensionar a capacidade máxima do sistema fotovoltaico, visando minimizar as perdas de energia devido a cortes. No estudo de complementariedade descrito em (Campos, 2020), a análise leva em consideração cálculos mais precisos, utilizando o Coeficiente de Correlação de Pearson (CCP) para quantificar a contribuição de cada fonte em diferentes escalas de tempo. Já em (Gonçalves, Costa, Martins, & Pereira, 2020), o autor busca otimizar as proporções com base na fração solar, realizando quantificação da variabilidade da geração híbrida em

horizontes horários, diários e mensais, utilizando métricas relacionadas à qualidade do fornecimento de energia.


## 2.5. Variabilidade Intra-horária de usinas solares e eólicas

Como citado, sistemas de geração intermitente enfrentam, além da variação de produção ao longo do dia, o desafio da variabilidade intra-horária, caracterizada por flutuações em intervalos inferiores a uma hora, essas variações podem gerar o indesejável efeito “rampa”. Este efeito, frequentemente desencadeado por fenômenos atmosféricos de curta duração, como a rápida passagem de nuvens ou variações repentinas da velocidade de vento, interferem na qualidade da energia entregue, exige respostas rápidas do sistema para garantir o fornecimento pleno a carga além de estressar equipamentos do sistema, como religadores, taps de transformadores, controladores de tensão e o sistema de proteção, (da Rocha, et al., 2020). Conforme evidenciado por Hofmann (2014), a detecção precisa desse fenômeno é frequentemente comprometida por instrumentos de medição que operam com intervalos de longa duração, superiores a 15 minutos. Essa limitação pode fazer com que as rampas de geração e seus efeitos adversos passem despercebidas em muitos estudos e análises. Portanto, abordagens de medição mais granulares são necessárias para compreender efetivamente os efeitos das rampas de geração causadas por fenômenos rápidos.

Conforme levantado por Mitchell et al. (2016), usinas solares apresentam menor variabilidade nos índices de rampa conforme sua potência instalada aumenta. No estudo citado, percebeu-se que, em uma análise temporal de 1 minuto, uma usina de 10 MWac era até 17% menos variável do que uma usina de 5 MWac. Entretanto, esse fator não elimina a ocorrência de rampas, especialmente em dias nublados, que são comumente usados como referência para estudos de soluções auxiliares para suavização de rampas. Na Figura 1, pode-se observar a intensidade de rampas em uma usina de 10 MWac em um dia de nebulosidade crítica, destacando-se a presença de degraus ascendentes e descendentes da geração ao longo do dia. Para a geração eólica, também observam-se variações rápidas na produção de energia devido a flutuações abruptas na velocidade do vento. Como ilustrado na Figura 2, essas variações podem ser bastante significativas, com mudanças na geração de energia ocorrendo em intervalos curtos de tempo. Diferentemente da geração solar, onde plantas maiores tendem a ter menor variabilidade na produção de energia devido ao efeito de escala, a geração eólica continua a exibir alta variabilidade mesmo em grandes sistemas, como no ERCOT (Electric Reliability Council of Texas) em que mesmo considerando todo um sistema multi-megawatts a potência eólica oscila de maneira estocástica, refletindo a natureza imprevisível e dinâmica do vento, (Wan, 2011).



**Figura 1:** Geração e taxa de variação de potência em um dia para uma usina solar de 10 MWac no Canada (Mitchell et al., 2016).



**Figura 2:** Variação da produção de energia ao longo de um dia de teste de parque eólico em Sri Lanka (Karunadasa et al., 2022).

Em países onde a penetração de energia proveniente de fontes não despacháveis é significativa e crescente, os governos aplicaram, por meio de regulação, regras para os limites de variação de rampas ascendentes e descendentes. Na Alemanha, o limite, em relação a capacidade instalada, é de 10%/min para rampas ascendentes (National Renewable Energy Laboratory (NREL), 2013), enquanto o México apresenta regras ainda mais rígidas, com limitações entre 2%/min e 5%/min para rampas ascendentes e entre 1%/min e 2,5%/min para rampas descendentes (Comisión Reguladora de Energía, 2012).

No Brasil, devido à forte presença de geração hidrelétrica, mesmo com uma parcela significativa da matriz elétrica sendo oriunda de fontes intermitentes, ainda há flexibilidade suficiente para contornar os desafios das rampas. No entanto, devido às perspectivas presentes no PNE 2050, considera-se que a parcela de energia variável ainda crescerá bastante, fragilizando a flexibilidade do sistema (Magalhães, Martins, & Dos Santos, 2022). Com esse cenário em mente, eventuais regulações podem surgir no contexto brasileiro, assim como nos países citados. Logo, toda solução que promova passivamente que o sistema de geração apresente rampas menos intensas é relevante, podendo até resultar em soluções de serviços ancilares mais econômicas, como sistemas de armazenamento (SAEs) com menor capacidade.

Para quantificar as rampas de geração, existem diferentes formulações e abordagens. Conforme discutido por (Deetjen, Rhodes, & Webber, 2017), a identificação da magnitude pode ser denominada fator de rampa. Esse índice calcula a taxa média de rampa entre intervalos de medição, ele mede a diferença na geração em um intervalo determinado, podendo ser expresso em relação à potência instantânea, equação 1 ou em relação à potência nominal da usina, embora para este estudo só sera aplicado a primeira.

$$FRR = \frac{P_i(k) - P_i(k-1)}{P_t} [P.U] \quad (1)$$

Em que,  $FRR$  representa o fator de rampa relativo,  $P_i(x)$  a potência instantânea no momento em watts e  $P_t$  a potência AC nominal da usina em watts,  $k$  representa o instante atual da observação, e  $k-1$  é o instante anterior ao momento de observação.

### 3. DESCRIÇÃO DA METODOLOGIA

A metodologia apresentada neste estudo é dividida em duas etapas. Na primeira etapa, realiza-se a análise da complementaridade global das fontes de energia solar e eólica e envolve a avaliação da sinergia da geração dessas fontes, verificando se há correlação entre os períodos de alta e baixa produção. Também, investiga-se a hipótese de que a hibridização das fontes pode suavizar as rampas, esta fase surge em um contexto em que pouco se sabe sobre o comportamento combinado das fontes e funciona como uma base exploratória para observar como a geração se comporta sob diferentes cenários de configuração das

usinas. Por fim, a segunda etapa busca identificar o melhor cenário, ou seja, aquele que resulta em uma geração com rampas mais suaves e tem como objetivo encontrar a melhor proporção entre as fontes solar fotovoltaica e eólica que minimize as variações abruptas na geração de energia.

### 3.1. Etapa 01: Estudo da complementariedade de geração

Como apresentado, este passo envolve a avaliação da sinergia na geração das fontes de energia solar fotovoltaica e eólica, verificando se há correlação entre os períodos de alta e baixa produção. Conforme apresentado pela EPE (2017), o perfil da complementariedade pode variar significativamente dependendo da região em que se busca implementar o projeto. Enquanto o perfil da geração solar tende a ser mais constante em diferentes regiões, a geração eólica está sujeita a uma maior sensibilidade regional (Pessanha, Almeida, & Melo, 2021). Logo, não há garantias de que a geração será complementar, por essa razão, é importante validar o comportamento previamente para diferentes horizontes, por exemplo, anual e mensal.

Tal sinergia pode ser aferida por meio da aplicação do CCP, uma ferramenta estatística para avaliar a relação linear entre duas variáveis quantitativas. O coeficiente de correlação de Pearson, denotado por  $r$ , mede tanto a força quanto a direção dessa relação linear. O valor de  $r$  varia de -1 a 1, em que  $r = 1$  indica uma correlação linear positiva perfeita,  $r = -1$  indica uma correlação linear negativa perfeita, e  $r = 0$  indica a ausência de correlação. A fórmula do coeficiente de correlação de Pearson é apresentada na Equação 3.1.

$$r = \frac{Cov(X,Y)}{\sigma_X \sigma_Y} \quad (2)$$

Em que,  $Cov(X,Y)$  representa a covariância entre as variáveis  $X$  e  $Y$  e  $\sigma_X \sigma_Y$  o desvio padrão das variáveis. No contexto de geração complementar, o ideal é que as duas fontes em comparação tenham um índice de correlação unitário negativo, indicando que quando uma fonte não gera, a outra produz. No entanto, ao analisar fontes eólicas e solares, é impossível alcançar um valor de correlação unitariamente negativo, as eólicas geram energia ao longo de todo o dia com variações na produtividade, e, além disso, o impacto das estações do ano faz com que o índice de correlação entre essas fontes varie ao longo do ano, existem períodos em que o módulo da correlação é mais elevado e outros em que é mais baixo.

Ainda nesta etapa, tem-se o objetivo de avaliar empiricamente o comportamento das associações entre fontes de energia, verificando se, em algum cenário, ocorre a suavização das variações na geração. Para essa análise, define-se três cenários distintos: um com predominância da energia solar, outro com predominância da energia eólica, e um terceiro com uma proporção equilibrada entre ambas as fontes. A única premissa para esses cenários é que a geração média das usinas em teste seja a mesma em todos os casos, definida como GMD, geração média desejada, e expressa em watts médios/ano.

Com a geração média determinada, é necessário tomar uma das usinas como referência, nomeada primária, e outra como fonte secundária. Desta forma, é preciso dimensionar a usina primária base e a usina secundária base, foi estabelecido que as usinas base são aquelas que, compostas por apenas um tipo de fonte, conseguem gerar a GMD, com esses conceitos definidos, a fonte primária torna-se também nossa referência dos cenários. A partir disso, são considerados três cenários: um em que a usina primária opera com 50% da capacidade original (cenário médio), outro com 90% da capacidade original (cenário

com predominância da fonte da usina primária) e um terceiro com apenas 10% da capacidade original (cenário com predominância da fonte da usina secundária). Em todos os cenários, a capacidade da usina secundária foi ajustada de forma que o resultado global do sistema alcançasse a GMD.

Os cálculos para determinação das capacidades das usinas são realizados da seguinte maneira: primeiro, é necessário calcular a geração média da usina primária ( $GMP$ ), conforme a Equação 3, em seguida, calcula-se a geração média necessária da usina secundária ( $GMS$ ), equação 4, por fim, as equações 5 e 6 descrevem a potência AC das usinas primária e secundária, respectivamente.

$$GMP = GMD \cdot FR [Wm/ano] \quad (3)$$

$$GMS = GMD - GMP [Wm/ano] \quad (4)$$

Em que  $GMP$  a geração média da fonte primária e  $GMS$  a geração média necessária da fonte secundária, todas dadas em watt médio por ano. Também se nota a presença do fator  $FR$  que dá a relação entre usina referência e a capacidade da usina base (sendo 0.1, 0.5 ou 0.9).

$$PP = PPB \frac{GMP}{GMD} [W] \quad (5)$$

$$PS = PSB \frac{GMS}{GMD} [W] \quad (6)$$

Sendo  $PP$  a potência AC nominal da fonte primária,  $PS$  a potência AC nominal da fonte secundária, ambas em watts, que representam as usinas que formulam os cenários e por fim, tem-se  $PPB$  e  $PSB$  sendo a potência, em watts, nominal das usinas base primária e secundária, respectivamente.

Com as potências das usinas primárias e secundárias definidas para cada cenário, a potência nominal da geração associada é a soma das duas. Ao final do processo, existirão cinco cenários: dois considerando as usinas base e outros três construídos a partir da mescla das duas primeiras. Em todos os cenários, apesar das potências nominais diferirem, a energia gerada média deverá ser igual entre eles.

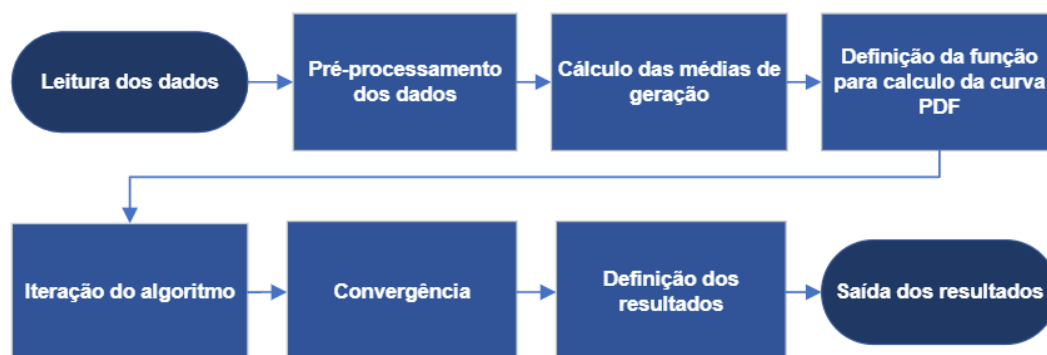
A análise da complementariedade é realizada aplicando a equação 1 aos dados de geração para um determinado período. Após essa aplicação, é importante implementar um filtro nos dados para capturar apenas os momentos de geração conjunta, por exemplo, filtrar para o período entre 6h da manhã e 17h da tarde, que corresponde ao horário de funcionamento das usinas fotovoltaicas. Dessa forma, obtém-se resultados menos poluídos e mais evidentes sobre os impactos da associação para cada cenário.

Com os dados calculados e filtrados, a próxima etapa é representá-los de forma estatística para identificar os efeitos na produção de energia em cada cenário. Pode-se utilizar curvas de densidade de probabilidade para essa representação. Esta etapa será mais bem explorada na próxima sessão.

Por fim, a análise dos resultados deve evidenciar a tendência de comportamento das usinas em teste. Além disso, caso seja do interesse de quem implementa, é possível observar as diferentes características de cada cenário e identificar qual proporciona mais benefícios ao investimento em foco. Se o objetivo for descobrir qual combinação oferece o melhor desempenho frente a suavização de rampas, isso poderá ser determinado por meio de um algoritmo computacional, que será explicado na próxima subseção.

### 3.2. Etapa 02: Definição do melhor cenário

O processo de determinar o melhor cenário para usinas hibridizadas pode ser realizado por meio de um algoritmo iterativo. Esse método utiliza os dados de geração das usinas base, que individualmente são capazes de gerar a energia média desejada, para explorar diversas combinações entre geração solar fotovoltaica e eólica. O algoritmo ajusta continuamente as proporções de geração de cada fonte até encontrar aquela que resulta na menor dispersão das variações de rampa de geração de energia. O critério de otimização se baseia na análise da curva de densidade de probabilidade das variações de rampa em relação à potência instalada, conforme calculado pela equação 1. O objetivo é identificar o cenário em que essa curva apresenta menor variância, indicando menor flutuação na geração. Dessa forma, o algoritmo busca por uma distribuição de densidade mais estreita, refletindo uma menor variabilidade na produção de energia. Após encontrar a proporção mais conveniente entre geração solar fotovoltaica e eólica, o algoritmo determina as potências ideais para cada fonte no sistema hibridizado. A figura 3 representa o fluxograma deste algoritmo computacional.



**Figura 3:** Fluxograma do algoritmo implementado

## 4. Estudo de caso

Nesta seção, a metodologia descrita ao longo do artigo será aplicada a dados reais e simulados de uma localidade no Ceará.

### 4.1. Dados de geração eólica

Para este estudo, são utilizados dados de geração eólica provenientes de medições realizadas em um parque eólico localizado no estado do Ceará. A usina tem uma potência instalada de 100 MW e um fator de capacidade de 45%. Os dados abrangem o período de outubro de 2019 a setembro de 2020. Devido a um acordo de confidencialidade com a empresa fornecedora dos dados, detalhes específicos sobre as tecnologias, modelos e outras informações técnicas da usina não serão divulgados. A geração de energia está registrada em intervalos de 10 minutos, resultando em um total de 56.704 medições ao longo do período de estudo. A geração média estabelecida para o estudo foi a mesma geração média desta usina, calculada em aproximadamente 45 MW médios ano.

### 4.2. Dados de geração solar

Para obter dados de geração solar fotovoltaica, iniciou-se uma busca por informações de usinas solares na mesma região do parque eólico estudado. No entanto, nenhuma administradora de parques solares da

região forneceu os dados necessários para a pesquisa. Diante dessa limitação, utiliza-se o software System Advisor Model (SAM) para simular um parque solar. Para a simulação, foi considerada uma usina com capacidade nominal de 126 MW, capacidade necessária para a produzir a geração média estabelecida, equipada com um sistema de rastreamento de um eixo com backtracking, e um fator de capacidade de 27%. A usina foi simulada para a mesma região e período dos dados do parque eólico mencionado, utilizando informações meteorológicas de intervalos de 10 minutos da base de dados National Solar Radiation Database (NSRDB).

### 4.3. Complementariedade de geração e sinergia operacional

Com base nos dados, utiliza-se a equação 2 para calcular a complementariedade da geração, tanto mensal quanto anualmente. Os resultados são detalhados na tabela a seguir:

**Tabela 1:** Tabela com as complementariedades calculadas.

Mês	Correlação
out./19	-0,5698
nov./19	-0,4997
dez./19	-0,4637
jan./20	-0,3483
fev./20	-0,3592
<b>mar./20</b>	<b>-0,0787</b>
abr./20	-0,3191
mai./20	-0,3571
jun./20	-0,3369
jul./20	-0,4838
ago./20	-0,5875
<b>set./20</b>	<b>-0,6566</b>
<b>Anual</b>	<b>-0,3562</b>

Observa-se que a complementariedade entre os dados comparados é negativa, alcançando um pico de -0,656 no mês de setembro. No entanto, a análise também revela que nos meses de fevereiro, março e abril, a complementariedade é significativamente menor. De forma geral, apesar das variações ao longo dos meses, os resultados mensais são todos negativos e, quando a complementariedade é calculada para o período anual, o resultado é de -0,356.

Após avaliar a complementariedade entre as usinas em estudo, define-se os cenários iniciais para análise. Primeiramente, estabelece-se a usina eólica como a usina primária e referência, a usina apresenta uma geração média anual de aproximadamente 45 MW médios. A partir dessa referência, determinam-se as potências de geração eólica para os diferentes cenários: um em que a usina eólica é a fonte predominante, outro em que ela é a fonte de menor participação e um terceiro em que a geração é equilibrada entre eólica e solar fotovoltaica. Para essas definições, são implementadas as equações 3 e 5.

Com as potências eólicas definidas, determina-se também a usina solar base equivalente que produz a mesma energia média da usina eólica base. Em seguida, aplicam-se as equações 4 e 6 para definir as potências das usinas solares em cada cenário. Os resultados obtidos para cada cenário estão apresentados na Tabela 2.




**Tabela 2:** Tabela com os cenários calculadas.

Cenário	Eólica (MW)	Solar (MW)	Potência Total (MW)	FC* (%)
1	100	0	100	45%
2	0	126	126	27%
3	10	113	123	29%
4	50	63	113	34%
5	90	13	103	42%

\*Fc em relação a capacidade instalada

A partir dos cenários definidos, aplica-se a equação 1 aos dados de geração das usinas ao longo do período considerado. Posteriormente, implementa-se o filtro dos dados que captura apenas os momentos de geração conjunta, filtra-se para o período entre 6h da manhã e 17h da tarde, correspondente ao horário de funcionamento da planta fotovoltaica simulada.

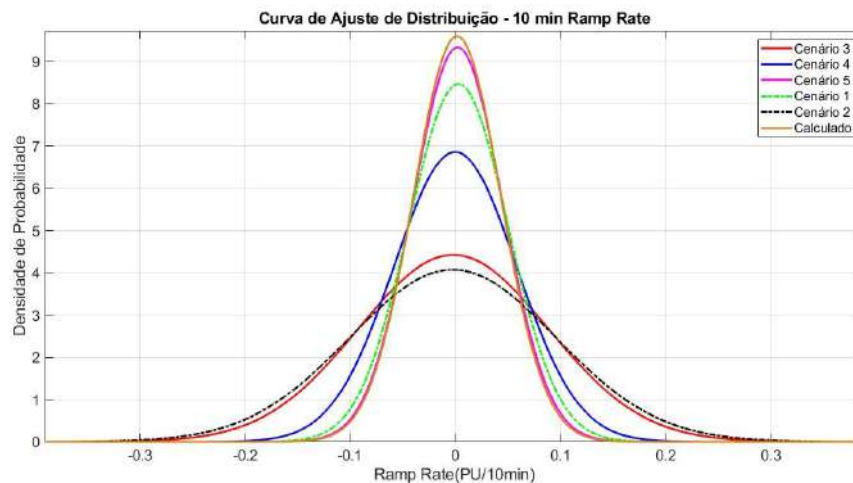
Para a análise do perfil da intensidade das rampas em cada cenário, são geradas curvas de densidade de probabilidade com base na distribuição normal, permitindo uma comparação mais robusta entre os diferentes cenários, apresentadas na Figura 4. O gráfico revela que as curvas associadas à cenários com predominância de energia solar apresentam uma maior variância, indicando a presença de uma maior quantidade de rampas com intensidades elevadas. Por outro lado, as combinações com predominância eólica tendem a mostrar menores variações abruptas na intensidade das rampas. A curva que exibe a menor variância é a do cenário 5, que possui predominância eólica. Esta curva apresenta um pico mais acentuado e sugere que as variações na geração de energia estão mais concentradas em torno de zero, indicando uma menor amplitude nas flutuações da produção de energia. Ao comparar este cenário com os cenários das usinas base, observa-se que a usina majoritariamente eólica, com uma pequena participação de energia solar fotovoltaica, demonstra uma melhoria em relação à usina eólica isolada (cenário 1) e, de forma mais significativa, em relação à usina puramente solar (cenário 2). Portanto, pode-se concluir que a combinação de fontes de energia em proporções específicas, como a predominância de geração eólica com uma contribuição de energia solar, confere robustez tanto à geração eólica quanto à solar, resultando em uma operação mais consistente.



**Figura 4:** Distribuições obtidas para as simulações dos 5 cenários propostos.

#### 4.4. Melhor cenário

Após analisar os cenários de associação, utiliza-se o algoritmo mencionado na seção 3.3, construído em Python. Os dados de geração das usinas base são inseridos como entrada, e o programa calcula que, para o contexto dos dados, o melhor cenário é uma usina associada de 104 MW. Essa usina deve ser composta por 23% de geração solar e 77% de geração eólica, correspondendo a 22.9 MW e 81.1 MW, respectivamente. Adicionalmente, são realizadas as simulações detalhadas na seção anterior para calcular as distribuições de probabilidade, levando em conta os cenários discutidos anteriormente e o cenário resultante do algoritmo, conforme mostrado na Figura 5. Esta figura evidencia que a geração da usina calculada, representada pela curva laranja, é a que apresenta maior quantidade de rampas de menor intensidade, validando o funcionamento do algoritmo e reforçando a ideia anteriormente discutida de que uma usina com predominância eólica e uma pequena participação de energia solar é mais eficaz na suavização das rampas de geração de energia.



**Figura 5:** Distribuições obtidas para as simulações dos 5 cenários, incluindo agora o melhor cenário.

Para evidenciar as reduções percebidas, tem-se a tabela 3, formada com base na equação 1. A Tabela 3 apresenta a distribuição da intensidade das rampas, evidenciando a porcentagem de rampas em relação ao total quantificado pela intensidade da rampa no período de 10 minutos, seja variação ascendente ou descendente. No cenário calculado, em comparação com os cenários das usinas base, 83,18% das rampas ocorrem com intensidade menor ou igual a 5% da potência total da usina. Além disso, não há rampas com intensidade superior a 50%. Esse dado é particularmente relevante, pois os sistemas de suavização geralmente são projetados para lidar com o pior cenário. Nesse caso, o pior cenário, além de ser menos frequente, apresenta menor intensidade.

**Tabela 3:** Tabela com as distribuições calculadas.

Distribuição da intensidade das rampas em relação a potência instalada							
Intervalos PU/10min	Cenários			Intervalos PU/10min	Cenários		
	1	2	Calculado		1	2	Calculado
0 a 5	79,80%	73,65%	83,18%	0 a 25	99,70%	96,27%	99,90%
5 a 10	15,70%	8,03%	13,30%				
10 a 15	3,01%	10,32%	2,62%				
15 a 20	0,87%	2,68%	0,65%				

20 a 25	0,32%	1,59%	0,15%				
25 a 50	0,27%	3,03%	0,10%	25 a 50	0,27%	3,03%	0,10%
50 a 75	0,03%	0,62%	0,00%	50 a 75	0,03%	0,62%	0,00%
75 a 100	0,00%	0,07%	0,00%	75 a 100	0,00%	0,07%	0,00%

## 5. CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo elaborar uma metodologia para investigar o potencial de redução das rampas de geração por meio da associação de usinas fotovoltaicas e eólicas. A metodologia proposta mostrou-se eficaz no estudo realizado, em que a combinação de uma planta fotovoltaica com uma usina eólica resulta na suavização das rampas de geração. Este resultado é particularmente relevante, pois pode viabilizar soluções auxiliares mais econômicas, uma vez que já houve a suavização parcial das rampas. Recomenda-se que estudos futuros utilizem dados de medições reais em vez de simulados, pois grandes usinas solares raramente são completamente afetadas por nuvens passageiras, o que pode distorcer a análise das variações intra-horárias. Além disso, a disponibilidade de dados de geração solares fotovoltaicos e eólicos ao longo de vários anos é importante para permitir análises de longo prazo e capturar fenômenos climáticos adversos.

Por fim, sugere-se, para futuros desenvolvimentos de metodologias baseadas neste estudo, a mensuração do impacto econômico da suavização das rampas na redução dos custos associados à implementação de soluções de sistemas auxiliares.

## REFERÊNCIAS

M. MITCHELL, M. CAMPBELL, K. KLEMENT and M. SEDIGHY, "Power variability analysis of megawatt-scale solar photovoltaic installations," 2016 IEEE Electrical Power and Energy Conference (EPEC), Ottawa, ON, Canada, 2016, pp. 1-4, doi: 10.1109/EPEC.2016.7771687.

BEZERRA, F. D. Energia eólica no nordeste. Banco do Nordeste, 2019. Disponível em: <https://bnb.gov.br/s482-dspace/handle/123456789/1192>. Acesso em: 23 jun. 2024.

COMISIÓN REGULADORA DE ENERGIA. Reglas generales de interconexión al sistema eléctrico nacional: Anexo 3. 2012.

J. P. KARUNADASA, B. H. A. V. L. GUNARATHNE, A. SENANAYAKE, H. S. PERERA, D. KAUNARATHNE and A. EKANAYAKE, "A Novel Strategy for Ramp Rate Control of Wind Farms," 2022 IEEE International Power and Renewable Energy Conference (IPRECON), Kollam, India, 2022, pp. 1-6, doi: 10.1109/IPRECON55716.2022.10059536.

ROCHA, V. R. da; GONÇALVES, A. R.; COSTA, E. B.; MARTINS, F. R.; INACIO, C. O.; FONTENELE, L. A.; FERREIRA, P. F. Avaliação da variabilidade do recurso solar em território brasileiro. CBENS, 2020. DOI: <https://doi.org/10.59627/cbens.2020.735>.

DEETJEN, T. A.; RHODES, J. D.; WEBBER, M. E. The impacts of wind and solar on grid flexibility requirements in the Electric Reliability Council of Texas. Science Direct, v. 123, p. 637-654, 15 mar. 2017. DOI: <https://doi.org/10.1016/j.energy.2017.02.021>.

DIAZ, N. V. Avaliação de desempenho das estratégias de controle para suavização da potência ativa de sistemas fotovoltaicos com armazenamento de energia. 2019. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Estadual do Oeste do Paraná, Foz do Iguaçu, PR, 2019. Disponível em: <http://tede.unioeste.br/handle/tede/4632>. Acesso em: 23 jun. 2024.

EMPRESA DE PESQUISA ENERGÉTICA. Usinas Híbridas - Uma análise qualitativa de temas regulatórios e comerciais relevantes ao planejamento. Brasília: EPE, 2018.

EMPRESA DE PESQUISA ENERGÉTICA. Avaliação da geração de usinas híbridas eólico-fotovoltaicas. Brasília: EPE, 2017.

FARIAS, L. M.; SELITTO, M. A. Uso da energia ao longo da história: evolução e perspectivas futuras. Revista Liberato, v. 12, n. 7, p. 7-16, dez. 2013. Disponível em: <https://revista.liberato.com.br/index.php/revista/article/view/164>. Acesso em: 23 jun. 2024.

GONÇALVES, A. R.; COSTA, R. S.; MARTINS, F. R.; PEREIRA, E. B. Estudo do perfil de complementariedade entre a geração eólica e solar no semiárido brasileiro. CBPE, 2020.

HOFMANN, M.; HEINEMANN, D. Improved Synthesis of Global Irradiance with One-Minute Resolution for PV System Simulations. International Journal of Photoenergy, p. 10, nov. 2014. DOI: 10.1155/2014/808509.

MAGALHÃES, L. P.; MARTINS, C. C.; DOS SANTOS, G. C. Sistemas de armazenamento e mercados de flexibilidade no setor elétrico brasileiro. Brasília: SNPTEE, 2022.

NASCIMENTO, L. R.; CAMPOS, R. A.; RUTHER, R. Avaliação do desempenho de tecnologias fotovoltaicas e complementariedade solar e eólica no Nordeste. CBENS, 2018. Disponível em: [https://fotovoltaica.ufsc.br/artigos\\_em\\_anais/CBENS\\_Lucas\\_Rafael\\_Ricardo\\_Gabriel.pdf](https://fotovoltaica.ufsc.br/artigos_em_anais/CBENS_Lucas_Rafael_Ricardo_Gabriel.pdf).

NATIONAL RENEWABLE ENERGY LABORATORY. Review of PREPA technical requirements for interconnecting wind and solar. 2013.

ONS. Sistema em números 2024. ONS, 2024. Disponível em: <https://www.ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>. Acesso em: 01 jul. 2024.

PEREIRA, E. B.; MARTINS, F. R.; DE ABREU, S. L.; RUTHER, R. Atlas brasileiro de energia solar. 1. ed. São José dos Campos: INPE, 2006. Disponível em: <http://mtc-m16b.sid.inpe.br/rep/sid.inpe.br/mtc-m17@80/2007/05.04.14.11>. Acesso em: 23 jun. 2024.

CAMPOS, R. A. Análise da complementariedade de geração de usinas solar e o papel do armazenamento de energia para usinas híbridas. 2020. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Santa Catarina, Florianópolis, SC, 2020. Disponível em: [https://fotovoltaica.ufsc.br/Dissertacoes/Dissertacao\\_Rafael\\_Antunes\\_Campos.pdf](https://fotovoltaica.ufsc.br/Dissertacoes/Dissertacao_Rafael_Antunes_Campos.pdf).

ACKERMANN, T. et al., Smart modeling of optimal integration of high penetration of PV. Technical report, Energynautics, UOC (Universitat Oberta de Catalunya), KTH (Royal Institute of Technology), DTU (Technical University of Denmark) e TUE (Eindhoven University of Technology), 2013.

PESSANHA, J. F.; ALMEIDA, V. A.; MELO, A. C. Fator de capacidade da geração eólica na região Nordeste: um estudo com dados de reanálises oriundos do MERRA-2 (global). SBSE, 2021. DOI: <https://doi.org/10.48011/sbse.v1i1.2269>.

WAN, Yih-huei. Analysis of Wind Power Ramping Behavior in ERCOT. Technical Report NREL/TP-5500-49218. Março 2011. National Renewable Energy Laboratory. Disponível em: <https://www.nrel.gov/docs/fy11osti/49218.pdf>.

## ANÁLISE DAS ESTIMATIVAS DE INCERTEZAS EM EMPREENDIMENTOS EÓLICOS PARTICIPANTES DOS LEILÕES DE ENERGIA NOVA

### Autores

Anderson da Costa Moraes<sup>1</sup>, Bruno Faria Cunha<sup>1</sup>, Charles Egberto G. V. V. de Mello<sup>1</sup>,  
Gustavo Pires da Ponte<sup>1</sup>, João Marcos de Oliveira Gaio<sup>2</sup>, Josina Saraiva Ximenes<sup>3</sup>,  
Leonardo Sanches Lima<sup>1</sup>, Paula Monteiro Pereira<sup>1</sup>, Rafael Pinho Furtado<sup>1</sup>

EPE - Empresa de Pesquisa Energética <sup>1</sup>

UERJ - Universidade Estadual do Rio de Janeiro<sup>2</sup>

UFRJ – Universidade Federal do Rio de Janeiro<sup>3</sup>

[anderson.moraes@epe.gov.br](mailto:anderson.moraes@epe.gov.br); [bruno.cunha@epe.gov.br](mailto:bruno.cunha@epe.gov.br); [charles.mello@epe.gov.br](mailto:charles.mello@epe.gov.br);  
[gustavo.ponte@epe.gov.br](mailto:gustavo.ponte@epe.gov.br) ; [joaomarcosgaio2015@gmail.com](mailto:joaomarcosgaio2015@gmail.com); [josinasx@gmail.com](mailto:josinasx@gmail.com);  
[leonardo.sanches@epe.gov.br](mailto:leonardo.sanches@epe.gov.br) ; [paula.pereira@epe.gov.br](mailto:paula.pereira@epe.gov.br); [rafael.furtado@epe.gov.br](mailto:rafael.furtado@epe.gov.br)

### RESUMO

A Incerteza Padrão é um parâmetro crítico para o cálculo da Garantia Física de usinas eólicas e sua estimativa é uma das maiores preocupações da avaliação energética dos projetos. A garantia física é determinada a partir do valor de P90 da produção certificada, que por sua vez é calculado a partir do P50 e da incerteza padrão.

Para um mesmo P50, quanto maior o valor da Incerteza Padrão, menor será a estimativa de produção P90 e, portanto, menor será a Garantia Física de Energia calculada para o empreendimento. Valores muito otimistas (incerteza padrão baixa) podem gerar expectativas de produção de energia que não serão efetivamente realizadas durante a operação comercial das usinas.

Considerando as definições existentes na IEC 61400-12-1 (IEC, 2022) e nos documentos da EPE, foram analisadas as composições das incertezas observadas na amostra dos empreendimentos habilitados nos leilões de energia nova entre 2017 e 2022. A partir da análise dos valores cadastrados, nota-se que há grande diferenciação das incertezas componentes observadas em função das premissas e metodologias utilizadas pelas diferentes Certificadoras.

Além disso a apresentação dos dados de incertezas tem como objetivo incentivar a discussão técnica entre os múltiplos agentes do setor, a fim de reduzir assimetrias de informação e de metodologias e contribuir para a melhoria dos processos de estimativa de geração de empreendimentos no país, buscando proporcionar maior segurança ao sistema e aos empreendedores na instalação de novos projetos.

### Palavras-chaves:

Incerteza; Eólica; Certificação; Leilão de Energia, Geração de Energia, Garantia Física.

### ABSTRACT

Standard Uncertainty is a critical parameter for calculating the Physical Guarantee of wind farms and its correct estimation is one of the biggest concerns in the energy assessment of projects. The physical guarantee is determined from the P90 value of the certified production, which in turn is calculated from the P50 and the standard uncertainty.

For the same P50, the higher the Standard Uncertainty value, the lower the P90 production estimate will be and, therefore, the lower the Physical Energy Guarantee calculated for the project will be. Very optimistic values (low standard uncertainty) can generate energy production expectations that will not be effectively realized during the commercial operation of the plants.

Considering the existing definitions in IEC 61400-12-1 (IEC, 2022) and EPE documents, the composition of uncertainties observed in the sample of projects qualified in new energy auctions between 2017 and 2022 were analyzed.

Notice that in registered values, there is a great difference in the uncertainties observed depending on the assumptions and methodologies used by the different Certifiers.

Furthermore, the presentation of uncertainty data aims to encourage technical discussion between multiple agents in the sector, in order to reduce asymmetries of information and methodologies and refine the considerations of the processes for estimating the generation of projects in the country, ensuring greater security to the system and to entrepreneurs when installing new projects.

### **Keywords:**

Uncertainty; Wind Energy; Certification; Energy Auction, Energy Generation, Physical Guarantee.

## **1. INTRODUÇÃO**

A incerteza reflete a falta de conhecimento preciso sobre um evento, medida ou estado futuro, proveniente de diversas fontes, como limitações nos instrumentos de medição, variações nas condições ambientais e a natureza probabilística de certos fenômenos.

O cálculo de incertezas é parte essencial das etapas de planejamento e projeto de empreendimentos eólicos e envolve componentes quantitativas e qualitativas. O JCGM 100:2008 (Bureau International des Poids et Mesures, 2008) busca definir os tipos de incerteza e a sua combinação, a fim de permitir a obtenção de uma incerteza resultante para o processo.

Comumente os certificadores tendem a adequar sua matriz de incertezas estimada de acordo com as normas constantes das Instruções para Solicitação de Cadastramento e Habilitação Técnica com vistas à Participação nos Leilões de Energia Elétrica (EPE, 2021).

A depender da metodologia adotada, os fatores incluídos no cálculo de cada componente de incerteza na geração eólica podem não ser idênticos. A formulação matemática para o cálculo do valor resultante pode evidenciar diferenças em relação à independência das componentes. Algumas certificadoras podem trabalhar com a hipótese de que todas as incertezas são independentes. Outras, podem assumir certo grau de dependência para determinadas componentes.

São objetos de estudo deste artigo os empreendimentos eólicos cadastrados e habilitados para participação nos leilões de energia nova, entre os anos de 2017 e 2022, cujos dados foram inseridos no Sistema de Acompanhamento de Empreendimentos de Geração de Energia – AEGE (EPE, s.d.), disponibilizado pela EPE aos agentes.

## **2. FUNDAMENTAÇÃO TEÓRICA**

### **2.1 Definição do P90 e da Garantia Física**

Conforme estabelecido na Portaria MME 101/2016 (MME, 2016), a garantia física determina uma quantidade de energia que um empreendimento pode suprir, dado um critério de suprimento. Adicionalmente, este parâmetro define a quantidade máxima de energia que um empreendimento pode comercializar em seus contratos de venda de energia elétrica.

A mesma portaria trata da consolidação da metodologia de cálculo de garantia física de empreendimentos eólicos, que passou a ser determinada diretamente pela produção anual de energia certificada, referente

ao valor de energia anual prevista que é excedido com uma probabilidade de ocorrência igual ou maior a 90% para um período de variabilidade futura de 20 anos (P90ac), com desconto das indisponibilidades (forçada e programada), do consumo interno e das perdas elétricas até a ponto de medição individual.

Supondo uma distribuição normal, a produção de energia (P90ac) pode ser obtida a partir da produção de energia do empreendimento com 50% de probabilidade de ocorrência (P50ac) e da incerteza padrão, conforme ilustrado na Figura 1 que apresenta um esquemático das etapas do cálculo de garantia física das usinas, desde a estimativa de geração bruta, sem perdas, até a garantia física.

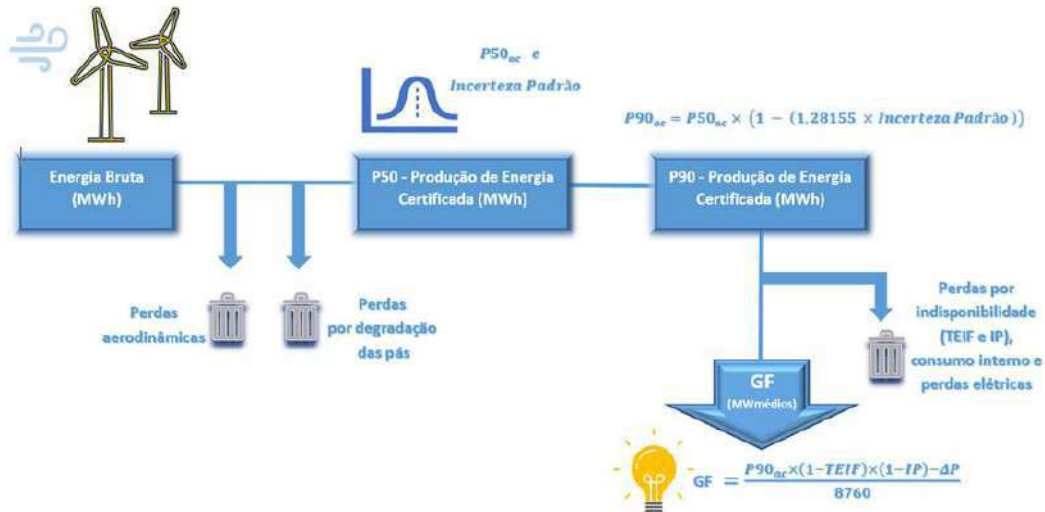


Figura 1– Etapas do cálculo da produção de energia e da garantia física de usinas eólicas

## 2.2 Definição de Incertezas

A incerteza e o erro são conceitos intrinsecamente ligados à natureza imperfeita das medições e previsões em diversas áreas do conhecimento, desempenhando papéis significativos em campos como ciência, estatística, engenharia e outros, influenciando a confiabilidade e a precisão das informações obtidas.

Conforme indicado pelo Guia para expressão de incerteza de medição (Bureau International des Poids et Mesures, 2008), no âmbito da metrologia, a incerteza é comumente categorizada em dois tipos principais:

**Incerteza Tipo A:** Este tipo de incerteza está associado à variabilidade aleatória nos resultados de medição e é avaliado por meio de análise estatística dos dados experimentais obtidos em condições repetidas. Métodos estatísticos, como o cálculo do desvio padrão a partir de múltiplas medições, são frequentemente empregados para tratar essa forma de incerteza, permitindo estimativas mais precisas à medida que mais dados são coletados.

**Incerteza Tipo B:** Refere-se a fontes sistemáticas de incerteza relacionadas a erros sistemáticos ou vieses na medição, como imperfeições nos instrumentos, calibração inadequada e efeitos ambientais não considerados. A avaliação desse tipo de incerteza muitas vezes envolve a aplicação de conhecimento especializado, análise de dados históricos ou informações técnicas específicas sobre os instrumentos utilizados. (Bureau International des Poids et Mesures, 2008).

Em resumo, enquanto a incerteza tipo A aborda a variabilidade aleatória intrínseca aos dados experimentais, a incerteza tipo B lida com fontes sistemáticas que podem afetar consistentemente os resultados de medição.

A IEC-61400-12-1 (IEC, 2022) fornece como orientação para estimativa da incerteza os procedimentos explicitados na ISO/IEC 98-3:2008 (Bureau International des Poids et Mesures, 2008), onde as categorias A e B de incerteza são apresentadas e o processo de composição é proposto. De forma geral, a incerteza pode ser definida como:

$$u_{c,i}^2 = \sum_{k=1}^M \sum_{l=1}^M c_{k,i} u_{k,i} c_{l,i} u_{l,i} \rho_{k,l,i,i}$$

Onde:

$c_{k,i}$  é o fator de sensibilidade do componente k no intervalo i;

$u_{k,i}$  é a incerteza do componente k no intervalo i;

$c_{l,i}$  é a sensibilidade do componente l no intervalo i;

$\rho_{k,l,i,i}$  é o coeficiente de correlação entre o componente de incerteza k no intervalo i e o componente de incerteza l no intervalo i.

Visando permitir uma análise comum aos empreendimentos que objetivam se conectar ao sistema elétrico, a EPE lista um grupo de incertezas que devem ser calculadas ou estimadas para o processo de cadastramento de empreendimentos (EPE, 2021). Dada a existência de múltiplas metodologias de estimativa, cada um dos certificadores adequa sua matriz de incertezas a fim de compatibilizar com o formato padronizado pela EPE, composto das seguintes incertezas: Incerteza das Medições Anemométricas; Incerteza da Curva de Potência; Outras Incertezas; Incerteza da Metodologia do Cálculo do Efeito Esteira; Incerteza da Variabilidade Interanual; Incerteza da Correlação de Longo Prazo; Incerteza da Extrapolação Vertical Total; Incerteza da Extrapolação Horizontal Total.

No caso da identificação pela certificadora de incertezas não desprezíveis que não estejam contidas nas definições da EPE, a componente “Outras Incertezas” permite a inclusão de um valor representativo para estas componentes adicionais.

### 3. MÉTODO DO ESTUDO

A partir dos dados do Sistema AEGE, foram selecionados os empreendimentos habilitados entre os anos de 2017 e 2022, a fim de se obter uma amostra de dados representativa dos projetos eólicos.

O artigo aborda o tema de incertezas em uma sequência de etapas que utilizam diferentes amostras a partir da inicial, de acordo com a análise a ser realizada.

A primeira etapa busca mostrar a visão geral dos empreendimentos habilitados nos leilões de energia nova. Para cada projeto habilitado em múltiplos leilões presente na amostra, foi selecionada a sua última participação, sendo removidas as demais aparições em certames anteriores. Estes filtros resultaram em uma amostra de 1.381 empreendimentos eólicos habilitados tecnicamente pela EPE, em suas mais recentes versões no Sistema AEGE. Nesta etapa não foi feita nenhuma classificação por certificadora ou localidade. Os valores de cada componente e da incerteza padrão são apresentados na forma de um gráfico de caixa (boxplot), o que permite ao leitor ter conhecimento da variação dos valores adotados e de medidas de tendência central. Adicionalmente, são construídos gráficos para cada incerteza componente, onde as faixas de valores adotadas pelas 12 certificadoras da amostra podem ser comparadas.

A segunda etapa requer um tratamento prévio da amostra de 1.381 projetos. É realizada a classificação por certificadora, sendo escolhidas as 6 com maior número de projetos habilitados. Ao final do tratamento, permaneceram 1.219 projetos. Após o cálculo do índice de incerteza de cada projeto, foram construídos os gráficos de frequência absoluta, permitindo verificar possíveis concentrações em faixas mais ou menos otimistas de incerteza padrão.

A etapa seguinte utilizou apenas as 4 certificadoras com maior número de projetos habilitados. Desta forma, a amostra foi constituída por 985 projetos. Foi realizado o cálculo da participação de cada componente de incerteza em relação ao quadrado da Incerteza Padrão, possibilitando a comparação dos pesos aplicados pelas diferentes certificadoras, através de gráficos de colunas empilhadas dos percentuais de cada componente por empreendimento. Com a mesma amostra, foi construído o gráfico dos valores médios adotados pelas certificadoras para cada componente.



A última análise abordou a adoção de valores diferenciados de acordo com a localização geográfica dos projetos que integram o estudo. Partindo da amostra de 985 projetos, foram excluídos aqueles fora das localidades destacadas no mapa, totalizando ao final 982 empreendimentos divididos entre as 4 certificadoras.

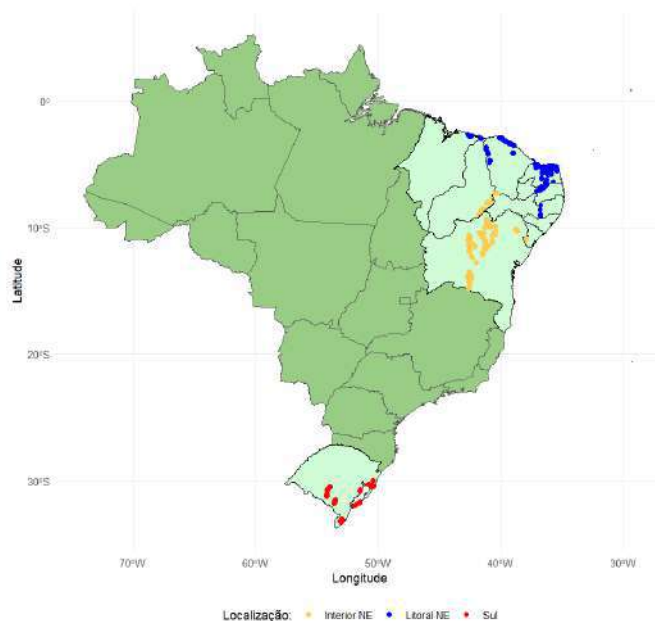











Figura 2 -Localização dos projetos eólicos que compõem a amostra

Para a obtenção, tratamento e apresentação dos dados, optou-se pela utilização da linguagem de programação R.

#### 4. ANÁLISE DOS DADOS SELECIONADOS

Objetivando simplificar o processo de análise e apresentação dos resultados, os gráficos deste artigo utilizam o código de cores contido na Tabela 1.

Tabela 1 - Código de cores considerado para incertezas

	Incerteza das Medições Anemométricas (IMA)		Incerteza da Correlação de Longo Prazo (ICLP)
	Incerteza da Extrapolação Vertical Total (IEVT)		Incerteza da Metodologia de Cálculo do Efeito Esteira (IMCEE)
	Incerteza da Extrapolação Horizontal Total (IEHT)		Outras Incertezas (OI)
	Incerteza da Curva de Potência (ICP)		Incerteza Padrão Resultante de Longo Prazo (IPR)
	Incerteza da Variabilidade Interanual (IVI)		

##### 4.1 Composição das Incertezas na Amostra de Dados

A distribuição das 8 incertezas que compõem a Incerteza Padrão Resultante é mostrada na Figura 3 através de diagramas de caixa (boxplot). Para cada uma das componentes e para a própria Incerteza Padrão Resultante de 20 anos, é possível identificar o primeiro quartil (25% dos dados), o segundo quartil (ou mediana) e o terceiro quartil (75% dos dados) da amostra, representados pelas linhas horizontais que formam cada caixa. A distância interquartilica (diferença entre o terceiro e o primeiro quartis) pode ser utilizada como uma boa medida de dispersão, pois não é influenciada por valores extremos. Adicionalmente, o valor mínimo (percentil 5%), o valor máximo (percentil 95%), a média (destacada como

um pequeno quadrado cinza dentro da caixa) e os outliers de cada incerteza podem ser facilmente identificados.

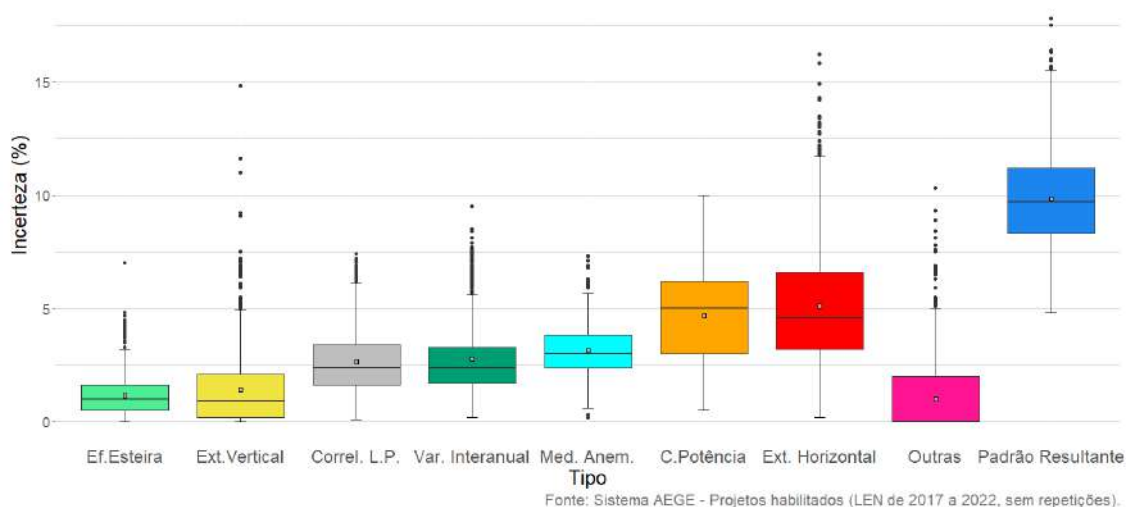


Figura 3 - Composição das incertezas da amostra

Restringindo-se aos projetos com valores declarados entre o primeiro e o terceiro quartil, as incertezas da Curva de Potência e da Extrapolação Horizontal se destacam em termos de maior dispersão de valores. Em relação às medidas de tendência central (média e mediana), as mesmas duas incertezas componentes se destacam com os maiores valores. As incertezas da Correlação de Longo Prazo, da Variabilidade Interanual e das Medições Anemométricas apresentam valores medianos comparados com as demais e uma distribuição reduzida. As Incertezas do Efeito Esteira, da Extrapolação Vertical e Outras Incertezas possuem os menores valores médios. Nota-se, no entanto, que as dispersões e os outliers da Extrapolação Vertical e Outras Incertezas compreendem valores não desprezíveis, quando comparadas às demais incertezas. Observa-se que a média e a mediana da Incerteza Padrão Resultante ficaram próximas a 10%, com dispersões próximas à 2,5%.

A Figura 4 possibilita a comparação entre os valores das incertezas componentes declarados para projetos de 12 certificadoras. Algumas considerações são listadas a seguir:

- Incerteza das Medições Anemométricas: a maioria dos projetos se encontra em uma faixa entre 1,5% e 5,4%, levando em conta o primeiro e o terceiro quartis. Entretanto, é possível identificar algumas peculiaridades comparando as certificadoras. A análise da amostra revela que as quatro primeiras (A, B, C e D) estimam valores bastante otimistas em alguns casos. A adoção de valores inferiores a 1,25% destoa do que é praticado pelas demais concorrentes. De maneira oposta, as certificadoras E, H, J, L e M optam por valores mais conservadores.
- Incerteza da Correlação de Longo Prazo: a maioria dos projetos se encontra na faixa de 0,7% a 6,3%, entre o primeiro e o terceiro quartis. A análise da amostra revela que as certificadoras G e I adotam em geral valores baixos, inferiores a 1,25%. De maneira oposta, as certificadoras L e M parecem optar por valores mais conservadores (não adotam valores abaixo de 2,5%). Adicionalmente, algumas certificadoras utilizam uma ampla faixa de valores em seus projetos, passando pelos mais otimistas até os mais conservadores, casos de A, B, C, E e F.
- Incerteza da Extrapolação Horizontal Total: a maioria dos projetos se encontra na faixa de 1,2% e 8,5%, entre o primeiro e o terceiro quartis. A análise da amostra revela que as certificadoras C, J e L adotam, em geral, valores baixos. De maneira oposta, as certificadoras B, E e F parecem optar por valores mais conservadores.



Figura 4 - Valores adotados para as componentes da Incerteza Padrão por certificadora

- Incerteza da Extrapolação Vertical Total: a maioria dos projetos se encontra em uma faixa entre 0% e 3%. Várias certificadoras adotam valor zero, principalmente quando os anemômetros estão na mesma altura do rotor. As certificadoras M e D adotam, em geral, valores baixos. De maneira oposta, as certificadoras H e E parecem optar por valores mais conservadores (altos).
- Incerteza da Metodologia de Cálculo do Efeito Esteira: a maioria dos projetos se encontra em uma faixa entre 0,5% e 2,4%, considerando o primeiro e o terceiro quartis. As seis certificadoras com mais projetos habilitados adotam faixas de valores semelhantes (em termos de amplitude) indo de 0 a 5%. As certificadoras G, H, I, J e M adotam, em geral, faixas mais restritas de valores.
- Incerteza da Variabilidade Interanual, a análise da amostra revela que as certificadoras C, H, I e J adotam em geral valores baixos, inferiores a 2,5%. De maneira oposta, a certificadora M parece optar por valores mais conservadores. Adicionalmente, algumas certificadoras utilizam uma ampla faixa de valores em seus projetos, passando pelos mais otimistas até os mais conservadores, casos de B, G e L.
- Incerteza da Curva de Potência: a análise da amostra revela que as certificadoras D, E, F, G, I e L adotam em geral valores mais otimistas, inferiores a 3,0%. De maneira oposta, as certificadoras A, H e J optam por valores mais conservadores, acima de 5%. Adicionalmente, algumas certificadoras utilizam um valor único ou no máximo três valores para todos os seus projetos, casos de B, D, G e M.

- Outras Incertezas: as três certificadoras com mais projetos habilitados (A, B e C) adotam, predominantemente, valores nulos para esta componente.

#### 4.2 Índice de Incerteza

Utilizando como base os empreendimentos das seis certificadoras mais presentes na amostra de dados selecionada, é importante tentar captar as diferenças entre as suas modelagens de forma qualitativa. Espera-se que, em algumas certificadoras haja padrões mais ou menos otimistas, uma vez que se trata de um processo individual. Tais variações de estimativas podem ser decorrentes de diversas características, como:

- Estrutura da modelagem;
- Características dos empreendimentos certificados;
- Características técnicas dos projetos;
- Riscos locacionais;
- Grau de confiança dos empreendedores e certificadoras;
- Grau de confiança dos resultados do P50 estimado.

As análises a seguir não possuem intenção de questionamentos aos valores de incertezas adotados pelas certificadoras, uma vez que esta avaliação deve ser obtida a partir da comparação do resultado operacional do parque em conjunto com os resultados da certificação.

Barriatto e Tilman (Barriatto & Tilman, 2018) sugerem um índice de incerteza (P90/P50) para a avaliação do risco associado às estimativas pré-construtivas de produção de energia para o período de 20 anos. O índice é obtido a partir da equação para o cálculo da probabilidade de excedência “P90 de 20 anos”, supondo uma distribuição Gaussiana. O risco é classificado em quatro níveis: baixo para o intervalo entre 0,90 e 0,95; médio entre 0,85 e 0,90; alto entre 0,80 e 0,85 e muito alto entre 0,75 e 0,80.

$$\text{Índice de Incerteza} = \frac{P_{90}}{P_{50}} = 1 - (\text{Incerteza Padrão} \times 1,28155)$$

O fato de não existir uma padronização de critérios entre as certificadoras para o cálculo da Incerteza Padrão Resultante e suas componentes pode levar a resultados práticos muito diferentes daqueles indicados nos projetos. Por exemplo, uma certificadora que adote critérios muito otimistas pode esconder riscos elevados de um parque não conseguir produzir a energia estimada na certificação.

A Figura 5 mostra a distribuição dos projetos de acordo com a relação P90/P50, que representa o índice de incerteza para estimativas de energia de parques eólicos para 20 anos, considerando os habilitados para os Leilões de 2017 a 2022 das seis certificadoras com mais projetos, identificadas no gráfico por letras. O valor do índice de cada projeto foi arredondado para a segunda casa decimal. As cores ajudam a identificar os níveis de risco, sendo: verde para baixo, amarelo para médio, laranja para alto e vermelho para muito alto. Idealmente, um valor alto do índice estaria associado a estimativas realizadas com dados mais robustos e confiáveis e, portanto, a uma incerteza menor. Um índice com valor baixo, por sua vez, indicaria uma incerteza alta associada a poucos dados medidos, efetivamente, no sítio onde o parque será instalado.

As certificadoras A e B são as que possuem distribuições mais simétricas, centradas aproximadamente na razão 0,87. As certificadoras C e D se destacam pela grande concentração de projetos com valores de índice de incerteza nas regiões superiores à 0,9. A certificadora E classifica a quase totalidade de seus projetos com razões inferiores à 0,9; com distribuição bastante dispersa neste intervalo. A certificadora F exibe grande dispersão ao longo de todo intervalo, com maior concentração também na região 0,87.

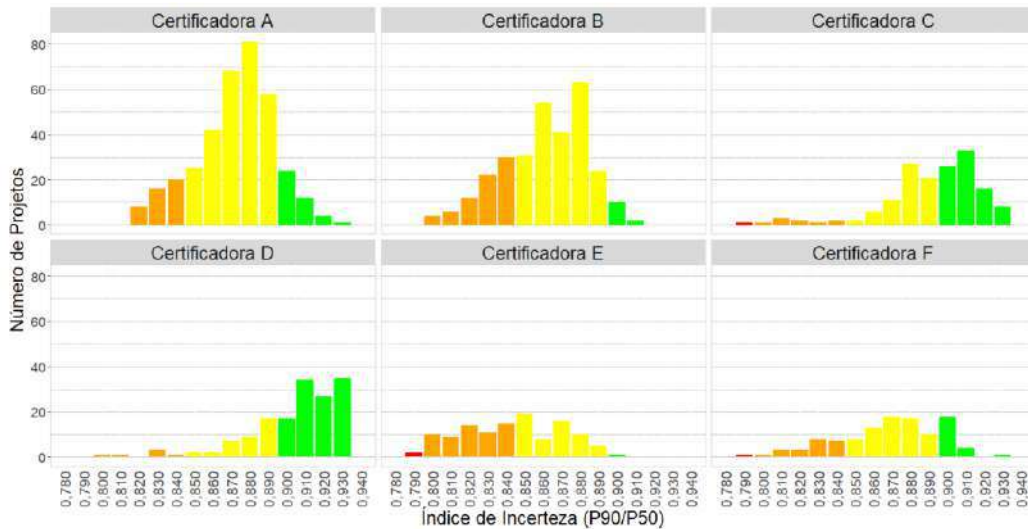


Figura 5 - Classificação dos projetos da amostra de acordo com o índice de incerteza

Ao comparar as seis certificadoras, constata-se que não existe uma distribuição padrão dos resultados, provavelmente, porque o universo dos empreendimentos certificados é heterogêneo ou devido à utilização de premissas e critérios distintos.

#### 4.3 Percentual de participação de cada componente na Incerteza Padrão Resultante

A identificação das componentes mais relevantes em projetos habilitados para participar de leilões é uma forma prática de comparar as metodologias e critérios de adoção de valores utilizados pelas certificadoras.

Conforme definição prévia das componentes e, pressupondo que os coeficientes de sensibilidade sejam unitários e as incertezas componentes independentes, é possível obter a equação abaixo:

$$IPR^2 = IMA^2 + ICP^2 + OI^2 + IMCEE^2 + IVI^2 + ICLP^2 + IEVT^2 + IEHT^2$$

Após desenvolvimento algébrico da equação acima, obtém-se a participação do quadrado de cada componente em relação ao quadrado da Incerteza Padrão Resultante. Como exemplo, segue a equação referente à Incerteza das Medições Anemométricas.

$$\frac{IMA^2}{IPR^2} = 1 - \frac{ICP^2 + OI^2 + IMCEE^2 + IVI^2 + ICLP^2 + IEVT^2 + IEHT^2}{IPR^2}$$

A última etapa consiste no cálculo da participação média de cada componente por certificadora.

Na Figura 6, a participação média das incertezas das quatro certificadoras com mais projetos é exibida em gráfico de barras. Nota-se que a maioria das certificadoras adota as Incertezas da Curva de Potência e de Extrapolação Horizontal como as principais componentes. As Incertezas Medições Anemométricas e Metodologia do Cálculo de Efeito Esteira e Variabilidade Interanual apresentam baixa variabilidade. Em contrapartida, as Incertezas de Correlação de Longo Prazo e Variabilidade Interanual tendem a ter maior variabilidade e em algumas certificadoras baixas participações.

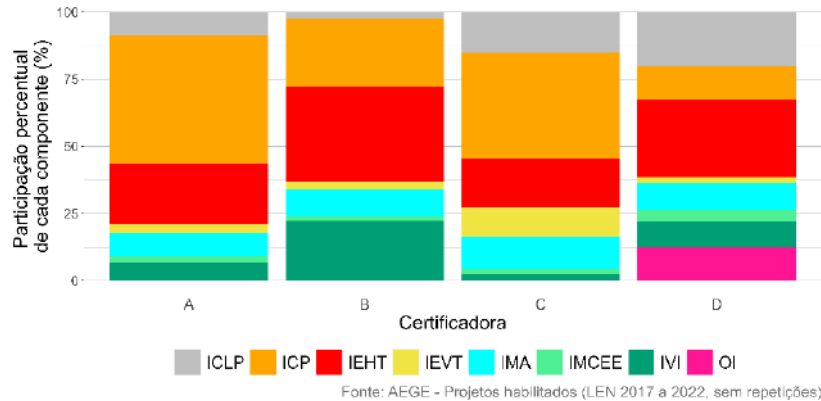


Figura 6 - Participação média de cada incerteza por certificadora

De forma mais detalhada, são mostrados a seguir os resultados das quatro certificadoras, permitindo identificar variabilidades de suas metodologias. Nas figuras seguintes, em cada unidade do eixo X está representado um projeto habilitado pertencente à amostra. No eixo Y a participação de cada componente é exibida em valores percentuais, de forma empilhada.

Nota-se na certificadora A que as Incertezas de Variação Interanual e Correlação de Longo Prazo retratam uma constância entre os múltiplos projetos. As Incertezas de Extrapolação Vertical e Curva de Potência são as que possuem maiores variabilidades, havendo grande número de empreendimentos com Incerteza de Extrapolação Vertical aproximadamente nula (Figura 7).

Na certificadora B é possível identificar grande participação das parcelas referentes às Incertezas de Variação Interanual e da Extrapolação Horizontal. Para as incertezas de Correlação de Longo Prazo e de Cálculo de Efeito Esteira predominam valores reduzidos. Em relação à Incerteza na Extrapolação Vertical, pode-se perceber desde a existência de projetos com participação desprezível a projetos com valores próximos de 30% (Figura 8).

A certificadora C reúne grande variabilidade entre a maior parte das incertezas, com grande participação na parcela de Incerteza de Medições Anemométricas, de Extrapolação Horizontal e de Curva de Potência. Já as parcelas de incertezas de Variabilidade Interanual revelam baixa variação de valores (Figura 9). Diferentemente das outras, a certificadora C pondera a Incerteza de Extrapolação Vertical com participação significativa em vários projetos.

Conforme pode ser visto na Figura 10, a certificadora D é caracterizada por grande estabilidade nas distribuições de incerteza observadas, com valores próximos na maior parte dos projetos. É possível identificar também que é a certificadora que apresenta a maior participação da parcela Outras Incertezas na sua metodologia, com quase todos os projetos tendo participação não desprezível desta componente.

É possível identificar, a partir da distribuição de empreendimentos, que a Incerteza da Curva de Potência é a principal componente para a certificadora A, e uma das principais componentes para a certificadora C.

A Incerteza da Extrapolação Horizontal é identificada como uma das principais componentes de todas as certificadoras, havendo grande quantidade de empreendimentos em que esta componente é a principal motriz da Incerteza Padrão Resultante. Observa-se a ocorrência de empreendimentos em que esta incerteza é reduzida, provavelmente nas localidades com terrenos simples ou cujas medições foram realizadas com grande proximidade dos locais previstos para a instalação dos aerogeradores.

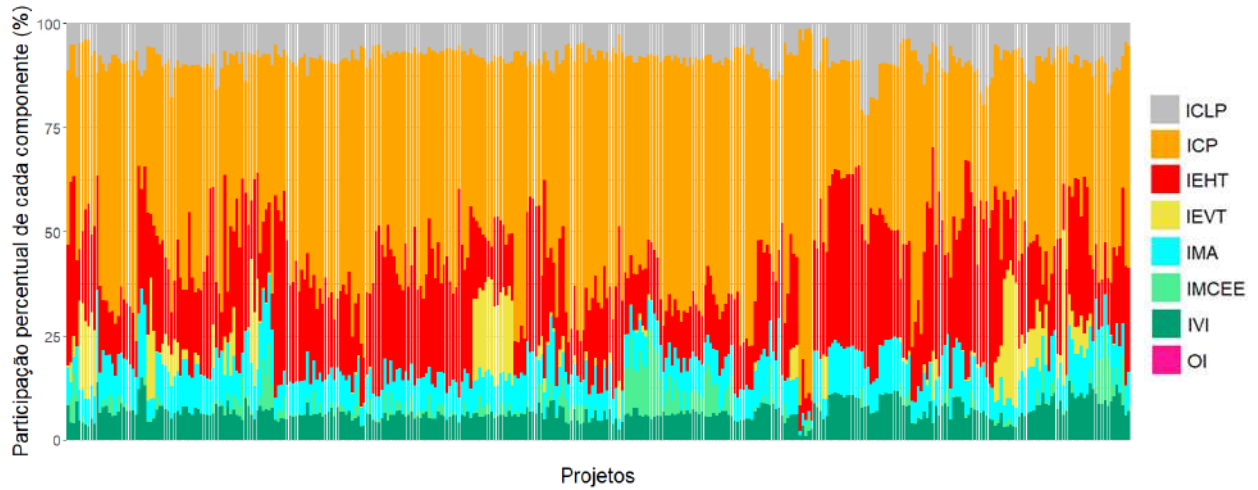


Figura 7 - Projetos da Certificadora A - Participação de cada componente na IPR<sup>2</sup>

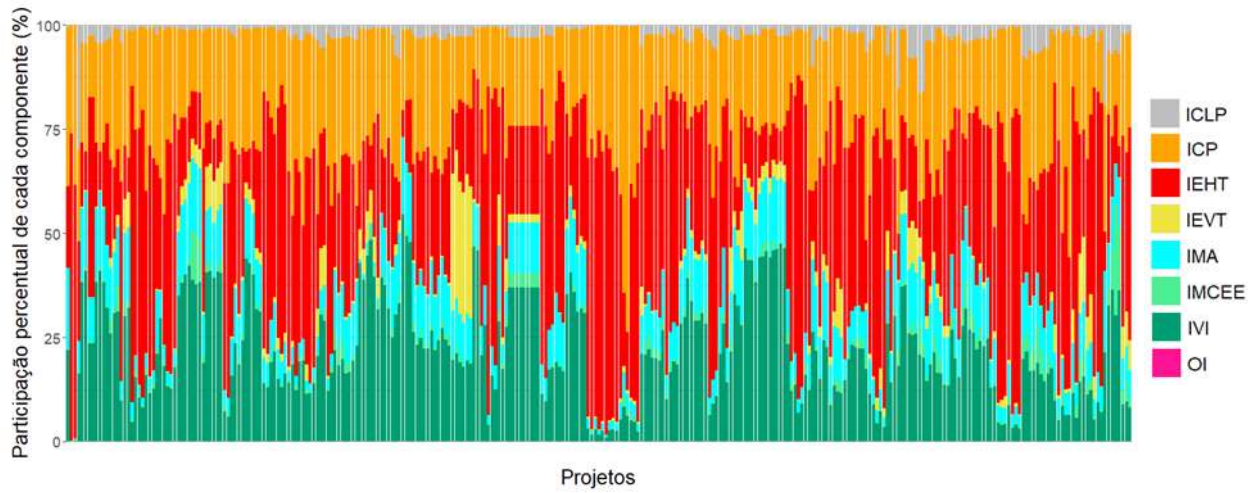


Figura 8 - - Projetos da Certificadora B - Participação de cada componente na IPR<sup>2</sup>

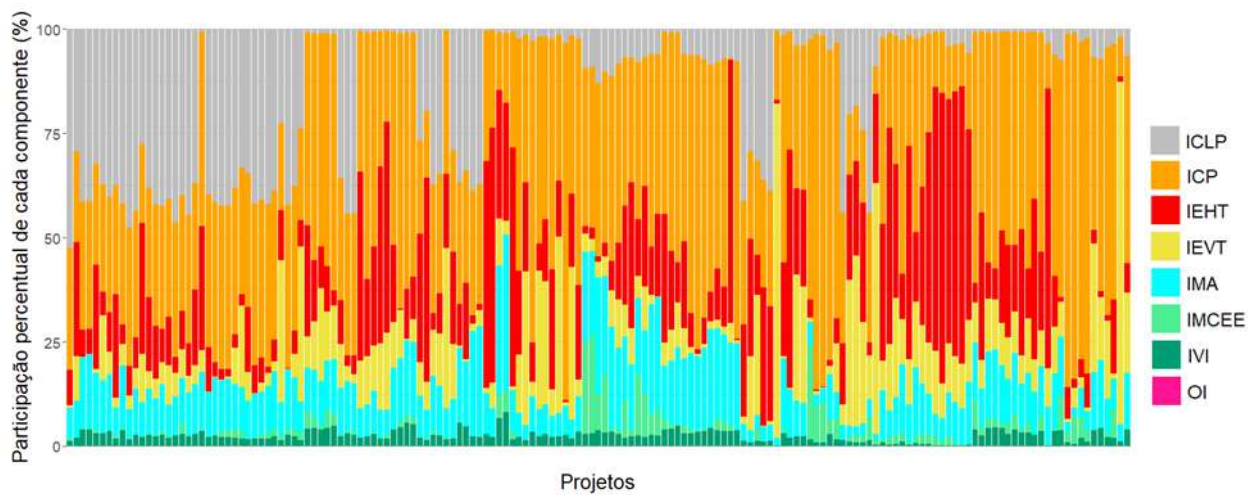


Figura 9 - Projetos da Certificadora C - Participação de cada componente na IPR<sup>2</sup>

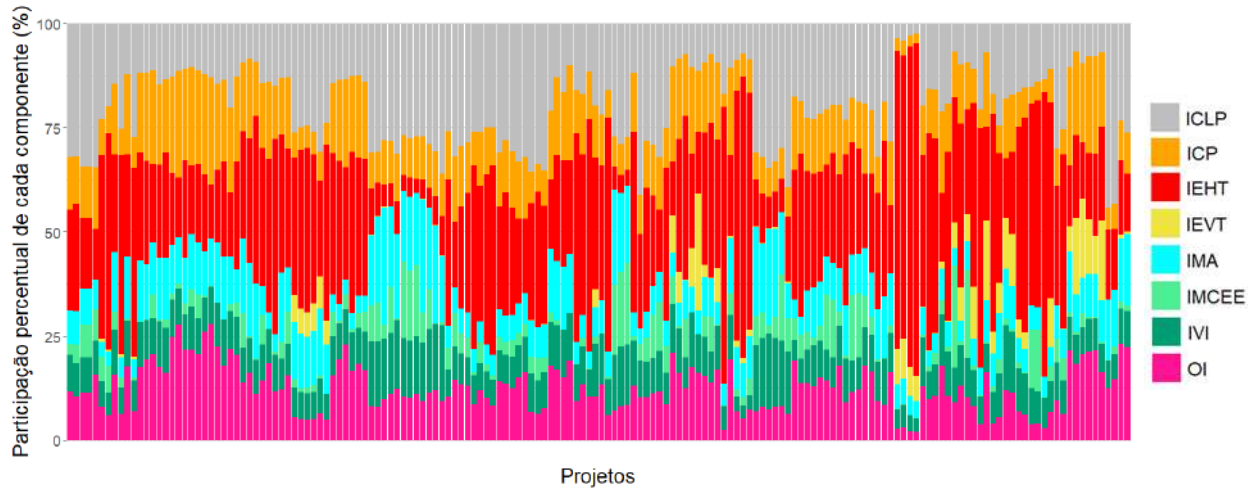


Figura 10 - Projetos da Certificadora D - Participação de cada componente na IPR<sup>2</sup>

#### 4.5 – Análise regional da participação das componentes da Incerteza Padrão

Para esta análise, os projetos das quatro certificadoras com maior participação na amostra foram categorizados, conforme pode ser constatado na Figura 11 e na Figura 12. Nestes gráficos são observadas as composições médias das incertezas em cada região, objetivando identificar a alteração da percepção de incerteza das empreendedoras em função da localidade. A localização Sul foi suprimida devido à baixa quantidade de projetos na maior parte das certificadoras.

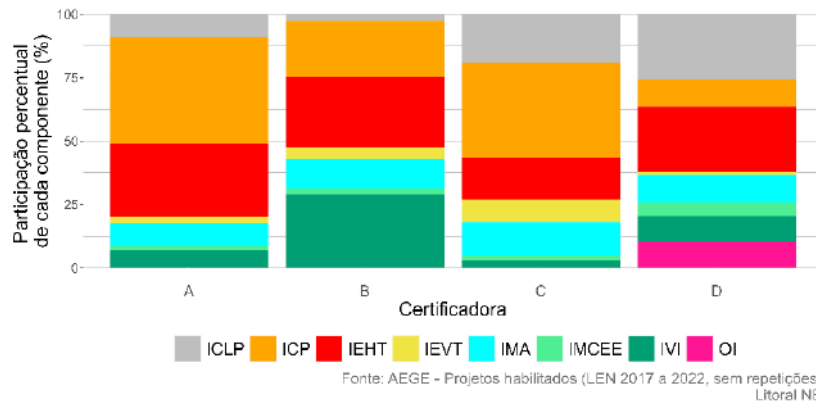


Figura 11 – Participação Média das Componentes na IPR2 por certificadora- Litoral NE

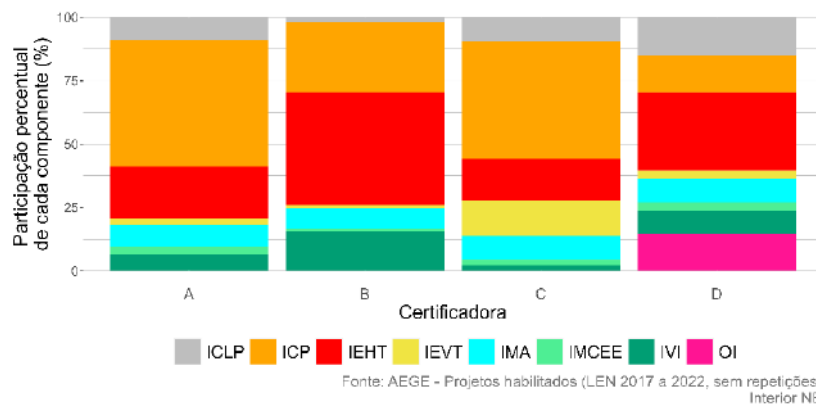


Figura 12 - Participação Média das Componentes na IPR2 por certificadora -Interior NE



A partir dos gráficos apresentados, análises comparativas por localização e entre as localizações podem ser realizadas, destacando-se alguns pontos:

- A Incerteza de Correlação de Longo Prazo tende a ser maior no Litoral do NE do que no Interior.
- As certificadoras A e C são caracterizadas por baixa variabilidade entre as duas localizações;
- Para a certificadora B, destaca-se a maior participação da IEHT e menor participação da IVI no “Interior-NE”, quando comparado com o “Litoral-NE”.
- Para a certificadora D, destaca-se a maior participação da ICLP e menor participação da ICP, da IEHT e da IEVT no “Litoral-NE”, quando comparado com o “Interior-NE”.

## 5. CONSIDERAÇÕES FINAIS

A intenção deste estudo não é fazer críticas ou questionamentos em relação às metodologias utilizadas nos cálculos das incertezas dos projetos utilizados. A adequabilidade e precisão das incertezas devem ser escopo de um estudo próprio, que permita comparar as incertezas estimadas na fase de projeto e os resultados operacionais observados.

Estudos, pesquisas e projetos cooperativos entre instituições que envolvam a definição de procedimentos padronizados e quantitativos para o cálculo de incertezas podem ser importantes para a evolução do setor eólico brasileiro, reduzindo variações de componentes entre certificadoras e gerando segurança aos empreendedores.

A análise dos dados apresentados mostrou que duas componentes são preponderantes na composição da Incerteza Padrão: a Incerteza de Curva de Potência e a Incerteza de Extrapolação Horizontal. Em algumas certificadoras, a parcela “Outras Incertezas” é mais frequentemente utilizada, porém a possibilidade de rastreamento da origem dos fatores aplicados por estas certificadoras fica prejudicada.

Com relação às duas localizações estudadas, podem ser observadas suaves alterações da composição das incertezas. Para a ICLP existe a tendência de redução da participação no “Interior-NE”. Em contrapartida, a ICP tende a sofrer suaves incrementos.

Apesar de removidos nos estudos de combinação de incertezas aqui apresentados, o pressuposto de combinação de incertezas a partir da soma quadrática das suas componentes não é observada por todos os projetos que participam dos leilões. Assim, a inclusão do memorial de cálculo utilizado para a obtenção da Incerteza Padrão Resultante no relatório da certificação é identificada como uma boa prática, permitindo a avaliação individualizada dos procedimentos e a avaliação pelos agentes das premissas aplicadas aos seus empreendimentos.

Análises de precisão dos processos de estimativa de geração dos empreendimentos são importantes e podem ser realizadas em estudos futuros, permitindo a complementação das análises aqui apresentadas. Tais estudos podem reduzir a assimetria de informações entre as certificadoras e permitir o avanço das discussões com relação a aprimoramentos mencionados acima.

## 6. REFERÊNCIAS

- Barriatto, L., & Tilman, F. (2018). *Um Guia para Estimativas de Incerteza na Produção de Energia Eólica*.
- Bureau International des Poids et Mesures. (2008). *Evaluation of measurement data - Guide to the expression of uncertainty in measurement - JCGM 100:2008*.
- EPE. (2021). *Instruções para Solicitação de Cadastramento e Habilitação Técnica com vistas à Participação nos Leilões de Energia Elétrica*. Fonte: Expansão da Geração - Empreendimentos de Geração Eólica: [https://www.epe.gov.br/sites-pt/leiloes-de-energia/Documents/EPE-DEE-017\\_2009\\_R17\\_EOL.pdf](https://www.epe.gov.br/sites-pt/leiloes-de-energia/Documents/EPE-DEE-017_2009_R17_EOL.pdf)
- EPE. (14 de 06 de 2024). *Garantia Física*. Fonte: Empresa de Pesquisa Energética: <https://www.epe.gov.br/pt/areas-de-atuacao/energia-eletrica/garantia-fisica>
- EPE. (s.d.). *Sistema de Acompanhamento de Empreendimentos Geradores de Energia Elétrica - AEGE*. Acesso em 14 de 06 de 2024, disponível em <https://www.epe.gov.br/pt/aceso-restrito/sistema-aege>
- IEC. (2022). *Wind energy generation systems - Part 12-1: Power performance measurements of electricity producing wind turbines*.
- MME. (2016). *Portaria N° 101, de 22 de março de 2016*. Ministério de Minas e Energia. Acesso em 14 de 06 de 2024, disponível em <https://www.gov.br/mme/pt-br/aceso-a-informacao/legislacao/portarias/2016/portaria-n-101-2016.pdf/view>

## **Aplicação da metodologia MCP a estimativa pós-construtiva de produção anual de energia em complexos eólicos**

### **Autores**

M. Costa<sup>1</sup>, T. Rocha<sup>2</sup>, J. Mendonça<sup>3</sup>, R. Pilão<sup>4</sup> e P. Pinto<sup>1</sup>

<sup>1</sup> MEGAJOULE S.A.

Rua do Divino Salvador de Moreira, 255; 4470-105 Maia (Portugal)  
mariana.costa@megajoule.pt,  
paulo.pinto@megajoule.pt

<sup>2</sup> INESC TEC, Centre for Power and Energy Systems

Rua Dr. Roberto Frias, 4200-465 Porto (Portugal)  
tomas.rocha@inesctec.pt

<sup>3</sup> SIIS, Instituto Politécnico do Porto,

R. Dr. Roberto Frias, 4200-465 Porto (Portugal)  
jpm@isep.ipp.pt

<sup>4</sup> CIETI, ISEP Instituto Politécnico do Porto

Rua Dr. António Bernardino de Almeida, 341; 4200-072 Porto (Portugal)  
rmp@isep.ipp.pt

### **SUMÁRIO**

A estimativa de produção de energia de um parque eólico pode ser feita através de estudo pré-construtivo que se baseia em dados de vento recolhidos no local e na modelação numérica do comportamento do vento e dos efeitos de esteira que as turbinas podem provocar e sofrer, sendo realizado antes da construção do parque eólico. No entanto, a estimativa pré-construtiva da produção anual de energia elétrica apresenta muitas incertezas, devido a imprecisões do modelo de escoamento utilizado no cálculo do regime de vento ou desvios na performance dos aerogeradores, por exemplo. Outra forma de estimar a produção de energia é através de um estudo pós-construtivo, que ocorre numa fase posterior ao comissionamento do parque eólico, feita com base nos dados reais do parque, incluindo a produção de energia e a disponibilidade dos aerogeradores. Este estudo pós-construtivo reduz as incertezas dos estudos pré-construção, apresentando vantagens para o proprietário do projeto.

O presente trabalho propõe uma metodologia simples e eficaz para estimar a produção anual de energia elétrica de Longo Termo pós-construtiva em complexos eólicos, correlacionando dados históricos de vento com produções mensais reais de parques operacionais. A análise conclui que a realização de estudos individuais para cada parque eólico não oferece benefícios substanciais em comparação ao estudo do complexo como um todo. A metodologia permite estimar a produção de energia de um complexo de forma eficiente, economizando tempo e recursos sem comprometer significativamente a precisão das estimativas.

**Palavras-chave:**

Energia eólica; estudo pós-construtivo; complexos eólicos

**ABSTRACT**

The energy production of a wind farm can be estimated through a pre-construction study based on wind data collected on-site and numerical modelling of wind behaviour and the wake effects that the turbines can cause and suffer, which is carried out before the wind farm is built. However, the pre-construction estimate of annual electricity production presents many uncertainties, due to inaccuracies in the flow model used to calculate the wind regime or deviations in the performance of the wind turbines, for example. Another way of estimating energy production is through a post-construction study, which takes place after the wind farm has been commissioned and is based on real data from the wind farm, including energy production and the availability of wind turbines. This post-construction study reduces the uncertainties of pre-construction studies, offering advantages for the project owner.

This paper proposes a simple and effective methodology for estimating wind complexes' annual post-construction long-term electricity production, correlating historical wind data with actual monthly production from operational farms. The analysis concludes that individual studies for each wind farm do not offer substantial benefits compared to studying the complex. The methodology makes it possible to estimate the energy production of a complex efficiently, saving time and resources without significantly compromising the accuracy of the estimates.

**Keywords:**

Wind energy; post-construction study; wind complexes

**1. INTRODUÇÃO**

O desenvolvimento de tecnologias associadas a fontes renováveis de energia, especialmente a energia eólica, é crucial para atingir a neutralidade carbónica devido aos avanços tecnológicos e elevado potencial, uma vez que o vento é uma fonte inesgotável de energia que se encontra disponível em grande parte da superfície terrestre. Muitas das vantagens da energia eólica são comuns a outras renováveis, nomeadamente o combate às mudanças climáticas, com a redução da utilização de combustíveis fósseis e a emissão de Gases com Efeito de Estufa (GEE), para além do facto de serem um auxílio para a autossuficiência energética, diminuindo as importações de recursos para produção de energia elétrica.

Contudo, a criação de um parque eólico enfrenta desafios como a avaliação da viabilidade económica e a obtenção de financiamento, tornando essencial o estudo de caracterização dos recursos eólicos e energéticos. A estimativa de produção de energia de um parque eólico pode ser feita de duas maneiras distintas. A primeira, conhecida como estudo pré-construtivo, baseia-se em dados de vento recolhidos no local e na modelação numérica do comportamento do vento e dos efeitos de esteira que as turbinas podem

provocar e sofrer. Este estudo é realizado antes da construção do parque eólico e não utiliza dados do parque em operação. No entanto, a estimativa pré-construtiva da produção anual de energia elétrica apresenta muitas incertezas, devido a imprecisões do modelo de escoamento utilizado no cálculo do regime de vento, desvios na performance dos aerogeradores, erros na medição do regime de vento local, entre outros. A segunda forma, chamada de estudo pós-construtivo, ocorre numa fase posterior ao comissionamento do parque eólico. Nesta abordagem, a estimativa de produção de energia é feita com base nos dados reais do parque, incluindo a produção de energia e a disponibilidade dos aerogeradores. Realiza-se uma projeção de Longo Termo, normalmente para 20 ou 25 anos, considerando pressupostos fundamentados nas condições de vento e performance energética. Após algum tempo de operação, a reavaliação da estimativa de produção anual, baseada em dados operacionais, apresenta muitas vantagens para o proprietário do projeto, nomeadamente a redução de incertezas dos estudos pré-construção, sendo importante para refinanciamento ou transações de compra e venda do parque eólico.

O trabalho em questão propõe uma metodologia simples e eficaz para estimar a produção anual de energia elétrica a Longo Termo em complexos eólicos, correlacionando dados históricos de vento com produções mensais reais de parques eólicos operacionais. O objetivo principal do estudo é perceber o potencial impacto, em termos de precisão, do uso de informação desagregada de cada um dos parques que constitui o complexo e da informação agregada como um todo do complexo. A importância deste estudo prende-se com o facto de haver a possibilidade de não ser necessário estudar os parques eólicos que constituem um complexo de forma individual, e realizar apenas uma estimativa de produção de Longo Termo ao próprio complexo eólico, tornando mais simples e expedita a metodologia utilizada para analisar um complexo eólico, revestindo-se da maior importância em contexto empresarial.

## 2. ESTADO DE ARTE

A variabilidade interanual da velocidade do vento torna insuficientes os dados de produção de apenas alguns anos para refletir o regime de ventos de um local. Para parques eólicos com poucos anos de operação (1 ou 2 anos), esses dados podem não ser suficientes para estimar com precisão a produção média de energia elétrica ao longo de 20 ou 25 anos, podendo levar a subestimativas ou sobre estimativas devido à elevada variabilidade interanual do vento [1].

O método estatístico *Measure-Correlate-Predict* (MCP) é utilizado para reduzir as incertezas das estimativas, correlacionando os dados de produção do parque com uma base de dados de vento de Longo Termo próxima aos dados locais. Essa abordagem estabelece uma correlação entre os dados de produção do parque e os dados históricos de vento para um período simultâneo, usando essa correlação para estimar a produção de energia de Longo Termo. O método MCP encontra-se esquematizado na Figura I.




Figura I. Representação esquemática do método MCP.

Existem diversos métodos para estimar a produção de energia a Longo Termo de um parque eólico em operação, como o método da curva de potência histórica, o método de índice e o método de regressão linear simples. Esses métodos utilizam dados de fontes históricas de Longo Termo e aplicam o método MCP para correlacionar os dados reais de medição com os dados históricos, como as séries de reanálise.

A regressão linear simples é uma técnica estatística que estabelece uma relação entre duas ou mais variáveis. No contexto mais comum, a regressão linear simples envolve duas variáveis: a variável que se pretende prever (dependente) e a variável utilizada para fazer a previsão (independente). A equação 1 descreve o método da regressão linear [2, 3].

$$y = \alpha x + \beta + \varepsilon \quad \text{[Equação 1]}$$

onde,  $y$  é a variável dependente,  $x$  é a variável independente,  $\alpha$  é o coeficiente da regressão que representa a inclinação da reta,  $\beta$  é o “ponto” de interseção da reta com o eixo vertical e  $\varepsilon$  é o erro aleatório.

De notar que a aplicação da regressão linear simples carece da verificação de alguns pressupostos nomeadamente a homocedasticidade e a normalidade da distribuição.

Neste estudo,  $y$  é a produção mensal e  $x$  é a velocidade média mensal do vento.

### 3. MÉTODO DE ESTUDO

#### 3.1. Base de dados do estudo

A base de dados utilizada no estudo é constituída por 8 complexos eólicos com períodos de funcionamento variáveis (2 a 8 anos), distribuídos por dois países, Espanha e Brasil. A seleção de complexos eólicos em diferentes partes do mundo teve como objetivo captar diferentes regimes de vento e o efeito que podem ter na qualidade das séries de reanálise e na estimativa da produção de energia a Longo Termo. As informações gerais sobre cada complexo eólico utilizado neste estudo são descritas na Tabela I.

Tabela I. Informação genérica sobre a base de dados utilizada no estudo

País	Designação	Nº de parques	Potência instalada (MW)	Anos de operação
Espanha	E1	2	101,4	4
	E2	3	94,5	4
Brasil	B1	5	160	8
	B2	8	267	5
	B3	7	223	3
	B4	8	205,1	6
	B5	2	40	2
	B6	3	70	2

### 3.2. Metodologia geral

Os dados de entrada utilizados foram a produção real de energia dos parques/complexos eólico(s) selecionados, numa base mensal, e a disponibilidade das turbinas eólicas que compõem o parque, para o período de funcionamento. Os dados da produção real do parque eólico foram corrigidos para uma disponibilidade de 100% do parque, ou seja, foi calculada a razão entre o valor da produção mensal e a disponibilidade do parque eólico nesse mês. O resultado obtido foi uma série de dados mensais de produção de energia que corresponde a uma disponibilidade de 100% do parque eólico. Para a localização central de cada complexo eólico, foram extraídas 8 séries de reanálise (4 do tipo ERA5 e 4 do tipo MERRA-2) para os pontos da grelha mais próximos desse ponto central [4,5]. Para cada série de dados de reanálise, os dados de produção mensal observados foram linearmente correlacionados com séries de dados de vento de Longo Termo para o período simultâneo, resultando em 8 correlações. Para melhorar estas correlações, os pontos demasiado afastados da linha de tendência ou com um valor de disponibilidade mensal inferior a 85 % foram filtrados. De entre as 8 correlações estabelecidas, foi selecionada a correlação com maior coeficiente de determinação ( $R^2$ ) e a mesma foi aplicada à série de dados de reanálise selecionada de Longo Termo, gerando uma série de produção mensal reconstruída para 20 anos. Posteriormente, a série de produção anual foi obtida através da soma das produções mensais de cada ano, e a estimativa de produção de energia a Longo Termo foi calculada através da média das produções anuais ao longo do período de 20 anos.

Tendo em vista cumprir os objetivos propostos foram conduzidos dois estudos distintos, variando os dados de entrada: no primeiro estudo, utilizaram-se os dados agregados do complexo eólico como um todo, enquanto no segundo estudo foram utilizados os dados individuais de cada parque que constitui o complexo.

A metodologia geral, descrita anteriormente, foi aplicada separadamente a cada complexo estudado utilizando os dados operacionais do complexo completo, e aos parques individuais que constituem cada complexo. Isso resultou na reconstrução de séries de produção de energia tanto para o complexo como um todo quanto para cada um dos parques dos complexos em estudo. Posteriormente, as séries individuais de produção de energia dos parques foram agregadas para formar a série de produção de energia de cada complexo. Em seguida, as séries de produção de energia dos complexos resultantes dos

diferentes conjuntos de dados de entrada (primeiro e segundo estudo) foram comparadas com a série de produção real do complexo.

No segundo estudo, que empregou os dados dos parques individualmente, foi também investigada a influência da escolha da fonte de reanálise. Foram realizadas estimativas de produção de energia utilizando a fonte de reanálise mais apropriada para o complexo eólico como um todo, e estas foram comparadas com as estimativas de produção de energia baseadas na fonte de reanálise mais adequada para cada parque. Ambos estudos descritos têm como objetivo avaliar a precisão da estimativa de produção de energia de Longo Termo, e têm como referência a estimativa de produção de energia de Longo Termo calculada com os dados do complexo, uma vez que não existem dados de produção reais de 20 anos do complexo eólico.

Além disso, foram realizadas análises estatísticas adicionais, incluindo a verificação da homogeneidade das variâncias e da normalidade da distribuição dos dados, bem como testes de hipóteses e análises post hoc. Essas análises visaram determinar se existem diferenças estatisticamente significativas entre utilizar os dados operacionais do complexo ou os dados dos parques individuais que os compõem, no âmbito da avaliação da precisão das séries de produção reconstruídas pelo modelo.

### 3.3. Avaliação estatística

Tendo como objetivo avaliar a precisão e a exatidão das projeções em comparação com os dados reais de produção de energia dos complexos foram calculados dois indicadores (RMBE e o RRMSE). Em seguida, foram investigadas diferenças significativas entre grupos com o uso de testes de hipótese.

A Raiz do Erro Quadrático Médio Relativo (RRMSE) e o Erro Absoluto Médio Relativo (RMBE) são métricas utilizados para medir a qualidade das previsões em relação aos valores reais, mas focam aspectos diferentes da precisão e exatidão do modelo. A principal diferença entre o RRMSE e o RMBE está nas suas abordagens para medir a precisão e exatidão do modelo. O RRMSE concentra-se na magnitude dos erros, enfatizando mais os erros maiores, enquanto o RMBE foca na direção dos erros e determina se há um viés no modelo [4].

O RRMSE é calculado através da Equação 2, na qual  $\bar{y}$  é a média dos valores observados,  $n$  o número de amostras,  $y_i$  o valor observado para a amostra  $i$  e  $p_i$  o valor previsto para a amostra  $i$ :

$$RRMSE = \frac{1}{\bar{y}} \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad \text{[Equação 2]}$$

O RMBE é calculado através da Equação 3:

$$RMBE = \frac{1}{\bar{y}} \times \frac{1}{n} \sum_{i=1}^n (y_i - p_i) \quad \text{[Equação 3]}$$



Tendo como objetivo perceber se existe um impacto significativo na precisão das séries de produção reconstruídas pelo modelo, utilizando a informação agregada ou desagregada dos complexos eólicos, compararam-se 3 séries de produção mensal reconstruídas de cada complexo, nomeadamente a série reconstruída com os dados do complexo, a série reconstruída com os dados dos parques individuais utilizando a melhor série de reanálise para cada parque e a série reconstruída com os dados dos parques individuais utilizando a melhor série de reanálise para o complexo. Para fazer essa comparação, as métricas de erro RRMSE e o RMBE foram calculadas para cada uma das 3 séries de produção, tomando como referência os respetivos dados reais de produção mensal.

Tendo como objetivo avaliar se existem diferenças significativas entre utilizar os dados do complexo ou dos parques individuais que o constituem, recorreu-se a ferramentas estatísticas que permitem avaliar se existem diferenças significativas entre as 3 séries de produção mensal reconstruídas de cada complexo. Para isso, começou-se por avaliar se pressupostos como a homogeneidade das variâncias e a normalidade da distribuição dos dados são cumpridos, recorrendo aos testes de Levene e de Kolmogorov-Smirnov, respetivamente. A aplicação destes testes é relevante no sentido de perceber se a análise de variância (ANOVA) pode ser aplicada ou se existe a necessidade de recorrer a um teste não paramétrico, como a ANOVA de Welch ou o teste de Kruskal-Wallis, que avalia se existem diferenças significativas entre as medianas dos grupos. No presente estudo, a análise estatística utilizada foi o teste de Kruskal-Wallis.

A Figura III apresenta um diagrama que detalha a metodologia estatística descrita, destacando a sequência de procedimentos estatísticos desde a verificação dos pressupostos até à realização das comparações post hoc para explorar as diferenças entre os grupos de forma mais detalhada.

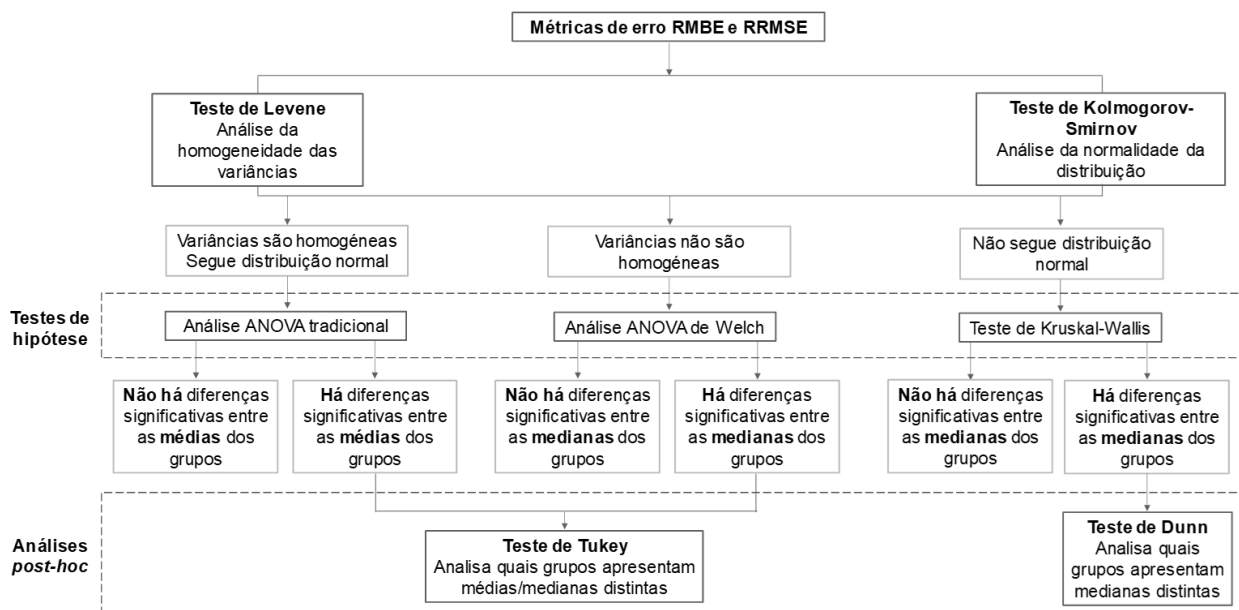


Figura III. Representação esquemática da metodologia adotada na análise estatística.

#### 4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

O estudo abordou a estimativa de produção de energia de um complexo eólico de duas maneiras distintas, sendo que os casos de estudo podem ser organizados da seguinte forma:

- C1: estudo com dados agregados da produção do complexo
- C2: estudo com dados desagregados da produção dos parques individuais, selecionando a série de reanálise mais representativa para todo o complexo
- C3: estudo desagregado da produção dos parques individuais, selecionando a série de reanálise mais representativa para cada parque

Na primeira parte do estudo, que tem como objetivo perceber a influência da agregação dos dados de produção na estimativa de produção de energia de Longo Termo do complexo, tomou-se como referência a estimativa de produção de energia de Longo Termo calculada com base em C1, uma vez que não existem dados reais do complexo para 20 anos. A Figura IV apresenta um gráfico de barras com duas séries de dados, sendo que a primeira série representa o desvio entre as estimativas de produção de energia usando os estudos C2 e C1 e a segunda descreve o desvio entre os estudos C3 e C1.




Figura IV. Desvio entre o valor estimado de Longo Termo para o complexo obtido nos estudos C2 e C3 e o valor estimado com os dados do próprio complexo (C1).

De uma forma geral, os desvios entre as estimativas de Longo Termo com dados individuais dos parques e do complexo são baixos (máximo de aproximadamente 2.7%). Para alguns complexos a melhor reanálise para o complexo é também a melhor reanálise para todos os parques, o que explica as diferenças de 0% nesses complexos. Uma vez que a informação contida na Figura IV não usa os dados reais de Longo Termo como referência, não é possível afirmar qual das estimativas é mais precisa, no entanto é possível

concluir que não há diferença considerável entre utilizar a reanálise mais adequada para o complexo ou para cada parque. Assim, não existe uma vantagem evidente em usar a informação individual de cada parque no estudo, pois a diferença em relação ao estudo usando a informação do complexo é pouco significativa, comparável à incerteza do modelo e da estimativa de produção de energia.

O estudo fundamentou a análise gráfica anterior com testes estatísticos sobre as métricas de erro RMBE e RRMSE, aplicadas a cada uma das 3 séries de produção mensal reconstruídas para cada complexo, com o objetivo de analisar a qualidade das séries reconstruídas pelo modelo. A Tabela II apresenta os resultados dos testes de Levene e Kolmogorov-Smirnov, para além da escolha do teste de hipótese mais adequado e o respetivo resultado. Ambas as métricas de erro apresentam variâncias homogêneas (valor de prova,  $p > 0,05$ ) e distribuições não normais (estatística de teste  $>$  valor de tabela da Distribuição Kolmogorov- Smirnov), para todos os complexos estudados. Assim, o teste de Kruskal-Wallis é considerado o teste de hipóteses mais apropriado para ambas as métricas de erro, para todos os complexos em estudo. Os resultados do teste de Kruskal-Wallis para as duas métricas de erro indicaram que as medianas dos grupos não são estatisticamente diferentes, para todos os complexos em estudo. Assim, é possível concluir que não existem diferenças significativas entre o uso dos dados do complexo e dos dados dos parques individuais, independentemente de a série de reanálise ser a melhor para o complexo ou para cada parque do complexo, uma vez que os testes demonstraram não existir diferenças significativas entre as séries reconstruídas nos três casos de estudo.

Tabela II. Resultados dos testes de Levene, Kolmogorov-Smirnov e Kruskal-Wallis, para os diferentes casos de estudo

Métrica de erro	Caso de estudo	Teste de Levene		Teste de Kolmogorov-Smirnov			Teste de Kruskal-Wallis	
		Valor de p	Conclusão	Valor Tabelado	Valor observado da estatística de teste	Conclusão	Valor de p	Conclusão
RRMSE	C1	0.22	Variâncias homogêneas	0.45	0.92	Distribuição não normal	0.90	Não existem diferenças significativas entre as medianas dos grupos
	C2			0.45	0.91	Distribuição não normal		
	C3			0.45	0.82	Distribuição não normal		
RMBE	C1	0.74	Variâncias homogêneas	0.45	0.60	Distribuição não normal	0.67	Não existem diferenças significativas entre as medianas dos grupos
	C2			0.45	0.77	Distribuição não normal		
	C3			0.45	0.79	Distribuição não normal		

## 6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

Tendo em consideração a base de dados utilizada, é possível concluir que a realização de estudos usando dados dos parques individuais, relativamente ao estudo do complexo como um todo, não apresenta benefícios substanciais na estimativa de produção de energia de Longo Termo, apesar de não ser possível afirmar qual é a mais precisa devido à insuficiência de dados reais de produção de Longo Termo do complexo. Por outro lado, no que diz respeito à precisão das séries de dados reconstruídas pelo modelo para os diferentes casos de estudo, conclui-se que as medianas dos grupos não são estatisticamente diferentes, pelo que não existem diferenças significativas entre o uso dos dados do complexo e dos dados dos parques individuais, independentemente da série de reanálise selecionada.

Através das duas análises conduzidas, é possível afirmar que estimar a produção de energia de um complexo, recorrendo apenas aos dados do complexo é uma mais-valia uma vez que não compromete significativamente a precisão das estimativas, resultando em economia de tempo e recursos.

Como sugestão de trabalhos futuros, sugere-se a inclusão de dados de produção de Longo Termo (20 anos), com o objetivo de fundamentar a primeira análise realizada, uma vez que a referência utilizada no estudo é a estimativa de produção de energia de Longo Termo com os dados do complexo, ao invés da média real dos dados de produção do complexo, para 20 anos.

## REFERÊNCIAS

- [1] D. S. N. J. E. B. Tony Burton, "The Nature of the Wind," em *Wind Energy Handbook*, JOHN WILEY & SONS, LTD, 2001, pp. 11-12.
- [2] J. Fox, *Applied Regression Analysis and Generalized Linear Models*, Sage Publications, 2015.
- [3] U. A. Vivek Krishnamoorthy, "Linear Regression: Assumptions and Limitations," Abril 2022. [Online]. Available: <https://blog.quantinsti.com/linear-regression-assumptions-limitations/>.
- [4] Climate Change Service, "Climate reanalysis," [Online]. Available: <https://climate.copernicus.eu/climate-reanalysis>.
- [5] S. P. H. H. J. S. I. S. C. B. K. G. A. N. H. M. J. M. K. N. L. X. G. L. J. L. B. P. Russell McKenna, "High-resolution large-scale onshore wind energy assessments: A review of potential definitions, methodologies and future research needs," em *Renewable Energy*, ELSEVIER, 2022, pp. 659-684.

## **Avanços Metodológicos na Previsão Eólica para o Planejamento de Curto Prazo do ONS**

**Autores** [Paulo Sérgio C. Nascimento<sup>1</sup>, Lais F. Araujo<sup>2</sup>, Rogerio J. M. Alves<sup>3</sup>, William Cossich M. Farias<sup>4</sup>, Carlos Alberto A. Junior<sup>5</sup>, André Luís M. Marcato<sup>6</sup>]

<sup>2,3,4</sup>Gerência de Metodologias e Modelos Energéticos – Operador Nacional do Sistema Elétrico, RJ, Brasil

<sup>1,5,6</sup>Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, MG, Brasil

pnascimento@ons.org.br, lais.araujo@ons.org.br, rogerio.alves@ons.org.br, william.farias@ons.org.br, carlosjunior@ons.org.br, andre.marcato@uff.edu.br

### **RESUMO**

Atualmente, a geração das usinas eólicas é representada nos modelos oficiais de planejamento energético de curto e médio prazo – DECOMP e NEWAVE – de forma determinística, conforme os critérios estabelecidos pela Resolução Normativa da ANEEL nº 843/2019. Segundo a REN 843, a geração é estimada com base nos fatores de capacidade mensais médios, calculados a partir da geração verificada nos últimos cinco anos das usinas em operação. Essa estimativa é subtraída diretamente da carga dos respectivos subsistemas de energia. No modelo de curtíssimo prazo – DESSEM, a geração eólica utilizada é baseada nas previsões fornecidas pelo Modelo de Previsão de Geração Eólica Semi-Horário desenvolvido pelo ONS, utilizado na programação diária da operação eletroenergética desde 2018. Para melhorar a assertividade da previsão da geração eólica em um horizonte mais estendido, foi proposta uma nova metodologia, capaz de gerar previsões para até um mês à frente. Esta metodologia proporciona uma representação mais fiel da geração eólica nos modelos de planejamento, oficialmente em uso pelo setor, contribuindo para a uniformidade dos dados utilizados no DESSEM e DECOMP. Além disso, a proposta representa uma evolução metodológica do processo de previsão de geração eólica em relação à metodologia vigente para o planejamento energético.

### **Palavras-chaves:**

Previsão Eólica; Planejamento energético; Evolução metodológica de insumos para o DECOMP.

### **ABSTRACT**

Currently, wind power generation is represented in the official short- and medium-term energy planning models – DECOMP and NEWAVE – in a deterministic manner, in accordance with the criteria established by ANEEL Normative Resolution No. 843/2019. According to REN 843, generation is estimated based on average monthly capacity factors, calculated from the generation verified in the last five years of the plants in operation. This estimate is subtracted directly from the load of the respective energy subsystems. In the very short-term model – DESSEM, wind generation used is based on forecasts provided by the Semi-Hourly Wind Generation Forecast Model developed by ONS, used in the daily programming of the

electroenergy operation since 2018. To improve the accuracy of wind generation forecasting over a longer horizon, a new methodology was proposed, capable of generating forecasts for up to one month ahead. This methodology provides a more accurate representation of wind generation in the planning models officially used by the sector, contributing to the uniformity of the data used in DESSEM and DECOMP. In addition, the proposal represents a methodological evolution of the wind generation forecasting process in relation to the current methodology for energy planning.

**Keywords:**

Wind Forecasting; Energy Planning; Methodological Evolution of Inputs for DECOMP.

## 1. INTRODUÇÃO

A busca por um futuro mais sustentável é cada vez mais essencial, e, como resultado, a participação das fontes renováveis na matriz energética dos países tem aumentado significativamente. Embora essa transformação energética seja indiscutivelmente importante, o rápido crescimento de algumas fontes renováveis, especialmente aquelas com alta variabilidade, torna a operação dos sistemas elétricos mais complexa. Essa variabilidade pode adicionar custos operacionais e aumenta a complexidade, particularmente para os modelos de previsão de oferta e demanda.

No Brasil, além da alta variabilidade e da dependência de fatores meteorológicos, essas fontes são não despacháveis, ou seja, em condições normais de operação, a geração está diretamente ligada ao recurso natural disponível na usina. Portanto, é essencial realizar previsões precisas da geração dessas fontes para compor um portfólio otimizado de produção energética do Sistema Interligado Nacional (SIN). Essas previsões são fundamentais para o planejamento eletroenergético de curto e médio prazo. Maior precisão na previsão de geração dessas fontes permite um uso mais eficiente dos recursos, reduzindo a necessidade de reserva de potência operativa ou de geração termoelétrica adicional àquela definida por mérito econômico pelos modelos de otimização em uso.

Este artigo apresenta um modelo proposto para gerar previsões eólicas semanais para até um mês à frente, focado no planejamento de curto prazo. As motivações e os benefícios esperados com esse trabalho serão detalhados nas próximas seções. Além disso, o artigo contextualiza o histórico dos modelos de previsão desenvolvidos pelo ONS (Operador Nacional do Sistema Elétrico), fornecendo uma referência metodológica para o modelo proposto, avalia o desempenho das previsões geradas e encerra com uma seção de considerações finais.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1. Estado da arte

Os modelos de previsão que deverão ser desenvolvidos podem ser classificados como métodos físicos, estatísticos e/ou híbridos [1]. Os modelos físicos, geralmente utilizam as características físicas das plantas, dados observados de vento, umidade, temperatura etc. Nos modelos baseados em métodos estatísticos, há uma classe de métodos clássicos como Box-Jenkins [2], modelos de regressões e modelos mais sofisticados baseados em inteligência artificial, tais como: ANN (*Artificial Neural Network*) [3], com *deep learning* [4]; SVM (*Support Vector Machine*); sistemas de inferência fuzzy; GA (*Genetic Algorithm*) e outros.

Embora possa existir diversos modelos de previsão diferentes atuando em paralelo, os resultados finais são destinados às aplicações que demandam uma previsão única. Portanto, é necessário desenvolver algoritmos dinâmicos de combinação de previsões, visto que será utilizado vários: (i) modelos meteorológicos [5]; e/ou (ii) modelos matemáticos [6].

Os conceitos que regem a representação da energia eólica na cadeia de planejamento da operação estão definidos no Submódulo 2.4 (Premissas, critérios e metodologia para estudos energéticos) dos

procedimentos de rede do ONS [7]. Para o horizonte de curto/médio prazo, a metodologia para representação da fonte eólica no Planejamento Mensal da Operação é, atualmente, feita com base na Resolução Normativa nº 843/2019 [8] da ANEEL (Agência Nacional de Energia Elétrica), atual REN 1078/2023 [9] e alimenta os modelos DECOMP (Modelo de Determinação da Coordenação da Operação a Curto Prazo) [10] e NEWAVE (Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo) [11]. De acordo com a formulação vigente, para as usinas existentes, é calculada a média mensal do histórico dos últimos cinco anos de geração disponibilizada ao SIN por cada usina. Essa média é agregada por subsistema, por mês e por patamar de carga. Cada mês do horizonte de planejamento utiliza a média calculada do respectivo mês do histórico. No primeiro mês, o valor mensal é repetido para todas as revisões semanais do modelo DECOMP. Para as usinas em expansão, é calculado um fator de capacidade por mês, por fonte e por subsistema, que consiste no somatório da razão entre a média da geração líquida e a média da potência dos últimos cinco anos de cada usina, dividido pelo número total de usinas. Esse fator é utilizado para estimar a geração das usinas futuras e é considerado para cada mês do horizonte de planejamento.

## 2.2. Modelo DECOMP

O modelo DECOMP [10], desenvolvido pelo CEPEL (Centro de Pesquisas de Energia Elétrica), tem como objetivo definir as diretrizes e metas energéticas de curto prazo para a operação coordenada do SIN (Sistema Interligado Nacional Brasileiro), visando otimizar o uso dos recursos de geração disponíveis.

A Função Objetivo do DECOMP é minimizar o custo total esperado de operação, utilizando a Programação Dinâmica Dual (PDD) como estratégia de otimização. O modelo adota uma discretização semanal para o primeiro mês de estudo e mensal para os meses subsequentes, com um horizonte de estudo máximo de dois anos. A partir do segundo mês, a estocasticidade das vazões é incorporada por meio da geração de cenários. Com base nas informações do modelo NEWAVE (Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo) sobre os custos futuros, o DECOMP determina as metas individuais de geração para usinas hidráulicas e térmicas, além dos intercâmbios de energia entre subsistemas [10].

O DECOMP é fundamental no Programa Mensal de Operação (PMO) para o planejamento da operação de curto prazo, cobrindo um horizonte de dois meses. O primeiro mês é discretizado semanalmente, enquanto o segundo mês é representado de forma detalhada com um processo estocástico de vazões afluentes aos reservatórios (árvore completa). Os dados de entrada são atualizados semanalmente, e os resultados do modelo são revisados durante cada semana operativa [12]. Além disso, o DECOMP é aplicado em estudos prospectivos para prever condições operacionais ao longo de vários meses, considerando previsões de afluência, carga e diversas fontes de geração, incluindo a energia eólica (o foco deste artigo).

O modelo DECOMP desempenha um papel crucial no Planejamento da Operação de Curto Prazo, projetando dois meses à frente. O primeiro mês é discretizado semanalmente, enquanto o segundo mês é representado de forma detalhada com um processo estocástico de vazões afluentes aos reservatórios (árvore completa). A metodologia proposta neste trabalho traz melhorias para o primeiro mês, enquanto o segundo mês é estimado conforme a REN 1032/2022 [9]. Além disso, o DECOMP é utilizado em estudos prospectivos no ONS, nos quais, a partir de previsões de afluência, carga e geração de fontes, incluindo a eólica (foco deste trabalho), são obtidas as condições operacionais ao longo de vários meses. Para aprimorar as previsões do modelo vigente [9], foi desenvolvido um método capaz de corrigir erros sistematicamente elevados. Embora essa metodologia precise ser integrada ao modelo proposto neste trabalho para o primeiro mês, os resultados obtidos até o momento são promissores. Mais detalhes sobre esse trabalho podem ser encontrados em [13].

## 2.3. Histórico dos desenvolvimentos de modelos de previsão eólica no ONS

Com o crescimento significativo da energia eólica no Brasil, sua geração tornou-se crucial para atender à demanda energética. Diante dessa expansão e da alta variabilidade dessa fonte, o Operador Nacional do Sistema Elétrico (ONS) desenvolveu o Modelo de Previsão de Geração Eólica para o curtíssimo prazo, conhecido como WEOL semi-horário (WEOL-SH) [14] e [15]. Este modelo visa fornecer dados essenciais

para estudos elétricos, programação diária da operação eletroenergética e para o modelo DESSEM (Modelo de Despacho Hidrotérmico de Curto Prazo) [16].

Com o objetivo de alinhar os valores de geração eólica adotados no DESSEM e no DECOMP, em 2021, foi proposta pelo Comitê Técnico PMO-PLD uma metodologia de previsão eólica para a primeira semana operativa do DECOMP [17]. Essa abordagem envolve a consolidação das previsões semi-horárias do modelo WEOL-SH em uma base semanal, além de estimar a geração de usinas eólicas não simuladas pelo WEOL-SH, como usinas de distribuição e/ou futuras. As previsões obtidas com este modelo deveriam substituir os volumes de geração eólica fornecidos pela Resolução Normativa ANEEL nº 843, após a conclusão do processo de ajuste desta resolução.

Devido aos resultados positivos alcançados pela metodologia proposta pelo CT PMO-PLD em 2021 para a primeira semana operativa do DECOMP, este trabalho propõe um modelo para estender o horizonte temporal das previsões de geração eólica para todo o primeiro mês operativo, cobrindo previsões de até 36 dias à frente.

### 3. DESENVOLVIMENTO METODOLÓGICO


Nesta seção, será tratada a proposta de modelagem para a previsão semanal no horizonte do primeiro mês operativo do DECOMP, modelo WEOL-SM.

#### 3.1. Principal motivação

Conforme mencionado anteriormente neste documento, a geração eólica nos modelos de planejamento de curto prazo (DECOMP) e médio prazo (NEWAVE) é representada de maneira determinística, utilizando uma estimativa baseada na Resolução Normativa ANEEL nº 843, atualmente 1078/2023. Essa estimativa se baseia em médias históricas da geração verificada pelos parques eólicos. A Figura 1 ilustra alguns resultados dessa estimativa comparados aos dados verificados. Observa-se que, entre os anos de 2017 e 2020, houve uma tendência de superestimação da geração eólica pelos critérios da resolução. Esse padrão aparente de desvio sistemático sugere a possibilidade de desenvolver modelos para corrigir essas previsões da resolução, aproximando-as dos valores verificados.

No entanto, a partir de 2021, houve uma mudança nesse padrão de desvio, onde a geração eólica passou a ser subestimada, apesar da aplicação dos mesmos critérios. Essa subestimação mais recente apresenta um desafio para implementar correções diretas através de modelos simples.

Figura 1 – Geração eólica média mensal do Nordeste dos últimos anos.



O modelo de previsão de curtíssimo prazo tinha o potencial de gerar previsões para o horizonte da primeira semana operativa, abrangendo a maioria das usinas eólicas representadas no DECOMP. Com o objetivo de aprimorar a precisão para esta semana inicial, foi proposto um modelo que oferece previsões com uma



semana de antecedência, utilizando as previsões do modelo de curtíssimo prazo como base. Os detalhes específicos dessa metodologia foram descritos em [18].

Essa metodologia serviu como ponto de partida para o desenvolvimento do modelo de previsão de curto prazo que, assim como o modelo de curtíssimo prazo, utiliza dados previstos por modelos numéricos de tempo. Este modelo busca proporcionar uma representação mais precisa da geração eólica no planejamento do primeiro mês do modelo DECOMP. Para alcançar esse objetivo, foi elaborada uma abordagem capaz de substituir as estimativas baseadas na resolução por previsões de um novo modelo. Isso visa obter uma representação mais alinhada no DECOMP, potencialmente resultando em uma função de custo futuro mais aderente às expectativas do planejamento de curtíssimo prazo (modelo DESSEM).

### 3.2. Estrutura básica do modelo

Antes de explorarmos os detalhes do modelo de previsão para o horizonte de curto prazo, é essencial abordar alguns aspectos relacionados ao horizonte de curtíssimo prazo. Nesse contexto, é importante explicar como diferentes tipos de usinas são considerados nos modelos de previsão e planejamento. O modelo de planejamento de curtíssimo prazo (DESSEM) utiliza como entrada de geração apenas as usinas em operação comercial e supervisionadas pelo ONS, classificadas como usinas tipo I e II, conforme definido nos Submódulos 26.2 dos Procedimentos de Rede [7]. Portanto, o modelo de previsão de curtíssimo prazo citado neste estudo abrange exclusivamente esse conjunto de usinas.

As usinas tipo III, que não são supervisionadas pelo ONS, são indiretamente consideradas no modelo DESSEM através de ajustes na carga prevista. Atualmente, a previsão de geração dessas usinas tipo III é estimada com base na média aritmética da geração passada. No entanto, essa abordagem enfrenta desafios devido à alta variabilidade na geração dessa fonte, que não é totalmente capturada pela simples média dos dados históricos.

Como resultado desta avaliação, foram desenvolvidas metodologias para estimar com maior precisão a geração futura dessas usinas tipo III. Embora ainda necessite de aprimoramentos para se tornar plenamente viável, este trabalho já demonstra resultados promissores, detalhados em [19].

Para o planejamento no horizonte de curto prazo, as usinas tipo I, II e III, bem como as usinas futuras (com previsão de entrada em operação dentro do horizonte do primeiro mês operativo em questão), são consideradas como fontes de geração diretamente no DECOMP. No entanto, obter dados observados de vento das usinas tipo III é difícil, tornando inviável a aplicação das curvas  $V \times P$ , ao contrário do que ocorre no modelo de curtíssimo prazo. Essa mesma limitação se estende às usinas futuras, que carecem de históricos confiáveis de dados observados. Portanto, foi necessário desenvolver uma metodologia distinta para gerar previsões também para esse conjunto de usinas.

O modelo desenvolvido foi estruturado em três blocos distintos: (i) usinas supervisionadas do tipo I e II (Bloco 1); (ii) usinas não supervisionadas do tipo III (Bloco 2); e (iii) usinas novas que já estão em operação comercial, mas que ainda não possuem históricos suficientes, além das futuras que entrarão durante o primeiro mês (Bloco 3).

### 3.3. Metodologia proposta para o bloco 1

A metodologia de previsão do bloco 1 é similar ao modelo de previsão de curtíssimo prazo, entretanto, essa metodologia precisou ser aprimorada e, ainda, adaptada para geração de previsões em patamares semanais, que é o nível de discretização do modelo DECOMP.

#### 3.3.1. Avaliação dos insumos meteorológicos utilizados pelo modelo

Para previsão de geração em horizontes mais extensos, os insumos com melhor poder preditivo frequentemente derivam de modelos meteorológicos conhecidos como Modelos Numéricos do Tempo. Neste estudo, foram utilizados os modelos GFS (*Global Forecast System*) do NCEP (*National Centers for Environmental Prediction*) [20], os quais possuem uma resolução espacial de 25 km e intervalos de previsão de 1 hora nos primeiros 5 dias, e de 3 horas para o restante do horizonte de até 14 dias à frente. No entanto, o GFS consegue atender apenas parcialmente até a segunda semana do horizonte de previsão planejado. É importante notar que, em geral, o modelo DECOMP é executado às quintas-feiras

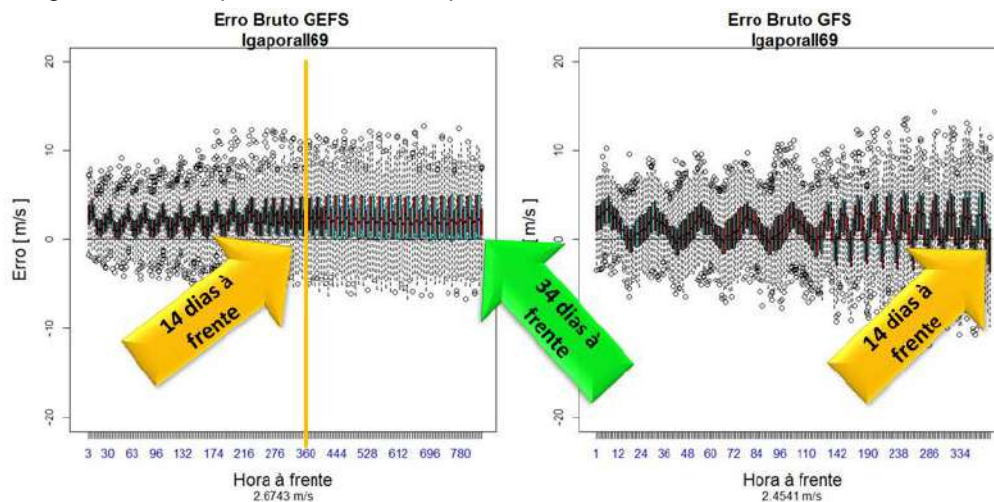
e que a semana operativa se inicia no sábado, i.e., para atender as duas primeiras semanas são necessárias previsões de até 15 dias à frente.

Para o restante do horizonte, são utilizadas as previsões do GEFS (*Global Ensemble Forecast System*) do NCEP, que possuem resoluções espaciais (~ 50 km) e temporais maiores. O GEFS cobre parcialmente até a quinta semana do horizonte de previsão desejado, estendendo suas previsões até 34 dias à frente. Nos primeiros 10 dias, as previsões são disponibilizadas a cada 3 horas, enquanto, no restante do horizonte, a cada 6 horas. Assim, as previsões para todas as semanas do horizonte de interesse são geradas a partir desses dois insumos meteorológicos, GFS e GEFS.

Embora exista um modelo estendido do ECMWF (*European Centre for Medium – Range Weather Forecasts*) que vai até 45 dias à frente, ainda não é possível utilizá-lo devido à falta de histórico suficiente para avaliar o desempenho dessas previsões até o momento.

Antes de utilizar diretamente as previsões meteorológicas, é crucial realizar uma avaliação e incorporar nos modelos de previsão de geração mecanismos para corrigir possíveis erros sistemáticos contidos nessas previsões. A Figura 2 a seguir mostra uma avaliação dos dados meteorológicos que serão utilizados pelo modelo proposto. A métrica utilizada é o erro médio, apresentado na forma de *boxplot*.

Figura 2 – Exemplo de desvios das previsões de vento dos modelos GEFS e GFS.



Na Figura 2, o *boxplot* à esquerda mostra os desvios do vento verificado em relação ao previsto pelo modelo GEFS para um ponto de conexão na região Nordeste, considerando um horizonte de até 34 dias à frente. Nos primeiros 10 dias de previsão, a discretização é de 3 horas, enquanto para o restante do horizonte, a discretização é de 6 horas.

O *boxplot* à direita ilustra os desvios do modelo GFS. Como mencionado anteriormente, o GFS tem uma discretização horária até a hora 120 à frente (primeiros 5 dias) e, para o restante do horizonte de previsão, de 3 horas. É possível observar que a discretização horária do vento previsto permite capturar a variação diária do desvio. Discretizações maiores, por outro lado, não conseguem capturar tão bem o perfil do desvio.

Neste gráfico, é possível avaliar o viés entre os valores previstos e os verificados. Ambos os modelos meteorológicos tendem a subestimar os valores de vento previsto (viés positivo), embora o sinal do viés possa variar ao longo do dia. Além disso, observa-se que o viés exibe um comportamento normal, ou seja, a sua magnitude média tende a permanecer constante até o final do horizonte de previsão.

### 3.3.2. Fluxo do modelo proposto para previsão do Bloco 1

A metodologia proposta para previsão eólica em base semanal até a quinta semana à frente tem como principais insumos os históricos de geração e de velocidade do vento verificada e prevista. Os históricos de geração e vento verificados são aqueles utilizados pelo modelo de curtíssimo prazo (construídos a partir de informações das bases de dados da CCEE (Câmara de Comercialização de Energia Elétrica), EPE

(Empresa de Pesquisa Energética) e do próprio ONS) e que, posteriormente, são adequados para estarem na discretização desejada. Em relação ao histórico previsto de velocidade do vento, o modelo proposto faz uso das previsões dos modelos GFS e GEFS.

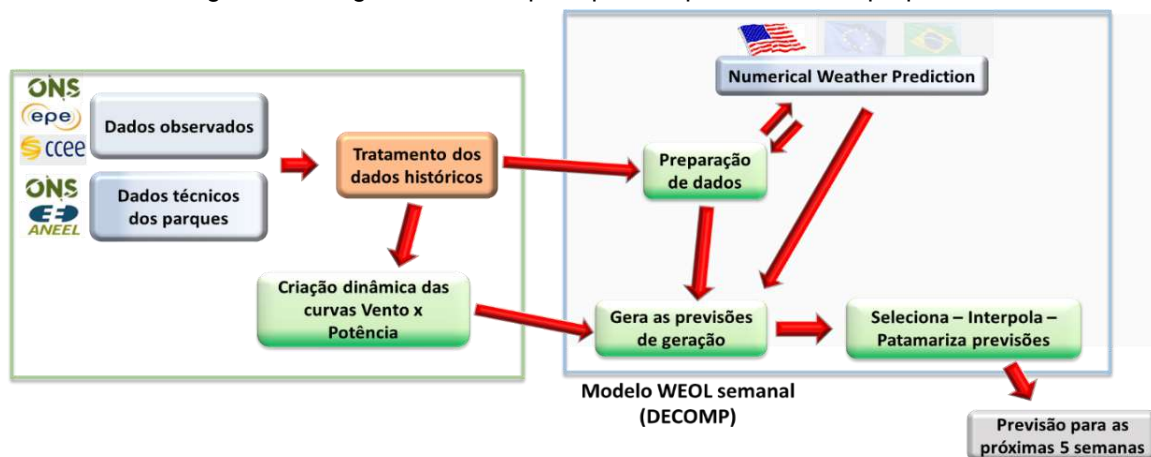
Em razão do horizonte de previsão de cada modelo meteorológico, as previsões para as primeiras duas semanas do mês podem contar com dados previstos de vento do GFS, enquanto, para as demais semanas, as previsões são obtidas com os insumos do modelo GEFS (único modelo meteorológico que alcança até a quinta semana à frente). Dessa forma, a simples seleção da previsão com base no horizonte temporal dos modelos meteorológicos utilizados atende ao modelo semanal. Entretanto, com a perspectiva de uso no futuro do modelo ECMWF estendido, mesmo para as semanas mais distantes do horizonte de simulação, o modelo poderá contar com previsões obtidas com insumos distintos. Nessa situação, ainda é necessário desenvolver um modelo de combinação que avalie a assertividade das previsões disponíveis para ponderar a parcela de cada previsão na previsão final.

Diferentemente do modelo de curtíssimo prazo, inicialmente, as previsões são geradas na mesma discretização do modelo meteorológico e, para serem agrupadas de acordo com o patamar de carga, elas precisam ser interpoladas de modo a respeitar a discretização horária. Após o processo de interpolação, as previsões são finalmente agrupadas conforme os patamares de carga pesada, média e leve. Os intervalos de duração dos patamares de carga utilizados pela cadeia de modelos energéticos podem ser consultados no documento [21].

Ressalta-se que a interpolação realizada no modelo de previsão de curto prazo não se trata de uma simples interpolação linear, tendo em vista que as discretizações das previsões obtidas com os insumos meteorológicos são maiores (no caso do modelo GEFS, a discretização das previsões pode ser de seis horas). Assim, foi proposta uma interpolação que considera o perfil de uma curva típica. Como a geração está sujeita a cortes durante a operação, optou-se por utilizar uma série verificada de vento médio.

As etapas recém-descritas estão esquematizadas no diagrama da Figura 3.

Figura 3 – Diagrama com as principais etapas do modelo proposto.



### 3.3.3. Modelo de previsão de geração

Para cada região, o comportamento do vento previsto e verificado para um mesmo intervalo pode variar significativamente ao longo dos meses de um ano, conforme ilustrado na Figura 4. Essa variação pode ocorrer de maneiras diferentes entre as duas séries, apresentando até mesmo sazonalidades distintas. Portanto, a metodologia de ajuste das previsões baseada em regressão linear adotada pelo WEOL-SH [15] não é adequada, pois o viés do modelo meteorológico pode mudar ao longo do horizonte de previsão.


Para superar essa dificuldade, buscamos modelar a sazonalidade das séries de vento verificado (curva vermelha) e previsto (curva azul) através do ajuste de funções seno. Os ajustes obtidos para o vento verificado e para o previsto estão representados pelas curvas laranja e ciano, respectivamente.

A equação a seguir é utilizada para representar essa sazonalidade:

$$V_i^{SS} = V_i - (A_i \cdot \text{sen}(\omega \cdot t + \varphi_i) + B_i) \quad (1)$$

Em que:  $V_i^{SS}$  é a velocidade de vento sem sazonalidade;  $V_i$  a velocidade de vento bruta;  $i$  um índice que quando representado pela letra  $p$  se trata de vento previsto e pelo  $v$ , de vento verificado;  $\omega$  representa a frequência anual das séries, com  $\omega = \pi/180$ ,  $t$  o tempo;  $A_i$  a amplitude;  $\varphi_i$  a fase;  $B_i$  o termo constante.

Figura 4 – Dessazonalização de séries de vento verificado e previsto.



Após a remoção da sazonalidade, o modelo consegue representar adequadamente as séries de vento, de forma padronizada entre os dados verificados e previstos. Entretanto, essa padronização, em termos de sazonalidade, representa apenas os comportamentos divergentes entre as séries na frequência anual. Caso ainda exista alguma componente de curto prazo, essa componente é modelada pela regressão da equação (2), similar ao que foi apresentado para o modelo de curtíssimo prazo.

$$V_a^{SS} = \alpha_a \cdot V_p^{SS} + \beta_a \quad (2)$$

Em que:  $V_a^{SS}$  a velocidade de vento ajustada sem sazonalidade;  $V_p^{SS}$  a velocidade de vento prevista sem sazonalidade;  $\alpha_a$  e  $\beta_a$  os coeficientes ajustados a partir da relação linear entre as parcelas sem sazonalidade do vento previsto e verificado,  $V_p^{SS}$  e  $V_v^{SS}$ .

Expandindo-se a Equação (2) utilizando a Equação (1) e retornando com a parcela da sazonalidade dos dados de vento verificado, tem-se o vento ajustado:

$$V_a = \alpha_a \cdot (V_p - (A_p \cdot \text{sen}(\omega \cdot t + \varphi_p) + B_p)) + \beta_a + (A_v \cdot \text{sen}(\omega \cdot t + \varphi_v) + B_v) \quad (3)$$

O próximo passo é descrever as curvas  $V \times P$ . Tais curvas já foram estimadas via regressão logística adaptada pelo modelo de previsão de curtíssimo prazo (WEOL-SH) apresentado em [14].


Substituindo a Equação (3) na formulação de [14], com as devidas manipulações matemáticas e agrupamentos de alguns parâmetros intermediários, tem-se a Equação (4), que relaciona a geração prevista total do ponto com o vento previsto bruto dos modelos numéricos. A Equação (4) difere do apresentado em [14] exatamente por considerar o vento bruto e não o vento ajustado. A modelagem através de uma equação única se apresenta como a alternativa mais intuitiva/transparente, uma vez que o modelo de ajuste das previsões numéricas de tempo ao ser aprimorado elevou o nível de complexidade da referida etapa.

$$G_p^t = \alpha_{mt} \cdot \left( \left( P_{mi} + \frac{P_{ma} - P_{mi}}{\left( 1 + 10^{b \left( v_{mid} \frac{(\alpha_a \cdot V_p - \alpha_a \cdot A_p \cdot \text{sen}(\omega \cdot t + \varphi_p) + A_v \cdot \text{sen}(\omega \cdot t + \varphi_v) + K) - \bar{V}_v}{\sigma_{ven}} \right)^s} \right)} \right) \cdot (G_{ma} - G_{mi}) + G_{mi} \right) + \beta_{mt} \quad (4)$$

Em que:  $A'_p$  a Amplitude do vento ajustada, relaciona a grandeza " $\alpha_a \cdot A_p$ ";  $K$  é uma constante do modelo que relaciona outras constantes parciais do desenvolvimento matemático.

O *boxplot* da Figura 5 ilustra o desempenho das previsões de geração para o subsistema Sul e o compara com o desempenho das previsões fornecidas pela REN 843/2019, atual REN 1078/2023 [9]. Para avaliação do modelo, foi adotado como período de teste a janela de tempo entre janeiro de 2021 a setembro de 2023. Ressalta-se que todas as análises apresentadas na sequência foram realizadas considerando-se esse horizonte.


Figura 5 – Comparação dos desvios das previsões semanais para o subsistema Sul.



Ao contrário do esperado, as previsões do modelo proposto apresentaram um viés, em relação ao verificado, até maior que da REN 843. Tal situação não é esperada, uma vez que a equação do modelo já minimiza possíveis vieses nos dados de entrada. Para mitigar esse problema, foi implementado uma etapa adicional para ajuste, através de regressões lineares, das previsões horárias de geração que foram agregadas a nível de subsistema.

O problema relatado acima foi investigado e a Figura 6 é utilizada para explicar a causa do viés. No gráfico de vento, a linha azul cheia corresponde à previsão de vento e a linha azul tracejada, à velocidade do vento ajustada. A linha vermelha representa a velocidade verificada. O gráfico de geração, por sua vez,

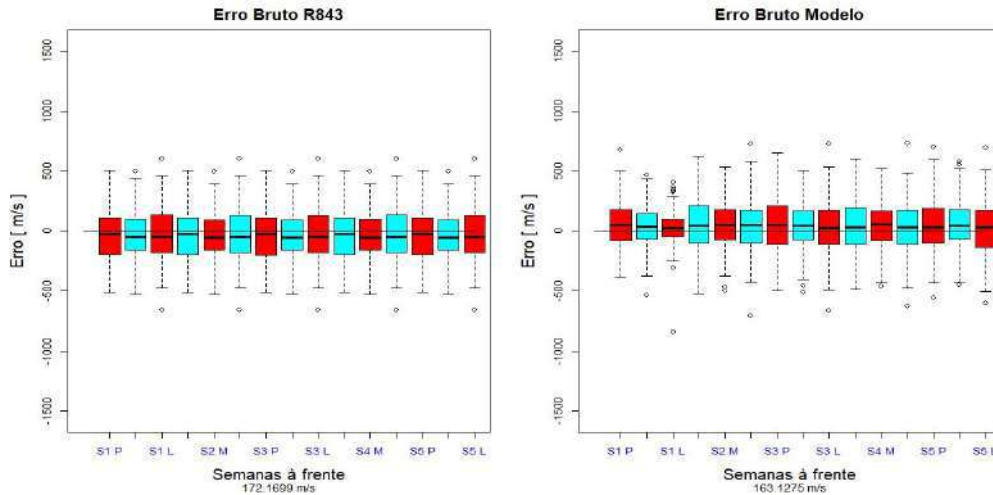
Figura 6 – Perfis da geração e velocidade do vento verificadas e previstas.



ilustra os perfis de geração previsto e verificado através das linhas azul e vermelha, respectivamente. Foi marcado no gráfico da curva V x P os valores 5 m/s e 10 m/s, que quando aplicados à curva resultam em gerações de 5 MW e 25 MW, respectivamente. Isso quer dizer que ao se dobrar a velocidade do vento, a geração do conjunto de usinas foi quintuplicada. Essa característica não linear da curva V x P produz picos muito elevados de potência, causando um viés quando é calculado a geração média semanal.


Por fim, o *boxplot* abaixo ilustra o efeito do ajuste aplicado para remover o viés da geração prevista. Fica evidente a melhora obtida com o ajuste implementado, sendo que agora o desempenho do modelo proposto passa a ser superior ao desempenho das previsões da resolução.

Figura 7 – Comparação dos desvios das previsões semanais ajustadas para o subsistema Sul.



As previsões realizadas para o subsistema NE já apresentavam ganhos em relação à REN 843, mas com a necessidade de ajustar as previsões para o Sul, identificou-se a possibilidade de melhorar o desempenho do modelo para o Nordeste. As comparações entre os desempenhos do modelo proposto e da Resolução após ajuste de geração para esse subsistema podem ser vistas na Figura 8.

Figura 8 – Comparação dos desvios das previsões semanais ajustadas para o subsistema Nordeste.



### 3.4. Estimativa da geração eólica para o bloco 2 e 3

Nesta seção, serão apresentadas as metodologias utilizadas para a estimativa de geração dos blocos 2 (usinas tipo III) e 3 (usinas futuras) do modelo de previsão eólica de curto prazo.

#### 3.4.1. Etapa de estimação da geração das usinas tipo III

Pela indisponibilidade de vento verificado para essas usinas, não é possível levantar as curvas  $V \times P$  dessas usinas, dessa forma, não é possível utilizar a metodologia anterior. Todavia, os valores de geração dessas usinas são observados pelo Sistema de Medição e Faturamento da CCEE, logo essas informações são utilizadas para criar um modelo de estimação da previsão dessas usinas tipo III.

A estimativa da previsão de geração para usinas tipo III é calculada através de uma regressão linear, a qual é obtida relacionando-se dados da CCEE do montante de geração verificada para todas as usinas (tipos I, II e III), de cada subsistema, com o montante de geração verificado de todas as usinas simuladas pelo modelo de curtíssimo prazo (tipos I e II).

O mesmo processo é utilizado para estimar a geração prevista das usinas eólicas não simuladas pelo modelo de curtíssimo prazo, isto é, a regressão linear ajustada é aplicada ao montante previsto para as usinas do bloco 1, resultando em uma previsão total da geração das usinas em operação consideradas no DECOMP. A parcela não simulada, representada pelo bloco 2, pode ser calculada como a diferença entre a previsão total e a parcela correspondente ao bloco 1.

### 3.4.2. Etapa de estimação da geração das usinas futuras

A previsão de geração referente ao montante das usinas futuras é feita a partir de uma relação de similaridade com as usinas existentes mais próximas em operação comercial. Na metodologia proposta, as cinco usinas mais próximas são identificadas e são calculados fatores que relacionam a potência instalada da usina futura com a potência de cada uma das cinco usinas mais próximas.

As previsões semanais das usinas existentes mais próximas já são conhecidas, uma vez que são usinas simuladas no bloco 1. Dessa forma, a estimativa de previsão da usina futura é obtida através da equação:

$$G_p^{fut} = \frac{1}{5} \cdot \sum_{i=1}^5 f_i \cdot G_{P_i} \quad (5)$$

Em que:  $G_p^{fut}$  é a previsão semanal de geração eólica por patamar de carga para dada usina futura;  $G_{P_i}$  é a previsão semanal de geração por patamar de carga da  $i$ -ésima usina mais próxima;  $f_i$  é o fator que relaciona a potência instalada da usina futura e da  $i$ -ésima usina mais próxima.

Por fim, as previsões consideradas no modelo DECOMP consistem no somatório das parcelas previstas para as usinas do bloco 1, somadas às usinas tipo III (bloco 2) e às usinas futuras com entrada nas semanas operativas do primeiro mês (bloco 3). Ressalta-se mais uma vez que os valores disponibilizados para o DECOMP são as previsões semanais por patamar de carga e agregadas por subsistema.

O modelo DECOMP desempenha um papel crucial no Planejamento da Operação de Curto Prazo, projetando dois meses à frente, com uma discretização semanal para o primeiro mês e mensal para o segundo. A metodologia proposta neste trabalho atende o primeiro mês, enquanto o segundo mês continua sendo estimado pela antiga REN 843 [8]. Vale destacar que o DECOMP também é utilizado em estudos prospectivos no ONS, nos quais, a partir de previsões de afluência, carga e geração por fontes, incluindo a eólica (foco deste trabalho), são fornecidas as condições operativas ao longo de vários meses. Foi pensando, especialmente, nesses estudos que foi proposta uma metodologia para aprimorar as previsões do modelo vigente, i.e., estimativas fornecidas pela REN 843. Nesse sentido, foi desenvolvido um método capaz de corrigir erros sistematicamente elevados, cujos resultados obtidos até o momento são promissores. Assim, tem-se um indicativo que a aplicação do mesmo método aos resultados fornecidos pelo WEOL-SM pode resultar em maior assertividade da previsão eólica. Mais detalhes sobre o trabalho de correção de desvios de estimativas de geração podem ser encontrados em [13].

## 4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Para o horizonte de curto prazo, as previsões eólicas geradas pelo modelo oficialmente utilizado no planejamento energético estão disponíveis. Essa metodologia, baseada na antiga REN 843/2019 e atual REN 1078/2023, servirá como referência (*benchmarking*) para o modelo proposto de previsão semanal de curto prazo.

Os gráficos a seguir apresentam uma comparação de desempenho entre as previsões geradas pela REN 843 e pelo modelo proposto para os subsistemas Nordeste (Figura 9) e Sul (Figura 10). Observa-se que houve reduções expressivas nos erros de previsão da nova metodologia em comparação com a vigente.

As reduções mais significativas ocorrem nas primeiras semanas do horizonte de previsão (S1 e S2), devido à maior acurácia das previsões de vento nesse período.

Figura 9 – Comparação de desempenho REN 843 vs modelo para o Nordeste.





Figura 10 – Comparação de desempenho REN 843 vs modelo para o Sul.



Embora as melhorias percentuais sejam mais discretas a partir da terceira semana, em termos absolutos (MW), essa redução pode ser significativa, especialmente para o Nordeste, que concentra uma grande capacidade instalada de energia eólica.

Apesar desta seção se concentrar principalmente no desempenho final do modelo, é crucial destacar os avanços significativos alcançados na modelagem do vento previsto. Mesmo enfrentando comportamentos inconsistentes e vieses complexos na previsão de vento, o modelo conseguiu aprimorar substancialmente essas previsões.



## 5. CONSIDERAÇÕES FINAIS

O modelo de previsão de curto prazo, que foi desenvolvido com foco no primeiro mês operativo do DECOMP, apesar de possuir estrutura semelhante à do modelo de curtíssimo prazo, exigiu algumas evoluções metodológicas, tendo em vista o horizonte mais distante de tempo e os desafios que isso representa. Uma das melhorias mais impactantes foi a identificação e representação da sazonalidade do viés nas previsões de vento dos modelos meteorológicos.

Além dos resultados de previsão, é importante destacar os benefícios obtidos com essa abordagem, como a compatibilização dos dados de geração eólica usados pelo DESSEM com os dados da primeira semana utilizados pelo DECOMP. Essa compatibilização aproxima as etapas da programação da operação de curtíssimo prazo e do planejamento de curto prazo, proporcionando maior assertividade nas previsões eólicas durante todo o primeiro mês.

Em relação à performance, observou-se uma maior precisão entre os montantes de geração verificados e previstos para as semanas operativas do primeiro mês do DECOMP, em comparação com os resultados do modelo vigente atualmente. Os maiores benefícios foram percebidos durante a primeira semana, seguidos por uma melhoria mais discreta na segunda semana. Nas semanas subsequentes, embora em menor escala, também foram observadas reduções nos desvios.

Alguns aprimoramentos para o modelo estão planejados para trabalhos futuros. Entre eles, destaca-se a evolução da metodologia de pós-processamento das previsões de geração, visando reduzir significativamente os desvios tanto para o subsistema sul quanto para o nordeste. Além disso, o ONS pretende utilizar os dados do modelo ECMWF estendido (com horizonte de até 45 dias) para gerar as previsões eólicas para o primeiro mês do DECOMP. Diferentemente dos modelos GFS e GEFS, o ECMWF cobre todos os dias do horizonte de previsão. A partir da incorporação das previsões do ECMWF, também será possível desenvolver metodologias para combinação das previsões de todas as semanas operativas. Esses aprimoramentos devem contribuir para um desempenho ainda melhor do modelo proposto.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] D. B. e. a. ALENCAR, "Hybrid approach combining SARIMA and neural networks for multi-step ahead wind speed forecasting in Brazil," *IEEE Access*, pp. 55986-55994, 2018.
- [2] E. YATIYANA, S. RAJAKARUNA e A. GHOSH, "Wind speed and direction forecasting for wind power generation using ARIMA model," *Australasian Universities Power Engineering Conference (AUPEC)*. IEEE, pp. 1-6, 2017.
- [3] M. ABDEL-NASSER e K. MAHMOUD, "Accurate photovoltaic power forecasting models using deep LSTM-RNN," *Neural Computing and Applications*, pp. 2727-2740, 2019.
- [4] A. e. a. GENSLER, "Deep Learning for solar power forecasting - An approach using AutoEncoder and LSTM Neural Networks," *IEEE international conference on systems, man, and cybernetics (SMC)*, pp. 002858-002865, 2016..
- [5] Y.-K. e. a. WU, "Probabilistic wind-power forecasting using weather ensemble models," *IEEE Transactions on Industry Applications*, pp. 5609-5620, 2018.
- [6] H.-z. e. a. WANG, "Deep learning based ensemble approach for probabilistic wind power forecasting," *Applied energy*, pp. 56-70, 2017.
- [7] ONS - Operador Nacional do Sistema Elétrico, "Procedimentos de Rede," [Online]. Available: <https://www.ons.org.br/paginas/sobre-o-ons/procedimentos-de-rede/vigentes>. [Acesso em 25 Março 2024].
- [8] ANEEL - Agência Nacional de Energia Elétrica, "Resolução Normativa ANEEL nº. 843/2019," 2019. [Online]. Available: <http://www2.aneel.gov.br/cedoc/ren2019843.pdf>. [Acesso em 30 março 2021].

- [9] ANEEL - Agência Nacional de Energia Elétrica, “Resolução Normativa ANEEL Nº 1.078,” 28 Novembro 2023. [Online]. Available: <https://www2.aneel.gov.br/cedoc/ren20231078.html>. [Acesso em 08 Julho 2024].
- [10] CEPEL - Centro de Pesquisas de Energia Elétrica, “Manual de Referência do Modelo DECOMP Versão 31,” 2021. [Online]. Available: [https://www.cepel.br/wp-content/uploads/2022/05/DECOMP\\_ManualUsuario\\_v31-Dez2021.pdf](https://www.cepel.br/wp-content/uploads/2022/05/DECOMP_ManualUsuario_v31-Dez2021.pdf). [Acesso em 06 julho 2023].
- [11] CEPEL - Centro de Pesquisas de Energia Elétrica, “Manual de Referência do Modelo NEWAVE Versão 31,” [Online]. Available: [https://www.cepel.br/wp-content/uploads/2022/05/DECOMP\\_ManualUsuario\\_v31-Dez2021.pdf](https://www.cepel.br/wp-content/uploads/2022/05/DECOMP_ManualUsuario_v31-Dez2021.pdf). [Acesso em 04 julho 2023].
- [12] ONS - Operador Nacional do Sistema Elétrico, “Submódulo 4.3 – Programação mensal da operação Energética,” 2022. [Online]. Available: [https://apps08.ons.org.br/ONS.Sintegre.Proxy/ecmprsite/ecmfragmentsdocuments/Subm%C3%B3dulo%204.3-PR\\_2020.12.pdf](https://apps08.ons.org.br/ONS.Sintegre.Proxy/ecmprsite/ecmfragmentsdocuments/Subm%C3%B3dulo%204.3-PR_2020.12.pdf). [Acesso em 06 julho 2023].
- [13] P. S. C. NASCIMENTO, L. F. ARAUJO, A. L. M. MARCATO, C. A. ARAUJO JUNIOR e A. M. L. BARROS, “Modelo de Previsão Eólica Semanal para Estudos Prospectivos de Curto Prazo do ONS,” *LIV Simpósio Brasileiro de Pesquisa Operacional*, 2022, Juiz de Fora.
- [14] ONS - Operador Nacional do Sistema Elétrico, “NT 0151-2018 - Desenvolvimento Metodológico para Previsão de Geração de Fonte Eólica,” 2018. [Online]. Available: <https://sintegre.ons.org.br/sites/8/103/105/Produtos/439>. [Acesso em 06 julho 2023].
- [15] P. S. C. Nascimento, M. C. A. Lima, C. A. A. Junior, A. M. R. Oliveira, F. Madeira, E. L. Mendes, A. S. Kligerman e R. N. F. Filho, “Desenvolvimento e Implantação no ONS de um Modelo de Previsão de Geração de Fonte Eólica com Customização Temporal,” *Brazil Wind Power*, 2017.
- [16] CEPEL - Centro de Pesquisas de Energia Elétrica, “Manual do Usuario do modelo DESSEM,” [Online]. Available: [https://www.cepel.br/wp-content/uploads/2022/05/DESSEM\\_ManualUsuario\\_v19.0.24.3.pdf](https://www.cepel.br/wp-content/uploads/2022/05/DESSEM_ManualUsuario_v19.0.24.3.pdf). [Acesso em 06 julho 2023].
- [17] ONS; CCEE, “Relatório técnico - GT Geração Eólica,” 2021. [Online]. Available: <https://ctpmopld.org.br/documents/33692/334934/Relat%C3%B3rio+t%C3%A9cnico++GT+Gera%C3%A7%C3%A3o+E%C3%B3lica.pdf>. [Acesso em 15 dezembro 2022].
- [18] P. S. C. NASCIMENTO, L. F. ARAUJO, F. MADEIRA, L. S. KHENAYFIS e R. R. AZAMBUJA, “Desenvolvimento de um Modelo de Previsão Eólica Semanal para Planejamento de Curto Prazo,” *Brazil WindPower*, 2021, São Paulo.
- [19] L. F. ARAUJO, P. S. C. NASCIMENTO, G. A. GONCALVES, A. L. M. MARCATO, F. MADEIRA e W. COSSICH, “Modelo de Estimção de Geração Eólica: Uma Proposta no Contexto de Recursos Energéticos Distribuídos,” *Brazil Windpower*, 2022, São Paulo.
- [20] NCEP - National Centers for Environmental Prediction, “The Global Forecast System (GFS) Documentation,” [Online]. Available: [https://www.emc.ncep.noaa.gov/emc/pages/numerical\\_forecast\\_systems/gfs/documentation.php](https://www.emc.ncep.noaa.gov/emc/pages/numerical_forecast_systems/gfs/documentation.php). [Acesso em 06 julho 2023].
- [21] CEPEL - Centro de Pesquisas de Energia Elétrica, “Atualização dos intervalos de duração dos patamares de carga para a operação energética 2023-2027,” 2022.

## **Metodologia e Análise de Complementaridade Solar em Usinas Híbridas: Utilização do Fator de Capacidade de Usinas Fotovoltaicas Vizinhas**

**Autores:** Maurílio Quirino da Silva Filho<sup>1</sup>, Damásio Fernandes Júnior<sup>2</sup>, Paulo Vitor da Silva Dias<sup>3</sup>,  
Rivanildo Alves Soares<sup>4</sup>, Eubis Pereira Machado<sup>5</sup>

1, 2, 3, 4 Programa de Pós-graduação em Engenharia Elétrica/ UFCG

5 Programa de Pós-graduação em Engenharia Elétrica/ Univasf

maurilio.filho@ee.ufcg.edu.br, damasio@dee.ufcg.edu.br, paulo.dias@ee.ufcg.edu.br,  
rivanildo.soares@ee.ufcg.edu.br, eubis.machado@univasf.edu.br

### **RESUMO**

Este estudo investiga a complementaridade entre energia solar e eólica por meio da análise de dados de fator de capacidade de usinas híbridas utilizando os dados abertos do Operador Nacional do Sistema Elétrico (ONS) do Brasil. Foram avaliadas seis usinas eólicas em combinação com usinas fotovoltaicas (UFV), analisando a capacidade ótima de geração da UFV para cada par de usinas. Os resultados demonstraram uma complementariedade eficaz entre as fontes, onde a geração solar compensa os momentos de baixa da geração eólica. As métricas estatísticas utilizadas apresentaram valores satisfatórios, indicando a robustez das análises. Este estudo fornece percepções valiosas para o planejamento e desenvolvimento de usinas híbridas visando otimizar a geração de energia e promover a transição para um sistema energético mais sustentável.

### **Palavras-chaves:**

Análise energética; complementaridade de fontes de energia; energia fotovoltaica; energia eólica; fator de capacidade; usinas híbridas.

### **ABSTRACT**

This study investigates the complementarity between solar and wind energy through the analysis of hybrid plant capacity factor data using the open data from the Brazilian National Electric System Operator (ONS). Six wind farms were evaluated in combination with photovoltaic plants (PV), analyzing the optimal PV generation capacity for each pair of plants. The results demonstrated effective complementarity between the sources, where solar generation compensates for periods of low wind generation. The statistical metrics used have shown satisfactory values, indicating the robustness of the analyses. This study provides valuable insights for the planning and development of hybrid plants aimed at optimizing energy generation and promoting the transition to a more sustainable energy system.

**Keywords:**

Capacity fator; energy analysis; energy source complementarity; hybrid plants; photovoltaic energy; wind energy.

## 1. INTRODUÇÃO

Nos últimos anos, o setor elétrico brasileiro tem testemunhado uma mudança significativa em sua matriz de geração, impulsionada pela crescente adoção de fontes renováveis, notadamente a energia eólica e a solar. Essa transição, embora promissora em termos de sustentabilidade e diversificação da matriz elétrica, tem suscitado desafios consideráveis, especialmente no que diz respeito à capacidade de transmissão da rede básica de energia elétrica.

Diante do horizonte temporal discrepante entre o desenvolvimento de parques eólicos e solares, com um ciclo médio de 2 a 3 anos desde o planejamento até a entrada em operação, aliados aos prazos longos para a expansão da capacidade de transmissão, estimados em 5 a 10 anos, torna-se evidente a urgência de abordar questões relacionadas à implementação de estratégias eficientes para diminuir gargalos existentes, buscando melhorar a estabilidade e a confiabilidade do sistema elétrico nacional, especialmente em regiões como o Nordeste do Brasil, onde a penetração de fontes renováveis é mais acentuada.

A hibridização de usinas fotovoltaicas é um tema de crescente interesse e relevância no setor de energia. A combinação de diferentes fontes alternativas, como solar e eólica, oferece uma série de benefícios. Estudos complementares realizados pela Empresa de Pesquisa Energética (EPE) indicam que a hibridização de fontes pode otimizar a utilização da capacidade disponível do sistema de transmissão, reduzir os custos de operação, otimizar o uso do terreno, obter ganhos em logística e planejamento da implantação das usinas, além de contribuir para a redução dos custos de manutenção e operação (EPE, 2018).

No cenário brasileiro, a Agência Nacional de Energia Elétrica (ANEEL) aprovou em novembro de 2021 a Resolução Normativa ANEEL nº 954/2021, que estabelece tratamento regulatório para a implementação de Centrais Geradoras Híbridas (CGH) e Centrais Geradoras Associadas (CGA). Tal regulamentação permite a combinação de diferentes fontes de geração, como usinas fotovoltaicas, eólicas, hidrelétricas (grandes e pequenas) e termelétricas (ANEEL, 2021).

A previsão precisa da geração de energia solar e eólica é crucial para o planejamento e suprimento à demanda dos sistemas elétricos. Vários estudos têm explorado o uso de modelos de aprendizado de máquina e abordagens estatísticas para prever a geração de energia solar e eólica. Alguns estudos também propuseram modelos híbridos que combinam dados numéricos do tempo e imagens de satélite para desenvolver modelos precisos de previsão da geração de energia solar (VENNILA *et al.*, 2022). Esses modelos híbridos podem levar em consideração tanto fatores temporais quanto espaciais ao prever a geração de energia solar. Por exemplo, dados numéricos do tempo podem refletir fatores temporais, como a hora do dia e a época do ano, enquanto imagens de satélite podem fornecer informações sobre características espaciais, como a direção do vento, a quantidade de nuvens e a presença de material particulado (KIM, SUH, 2020).

Neste artigo, utilizando os dados abertos do ONS, será apresentada uma análise da complementaridade entre as fontes de energia solar e eólica no nordeste do Brasil, a fim de determinar a capacidade de geração de uma usina solar a ser instalada em uma usina eólica existente. Por meio dessa análise, busca-se identificar padrões e sinergias entre essas fontes, o que pode ser fundamental para o planejamento e desenvolvimento de usinas híbridas no Brasil.

## 2. ESTADO DA ARTE

Em um estudo realizado pela EPE em 2017, é sugerido uma metodologia para avaliação de usinas híbridas eólico-fotovoltaicas, sob a ótica energética. Nesse estudo é levado em consideração alguns critérios para seleção dos locais a serem avaliados, como a necessidade de medições anemométricas e solarimétricas *in loco*, por período não inferior a 12 meses consecutivos, disponibilidade de medições com alta resolução temporal (sub-horária) e proximidade das regiões. O estudo revela a importância de avaliação dos dados discretizados devido às características estocásticas das fontes. Além disso, constatou-se que para uma mesma região, pode-se obter resultados diferentes, a depender do dimensionamento considerado das usinas (EPE, 2017).

Vega-Sánchez *et al.* (2017) aplicaram técnicas de processamento de imagem a mapas de alta resolução de recursos eólicos e solares no México para avaliar a possibilidade de uso combinado de fontes de energia renovável. Foi aplicado o coeficiente de correlação de Pearson para obter novos mapas que mostram o grau de correlação entre os recursos eólicos e solares. Os resultados obtidos mostram um bom grau de complementaridade entre ambas as fontes de energia em locais específicos do país em diferentes estações do ano. Os mapas gerados podem ser úteis em projetos relacionados à instalação de sistemas híbridos de geração de energia elétrica.

Jurasz *et al.* (2019) apresentaram uma revisão das técnicas de avaliação da complementariedade entre sistemas de energia eólica e solar. Foi demonstrado que o coeficiente de Pearson é amplamente utilizado para realização das análises de complementariedade. As bases de dados comumente utilizadas são as relacionadas a fatores climáticos (Velocidade e direção do vento e irradiância), sendo a escala temporal horária amplamente utilizada. Com principal contribuição, os autores apresentaram uma percepção dos caminhos e desafios que ainda podem ser propostos em trabalhos futuros.

Couto e Estanqueiro (2021) apresentaram análises de complementariedade em Portugal, utilizando dados de radiação solar e velocidade do vento. Os autores utilizaram técnicas de otimização para determinar as combinações ótimas dos valores de capacidade instalada de cada fonte geradora e montar cenários com *curtailments* de 5% e 10%. Tais combinações levaram em consideração as demandas energéticas de Portugal e não, necessariamente, as limitações físicas e elétricas de cada empreendimento. Foi demonstrado a sinergia entre as fontes e que o estudo fornece uma metodologia que pode ser aplicada em outras regiões.

Gonçalves (2021) avaliou a complementariedade local nos estados de Pernambuco e no Rio Grande do Sul por meio da variação temporal e espacial do vento e da radiação solar. Foi avaliada a sensibilidade dos resultados à variação do período dos dados e na resolução temporal dos dados, sendo demonstrado que para intervalos de até três horas, os índices de desempenho utilizados no trabalho

tiveram baixo impacto, como é o caso do erro médio absoluto abaixo de 10%. O estudo verificou que, para combinações eólico-solares com potencial híbrido instalado igual para todas as combinações, onde a participação solar é de 20% ou 80%, os montantes de corte em caso de restrição de despacho são menores, quando comparados com outras frações solares.

Croce (2023) realizou análises técnico-econômicas na implantação de usinas híbridas no Brasil com o auxílio do *software Homer Pro*. O *software* importa os dados médios dos recursos energéticos de cada local para realização dos cálculos do valor de geração de cada fonte primária de energia elétrica. De acordo com as simulações realizadas, o estudo demonstra que as regiões Sul e Centro-Oeste apresentam incertezas sobre a viabilidade, o Sudeste é viável, o Norte totalmente inviável e o Nordeste é atrativo economicamente.

Oliveira Silva *et al.* (2024) apresentaram um estudo robusto sobre a complementaridade entre energia eólica e solar no estado de Alagoas, Brasil. Utilizando modelos atmosféricos avançados, como o WRF-Solar, os pesquisadores mapearam o potencial eólico e solar da região, identificando áreas promissoras para instalação de usinas renováveis. Além disso, foram exploradas simulações para entender a viabilidade e eficiência da geração híbrida, considerando diferentes cenários de combinação de recursos e a influência sazonal. Os resultados destacam a importância da integração de fontes renováveis para garantir um suprimento estável de energia, especialmente em regiões propensas a variações climáticas, como o semiárido de Alagoas.

A literatura revela que a combinação de diferentes fontes de energia renovável, como eólica e solar, pode proporcionar uma maior eficiência e estabilidade na geração de energia elétrica. Estudos como o da EPE (2017) e de Vega-Sánchez *et al.* (2017) destacam a importância do uso de base de dados com alta resolução espacial e temporal. Revisões como a de Jurasz *et al.* (2019) demonstram o uso recorrente do coeficiente de Pearson para essas análises, enquanto pesquisas de Couto e Estanqueiro (2021) e Gonçalves (2021) exploram a otimização e a sensibilidade dos dados em diferentes contextos regionais. Croce (2023) apresentou análises técnico-econômicas e Oliveira Silva *et al.* (2024) apresentaram modelagens avançadas, sendo que ambos os trabalhos reforçam a viabilidade e os benefícios das usinas híbridas, especialmente em regiões específicas do Brasil, como o Nordeste. A revisão evidencia o avanço no entendimento e na aplicação de usinas híbridas e associadas, oferecendo uma base sólida para o desenvolvimento de novas metodologias e aplicações no setor de energia renovável.

Nos trabalhos apresentados, não é avaliada a precisão dos dados analisados em comparação com os valores reais de geração no local. A validação da forma como os dados foram coletados não fez parte do escopo daqueles estudos, embora seja importante realizar essa análise para certificar que os métodos utilizados refletem com precisão a realidade operacional. A falta dessa validação pode levar a conclusões que, embora teoricamente sólidas, podem não se traduzir em resultados práticos eficientes. Uma etapa essencial que deve ser considerada é a comparação direta dos dados estimados com os valores reais medidos, garantindo assim a confiabilidade e a aplicabilidade das metodologias propostas.

### 3. MÉTODO DO ESTUDO

Para realizar a análise da complementariedade entre fontes eólica e solar, foram observados registros de geração, capacidade instalada e fator de capacidade das usinas, segundo o repositório de dados abertos disponibilizado pelo ONS. O fator de capacidade é a razão entre a geração verificada e a capacidade instalada. Este fator pode representar o potencial de geração naquela região, uma vez que ele carrega todos os fatores que são usados para previsão de geração como, temperatura, velocidade dos ventos, irradiância, eficiência dos painéis, entre outros.

Dito isto, as análises de complementariedade energética foram realizadas utilizando os dados da geração verificada da usina eólica, fator de capacidade da usina eólica e os dados do fator de capacidade da UFV, configurando o caso da seguinte forma:

1. Foram selecionados seis pares de usinas com base na distância entre elas e na disponibilidade de dados durante todo o ano de 2022, visando análises mais precisas. Priorizou-se pares com coeficiente de correlação de Pearson negativo, que expressa o grau de correlação entre os fatores de capacidade das usinas eólicas e solares neste estudo.
2. Sendo o parque eólico já implantado, o dimensionamento da UFV foi adotado como ferramenta de estudo para a determinação do valor ótimo de sua capacidade de geração da usina solar;
3. Variação de valores *curtailment* (cortes ou redução de geração) que cada usina sofrerá com a instalação da UFV.

A determinação da capacidade de geração da UFV foi feita considerando diferentes porcentagens de *curtailment*. Esse corte de geração foi especificado para atender ao Montante de Uso do Sistema de Transmissão (MUST) contratado de cada usina eólica. Neste estudo, o MUST contratado de cada usina eólica foi considerado igual a sua capacidade instalada, uma vez que os valores contratados de MUST são próximos da capacidade instalada do parque. Na Tabela 3.1, são descritos os dados das usinas utilizadas, simulando um conjunto de usina híbrida (UHIB).

Tabela 3.1 – Dados das Usinas.

UHIB	Usina eólica	UFV	Distância (km)	MUST (MW)
1	Conj. Amazonas	Conj. Floresta	6,6	250,485
2	Conj. Brotas de Macaúbas	Conj. Sol do Sertão	30,1	95,190
3	Conj. Carcará II	Conj. Floresta	9,0	90,000
4	Conj. Filgueira	Conj. Floresta	9,0	67,450
5	Conj. Serra do Mel A	Conj. Floresta	23,7	287,190
6	Conj. Serra do Mel II A	Assú V	31,9	211,365

Nos dados abertos do ONS, é possível obter a localização geográfica (latitude e longitude) das usinas, dessa forma, foi possível calcular a distância radial entre os pares de usinas. Como as usinas fotovoltaicas são utilizadas para obter a capacidade de geração solar, não se faz necessário verificar a capacidade instalada dessas usinas, apenas o fator de capacidade.

#### 4. ANÁLISE E DISCUSSÃO DOS RESULTADOS

De acordo com a metodologia adotada para analisar a complementariedade entre as fontes, foram utilizados os dados de geração da usina eólica e do fator de capacidade da usina UFV referente ao ano de 2022.

Para análise da complementariedade e determinação das usinas do estudo, além da distância entre as usinas, foi utilizado o coeficiente de Pearson, amplamente empregado na literatura para estimar o grau de complementariedade energética. De acordo com Correa (2003), o coeficiente de Pearson varia entre 1 e -1, onde 1 indica uma correlação positiva perfeita em que ambas as variáveis aumentam juntas e -1 indica uma correlação negativa perfeita em que uma variável aumenta enquanto a outra diminui de maneira linear e o 0 (zero) indica ausência de correlação, portanto, quanto mais próximo os valores do coeficiente de Pearson são de -1, indicam alto grau de complementariedade entre as usinas.

Na Tabela 4.1 são descritos os valores do coeficiente de correlação de Pearson para cada par de usinas.

Tabela 4.1 – Coeficientes de Pearson.

UHIB	CP
1	-0,23
2	-0,35
3	-0,22
4	-0,25
5	-0,18
6	-0,44

Segundo Schober (2018), os valores absolutos no intervalo entre 0 e 0,39 podem ser interpretados como uma fraca correlação e os valores entre 0,40 e 0,69, como uma correlação moderada. Dito isto, por meio da Tabela 4.1, é possível inferir que os conjuntos UHIB 1, 2, 3, 4 e 5 apresentam uma fraca correlação e o conjunto UHIB 6, uma correlação moderada.

##### 4.1 Geração Média Mensal

Na Figura 4.1, é ilustrada a geração média mensal do conjunto UHIB 1 e na Figura 4.2 a geração média mensal do conjunto UHIB 6. Em azul, a contribuição da geração eólica e em laranja a contribuição de geração fotovoltaica. A faixa em vermelho, indica a capacidade instalada da usina eólica.

A partir dos resultados exibidos na Figura 4.1, pode-se inferir que há complementariedade entre as fontes de geração. Se for visto apenas a geração eólica, é notório a vacância deixada pelo sistema. Por meio do gráfico, é visto que nos horários de pico de geração eólica, a geração solar é baixa, enquanto no período em que a geração eólica é baixa, ocorre o pico da geração solar.

Apesar da fraca correlação negativa entre as fontes de energia para a usina Conj. Amazonas, segundo o coeficiente de correlação de Pearson apresentado na Tabela 4.1, por meio da Figura 4.1 pode-se observar que a UFV Conj. Floresta é complementar devido à vacância deixada pelo sistema eólico. Para as outras usinas, isso fica mais evidente, como pode ser visto na Figura 4.2, que ilustra geração média mensal da usina hibridizada Conj. Serra do Mel II A, que de acordo com a Tabela 4.1, apresenta a maior correlação negativa.



Figura 4.1 – Médias mensais - Simulação da geração horária híbrida na Usina Conj. Amazonas e Conj. Floresta em 2022.

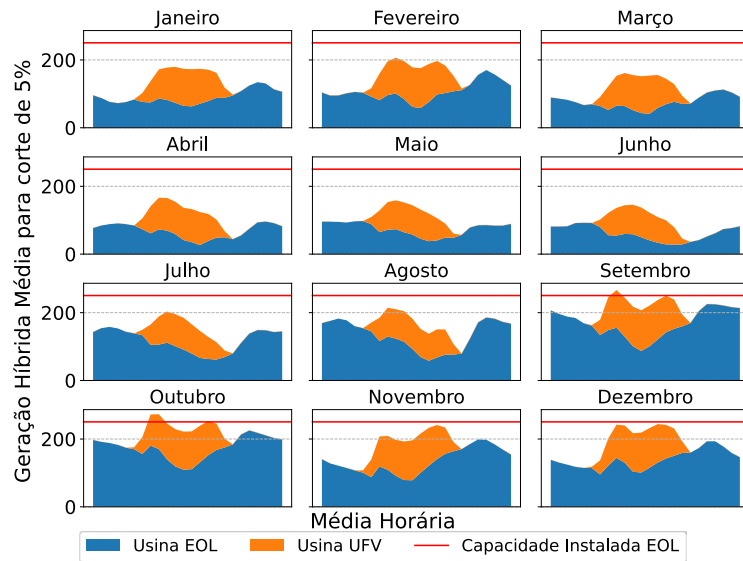
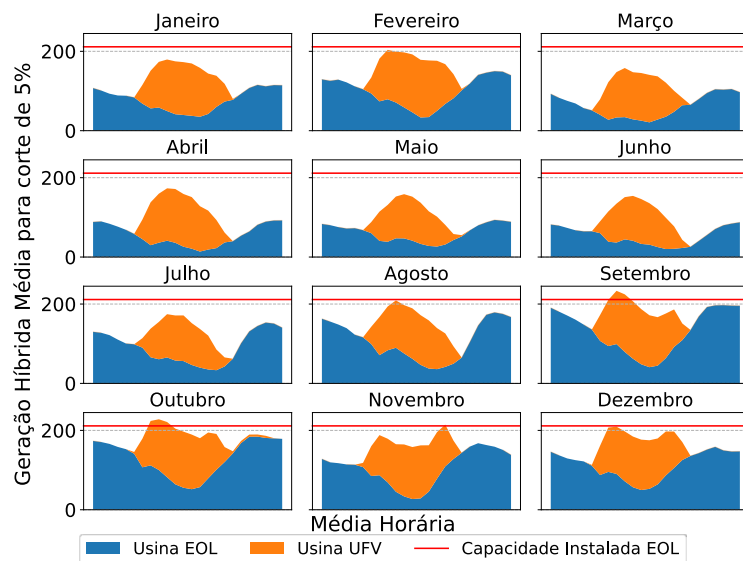


Figura 4.2 – Médias mensais - Simulação da geração horária híbrida na Usina Conj. Serra do Mel II A e Assú V em 2022.




### 3.2 Curtailments em Função da Capacidade Instalada da UFV

Após as análises de complementariedade, faz-se necessário quantificar a capacidade de geração da usina solar a ser construída de forma híbrida com o sistema eólico existente. Para isso, foi elaborado um gráfico, conforme é exibido na Figura 4.3, que relaciona a capacidade de geração da UFV com os cortes de geração que a usina hibridizada está sujeita. O corte energético é calculado dos valores horários e não da média mensal. Os valores percentuais de *curtailments* de geração foram considerados em relação a UFV, uma vez que ela representa a expansão do sistema.

A partir dos resultados apresentados para usinas em análise, pode-se inferir que é possível dobrar a capacidade instalada da usina eólica e ter *curtailments* inferiores a 10% em relação ao novo montante

energético acrescentado ao sistema. A viabilidade desse novo sistema fotovoltaico a ser instalado é algo complexo a ser estudado, pois envolve questões financeiras que fogem do escopo deste trabalho, que se detém apenas às análises energéticas.


Figura 4.3 – Cortes na geração em função da capacidade instalada da UFV.



### 3.3 Curva de Permanência

De modo a visualizar, graficamente, a vacância deixada pelo sistema eólico, assim como o ganho e os cortes energéticos da usina hibridizada, foram computadas curvas de permanência para alguns valores de *curtailments*, como podem ser observadas na Figura 4.4. A linha pontilhada em vermelho representa a capacidade instalada da usina eólica, enquanto as curvas azul, laranja, verde, vinho e roxo representam a geração híbrida. A área em azul claro representa todo o energético da usina eólica antes da hibridização. Para todas as UHIB o gráfico de permanência apresentou o mesmo perfil.

Figura 4.4 – Curvas de permanência para o conjunto UHIB 6.



Por inspeção da Figura 4.4, é possível constatar a vacância deixada no sistema elétrico pela usina eólica, que utiliza menos de 50% da capacidade instalada. Para cortes de geração de 5% do valor da usina a ser instalada, tem-se que esses cortes ocorrerão em 7,5% do tempo aproximadamente, enquanto para


cortes de até 10% da geração da usina a ser instalada, os cortes ocorrerão em 15% do tempo aproximadamente.

### 3.4 Ganho Energético em Função da Capacidade Instalada da UFV

O ganho energético refere-se ao aumento da geração líquida de energia obtida a partir do conjunto híbrido, desconsiderando os valores que ultrapassam o MUST. O ganho energético percentual é a relação entre o aumento de geração líquida e a geração do sistema eólico.


A partir de valores de capacidade instalada de UFV que resultam em *curtailments* acima de 20%, o ganho energético não cresce proporcionalmente aos cortes gerados, isto é evidenciado no gráfico da Figura 4.5. De modo geral, a curva que descreve o ganho energético do parque híbrido sofre saturação para valores de *curtailment* acima de 20%.

Figura 4.5 – Ganho Energético [%] versus *Curtilment* [%].



A relação entre o ganho energético e a capacidade instalada da UFV é apresentada na Figura 4.6.

Figura 4.6 – Ganho Energético [%] versus Capacidade Instalada da UFV [MW].



É notável que a taxa de crescimento do ganho energético diminui após uma determinada capacidade instalada. O ponto destacado em vermelho no gráfico corresponde ao limiar em que a derivada do ganho em relação à capacidade instalada mostra-se constante. Capacidades instaladas de UFV acima desses pontos críticos devem ser repensadas, uma vez que, conforme observado na Figura 4.5, os cortes

de geração tornam-se significativos. Os dados referentes aos ganhos energéticos para três valores de capacidade instalada da UFV são exibidos na Tabela 4.2.

Tabela 4.2 – Dados Energéticos do Sistema Eólico.

UHIB	<i>Curtailment</i>	Capacidade UFV [MW]	Ganho [GWh]
1	0%	34,44	81,07
	5%	139,58	309,49
	10%	184,6	387,83
2	0%	17,94	46,73
	5%	43,42	107,52
	10%	61,31	143,76
3	0%	11,63	27,15
	5%	48,72	108,12
	10%	64,192	134,96
4	0%	10,03	23,40
	5%	37,63	83,53
	10%	49,10	103,2
5	0%	75,44	176,09
	5%	199,93	443,71
	10%	249,12	523,47
6	0%	23,87	52,64
	5%	181,10	380,08
	10%	224,34	445,81

Considerando que o valor ótimo a ser aceito como corte de geração seja entre 5% e 10% da geração, a capacidade instalada da usina UFV seria praticamente a mesma do sistema eólico e, devido à sua complementariedade, esses valores não se somam de forma direta, elevando o aproveitamento das instalações. A partir desses resultados, constata-se que os ganhos são expressivos. Além do mais, os cortes na geração podem ser minimizados adicionando bancos de bateria ou contratando um adicional de MUST.

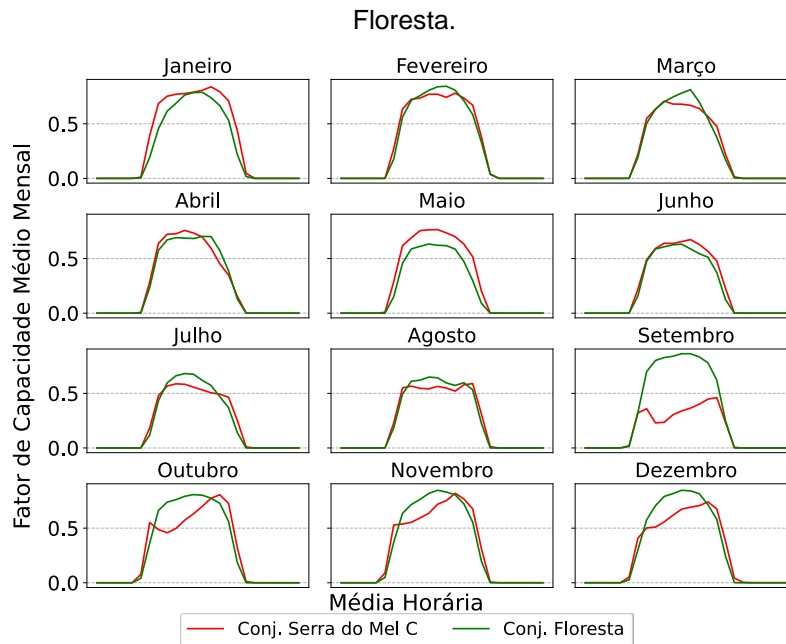
### 3.5 Avaliação dos Dados Utilizados nas Análises

Para mensurar a eficiência dos dados utilizados para determinar os valores de capacidade de geração da usina UFV, os dados do fator de capacidade do Conj. Floresta foram comparados com os dados do fator de capacidade do Conj. Serra do Mel C no ano de 2023, que é um parque solar, situado na mesma localização do Conj. Serra do Mel A.

Na Figura 4.7 são ilustrados os gráficos dos fatores capacidade do Conj. Floresta e do Conj. Serra do Mel C. Por meio dos gráficos, constata-se a similaridade dos dados utilizados para mensurar a capacidade instalada da UFV, que são os dados do Conj. Floresta, localizado a 24 km aproximadamente da usina eólica e dos dados reais do local da usina eólica.

Os dados do mês de setembro do Conj. Serra do Mel C são valores atípicos, os quais podem ter sido causados por conta de erro dos dados ou até mesmo por restrições de geração no local para evitar sobrecarga.

Figura 4.7 – Fator de Capacidade Médio Mensal das Usinas Fotovoltaicas Conj. Serra do C e Conj. Floresta.



Foram utilizadas métricas estatísticas para avaliar com precisão o desempenho e acurácia dos dados. De acordo com Carmo *et al* (2023) e Correa (2003), o MSE (Erro Quadrático Médio) é a média dos quadrados dos erros entre os valores originais e os valores preditos pelo modelo, indicando um bom ajuste quando o valor é próximo de zero, o RMSE (Raiz do Erro Quadrático Médio) fornece uma interpretação intuitiva do erro médio de predição em relação à escala dos dados, um RMSE de 0,1 indica que, em média, as predições do modelo estão desviando aproximadamente 0,1 unidades da variável de resposta original, o que é considerado satisfatório para os propósitos deste estudo, por fim, o coeficiente de determinação  $R^2$  representa a proporção da variância explicada pelo modelo, sendo um valor de  $R^2$  igual a 0,95 sugere que o modelo é capaz de explicar cerca de 95% da variabilidade nos dados, indicando um ajuste forte entre as predições e os dados reais. Na Tabela 4.3 são descritos os valores obtidos das métricas estatísticas utilizadas.

Tabela 4.3 – Métricas Estatísticas.

MSE	RMSE	$R^2$
0,0120	0,1096	0,8681

Na Tabela 4.4 são apresentadas as métricas com o mês de setembro excluído. Observa-se uma melhoria em todas as métricas, sugerindo que a utilização de métodos probabilísticos para tratamento dos dados analisados, pode resultar em estimativas ainda mais precisas.

Tabela 4.4 – Métricas Estatísticas.

MSE	RMSE	$R^2$
0,0058	0,0762	0,9392

## 5. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

A análise detalhada realizada revelou um grau significativo de complementaridade entre as gerações eólica e fotovoltaica na região nordeste do Brasil. Esse estudo ressalta uma oportunidade única para otimizar a eficiência energética ao integrar estrategicamente essas duas fontes de energia renovável. Enquanto a energia solar atinge seu pico durante o dia, a energia eólica é mais proeminente à noite, permitindo uma melhor utilização dos recursos naturais disponíveis.

A análise se baseou em dados detalhados de fator de capacidade de seis conjuntos de usinas eólicas e solares, essenciais para determinar a capacidade ótima de geração da usina fotovoltaica (UFV) em uma configuração híbrida. Esses dados possibilitaram uma estimativa precisa da complementaridade entre as fontes e evidenciaram os benefícios dessa abordagem para o sistema elétrico. As métricas estatísticas utilizadas revelaram valores satisfatórios, demonstrando a robustez e confiabilidade das análises realizadas.

É crucial destacar que, à medida que mais dados de alta qualidade se tornam disponíveis ao longo do tempo, a precisão das estimativas e previsões energéticas tende a aumentar. A expansão de bancos de dados abrangentes, incluindo informações detalhadas sobre o comportamento sazonal e variabilidade das fontes de energia renovável, é essencial para aprimorar essas análises. Com uma base de dados mais rica e histórica, os modelos de previsão e otimização podem ser refinados, proporcionando uma visão mais clara e confiável para o planejamento e implementação de sistemas híbridos de energia.

Embora os resultados energéticos sejam promissores, a implementação prática de uma usina híbrida de 200 MW requer uma análise financeira detalhada. Aspectos como investimentos iniciais, custos operacionais e retorno financeiro precisam ser avaliados para determinar a viabilidade econômica desse sistema.

A integração estratégica de energia eólica e solar não apenas maximiza a eficiência energética, mas também oferece benefícios financeiros substanciais. Equilibrar a geração de energia ao longo do dia evita investimentos excessivos em capacidade de reserva e infraestrutura redundante, resultando em uma alocação mais eficiente de recursos financeiros. Além disso, contribui para a economia ao reduzir a ociosidade das instalações de transmissão e melhorar a eficiência geral do sistema, resultando em menores perdas de energia e custos operacionais reduzidos.

A análise realizada neste estudo serve como base para futuras pesquisas e implementações práticas que possam impulsionar essa importante transição energética.

## REFERÊNCIAS

ANEEL. Regulamentação para o funcionamento de Centrais Geradoras Híbridas (UGH) e centrais geradoras associadas. Agência Nacional de Energia Elétrica. 2021. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-normativa-aneel-n-954-de-30-de-novembro-de-2021-364715864>. Acesso em: 31 maio. 2024.

ANEEL. Regras dos serviços de transmissão de energia elétrica. Módulo 5 – Acesso ao Sistema. Agência Nacional de Energia Elétrica 2024. Disponível em: <https://www.gov.br/aneel/pt-br/centrais-de-conteudos/procedimentos-regulatorios/regras-de-transmissao>. Acesso em: 20 jun. 2024.

CARMO, C. R. S., SILVA, J. R. M. Aprendizado de Máquina e Prestação de Serviços de Armazenamento de Dados: Métricas Para Análise e Validação de Algoritmos Previsores. GETEC Gestão, Tecnologia e Ciências. Monte Carmelo: v. 12 n. 38, p.123-144, 2023.

CORREA, S. M. B. B. Probabilidade e estatística. 2 ed. Belo Horizonte: PUC Minas Virtual: 2003.

COUTO, A., ESTANQUEIRO, A. Assessment of wind and solar PV local complementarity for the hybridization of the wind power plants installed in Portugal. Journal of Cleaner Production, 2021. Disponível em: <https://doi.org/10.1016/j.jclepro.2021.128728>. Acesso em: 31 maio. 2024

CROCE, L. F. Análise da Atratividade da Geração Híbrida de Energia Elétrica de Acordo com o Atual Cenário do Mercado Brasileiro. 2023. 137f. Dissertação (Mestrado em Planejamento e gestão de sistemas energéticos) - Universidade Federal de Itajubá, Itajubá-MG, 2023.

EPE. Avaliação da Geração de usinas Híbridas Eólico-Fotovoltaicas: Proposta metodológica e estudos de caso. Empresa de Pesquisa Energética. 2017. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/nota-tecnica-usinas-hbridas-no-contexto-do-planejamento-energetico>. Acesso em: 31 maio. 2024.

EPE. Usinas Híbridas: uma análise qualitativa de temas regulatórios e comerciais relevantes ao planejamento. Empresa de Pesquisa Energética. 2018. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Usinas-Hbridas-uma-analise-qualitativa-de-temas-regulatorios-e-comerciais-relevantes-ao-planejamento>. Acesso em: 31 maio. 2024.

GONÇALVES, A. R. Hibridização de Usinas Solares e Eólicas e Sua Complementariedade no Brasil. 2021. 175f. Tese (Doutorado em Ciência do Sistema Terrestre) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2021.

JURASZ, J., CANALES, F. A., KIES, A., GUEZGOUZ, M., BELUCO, A. A review on the complementarity of renewable energy sources: Concept, metrics, application and future research directions. Solar Energy, v.195, 703-724, 2020. Disponível em: <https://doi.org/10.1016/j.solener.2019.11.087>. Acesso em: 31 maio. 2024.

KIM, B., SUH, D. A Hybrid Spatio-Temporal Prediction Model for Solar Photovoltaic Generation Using Numerical Weather Data and Satellite Images. Remote Sens, 2020. Disponível em: <https://doi.org/10.3390/rs12223706>. Acesso em 31 maio. 2024.

OLIVEIRA SILVA, L. S., SILVA JUNIOR, R. S., LYRA, R. F. F., MARTINS, F. R., MOURA, M. A. L., LEAL JUNIOR, J. B. V., MUNIZ, E. S., VASCONCELOS, L. N. Avaliação da complementariedade entre os recursos eólico-solar e considerações sobre estabilidade no setor elétrico. Revista Brasileira de Geografia Física, [S. l.], v. 17, n. 3, p. 1942–1960, 2024. Disponível em: doi: 10.26848/rbgf.v17.3.p1942-1960. Acesso em: 31 maio. 2024.

ONS. Dados Abertos. Disponível em: <https://dados.ons.org.br/>. Acesso em: 31 maio. 2024.

ONS. Glossário. Disponível em: <https://www.ons.org.br/paginas/conhecimento/glossario>. Acesso em: 31 maio. 2024.

SCHOBER P., BOER C., SCHWARTE, L. A. Correlation Coefficients: Appropriate Use and Interpretation. Anesthesia & Analgesia, 2018. Disponível em: doi: 10.1213/ANE.0000000000002864. Acesso em 31 maio. 2024.

VEGA-SANCHEZ, M. A., CASTAÑEDA-JIMÉNEZ, P. D., PEÑA-GALLARDO, R., RUIZ-ALONSO, A., MORALES-SALDAÑA, J. A., PALACIOS-HERNÁNDEZ, E. R. Evaluation of complementarity of wind and solar energy resources over Mexico using an image processing approach. IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC), 2017. Disponível em: doi: 10.1109/ROPEC.2017.8261637. Acesso em 31 maio. 2024.

VENNILA, C., TITUS, A., SUDHA, T. S., SREENIVASULU, U., REDDY, N. P. R., JAMAL, K., LAKSHMAIAH, D., JAGADEESH, P., BELAY, A. Forecasting Solar Energy Production Using Machine

---

Learning. V. Mohanavel. International Journal of Photoenergy, 2022. Disponível em: <https://doi.org/10.1155/2022/7797488>. Acesso em 31 maio. 2024.



## ENHANCING OFFSHORE WIND ENERGY ASSESSMENT THROUGH COUPLED ATMOSPHERE-WAVE MODELING: CASE STUDY OF NORTHEAST BRAZIL

Nícolás A. Bose<sup>1,2</sup>, Vanessa de Almeidas Dantas<sup>1</sup>, Alessandro Rene Souza do Espírito Santo<sup>1</sup>, Karen Fernanda Teixeira Braz Lima<sup>1</sup>, Maria de Fátima Alves de Matos<sup>1</sup>, Samira de Azevedo Santos Emiliavaca<sup>1</sup>, Leonardo de Lima Oliveira<sup>1</sup>, Luciano Andre Cruz Bezerra<sup>1</sup> and Leandro Farina<sup>2,3</sup>

<sup>1</sup>Instituto SENAI de Inovação em Energias Renováveis

<sup>2</sup>Institute of Geosciences, Federal University of Rio Grande do Sul, Porto Alegre, RS, 91501-970, Brazil.

<sup>3</sup>Institute of Mathematics and Statistics, Federal University of Rio Grande do Sul, Porto Alegre, RS, 91509-900, Brazil.

[nicolasbose@isi-er.com.br](mailto:nicolasbose@isi-er.com.br), [vanessadantas@isi-er.com.br](mailto:vanessadantas@isi-er.com.br), [alessandrosanto@isi-er.com.br](mailto:alessandrosanto@isi-er.com.br), [karenlima@isi-er.com.br](mailto:karenlima@isi-er.com.br), [fatimamatos@isi-er.com.br](mailto:fatimamatos@isi-er.com.br), [samira@isi-er.com.br](mailto:samira@isi-er.com.br), [leonardooliveira@isi-er.com.br](mailto:leonardooliveira@isi-er.com.br), [luciano@isi-er.com.br](mailto:luciano@isi-er.com.br), [farina@alum.mit.edu](mailto:farina@alum.mit.edu)

### ABSTRACT

Offshore wind energy is vital for achieving global renewable energy goals, with Brazil holding significant untapped potential. This study focuses on the northeast coast of Brazil, particularly Rio Grande do Norte, where future wind farms are planned. By comparing coupled atmosphere-wave models (WRF+SWAN) with stand-alone atmospheric models, we analyze wind-wave interactions and their impact on wind power production. Results indicate that the coupled model outperforms the stand-alone model in predicting wind speeds at various heights, with lower bias, RMSE, and MAE values, and higher correlation coefficients. The Drennan et al. (2003) parameterization within the coupled model effectively accounts for wave conditions, enhancing accuracy. Additionally, horizontal wind speed analysis along the coastline to open ocean transition reveals significant increases at higher altitudes, suggesting optimal wind farm placement. These findings demonstrate the benefits of incorporating wind-wave interactions in offshore wind resource assessments, supporting Brazil's efforts to harness its substantial offshore wind potential and contribute to global renewable energy targets.

### Keywords:

Offshore wind energy, Wind-wave interaction, Numerical modeling, Renewable energy assessment

## 1. INTRODUCTION

Offshore wind energy is crucial for meeting global renewable energy targets. Over recent decades, offshore wind farm deployment has increased substantially worldwide, with China's offshore wind power capacity rapidly expanding and expected to reach 200 GW by 2050, becoming the most prominent offshore producer (Costoya et al., 2021). Conversely, Brazil's offshore wind potential remains untapped despite its significant capacity. Research by Pimenta et al. (2019) identified up to 725 GW potential within 0-35 m water depth and 7.2 TW within Brazil's Exclusive Economic Zone (EEZ).

Brazil will explore its offshore wind resources, focusing on four key regions: north, northeast, southeast, and south, which are known for strong winds (Reis et al., 2021). Accurate offshore wind measurements are challenging due to scarce data, necessitating a combination of observed wind speeds and numerical weather simulations. Numerical weather models are crucial during wind resource assessment stages because wind speeds are typically measured at later stages of wind farm planning (Rohrig et al., 2019).

These models simulate wind dynamics over large domains and are used for production forecasting, future wind scenarios, and developing wind atlases (GOV-RN and ISI-ER, 2022; Souza et al., 2022; Salvação and Soares, 2018). Accurate wind power estimates require models with physical parameterization, surface information, domain characteristics, and forcing databases.

Offshore wind simulation faces challenges due to land-sea interactions, temperature differences, and ocean dynamics affecting atmospheric stability and wind patterns (Svensson et al., 2019; Hahmann et al., 2015). Most studies do not account for atmospheric-wave-ocean interactions, impacting wind speeds and power production (Porchetta et al., 2021). Upwelling, for instance, can reduce wind speeds by affecting the lower atmosphere, as shown in the Baltic Sea study by Sproson and Sahlée (2014).

Local wind and wave conditions influence heat and momentum flux between the atmosphere and ocean. Offshore wind farms alter these conditions by extracting momentum from the wind, reducing wind speeds in their wake (Fischereit and Larsén, 2019). This affects wave generation, altering overall wave conditions and air-sea momentum flux, impacting downwind farms' power production.

Recent studies highlight the importance of atmosphere-wave coupling for accurate offshore wind energy assessment (Porchetta et al., 2021; Kalvig et al., 2014). For example, Porchetta et al. (2021) showed that coupling the Weather Research and Forecasting (WRF) model with the Simulating Waves Nearshore (SWAN) model improves wind speed accuracy and energy production. Other research indicates that aligning waves and winds can increase energy production of wind turbines by 3% to 8.4% (Alsam et al., 2015). Incorporating oceanic-atmospheric interactions increased potential wind power by 2% in winter but decreased it by 3% in summer (Wu et al., 2020).

As Brazil ventures into offshore wind resources, leveraging wind-wave interactions can reduce uncertainty in offshore wind speed estimates. This study aims to compare wind speed and power along Brazil's

Northeast coast using coupled atmosphere-wave and stand-alone atmospheric models, examining wind-wave interaction impacts under actual weather conditions.

The paper is structured as follows: Section 2 describes the state of art. Section 3 discusses study method, site selection, wind-wave coupling, wave and atmosphere model, and model validation. The section 4 discusses the results of coupled and stand-alone simulations, focusing on wind-wave interaction. Section 5 concludes the study.

## 2. STATE OF THE ART

### 2.1. WIND-WAVE INTERACTION

Understanding the momentum flux transfer between the ocean surface and the upper atmosphere is critical for investigating wind-wave interaction. This complex interaction is often quantified using the aerodynamic roughness length parameter. To accurately represent the momentum flux transfer in numerical models of the atmosphere-ocean surface interaction, many researchers utilize Charnock's aerodynamic roughness length parameter (Charnock, 1955).

$$z_0 = \alpha \frac{u_*^2}{g} \quad (1)$$

Here,  $\alpha$  stands for the Charnock coefficient,  $g$  is the gravitational constant, and  $u_*$  is the friction velocity. The Charnock coefficient is an essential parameter for describing momentum flux transfer between the ocean surface and the atmosphere. Typically, a constant value of 0.012 (Charnock, 1955) is used to represent the Charnock coefficient for the ocean surface, assuming the sea state is in equilibrium with the wind, regardless of the wind generation process, such as local breeze or storm. However, other studies have proposed different Charnock coefficients based on the sea state. For example, Garratt (1977) suggested using  $\alpha = 0.018$  for shallow water, while Smith (1988) and Chris W. Fairall et al. (1996) identified a Charnock coefficient of  $\alpha = 0.011$  for the deep ocean. Additionally, Wu (1982) specified a Charnock coefficient of  $\alpha = 0.0185$  for hurricanes. Charnock coefficients near  $\alpha \cong 0.018$  indicate fully developed sea states in the deep ocean, which can lead to an overestimation of wind speed in shallow water.

Therefore, coupling wave-atmosphere models allows for the implementation of multiple roughness length parameterizations, including one proposed by Drennan et al. (2003). This specific parameter performs exceptionally well in capturing the momentum exchange between the ocean surface and the atmospheric boundary layer under pure wind-sea conditions, owing to its exclusive consideration of mixed and pure wind-sea states in the algorithm development. This parameter is defined as

$$z_0 = 3.35H_s \left( \frac{u_*^2}{c_p} \right)^{3.4} \quad (2)$$

Here,  $H_s$  stands for significant wave height, and  $c_p$  is the wave speed group at the peak frequency. The roughness length equation used here is designed specifically for pure wind-sea conditions. To account for the increase in ocean surface roughness that occurs for young waves compared to old waves in offshore conditions, the equation incorporates the effects of wind speed, wind duration, and fetch size.

The utilization of coupled atmosphere-wave models is complex, as it allows for the computation of roughness lengths based on equations that consider the sea surface conditions. This relationship reveals a significant dependence of roughness on the wave age, expressed as the ratio of phase speed to the 10-meter wind speed ( $c_p/U_{10}$ ). In the scenario of young wind seas, waves actively extract momentum from the wind, therefore, during this phase, the momentum flux consistently directs downward, as noted by Semedo et al. (2009). Indeed, under swell conditions or in the case of older seas, the situation is reversed, and the wave-induced wind becomes positive, facilitating the transfer of momentum to the atmosphere (Drennan et al. 2003).

### 3. STUDY METHOD

#### 3.1. SITE SELECTION

The central point of this study is the northeast coast of Brazil, specifically the Rio Grande do Norte, where significant investments are planned for future wind farms. The study aims to investigate the interaction between wind and wave dynamics. Figure 1 presents the study site and the numerical domain areas.

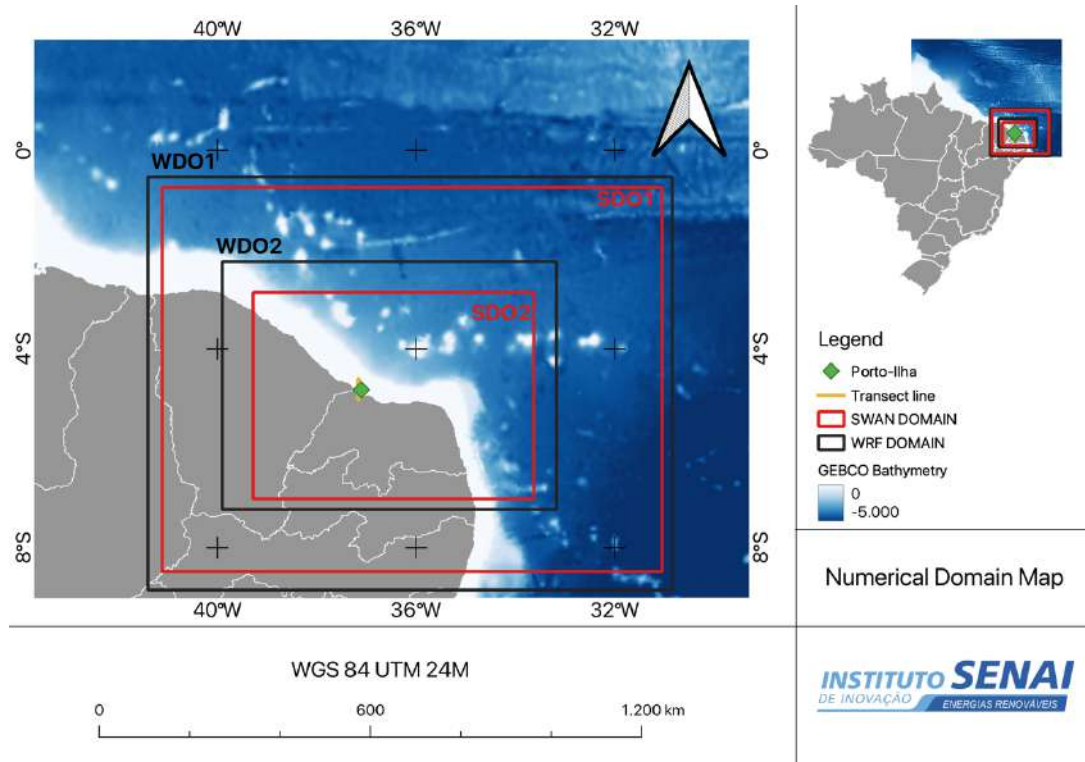


Figure 1. Study site and numerical grid from the WRF and SWAN models.

### 3.2. WIND-WAVE COUPLING

The model system chosen for investigating the sensitivity of wind power production under ocean wave conditions is the Coupled Ocean-Atmosphere-Wave-Sediment Transport Modeling System (COAWST, v3.7). COAWST is an open-source code that integrates four different models using the Model Coupling Toolkit (MCT) (Warner et al., 2010). This system facilitates the study of interactions among the atmosphere, ocean, waves, and sediment transport processes. For this study, our focus is specifically on the interaction between the atmosphere and waves, so we will couple the atmospheric model with the wave model.

The atmospheric component of COAWST is the Weather Research and Forecasting model (WRF) (Skamarock et al., 2019), which simulates atmospheric conditions including wind speeds at hub height using Monin-Obukhov similarity theory. The wave conditions will be simulated using the Simulating Waves Nearshore model (SWAN) (Booij et al., 1999), which provides parameters such as significant wave height, wavelength, and wave direction.

COAWST allows for the use of different numerical grids for each model component. The interpolation between these grids is facilitated by the Spherical Coordinate Remapping Interpolation Package developed by Jones (1998). This package calculates weights for interpolation based on the nearest neighbor method, ensuring that information is exchanged only in regions where both WRF and SWAN grids overlap. In regions where grids do not overlap, such as offshore areas, additional data sources like reanalysis data can be used alongside simulated data to supplement the model outputs.

This approach enables comprehensive modeling of wind-wave interactions, crucial for understanding their combined impact on wind power production along the northeast coast of Brazil, particularly in Rio Grande do Norte, where future wind farm developments are planned. The Drennan (2003) parametrization expressed by the equation 2 is used in this study.

### 3.3. WAVE MODEL

Wave modeling was conducted using the third-generation Simulating Waves Nearshore (SWAN) model, version 41.31 (Booij, 1999), developed by Delft University of Technology. This model characterizes the main features of the wind-wave system through a two-dimensional wave action density spectrum. The governing equation of SWAN, the wave action balance equation, accounts for wave growth due to wind, dissipation through white-capping and breaking, and wave interaction via quadruplet and triad schemes. The model's sensitivity allows it to accurately describe wave behavior from deep ocean to shallow waters, including small or enclosed environments like lakes and estuaries, considering wind, wave boundary, bottom, and current conditions (SWAN4131, Ris, 1999; Booij, 1999).

In this study, SWAN version 41.31 was utilized, employing a frequency bin spectrum divided into 25 ranges from 0.005 to 1 Hz and wave directions divided into 36 bands. The bathymetric data used were sourced

from GEBCO, providing a resolution of  $0.004^\circ$  in both latitude and longitude. Two numerical grids were employed with resolutions of approximately 6 km and 2 km, respectively (Fig. 1).

SWAN wave boundary conditions were derived from the ERA5 database, available hourly with a grid spacing of  $0.5^\circ$ . This dataset facilitated the inclusion of wave energy spectra, generating outputs such as Significant Wave Height, peak wave period, and mean wave direction. These parameters were crucial for accurately defining wave boundary conditions in the modeling process.

### **3.4. ATMOSPHERIC MODEL**

The WRF model, developed at the National Center for Atmospheric Research (NCAR), utilizes a non-hydrostatic compressible Euler equation with infinite difference discretization to simulate atmospheric dynamics. To comprehensively capture physical processes such as microphysics, radiation, ocean surface roughness, turbulence flux, and the surface layer, parameterization schemes are essential. In this study, particular emphasis is placed on processes occurring within the atmospheric boundary layer.

The lower boundary conditions for velocity and temperature are determined by the surface layer scheme within WRF. This scheme calculates crucial parameters like friction velocity and exchange coefficients for heat and momentum fluxes. These exchanges serve as fundamental inputs for the planetary boundary layer parametrization, which estimates vertical fluxes throughout the atmosphere.

In the context of the coupled atmospheric-wave model used in this study, the surface layer scheme in WRF continues to compute friction velocity and exchange coefficients specifically over the ocean. This integration allows for the inclusion of wave characteristics generated by the wave model into the surface layer scheme, enhancing the model's ability to simulate realistic interactions between atmosphere and ocean dynamics.

The numerical domain for this research encompasses a segment of Brazil's northeast coast, focusing on the Rio Grande do Norte offshore region where oceanographic buoy data is collected (refer to Fig. 1). The WRF simulation employs two two-way coupled nested domains with horizontal resolutions of 6 km and 2 km, respectively, and 48 vertical levels. The simulation period spans from the 1st to the 30<sup>th</sup> of June. Initial and boundary conditions are derived from the ERA5 reanalysis dataset provided by the European Centre for Medium-Range Weather Forecasts. This dataset offers spatial and temporal resolutions of  $0.25^\circ \times 0.25^\circ$  and hourly, respectively, with 48 vertical levels available up to 10 Pa.

### **3.5. MODEL VALIDATION**

To ensure the accuracy of the simulation, several statistical metrics are employed to assess the agreement between measured and modeled data. These metrics include Bias, root mean squared error (RMSE), Scatter Index (SI), Pearson's correlation coefficient ( $r$ ), and mean absolute error (MAE). The model data is validated against wind information obtained from LiDARs installed at the Areia Branca Saline Terminal - commonly referred to as Porto-Ilha de Areia Branca. This port is located in the Atlantic Ocean,

approximately 13.40 km off the coast of Areia Branca and 330 km from Natal, the capital of Rio Grande do Norte (Fig. 1).

$$\text{BIAS} = \frac{\sum(M_i - \text{Obs}_i)}{n} \quad (3)$$

$$\text{RMSE} = \sqrt{\frac{\sum(M_i - \text{Obs}_i)^2}{n}} \quad (4)$$

$$\text{SI} = \frac{\text{RMSE}}{\text{Obs}' } \quad (5)$$

$$r = \frac{\sum(M_i - M_i')( \text{Obs}_i - \text{Obs}' )}{\sqrt{(\sum(M_i - M_i')^2 \sum(\text{Obs}_i - \text{Obs}' )^2)^{0.5}}} \quad (6)$$

$$\text{MAE} = \frac{1}{2} \sum |M_i - \text{Obs}_i| \quad (7)$$

Here,  $M_i$  represents the model values for a given number of observations denoted by  $n$ , while  $\text{Obs}_i$  refers to the corresponding measured values.  $M'$  and  $\text{Obs}'$  signify the means of the model and measured values, respectively. All these statistical metrics have been employed in various validation studies (Li et al. 2021, Souza et al. 2022) to ensure the reliability and accuracy of the models.

## 4. ANALYSIS AND DISCUSSION OF RESULTS

### 4. 1. SENSITIVITY TO ATMOSPHERE-WAVE COUPLING

Upon comparing the simulated wind speeds at hub heights of 100, 150, and 200 meters with measurements from the LiDAR, a notable agreement between the model's predictions and actual measurements is observed (Fig. 2). This agreement is consistent across both the stand-alone atmospheric model and the coupled atmosphere-wave model, with a slight improvement noted in the coupled approach.

As illustrated in Table 1, the coupled atmosphere-wave model consistently shows lower relative averaged wind velocities over the simulated one-month period compared to the stand-alone atmospheric model. Bias values vary with height, measuring 1.27, 1.34, and 1.42 for the stand-alone model, and 1.21, 1.29, and 1.36 for the coupled model, highlighting the comparative performance and indicating a significant advantage for the coupled atmosphere-wave model.

Furthermore, the superiority of the coupled atmosphere-wave model is evident in the performance metrics comparison. The model achieves a correlation coefficient of 0.64 for wind speed, indicating a strong relationship between simulated and observed values. Additionally, the Root Mean Square Error (RMSE) values are low at 2.37, 2.42, and 2.50, reflecting the model's accuracy in capturing wind speed variability

across different heights. The Mean Absolute Error (MAE) for the coupled atmosphere-wave model is 1.83, 1.87, and 1.97, underscoring its precision in wind speed prediction.

In contrast, the stand-alone atmospheric model, while still performing well, exhibits slightly lower correlation (0.62), RMSE (2.41, 2.49, and 2.56), and MAE (1.86, 1.91, and 1.97) values, indicating the enhanced performance of the coupled atmosphere-wave model across these metrics. Similarly, both models effectively capture wind direction variability, demonstrating comparable statistical metrics. However, the influence of wind and wave interaction is more pronounced in wind speed predictions.




Figure 2. Wind speed time series analysis from June 2023.

In WRF model, the roughness length is a crucial parameter that influences the representation of surface processes, especially in the atmospheric boundary layer. The roughness length characterizes the surface roughness and is an essential input for determining the surface drag, which affects the transfer of momentum, heat, and moisture between the land surface and the atmosphere (Skamarock et al. 2019). The WRF model typically allows users to specify the roughness length for various land use categories through parameterization schemes. These schemes consider the characteristics of the underlying surface, such as land cover, vegetation, and terrain.



STATISTIC METRICS	WRF	WRF-SWAN
<b>BIAS (m/s)</b>		
<b>100 m</b>	1.25	1.21
<b>150 m</b>	1.34	1.29
<b>200 m</b>	1.42	1.36
<b>RMSE (m/s)</b>		
<b>100 m</b>	2.41	2.37
<b>150 m</b>	2.49	2.42
<b>200 m</b>	2.56	2.50
<b>MAE (m/s)</b>		
<b>100 m</b>	1.86	1.83
<b>150 m</b>	1.91	1.87
<b>200 m</b>	1.97	1.92
<b>r</b>		
<b>100 m</b>	0.62	0.64
<b>150 m</b>	0.62	0.64
<b>200 m</b>	0.62	0.64

However, the interaction with the ocean surface is not explicitly computed in stand-alone WRF models, where the roughness length is typically based on a constant value. However, the ocean surface is dynamic and subject to movement. In contrast, coupled atmosphere-wave models offer a more accurate estimation of this interaction. In this study, the parametrization proposed by Drennan et al. (2003) (Eq. 2) was employed in the coupled atmosphere-wave model. This allows for the consideration of all wave conditions in the computation of the roughness length, providing a more precise calculation of the momentum transfer from the ocean surface to the atmosphere.

The wind profile, a critical element in understanding offshore wind dynamics, is represented in Figure 3. Typically, wind velocity measurements and models are conducted at a standard height of 10 meters. However, with LiDAR measurements, it is possible to extend this comparison to heights of 100, 150, and 200 meters. This approach enables a comprehensive analysis of wind characteristics by investigating the vertical distribution of wind speed. It is crucial to note that atmospheric stability is considered in the model, allowing for an accurate representation of wind variability with height.

The WRF stand-alone model shows an increasing error with height compared to the WRF+SWAN model. This discrepancy is attributed to the Drennan et al. (2003) equation (Eq. 2), which effectively captures the wave conditions around Porto-Ilha. During the simulation period, these conditions represented a wind-sea

scenario (Reis et al., 2024), where there is a downward flux of energy from the wind to the sea surface, resulting in a decrease in wind speed along the profile. Consequently, the coupled WRF+SWAN model demonstrates improved accuracy in capturing the decrease in wind speed distribution with height.




Figure 3. The wind bias profile considering the hub height.

## 4. 2. HORIZONTAL WIND SPEED

In offshore wind projects, understanding the variability of wind speed along the transition between the coastline and the ocean is crucial. This region often experiences complex fluxes of heat and momentum, which affect wind patterns. To evaluate these changes, a metric is used to calculate the percentage of increase in wind speed as a function of the distance from the coast ( $R_u$  [%]). By analyzing this metric, it is possible to determine the optimal depth and distance from the coast that can best satisfy the planning requirements for offshore wind farms. This approach ensures that the selected locations will maximize wind energy capture and enhance the efficiency of wind farm operations.

In Figure 4, the plot illustrates the increase in wind speed along a transect line from Areia Branca to 37 km offshore (Fig. 1). Both models demonstrate an increase in wind speed percentage with distance, reaching nearly 50% at a height of 10 meters at the furthest distance. Interestingly, the highest wind speeds show the lowest percentage increase: winds at 100-, 150-, and 200-meters exhibit increases of approximately 25%, 18%, and 10%, respectively, while at 10 meters, the increase is about 50%. This indicates a greater relative change in wind speed at lower altitudes as the distance from the coast increases.




Figure 4. Horizontal wind speed velocity as a function of distance from the coast.

## 5. CONCLUSIONS

This study provides a detailed analysis of wind-wave interactions and their impact on wind power production along the northeast coast of Brazil, particularly focusing on the Rio Grande do Norte region. By comparing coupled atmosphere-wave models with stand-alone atmospheric models, significant insights were gained into the benefits of incorporating ocean wave condition into wind resource assessments.

The key findings demonstrate that the coupled atmosphere-wave model (WRF+SWAN) consistently outperforms the stand-alone atmospheric model in predicting wind speeds at various heights. The coupled model showed lower bias, RMSE, and MAE values, and higher correlation coefficients, highlighting its superior accuracy in capturing wind speed variability. Specifically, the Drennan et al. (2003) parameterization within the coupled model effectively accounted for wave conditions, improving the model's performance.

Furthermore, the study highlights the importance of considering wind-wave interactions for offshore wind energy projects. The analysis of horizontal wind speed along the transition from the coastline to the open ocean revealed significant increases in wind speed at higher altitudes, indicating optimal locations for wind farm placement to maximize energy capture.

Overall, the findings suggest that coupled atmosphere-wave models can enhance the precision of offshore wind resource assessments, thereby reducing uncertainties and supporting the efficient planning and operation of future wind farms in Brazil. This approach can play a crucial role as Brazil explores its substantial offshore wind potential, contributing to global renewable energy targets.

## REFERENCES

Ali AlSam, R Szasz, and Johan Revstedt. The influence of sea waves on offshore wind turbine aerodynamics. *Journal of Energy Resources Technology*, 137(5), 2015.

Andrea N Hahmann, Claire L Vincent, Alfredo Peña, Julia Lange, and Charlotte B Hasager. Wind climate estimation using WRF model output: method and model sensitivities over the sea. *International Journal of Climatology*, 35(12):3422–3439, 2015.

Drennan, W. M., H. C. Graber, D. Hauser, and C. Quentin, 2003: On the wave age dependence of wind stress over pure wind seas. *J. Geophys. Res.*, 108, 8062, doi:10.1029/2000JC000715.

Felipe M Pimenta, Allan R Silva, Arcilan T Assireu, Vinicio de S e Almeida, and Osvaldo R Saavedra. Brazil offshore wind resources and atmospheric surface layer stability. *Energies*, 12(21):4195, 2019.

Government of Rio Grande do Norte State GOV-RN and SENAI Innovation Institute for Renewable Energies ISI-ER. Wind and solar atlas of rio grande do norte state. *Atlas*, 1(1):211, 2022.

Jana Fischereit and Xiaoli Guo Larsén. Interactions of oceanic surface waves and offshore wind farm wakes. In *Annual meeting 2019: European Conference for Applied Meteorology and Climatology*, 2019.

Lichuan Wu, Mingming Shao, and Erik Sahlée. Impact of air–wave–sea coupling on the simulation of offshore wind and wave energy potentials. *Atmosphere*, 11(4):327, 2020.

Li, H., Claremar, B., Wu, L., Hallgren, C., Körnich, H., Ivanell, S., & Sahlée, E. (2021). A sensitivity study of the WRF model in offshore wind modeling over the Baltic Sea. *Geoscience Frontiers*, 12(6), 101229.

Max Mauro Lozer Reis, Bruno Mitsuo Mazetto, and Ezequiel Costa Malateaux Silva. Economic analysis for implantation of an offshore wind farm in the Brazilian coast. *Sustainable Energy Technologies and Assessments*, 43:100955, 2021.

N Salvação and C Guedes Soares. Wind resource assessment offshore the Atlantic Iberian coast with the WRF model. *Energy*, 145:276–287, 2018.

Nina Svensson, Hans Bergström, Anna Rutgersson, and Erik Sahlée. Modification of the Baltic Sea wind field by land-sea interaction. *Wind Energy*, 22(6):764–779, 2019a.

Nina Svensson, Johan Arnqvist, Hans Bergström, Anna Rutgersson, and Erik Sahlée. Measurements and modelling of offshore wind profiles in a semi-enclosed sea. *Atmosphere*, 10(4):194, 2019b.

Noele Bissoli Perini Souza, Erick Giovanni Sperandio Nascimento, Alex Alisson Bandeira Santos, and Davidson Martins Moreira. Wind mapping using the mesoscale WRF model in a tropical region of Brazil. *Energy*, 240:122491, 2022.

Sara Porchetta, Domingo Muñoz-Esparza, Wim Munters, Jeroen van Beeck, and Nicole van Lipzig. Impact of ocean waves on offshore wind farm power production. *Renewable Energy*, 180:1179–1193, 2021.

Siri Kalvig, Eirik Manger, Bjørn H Hjertager, and Jasna B Jakobsen. Wave influenced wind and the effect on offshore wind turbine performance. *Energy Procedia*, 53:202–213, 2014.

X Costoya, M DeCastro, D Carvalho, Z Feng, and M Gómez-Gesteira. Climate change impacts on the future offshore wind energy resource in China. *Renewable Energy*, 175:731–747, 2021.

## Theoretical approach to optimize the installation of renewable generations in hybrid Power Plants

**Authors,** Anderson Lima<sup>1</sup>, Leticia Frata<sup>1</sup>, Ricardo Galvão<sup>1</sup> Vinicius Lopes<sup>1</sup>

<sup>1</sup>Hitachi Energy

anderson.lima@hitachienergy.com, leticia.frata@hitachienergy.com, ricardo.galvao@hitachienergy.com,  
vinicius.lopes@hitachienergy.com

### ABSTRACT

The paper introduces a novel theoretical approach by Hitachi Energy Brazil Power Consulting team to estimate the impacts of installing an additional generation from a solar source operating concomitantly with the installed Wind Farm. This methodology and its results should be seen as a decision-taking support on technical and economics analytics in order to support the evaluation of the operation of a hybrid power plant, optimizing the MUST (Montante de Uso do Sistema de Transmissão) limits contracted on a daily operational basis over an estimated annual period. Secondary installed power is the goal of the study; therefore, defined values are simulated with the intention of finding the best amount of installed power. An illustrative case application is presented.

### Keywords:

Wind Power Plant; Solar Power Plant; Hybrid Generation.

### 1. INTRODUCTION

More recently, with the issue of climate change and the need to reduce greenhouse gas emissions increasingly on the agenda on the world, there is pressure for a paradigm shift to enable the reliable and cost-efficient production of electricity, in which polluting resources are replaced by renewable energy, aiming for a safe and flexible network with low environmental impact.

Renewable energy from wind and solar plants has recently delivered energy at lower costs compared to the traditional electric grid system. However, a significant challenge remains: this energy is more variable and less predictable than current electricity demand. Therefore, to tackle this issue, discussion about hybrid electricity generation projects has been growing.

Hybrid power plants are those that combine multiple generation assets in a single power plant, including wind, solar and hydraulic, among other integrated sources. This type of installation stands out due to its advantage, especially related to cost reduction and increased efficiency in project installations.

One example of the benefits is the possibility that hybrid power plants can help with the intermittence of renewable energies, which consequently depends on the availability of natural resources for generation, meaning that when one source is not available, another can supply the demand by taking advantage of free space in the transmission network, without the need for expand it. Therefore, the main advantage of generating energy from different sources that share the same transmission infrastructure is the optimization of the use of the electrical grid.


Additionally, when integrating wind and solar plants, solar plants perform best on sunny days, while the ideal winds for power generation generally occur at night, when temperature changes causing air movement. This complementarity between sources allows for more efficient and continuous operation of the system.

Finally, this integration is especially beneficial for investors in hybrid plants, as it offers greater predictability to renewable projects, reducing variability in generation over time and increasing energy generation throughout the day.

To evaluate technical and economic feasibility of a project, it is necessary to study whether the region of interest has resources with good generation potential, because depending on the specific location, there are different profile of renewable resources for solar and wind generation, which present different timescales of interest.

In this paper we will focus on wind and solar resources which are illustrate in figure 1, followed by a brief summary of the main characteristics of the energy resources.

Figure 1: Hybrid Power Plant Topology




Source: Author

For solar generation the main characteristics is the heavy influence of the time of year and latitude of its location, which strongly shape its diurnal cycle. Furthermore, regional weather patterns, particularly cloud cover, significantly affect the resource, which are less predictable in the short term.

Based on the data made available by the ONS (Operador Nacional do Sistema), figure 2 presents the energy generation profile from the solar source for the state of Bahia, which was selected based on the strong presence of renewable energy and a considerable database of last years of its operations [1][2].

Figure 2: Behavior of solar generations in average for the region of interest for the year 2023.



Source: Author


For wind energy resources the main characteristic is the widely variation of production, which depends on the global position. First, there are different driving sources for wind energy, including pressure forces because of differential heating of the Earth's regions, Coriolis forces because of the Earth's rotation, inertial forces of the wind itself because of largescale circular motions, and frictional forces from interacting with

the Earth's surface [3].

Topographical variations employ a significant influence on frictional forces and the characteristics of the local resource at a specific site, including its precise location within that site. It is known also that the proximity with the coast affect the wind profile of the region, so all those geographical factors must be taken into account.

Based on the data made available by the ONS [1][2], figure 3 presents the energy generation profile from the wind source for the state of Bahia, in order to have the same geographical location for comparison.

Figure 3: Behavior of wind generations in average MW for the region of interest for the year 2023



Source: Author

Predicting variations in wind resources over time is even more challenging, because wind resources generally show less correlation with specific times of day compared to solar energy.

## 2. HYBRID GENERATION AND BRAZILIAN REGULATIONS

In 2021, ANEEL (Agência Nacional de Energia Elétrica) approved regulations for the operation of Hybrid Generating Power Plants and Associated Generating Power Plants [4]. These regulations established the rules for granting these projects, contracting the use of transmission systems, in addition to how the power plants are charged and the application of legal discounts on tariffs for using the transmission system.

These regulations allow combinations of various generation sources, such as solar, wind, large and small hydroelectric plants, and thermoelectric plants. Among the advantages highlighted by ANEEL are the complementarity of generation sources, the more efficient and stable use of the transmission network, the reduction of commercial risks and savings related to the purchase of land and other costs [5].

This measure presents itself as an alternative for the efficient use of resources available in the electrical system, enabling cost reduction and the postponement of new investments in expansions, especially at connection points with the Basic Network.

## 3. CURTAILMENT ANALYSIS METODOLOGY

In this study, a novel theoretical approach was developed to estimate the impacts of installing an additional generation, from a solar source, operating concomitantly with the installed Wind generation, considering the influence of each of the generation sources, in simultaneous operation, with the power delivered to the Connection Point being evaluated, given the limits of the enterprise's MUST (Montante de Uso do Sistema de Transmissão), in order to optimize the operation.

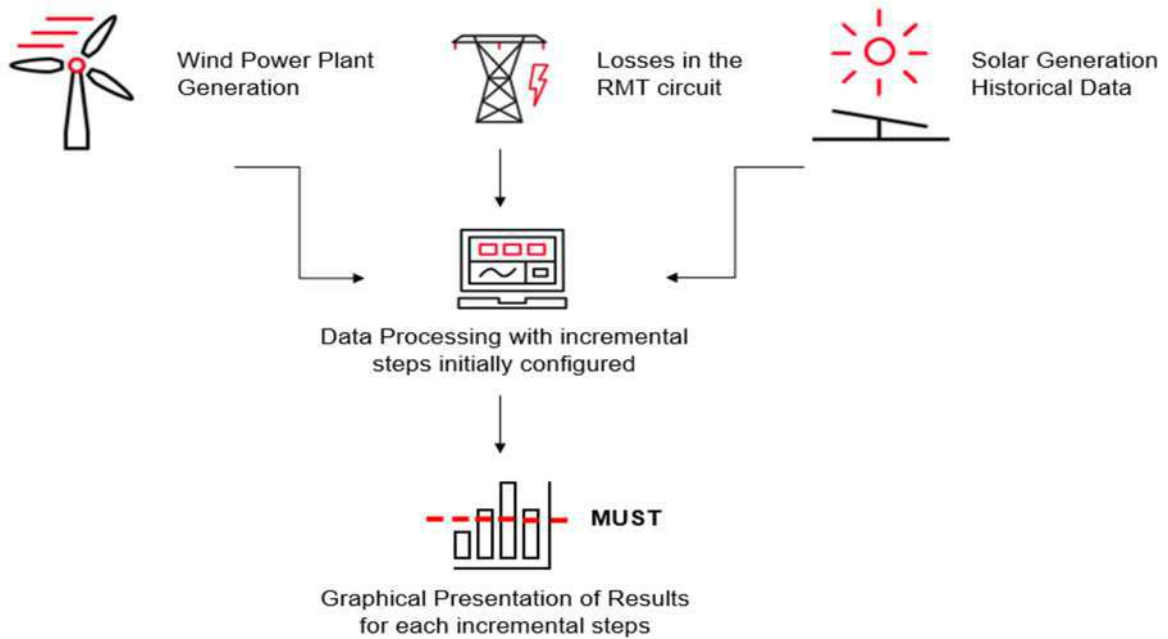
To this end, the region's wind and solar generation profiles are surveyed throughout the days and throughout the year, in order to evaluate the generation curves in each scenario. With this, there will be pre-defined incremental steps in the solar source power to be installed considering the impacts on simultaneous generation assessed, checking whether the margins defined for generation are exceeded or not.



After that, for each step of solar power, 1000 simulations are carried out for each month of the year, making each simulation represent approximately 43 minutes of monthly operation. The significant number of simulations is carried out so that the deviations of each generation do not interfere with the results to the point of characterizing an inappropriate availability of natural resources.

Initially, for the execution of the study, the developed tool is adjusted considering the specific data of the enterprise and the main variables. The main variables to be defined refer to installed power, the losses in the medium voltage branch (RMT) and the main energy matrix, according to the methodology illustrated in figure 4.


Figure 4: Iterative methodology to define the appropriate power of complementary solar generation



Source: Author

For the calculations of the script, the behavior of the energy resources presented in figure 2 and figure 3 were considered to calculate the energy matrices involved in the study which needs to present a 12 month x 24 hours average generation curve, together with a standard deviation table, according to the example illustrated in figure 5:

Figure 5: Example with 12 months x 24 hours average generation curve.



Source: Author

The calculations performed in the study takes the following normalized variables into consideration.

- Installed Power of the Main Matrix - (“P\_Main”)
- Average Hourly Generation (Wind) – (“Main\_Average”)
- Average Hourly Generation (Solar) – (“Secondary\_Average”)

Considering these inputs, 1000 scenarios are simulated per month to take the generation standard deviation into account. We can simplify this methodology using the equation below.

$$Generated\ Power = P\_Main * Main\_Average( deviation) + P\_Secondary * Secondary\_Average( deviation) \quad (eq\ 1)$$

Secondary power is the object of study, therefore, some values, according to the defined steps, will be simulated with the intention of finding the best amount of installed power.

In the graphical presentation of the results, comparisons of hourly loads are presented, month by month for the modeled typical year, with which is possible to compare the impacts of each increment on the solar installed power over the energy generated by the existing wind power plant. The best-case scenario is the one in which the generated power is no more and no less than the contracted MUST, that is, the Transmission Systems is being used at the optimal point.

### 5. AN ILLUSTRATIVE CASE


As presented in the introduction, energy generation from renewable sources presents intermittent behavior and allows the combination of energy matrices in a generation enterprise to be possible and economically viable. In this way, with the aims to verify the possibility to implement a hybrid generation power plant, probabilistic analysis was carried out, initially considering a wind farm with 385MW.

To develop the analysis, a typical region of Bahia was considered through a survey of the operation history on a daily basis for each month of a typical year of the different types of generating resources in the region, according to their source characteristics, geographic location and deviations over the years. Considering the profile presented in figure 2 and figure 3 it was possible to define the average hourly behavior of the generations using the data provided by the ONS.

Based on the methodology presented and input data considered and defined, the annual behavior of the generation scenario could be estimated and the scenarios where the defined limit was exceeded could be determined. If generation above the limit occurs, the generation itself must cut the excess production to avoid violating the contracted MUST, under the risk of being penalized by the operator.

In this way, by simulating the various steps of solar energy, for all months of the year, according to figure 6 it is possible to analyze how much additional energy per year can be transmitted to the system.

Figure 6: Incremental steps to evaluate the amount of additional energy to be transmitted to the system.



Source: Author

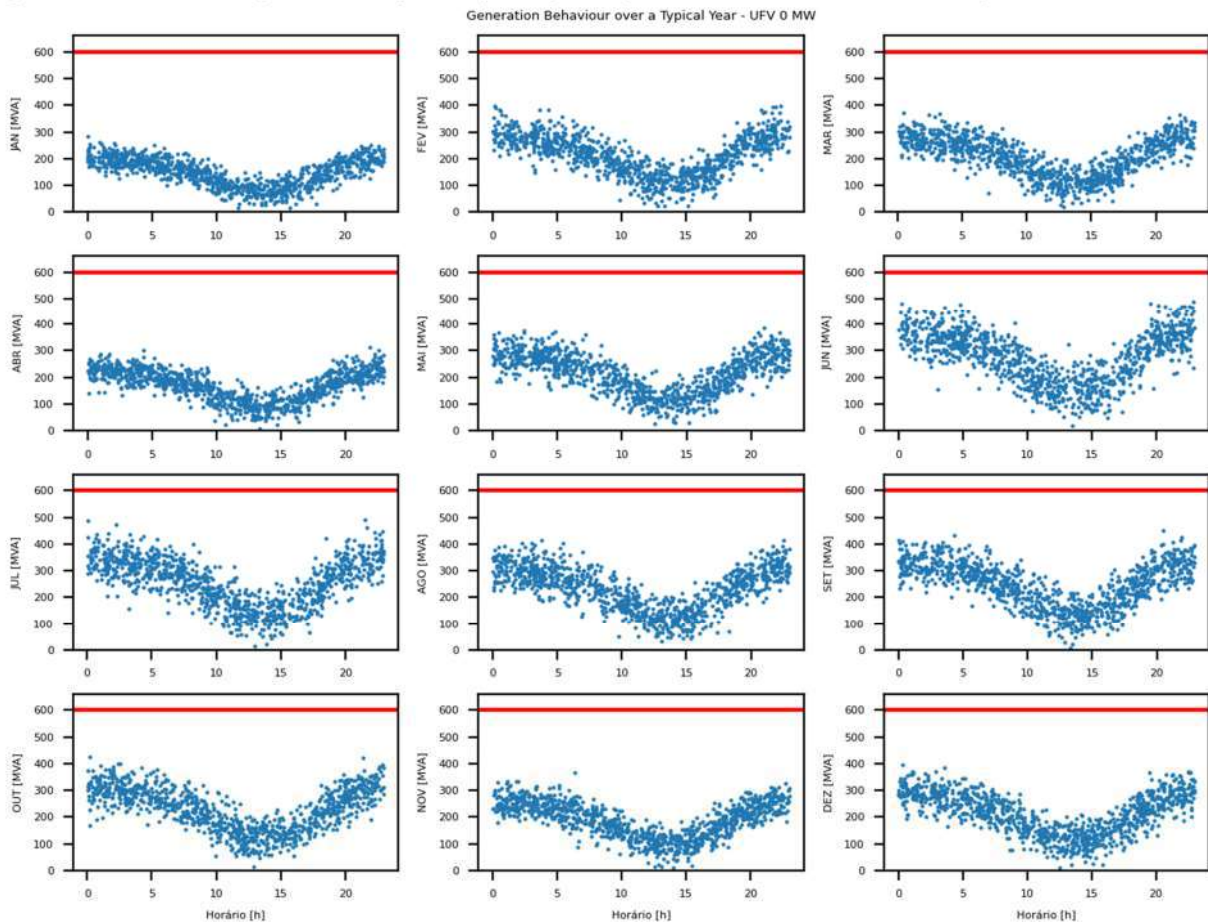
To demonstrate this effect, figures 7 to 10 presents the energy generated at each scenario, starting with no additional solar power (Figure 7) to an additional 600 MW of installed solar power (Figure 10), as well as with intermediate values of 200 MW and 400MW (Figure 8) and (Figure 9) respectively. In a certain time range, the solar power plus the wind power exceeds the MUST and the power generated must be limited by the operation of the power plant.

The presentation of the results is defined as a color-coded graph, where:

**Blue dots:** Dispersion of the 1000 simulations with the sum of energy generated by the power plant at a given time/month, from both sources, wind and solar.

**Red line:** Limit defined by MUST evaluated in the presented scenario.

Figure 7: Power curve generated by this hybrid power plant when the installed solar power is 0MW.



Source: Author

Figure 8: Power curve generated by this hybrid power plant when the installed solar power is 200MW.

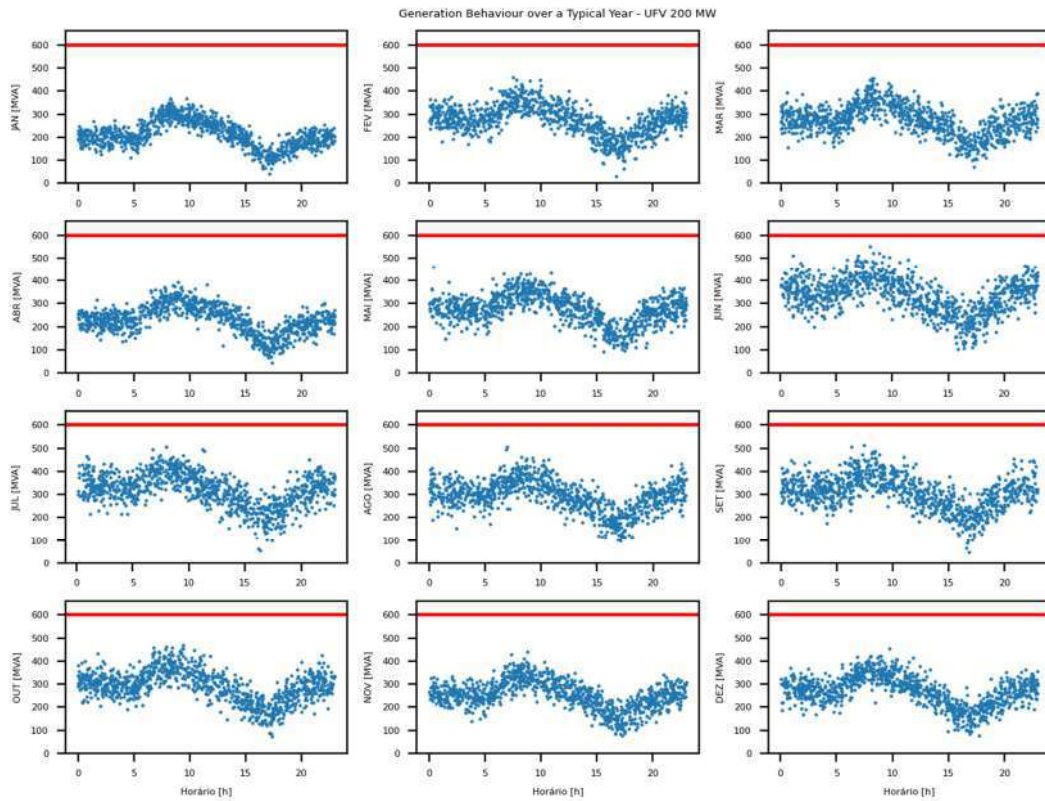
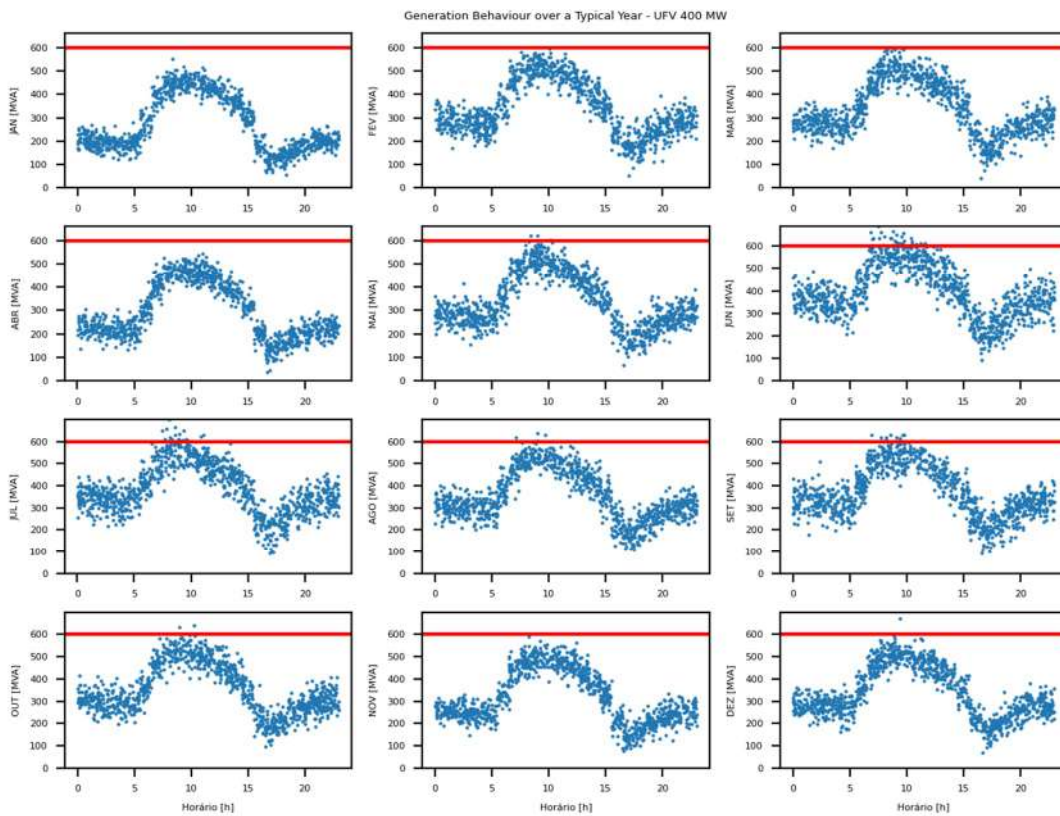
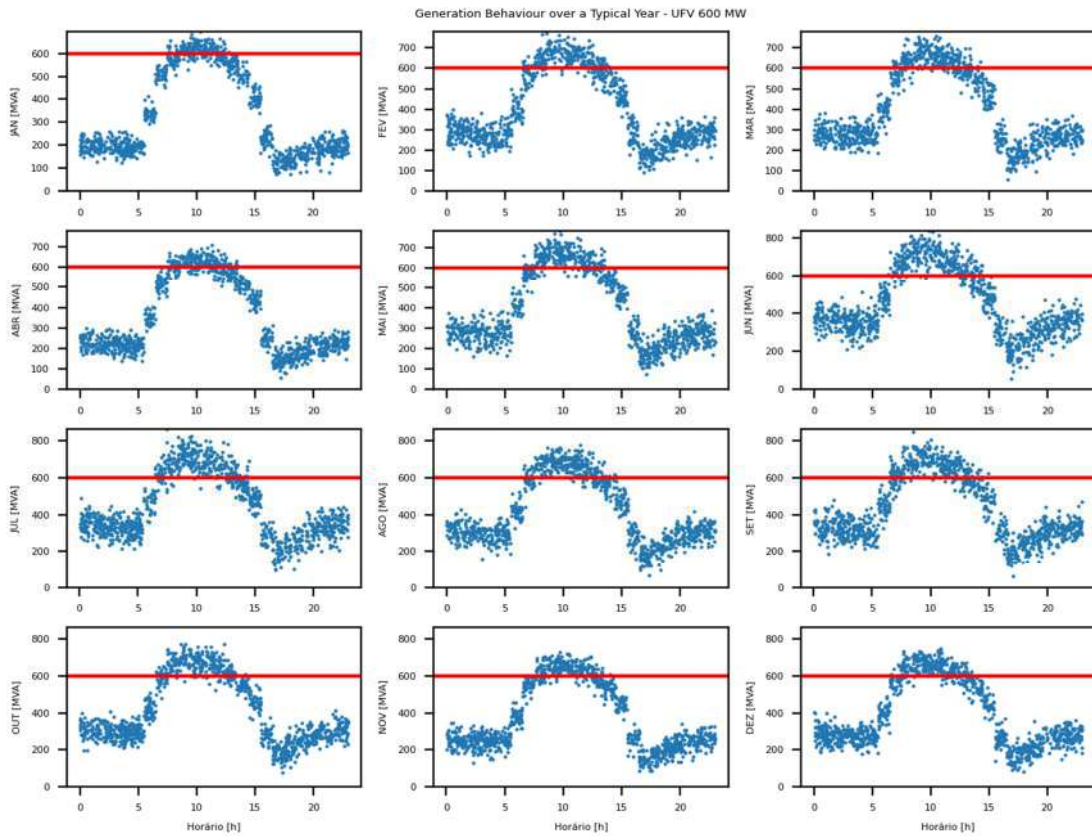


Figure 9: Power curve generated by this hybrid power plant when the installed solar power is 400MW.



Source: Author

Figure 10: Power curve generated by this hybrid power plant when the installed solar power is 600MW.




Source: Author

As can be seen on the presented Figures, the wind power alone (Figure 7) presents a lower generation during daytime, therefore presenting a sub-utilization of the contracted MUST. At the other extreme, with the installation of additional 600 MW (Figure 10) of solar power, the power plant has capacity of generating energy above the MUST during several hours of the day, that is, the generation will have to be limited, losing its full potential.

So, it is possible, on this scenario, to say that the optimal installation of solar power will be close to 400MW (Figure 9), once in this scenario there is the balance between using the closest to the maximum potential of the transmission system (with reference on the MUST) and having the closest to the minimal investment on additional solar infrastructure.

From the point of view of an investor in a renewable energy, the installed solar power represents a CAPEX investment, while the additional annual energy produced represents the return on investment (ROI). Thus, it is possible to convert the graph above into a Return on Investment based on the value of the investment. Using average market values for the price of installing a solar power plant and the average price of energy in the free market [6], we find the expected return shown in figure 11.

Figure 11: Expected return of Investments for a hybrid power plant.



Source: Author

The greater the installed capacity of the solar, the greater the chances that the total power produced by the hybrid generation will exceed the contracted MUST value so the annual return is not linear with the investment. As the return is not linear with the investment, when the ROI is calculated there is a decrease in percentage the greater the incidences of curtailment.

With this assessment, the investor can make the best decision that is in line with their renewable energy investment strategy and have greater assertiveness about the amount of additional energy that can be generated and sold in the following years.

## 6. FINAL REMARKS

The paper introduces a novel theoretical approach on hybrid power plant optimization analysis for wind and solar power plants.

Energy generation from renewable sources presents intermittent behavior and allows the combination of energy matrices in a generation plant to be possible and economically viable. Therefore, this methodology was developed to estimate the impacts of installing an additional generation from a Solar source, operating concomitantly with the installed Wind. This study aims to support the evaluation of the operation of a hybrid plant, optimizing the MUST limits contracted on a daily operation over an estimated annual period for a specific facility or region, considering the power generation estimated for a typical wind and solar profile based on historical data.

This methodology and its results should be seen as a decision-taking support on technical and economics analytics, as wind and system demand patterns itself could be hard to be precisely predicted. The results presented on this evaluation methodology can be optimized even more by having a smaller step on the evaluation of solar increments, an increase on the historical data of the location or even on the number of simulations done at each window.

In summary, with this assessment, the investor can make the best decision in terms of technical and economic feasibility to check if the outcome is in line with their renewable energy investment strategy and have greater assertiveness about the amount of additional energy that can be generated and sold in the following years.

From an energy perspective, there is a benefit in diversifying sources due to the portfolio effect. Each renewable source has unique characteristics of seasonality, modulation, and instantaneous production profile. By integrating them, it is possible to achieve greater stability in global production.

Finally, the structuring of commercial portfolios by entrepreneurs generates financial effects similar to the installation of hybrid power plants. By diversifying between plants from diverse sources, each with different generation profiles, the lack of correlation between their production minimizes entrepreneurs' potential financial exposure to fluctuations in primary resources.

---

## REFERÊNCIAS

- [1] “Resultados da Operação – Evolução da Capacidade Instalada”, Operador Nacional do Sistema Elétrico (ONS). Available in: <https://www.ons.org.br/>.
- [2] “Resultados da Operação – Geração Média Diária e Horária”, Operador Nacional do Sistema Elétrico (ONS). Available in: <https://www.ons.org.br/>.
- [3] James F.. Manwell, Jon G.. McGowan, and Anthony L. Rogers. *Wind energy explained: Theory, design and application*. John Wiley & Sons., 2009
- [4] “Resolução Normativa ANEEL Nº 954, de 30 de Novembro de 2021”, Agência Nacional de Energia Elétrica (ANEEL), Available in: <https://www2.aneel.gov.br/>.
- [5] Usinas híbridas são regulamentadas pela ANEEL, 1 de dezembro de 2021, “Canal Solar”, Available in <https://canalsolar.com.br/2021/12/01/>.
- [6] CCEE- Câmara de Comercialização de Energia Elétrica. Preço Médio da CCEE (R\$/MWh). Disponível em: <https://www.ccee.org.br/>.
- [7] Dykes, Katherine, et al. Opportunities for research and development of hybrid power plants. No. NREL/TP-5000-75026. National Renewable Energy Lab.(NREL), Golden, CO (United States), 2020.
- [8] Estudos De Planejamento aa Expansão Da Geração – Usinas Híbridas No Contexto do Planejamento Energético, Empresa de Pesquisa Energética (EPE). Available in: <https://www.epe.gov.br>
- [9] EPE- Empresa de Pesquisa Energética. Usinas Híbridas - Uma análise qualitativa de temas regulatórios e comerciais relevantes ao planejamento. Nota Técnica, 2018. Disponível em:<http://www.epe.gov.br>
- [10] EPE- Empresa de Pesquisa Energética. EPE realiza o Workshop "Usinas Híbridas no SIN" Publicado em 16/05/2019. Disponível em <http://epe.gov.br/>.

## **Análise comparativa entre modelos na detecção de anomalias em medições de torres anemométricas**

**Leonardo César Mendes Santos Portela<sup>1</sup>, Lucas Mateus Cordeiro Jurema<sup>1</sup>, Yasmin Matsunobu<sup>1</sup>**

1 Casa dos Ventos

[leonardo.mendes@casadosventos.com.br](mailto:leonardo.mendes@casadosventos.com.br), [lucas.cordeiro@casadosventos.com.br](mailto:lucas.cordeiro@casadosventos.com.br),  
[yasmin.oliveira@casadosventos.com.br](mailto:yasmin.oliveira@casadosventos.com.br)

### **RESUMO**

Considerando a expansão do setor de geração eólica no Brasil, principalmente na etapa de desenvolvimento de projetos com o uso de dados coletados por torres anemométricas, este trabalho propõe uma solução no âmbito do aprendizado de máquina que consiga identificar anomalias nas medições de forma eficiente e assertiva. Para tal objetivo, utilizou-se dados provenientes de 16 torres anemométricas com mais de 2 anos de medição, que foram analisados manualmente e com isso criou-se dois conjuntos, um para treino e outro para teste dos modelos treinados. Os algoritmos utilizados foram Random Forest, XGBoost, Catboost e LightGBM, todos baseados em árvores de decisão, além disso, também foram treinados utilizando RandomizedSearchCV, um algoritmo de otimização de hiperparâmetros, para comparar se os resultados seriam aprimorados. Por serem dados desbalanceados, a métrica escolhida para ranquear os modelos foi o F1-Score, além do tempo de treino. Por fim, o algoritmo Catboost mostrou-se o mais adequado, performando bem tanto nos dados de treino quanto nos dados não utilizados previamente.

### **Palavras-chaves:**

Dados Anemométricos; Aprendizado de máquina; Catboost; LightGBM; Desenvolvimento eólico

### **ABSTRACT**

Considering the expansion of the wind power generation sector in Brazil, especially in the project development stage using data collected by anemometric towers, this work proposes a machine learning solution to efficiently and accurately identify anomalies in the measurements. For this purpose, data from 16 anemometric towers with over 2 years of measurements were used, which were manually analyzed to create two sets: one for training and one for testing the trained models. The algorithms used were Random Forest, XGBoost, Catboost, and LightGBM, all based on decision trees. Additionally, RandomizedSearchCV, a hyperparameter optimization algorithm, was used to compare if the results would improve. Given the imbalanced data, the metric chosen to rank the models was the F1-Score, in addition to the training time. Finally, the Catboost algorithm proved to be the most suitable, performing well on both the training data and the previously unused data.

### **Keywords:**

Anemometric Data; Machine Learning; Catboost; LightGBM.



## 1. INTRODUÇÃO

A concepção de um projeto eólico está fortemente ligado à viabilidade do recurso eólico na região escolhida para o empreendimento, portanto é necessário que os dados coletados por torres anemométricas apresentem uma alta qualidade no decorrer de suas campanhas, de forma a garantir tanto uma predição de produção de energia confiável quanto para seguir as diretrizes estabelecidas pela Empresa de Pesquisa Energética (EPE) a fim de participar de leilões de energia elétrica [1].

Para garantir a qualidade dos dados, é necessário checagem dos mesmos em busca de encontrar possíveis anomalias ou defeitos nos instrumentos de medição, para que possíveis defeitos sejam sanados o mais breve possível, garantindo que as informações estão medidas pelos sensores estão de acordo com a realidade. Comumente, é realizada uma análise gráfica das séries temporais dos sensores, porém, conforme o aumento na quantidade de dados a serem analisados, este processo pode se tornar demorado, a ponto de ser inviável a detecção de dados inválidos em tempo hábil. Assim, a implementação de modelos e algoritmos de classificação, no âmbito do aprendizado de máquinas, pode otimizar o processo, automatizando-o e melhorando a eficiência da análise.

Nesse sentido, o presente estudo teve como objetivo identificar um modelo que ofereça agilidade no treinamento dos dados, devido ao tamanho das séries temporais utilizadas, ao mesmo tempo que proporciona precisão na detecção de anomalias/dados inválidos, que, em conjunto com análise manual, garanta a integridade dos dados e agilidade na manutenção dos equipamentos. O estudo propõe a comparação da performance de modelos atuais como o Catboost e o LightGBM, frente a modelos mais conhecidos como XGBoost e Random Forest, além da utilização da técnica de otimização de hiperparâmetros RandomSearchCV, frente a um modelo sem otimização de hiperparâmetros.

Para atingir esse objetivo, foram utilizados dados de torres anemométricas localizadas em uma região em comum, onde as anomalias/dados inválidos já foram identificadas. Essas informações serão utilizadas para treinar os modelos, e em seguida, avaliar a performance dos mesmos em dados de torres que não foram utilizadas no treinamento.

## 2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

Para realizar a classificação e predição dos dados anômalos ou inválidos, foi feita a comparação entre diferentes modelos de "ensemble". Os "ensembles" são algoritmos que combinam modelos existentes em busca de melhores resultados. Neste caso, foram empregados dois dos principais tipos de ensembles, o "Bagging" e o "Boosting".

O ensemble do tipo "Bagging" ("Bootstrap Aggregation") funciona de forma que treina vários modelos com conjuntos de dados diferentes, criados por meio da reamostragem ("Bootstrap") e tem seu resultado final a partir da média das previsões dos modelos treinados ("Aggregation"), apresentando no final uma previsão mais precisa, robusta e geral. Nesse projeto, foi utilizado um dos algoritmos de "Bagging" mais robusto, conhecido como "Random Forest", que é, essencialmente, uma agregação de árvores de decisões. Já o "Boosting" é uma técnica de ensemble que treina os modelos de forma sequencial, com cada modelo subsequente corrigindo os erros do modelo anterior. Um subtipo do "Boosting" é o "Gradient Boosting", que utiliza gradientes da função perda para ajustar os modelos. Neste projeto, foram utilizados os modelos XGBoost ("Extreme Gradient Boosting"), LightGBM e CatBoost.

O modelo "Random Forest", é um método de ensemble do tipo "Bagging". Ele cria múltiplas árvores de decisão a partir de subamostras aleatórias do conjunto de dados, combinando suas predições para formar a predição final. Essa aleatoriedade aumenta a robustez e generalização do modelo, reduzindo o "overfitting". No entanto, o treinamento é mais lento e exige mais memória, especialmente com grandes volumes de dados.

O XGBoost, é um método de "gradient boosting" que constrói árvores de decisão sequencialmente, corrigindo erros das anteriores. Ele é eficiente em grandes volumes de dados devido ao processamento paralelo e distribuído, além de lidar bem com dados ausentes, sendo frequentemente usado em competições de "machine learning" da plataforma Kaggle.

O LightGBM, também é um "gradient boosting" de árvores de decisão. Sua principal diferença é o crescimento das árvores em largura (leaf-wise), ou seja, escolhe um nó e continua crescendo a partir desse nó, tornando o processamento mais rápido. Devido à sua velocidade, ele tem ganhado popularidade em competições do Kaggle.

O Catboost, introduzido por Prokhorenkova et al. (2018), é um "gradient boosting" que se destaca por lidar naturalmente com dados categóricos e por criar árvores de forma simétrica, o que diminui o "overfitting". Essas características o tornam mais eficiente para dados categóricos.

Para realizar este estudo, os modelos anteriores foram treinados com o mesmo dataset de torres, primeiramente com seus hiperparâmetros padrões com a divisão de dados de treino e teste (20% dos dados para teste) e em seguida utilizando a técnica de "GroupKFold" junto com o método de "RandomizedsearchCV".

O "GroupKFold" é uma forma de "cross-validation" (validação cruzada) que pode ser utilizado em datasets que apresentam estrutura de agrupamento. Nessa abordagem, o dataset é dividido em N conjuntos, preservando os grupos originais, e cada grupo será utilizado para validação do modelo treinado pelos outros N-1 grupos [4].

Já o "RandomizedsearchCV" é um algoritmo presente na biblioteca Scikit-learn, que realiza uma "busca" aleatória em um conjunto de hiperparâmetros, buscando encontrar qual combinação apresenta a melhor otimização para o modelo, diferente do "GridSearchCV", nem todos os hiperparâmetros são testados, apenas uma quantidade é testada com base na variável "n\_iter", o que torna sua implementação mais rápida. Nesse algoritmo, a variável "Scoring" se refere a métrica utilizada para avaliar o desempenho de cada combinação de hiperparâmetros [5].

Por se tratar de um problema de classificação, para avaliar a performance do modelo, foi utilizado a abordagem de matriz de confusão, onde nela é possível calcular algumas métricas que direcionarão ao modelo mais eficiente, dentre elas temos a precisão ("Precision"), a sensibilidade ("Recall"), o F1-Score e a acurácia ("Accuracy"). Devido à natureza desbalanceada dos dados, ao invés de utilizar a acurácia, foi decidido utilizar o F1-Score para avaliar a performance dos modelos, pois quando uma das classes da classificação prevalece, a acurácia acaba retornando um resultado enviesado.

A métrica de desempenho escolhida tanto para o treino com os hiperparâmetros padrões quanto para o "RandomizedSearchCV" em conjunto com "GroupKFold", foi a AUC-PR, que é a área sob a curva "Precision-Recall", essa métrica tem a capacidade de mostrar a relação entre a precisão e a sensibilidade do modelo, além disso é mais preferível em classificação binária com dados desbalanceados que a curva ROC [6].

Além dessa métrica, também foi avaliado a velocidade do modelo em treinar os dados, pois por se tratar de um problema com um grande volume de dados, alguns modelos podem apresentar um tempo de treino que os tornam inviáveis, importante também ressaltar que para os hiperparâmetros padrões foi utilizado uma divisão dos dados em treino e teste, a fim de diminuir a possibilidade de "overfitting".

### 3. MÉTODO DO ESTUDO

Os dados utilizados para elaboração desse artigo foram coletados a partir da medição da velocidade do vento em 16 torres anemométricas, sendo utilizadas 7 delas para treinamento do modelo e 9 para a validação dos modelos treinados. Essas torres fazem parte da infraestrutura de monitoramento de dados anemométricos de uma das maiores empresas de energias renováveis do país.

As torres selecionadas apresentam período de medições maiores que 2 anos, nessas torres os dados são obtidos a partir de 3 ou 4 anemômetros espalhados em sua extensão. Os dados em questão são agregações de 10 minutos dos valores medidos pelos sensores. Além disso, esses dados já foram

analisados previamente e já apresentam marcações de inválidos ou não, inclusive com manutenções realizadas para sanar os problemas que causaram as marcações.

Importante ressaltar que por estarem na mesma região (nordeste), tendem a ter um perfil de velocidade de vento diário semelhante, podendo apresentar algumas diferenças relacionadas à altitude e relevo próximo de onde a torre está instalada.

Por serem provenientes de grandes períodos de medições, a quantidade de dados de cada torre acaba tornando as tabelas pesadas, sendo assim, em busca de velocidade de leitura/escrita e também em arquivos mais leves, foi feita a escolha de salvar e ler os dados por meio do formato *parquet*, pois esse tipo de armazenamento de dados torna sua leitura e armazenamento bastante eficiente, devido ao seu formato de armazenamento colunar [2].

As variáveis que foram utilizadas na modelagem dos dados podem ser encontradas na Tabela 1 abaixo:

Tabela 1. Descrição das variáveis utilizadas

Variável	Descrição
<b>AVG</b>	Média agregada de 10 minutos do sensor
<b>AVG_lag_x</b>	Média agregada em relação a um timestamp anterior (x representa quantas medições anteriores)
<b>AVG_lead_x</b>	Média agregada em relação a um timestamp posterior (x representa quantas medições posteriores)
<b>STD</b>	Desvio padrão médio da medição
<b>STD_lag_x</b>	Desvio padrão médio em relação a um timestamp anterior (x representa quantas medições anteriores)
<b>STD_lead_x</b>	Desvio padrão médio em relação a um timestamp posterior (x representa quantas medições posteriores)
<b>Sensor_1</b>	Medição do AVG de outro sensor da mesma torre.
<b>Sensor_2</b>	Medição do AVG de outro sensor da mesma torre.

Fonte: Dados originais da pesquisa.

Na Tabela 2, é possível ver as estatísticas descritivas das variáveis utilizadas no treino do modelo, nessa tabela as variáveis do tipo “lag” e “lead” não serão apresentadas, pois são semelhantes às variáveis originais, apenas deslocadas no em um timestamp anterior ou posterior, além disso, nos dados de treino a distribuição das classes válidas e inválidas foi de 85661 linhas classificadas como inválidas e 6697643 classificadas como válidas.

Tabela 2 - Estatísticas Descritivas dos Dados de Treino

	<b>AVG</b>	<b>STD</b>	<b>Sensor_1</b>	<b>Sensor_2</b>
<b>Mean</b>	8,7	0,9	8,9	8,6
<b>STD</b>	3,2	0,7	3,3	3,2
<b>Min</b>	0,2	0,0	0,2	0,2
<b>25%</b>	6,6	0,5	6,8	6,6
<b>50%</b>	8,7	0,9	8,9	8,6
<b>75%</b>	10,8	1,2	11,1	10,7
<b>Max</b>	22,7	61,8	22,7	22,3

Fonte: Dados originais da pesquisa

Além disso, com a biblioteca Seaborn é possível criar o gráfico do tipo “scatterplot matrix”, esse gráfico permite explorar a relação entre as múltiplas variáveis dos dados, por meio de análise das variáveis duas a duas, também mostrando o comportamento de cada classe da classificação. O “scatterplot matrix” desses dados pode ser visto na Figura 1, alguns pontos podem ser destacados em relação aos dados inválidos (Invalid = 1.0) a partir desta figura.

O comportamento do vento para os sensores de uma mesma torre em alturas diferentes tendem a ter um comportamento parecido, o que poderia levar a relação linear, o que explica a concentração de dados classificados como inválidos acima de uma reta diagonal na comparação AVG com Sensor\_1 e AVG com Sensor\_2, outro ponto importante de destacar é que grande parte dos dados classificados como inválidos apresentam um desvio padrão bem maior que 10.

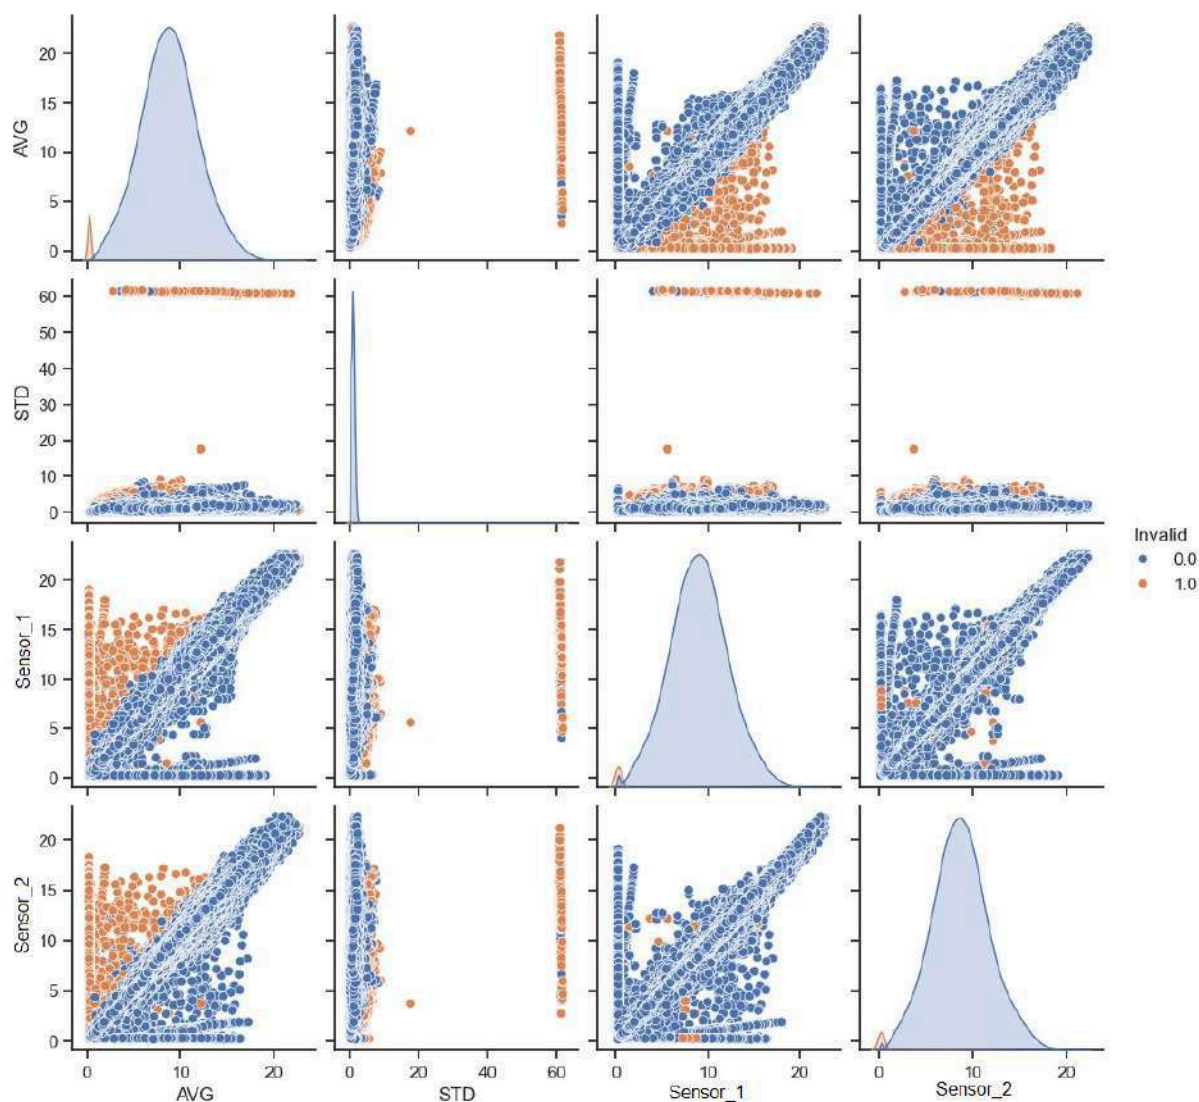


Figura 1 - Scatterplot Matrix Dados de treino

Fonte: Dados originais da pesquisa

A média e o desvio padrão da medição da velocidade do vento, agregada de 10 em 10 minutos, são as principais medidas observadas em busca de dados inválidos, pois tendem a ficarem próximas de uma média, logo qualquer distúrbio no equipamento irá gerar dados incoerentes.

Além disso, quando um equipamento apresenta defeito, os dados serão inválidos por um intervalo de tempo até ser realizado a manutenção, ou seja, ao verificar um timestamp "t" invalidado, na maioria dos casos, o timestamp anterior "t-1" e o posterior "t+1", também será invalido, por conta disso, foi feito a escolha de também utilizar as variáveis lag e lead dessas medições.

Observou-se também a inter-relação entre as medições dos sensores localizados em diferentes alturas em cada torre. Dado que a velocidade do vento geralmente aumenta com a altura [3], se o sensor instalado em uma posição mais elevada registra velocidades inferiores ao sensor em uma posição mais baixa no mesmo momento, isso pode sugerir inconsistências nas medições. Portanto, também foram utilizadas as medições dos outros sensores no mesmo timestamp.

## 5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

O resultado do treino dos modelos escolhidos utilizando os dados das 7 torres pode ser visto na Tabela 3, os resultados indicam que nos treinos os modelos “padrões” sem a utilização de “GroupKFold” apresentaram melhores indicadores, exceto para o LightGBM, além de um menor tempo de processamento. Dos modelos treinados, o Catboost Padrão é o que apresenta o maior F1-Score para a classificação 1 (Dado inválido), ou seja, já é um indicativo que esse modelo é o que pode se adequar melhor aos dados que não estavam no treinamento.

Tabela 3 - Modelos e Resultados

Modelo	Tempo	Flag	Precision	Recall	F1-Score	Accuracy
Catboost Padrão	12 min	0	1	1	1	1
		1	0,99	0,88	0,93	1
Catboost GroupKFold	136 min	0	1	1	1	1
		1	0,99	0,85	0,92	1
XGBoost Padrão	10 min	0	1	1	1	1
		1	0,99	0,88	0,93	1
XGBoost GroupkFold	104 min	0	1	1	1	1
		1	0,99	0,88	0,93	1
LightGBM Padrão	2 min	0	1	1	1	1
		1	0,98	0,87	0,92	1
LightGBM GroupKfold	32 min	0	1	1	1	1
		1	0,99	0,88	0,93	1
RandomForest Padrão	85 min	0	1	1	1	1
		1	0,99	0,88	0,93	1

Fonte: Dados originais da pesquisa

Após o treinamento dos modelos, foi feita a validação dos mesmos com os dados de 9 torres diferentes, importante ressaltar que não foi feito “GroupKfold” para o “Random Forest”, pois o tempo de processamento nos testes já era maior que 4 horas.

Para ter uma comparação melhor dos resultados, os modelos semelhantes foram comparados em termos de F1-Score em duplas e no final os melhores foram comparados entre si. Inicialmente a comparação foi feita em relação ao comportamento dos modelos em relação a cada sensor de cada torre, pois cada sensor pode ter um comportamento diferente dentro da mesma torre, devido a mudança de velocidade do vento em relação à altura, além disso, foram retirados da análise sensores com menos de 20 marcações de inválido, pois no decorrer do desenvolvimento, foi possível perceber que existiam alguns sensores com uma marcação apenas na série completa, o que provavelmente pode ter sido um erro na hora de aplicar a flag manualmente.

Como pode ser visto na Figura 2, o modelo de CatBoost sem utilização de “GroupKFold” conseguiu apresentar um F1-Score maior para grande parte dos equipamentos, principalmente para os equipamentos da torre T3 (AN1 e AN3), T4 (AN1 e AN2), T6 e T7, o que já demonstra uma melhora habilidade de classificação desse modelo, além de ter apresentado um menor tempo para realizar o treinamento.

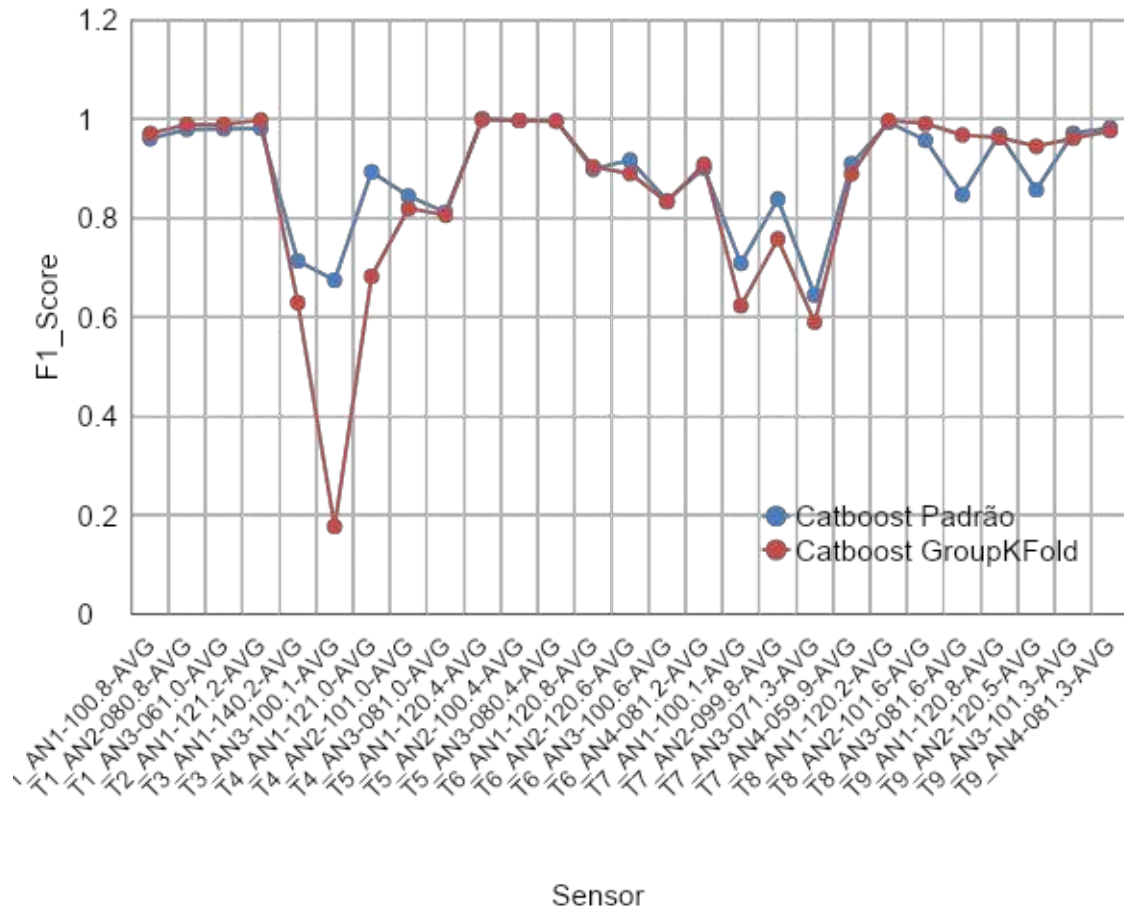


Figura 2. Catboost Padrão X “GroupKFold” (“RandomizedSearchCV”)

Fonte: Dados originais da pesquisa

Já na Figura 3, que mostra os resultados do XGBoost, tanto com a utilização do GroupKFold quanto sem utilizá-lo os dois tiveram um comportamento bem parecido, porém o XGBoost apenas com o train\_test\_split apresentou melhores resultados de F1 Score, principalmente nos equipamentos das torres T4, T6, T8 e T9, sendo assim, sua escolha se torna mais adequada do que a utilização do GroupKFold.




Figura 3. XGBoost Padrão X GroupKFold (RandomizedSearchCV)

Fonte: Dados originais da pesquisa

Para o LightGBM, na Figura 4, é possível verificar que o uso do “GroupKFold” apresentou um melhor desempenho em relação ao modelo com os parâmetros padrões, apesar de o modelo padrão ter apresentado um tempo de treinamento mais rápido, o desempenho nos dados de teste indicam que a melhor escolha seria a utilização do treino com “GroupKFold”, além do que seu tempo não passou de 60 minutos, sendo o mais rápido dos modelos com “RandomizedSearchCV”.






Figura 4. LightGBM Padrão X GroupKFold (RandomizedSearchCV)

Fonte: Dados originais da pesquisa

Como pode ser visto nas figuras anteriores, os modelos padrões tiveram melhor desempenho em praticamente todos os sensores de todas as torres, exceto para o LightGBM, que foi o único no qual o modelo padrão performou pior, além disso, também será acrescentado o resultado do “Random Forest” padrão, que foi o único que o tempo de treino do “GroupKFold” foi inviável.

Conforme o gráfico da Figura 5, é possível perceber que o único modelo a ter um bom F1-Score no sensor AN1 da torre T4 foi o Catboost Padrão, um indício de que ele é o modelo mais adequado. Apesar de apresentar um desempenho pior no sensor AN2 da torre T9, o Catboost consegue apresentar resultados consistentes para os outros sensores, ficando bem próximo dos resultados médios.

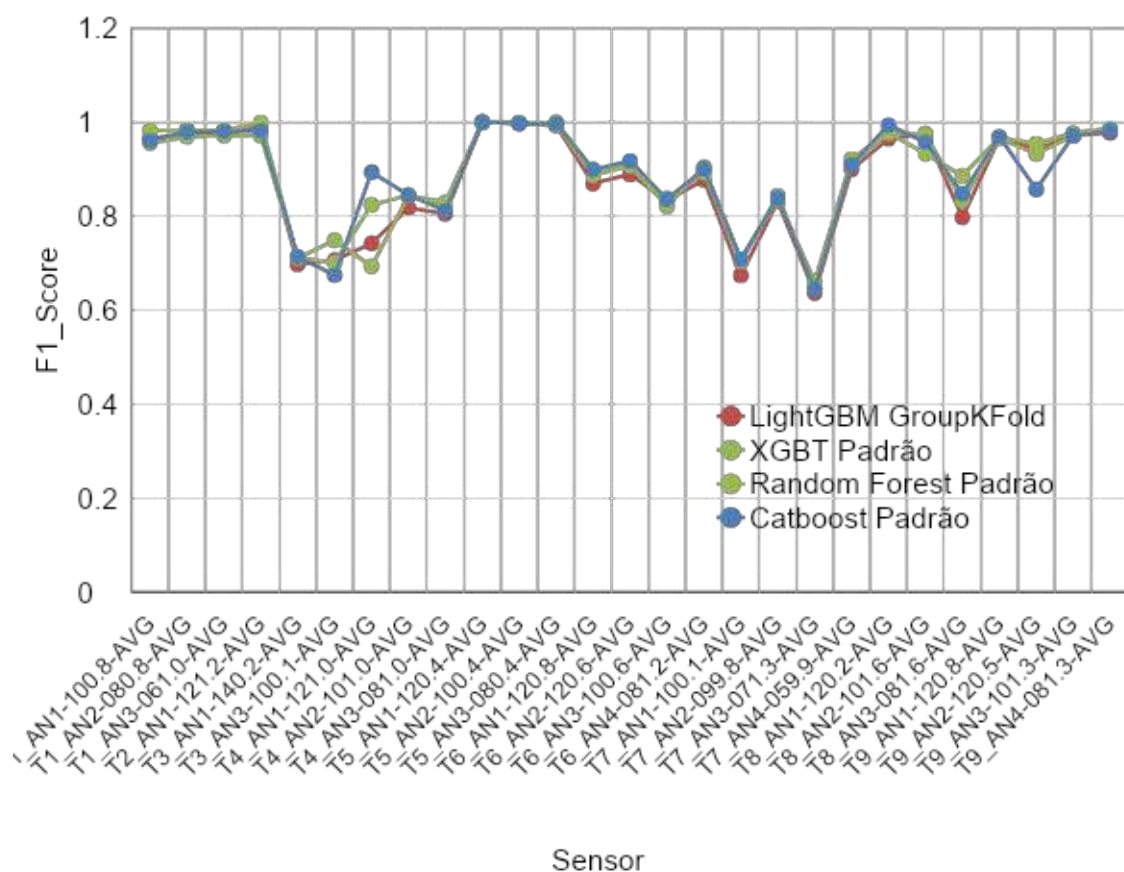


Figura 5. Comparação final entre modelos

Fonte: Dados originais da pesquisa

Além disso, na Tabela 4 é possível encontrar o resultado da matriz de confusão utilizando os dados de teste completo, sem a categorização por torres. Os modelos que apresentaram o F1-Score foram o Catboost e o “Random Forest”.

Tabela 4. Resultados Modelos Dados de Teste

Modelo	Flag	Precision	Recall	F1-Score	Accuracy
Catboost Padrão	0	1	1	1	1
	1	0,97	0,89	0,93	1
XGBoost Padrão	0	1	1	1	1
	1	0,96	0,89	0,92	1
LightGBM GroupKFold	0	1	1	1	1
	1	0,95	0,88	0,92	1
RandomForest Padrão	0	1	1	1	1
	1	0,97	0,89	0,93	1

Fonte: Dados originais da pesquisa

Portanto, baseado nos resultados encontrados nos gráficos anteriores e na Tabela 4, o modelo com melhor performance foi o Catboost, pois apesar de apresentar o mesmo F1-Score que o “Random Forest” para o conjunto de teste completo, o Catboost consegue apresentar uma melhor performance em sensores que o “Random Forest” falha, além de apresentar um menor esforço computacional.

Por fim, as figuras Figura 6 e Figura 7 representam a aplicação do modelo escolhido na série temporal de duas torres. Conforme pode ser observado, o modelo consegue classificar com êxito momentos de falhas na medição, onde ocorrem travamento e distanciamento da medição dos outros sensores, isso fica bastante evidente na Figura 7.

Já na Figura 6, ocorreu uma situação de falha intermitente, causada por um possível mal contato ou cabo do sensor solto, nesse caso, o sensor classificou corretamente os momentos em que a medição foi perdida, porém apresentou falsos negativos nos momentos em que o sensor AN1 mediu semelhante ao sensor AN3, que não estava com defeito, ou seja, essas medições podem ser consideradas válidas, ficando a critério do analista marcá-las como inválido.




Figura 6. Aplicação do Modelo na torre T3

Fonte: Dados originais da pesquisa




Figura 7. Aplicação do Modelo na torre T4

Fonte: Dados originais da pesquisa

## 6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

O objetivo deste trabalho foi buscar soluções no âmbito de aprendizado de máquinas que pudesse, de forma eficiente e assertiva, auxiliar o processo de identificação de sensores com falhas em campanhas de medições anemométricas.

Utilizando-se de modelos conhecidos como “Random Forest” e XGBoost, frente a outros modelos menos conhecidos como CatBoost e LightGBM, foi possível treinar modelos baseados em dados já invalidados manualmente, que conseguiram a partir desses modelos, invalidar outros dados que não foram utilizados no treinamento, ou seja, de forma autônoma, a partir do aprendizado de máquina.

Tal resultado demonstra que é possível utilizar-se de modelos de aprendizado de máquina para auxiliar empresas de desenvolvimento eólico no tratamento de suas campanhas, direcionando de forma mais assertiva o olhar do especialista, visto que é necessária análise frequente dessas medições, no mínimo duas vezes por semana, a fim de garantir que as manutenções sejam realizadas em no prazo esperado.

Por fim, os modelos apresentam espaço para evolução, com a utilização de uma quantidade de dados mais abrangentes e também com a utilização de outros algoritmos de otimização de hiperparâmetros, a fim de encontrar melhores resultados em menores tempos, visto o tamanho das bases utilizadas nesse estudo. Além disso, existe espaço para evolução no tratamento e armazenamento dos dados, com a utilização de bibliotecas como o DuckDB, que permite a criação de bancos de dados locais e possibilita a utilização da linguagem SQL para consultas mais eficientes.

## REFERÊNCIAS

[1] Empresa de Pesquisa Energética [EPE]. (2021). Instruções para Solicitação de Cadastramento e Habilitação Técnica com vistas à Participação nos Leilões de Energia Elétrica. Acesso em 10 de jul. de 2024. Disponível em:

[https://www.epe.gov.br/sites-pt/leiloes-de-energia/Documents/EPE-DEE-017\\_2009\\_R17\\_EOL.pdf](https://www.epe.gov.br/sites-pt/leiloes-de-energia/Documents/EPE-DEE-017_2009_R17_EOL.pdf)

[2] Databricks. (24 de Março de 2022). What is Apache Parquet? Acesso em 10 de jul. de 2024, disponível em Parquet: <https://www.databricks.com/glossary/what-is-parquet>

[3] MENDIS, P., NGO, T., HARITOS, N., HIRA, A., SAMALI, B., & CHEUNG., J. (2007). Wind Loading on Tall Buildings. *Electronic Journal of Structural Engineering*, pp. 41-54. Acesso em 10 de jul. de 2024, disponível em <https://ejsei.com/EJSE/article/view/64>

[4] Scikit-learn. (2023). Group K-Fold. Acesso em 10 de jul. de 2024, disponível em

[https://scikit-learn.org/stable/modules/cross\\_validation.html#group-k-fold](https://scikit-learn.org/stable/modules/cross_validation.html#group-k-fold)

[5] Scikit-learn. (2023). `sklearn.model_selection.RandomizedSearchCV`. Acesso em 10 de jul. de 2024, disponível em

[https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.RandomizedSearchCV.html#sklearn-model-selection-randomizedsearchcv](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.RandomizedSearchCV.html#sklearn-model-selection-randomizedsearchcv)

[6] Davis, J., & Goadrich, M. (25 de 6 de 2006). The Relationship Between Precision-Recall and ROC Curves. *ICML '06: Proceedings of the 23rd international conference on Machine learning*, pp. 233-240.

## **Análise da Geração de Energia em regiões homogêneas de Velocidade do Vento à 100m na Margem Equatorial Brasileira**

**Ana Cleide Bezerra Amorim<sup>1</sup>, Raniere Rodrigues Melo de Lima<sup>1</sup>, Leonardo de Lima Oliveira<sup>1</sup>, Sophia Victoria Santos<sup>1</sup>, Wendell Alves da Silva<sup>1</sup>, Rafael Dias Ribeiro de Almeida<sup>1</sup>, Luciano André Cruz Bezerra<sup>1</sup>, Vanessa de Almeida Dantas<sup>1</sup>, Antônio Marcos de Medeiros<sup>1</sup>**

1 Instituto SENAI de Inovação em Energias Renováveis (ISI-ER)

anaamorim@isi-er.com.br, ranierelima@isi-er.com.br, leonardooliveira@isi-er.com.br, sophiasantos@isi-er.com.br, wendellsilva@isi-er.com.br, rafaelalmeida@isi-er.com.br, luciano@isi-er.com.br, vanessadantas@isi-er.com.br, ammedeiros@isi-er.com.br

### **RESUMO**

A Margem Equatorial Brasileira (MEQ) é considerada uma região de interesse estratégico para o país. Pesquisas que envolvem o cenário offshore tem a vantagem de explorar velocidades de vento mais constantes, em contrapartida a escassez de dados de velocidade do vento na região marítima não é muito diferente da região onshore. Diante da escassez de dados in situ, as reanálises tem exercido um papel fundamental na caracterização da velocidade de vento. Assim, objetivo desta pesquisa é sinalizar áreas potencialmente homogêneas em relação a velocidade do vento à 100m de altura na MEQ, e estimar a geração de energia com dados do ERA5, de 1991 a 2020. Utilizaram-se dados das componentes meridional e zonal do vento a 100 metros do solo, a qual foi realizada a análise de agrupamento e posterior estimativa da produção anual e mensal de energia eólica offshore. O presente trabalho sintetiza a avaliação de um potencial ainda teórico, ou seja, não se aplicou critérios para a exclusão de áreas com base em limitantes técnicos, ambientais e econômicos. A região offshore ao norte do Nordeste surgiu com agrupamento para seis regiões homogêneas. A variabilidade sazonal de produção de energia foi capturada a partir dos dados do ERA5. Em resumo, a região ao norte do RN, a produção de energia elétrica média mensal varia entre 0,6 e 1,4TWh ao ano.

### **Palavras-chaves:**

Geração de Energia; Recurso Eólico; ERA5; Região Offshore;

### **ABSTRACT**

The Brazilian Equatorial Margin (MEQ) is considered a region of strategic interest for the country. Research involving the offshore scenario has the advantage of exploring more consistent wind speeds, although the scarcity of wind speed data in the maritime region is not significantly different from the onshore region. Given the scarcity of in situ data, reanalysis has played a key role in characterizing wind speeds. Therefore, the aim of this research is to identify potentially homogeneous areas in relation to wind speed at 100 meters height in the MEQ and to estimate energy production using ERA5 data from 1991 to 2020. Data from the meridional and zonal components of the wind at 100 meters above ground level were used for cluster analysis and subsequent estimation of annual and monthly offshore wind energy production. This study summarizes the assessment of a still theoretical potential, meaning that no criteria were applied to exclude areas based on technical, environmental, and economic limitations. The offshore region north of the Northeast emerged with six homogeneous regions. The seasonal variability of energy production was captured from ERA5 data. In summary, in the region north of RN, average monthly electricity production varies between 0.6 and 1.4 TWh per year.

### **Keywords:**

Energy Production; Wind Resource, ERA5; Offshore Region

## **1. INTRODUÇÃO**

A Margem Equatorial Brasileira (MEB) emerge como uma região estratégica para o desenvolvimento eólico offshore, dado seu grande litoral e diversidade de características fisiográficas e climáticas. A presença de sistemas atmosféricos como a Zona de Convergência Intertropical (ZCIT) e as

circulações termicamente induzidas geram um contexto favorável para a geração de energia eólica, com ventos potenciais que podem ser explorados.

As discussões em torno da regulamentação e do licenciamento ambiental para a energia eólica offshore são fundamentais para garantir um desenvolvimento ordenado e sustentável do setor. Um marco regulatório claro pode facilitar a implementação de projetos, proporcionando segurança jurídica e atratividade para investidores. Além disso, a exploração de energia eólica offshore pode trazer benefícios econômicos e sociais significativos para as regiões costeiras, contribuindo para a diversificação da matriz energética do Brasil, criando empregos e impulsionando a economia local.

É essencial que, à medida que o Brasil avança na implementação da energia eólica offshore, haja um cuidado especial com os impactos ambientais e sociais, promovendo um diálogo contínuo entre as partes interessadas e garantindo a participação das comunidades locais nos planos de desenvolvimento. A combinação de tecnologia, regulamentação apropriada e consideração das especificidades locais poderá posicionar o Brasil como um líder no aproveitamento da energia eólica no cenário global.

A MEB é considerada uma região de interesse estratégico para o país. Sua posição geográfica está inserida no contexto das Bacias Sedimentares de exploração petrolífera: Foz do Amazonas, Pará-Maranhão/Barreirinhas e Potiguar, e as recentes descobertas de óleos leves, indicam grande potencial exploratório. Isso leva à inserção de novas fontes renováveis de energias para suprir o desenvolvimento da atividade industrial e tecnológica desta região.

Estados como Rio Grande do Norte, Ceará, Piauí possuem excelentes potencialidades para instalação das usinas eólicas offshore, considerando nesse contexto, a grande quantidade de solicitações junto ao IBAMA para a instalação de usinas em mar e estudos prévios realizados pela Equipe do ISI-ER em projetos de P&D ANEEL. No que se refere a energia eólica, esta fonte está crescendo vertiginosamente nos últimos anos. Toda a cadeia tecnológica com os preços envolvidos a tornam mais competitivas em diversos mercados (GWE, 2018). A fonte eólica vem exercendo um papel importante na transição energética global, se mostrando limpa, confiável e financeiramente competitiva.

Pesquisas que envolvem o cenário offshore tem a vantagem de explorar velocidades de vento mais constantes, em contrapartida a escassez de dados de velocidade do vento na região marítima não é muito diferente da região onshore. A grande dificuldade e limitação que envolve a pesquisa científica está na ausência de dados. Dados observacionais de velocidade do vento em diferentes níveis são raros, e só são obtidos quando existem estações anemométricas automáticas. No entanto, ainda existem inúmeros problemas em relação aos dados in situ, os desafios técnicos e altos custos à realização de projetos de medição (GALVÃO et al., 2023) são exemplos dessa dificuldade.

Diante da escassez de dados in situ, os dados de reanálises tem exercido um papel fundamental na caracterização da velocidade de vento (GRUBER et al., 2022; FREITAS et al., 2023; REIS et al., 2023). No Brasil, existem vários estudos utilizando dados de diferentes fontes, MERRA e ERA5 são exemplos de uso no território brasileiro para avaliar os recursos eólicos (SIEFERT et al., 2022; REIS et al., 2023). Se tratando em área offshore, a escassez se torna ainda mais acentuada. Outra limitação é referente aos dados em diferentes alturas, as estações meteorológicas na região onshore, quando disponibilizam, são dados referentes à 10 m de altura. Desta forma, as reanálises climáticas tornam-se produtos de grande importância para comunidade científica (HERSBACH et al., 2020) em termos de cobertura temporal e espacial. Os dados de velocidade do vento são disponibilizados em escala horária para todo o globo.

Os dados secundários são essenciais para avaliar a viabilidade técnica e econômica de um projeto eólico antes de realizar investimentos significativos. Permitem reduzir os riscos associados à incerteza do recurso eólico, garantindo que as previsões de geração de energia mais próximas da realidade. Apesar da limitação dos dados de reanálises, o uso de dados secundários é uma prática essencial e sofisticada no setor de energia eólica, permitindo uma análise detalhada do potencial de vento em diferentes localizações e diferentes alturas, e tem contribuído para o desenvolvimento sustentável de projetos energéticos renováveis.

Desta forma, o objetivo desta pesquisa é sinalizar áreas potencialmente homogêneas em relação a velocidade do vento à 100m de altura na Marquem Equatorial Brasileira, e estimar a geração de energia dessas regiões com dados do ERA5, de 1991 a 2020.

## 2. ESTADO DA ARTE/ FUNDAMENTAÇÃO TEÓRICA

O Brasil é um grande produtor de energia renovável, e a energia hidráulica é a principal fonte. O país possui vastos recursos hídricos e várias usinas hidrelétricas, sendo a Usina de Itaipu, que faz divisa entre Brasil e Paraguai, uma das maiores do mundo em capacidade instalada. Além da energia hidráulica, o Brasil também tem investido em outras fontes renováveis, como a energia eólica e solar, que têm crescido significativamente nos últimos anos. Esses investimentos têm contribuído para a diversificação da matriz energética e para a redução da dependência de fontes fósseis.

Existe um indicativo desde a década de 2000 que energia eólica pode ser complementar à energia hidroelétrica, uma vez que existe uma sazonalidade entre as duas fontes no território brasileiro. Estudos apontam que em anos secos, como os observados nos últimos anos, a eólica offshore pode trazer uma proteção energética (WORLD BANK GROUP, 2024). Na década de 2000, essa complementaridade sazonal entre o regime de ventos e os fluxos hidrológicos nos reservatórios hidrelétricos já tinha sido discutida, no entanto esse programa não obteve resultados. Em seguida, o Programa de Incentivo às Fontes Alternativas de Energia Elétrica, o PROINFA, foi quem abriu caminho para a fixação da indústria do setor eólico no país (MAUAD *et al.*, 2017).

Nos últimos anos, o Brasil se tornou um dos líderes em energia eólica na América Latina, com grandes parques eólicos sendo implantados principalmente na região Nordeste, onde as condições de vento são favoráveis. O país tem experimentado um crescimento robusto na capacidade instalada, tornando-se uma parte relevante da matriz energética nacional, contribuindo para a diversificação das fontes de energia e para a redução das emissões de gases de efeito estufa. Dessa forma, a trajetória da energia eólica no Brasil reflete não apenas avanços tecnológicos, mas também um comprometimento crescente com fontes de energia renovável e sustentável nos esforços para atender à demanda crescente por eletricidade e mitigar as mudanças climáticas.

## 3. MÉTODO DO ESTUDO

### 3.1 Dados

Utilizaram-se dados das componentes meridional e zonal do vento ( $m.s^{-1}$ ) a 100 metros do solo, da quinta e mais recente geração do European Centre for Medium-Range Weather Forecasts -ECMWF (HERSBACH e DEE, 2016), para toda região da MEQ (Figura 1). Em relação a versão anterior, ERA-Interim (DEE *et al.*, 2011), houve significativas melhorias na resolução espacial, temporal e vertical, principalmente as alterações no cálculo de parâmetros atmosféricos devido à mudança no sistema de assimilação do IFS Cycle31r2 para o IFS Cycle41r2. A partir de 2020, os dados do ERA5 são disponibilizados do período de 1950 até o presente, com atualizações diárias, no entanto com atraso de 5 dias. A resolução espacial é de  $0.25^\circ \times 0.25^\circ$  e resolução temporal horária compreende o período de 01 de janeiro de 1991 a 31 de dezembro de 2021. Os dados estão disponíveis em <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-pressure-levels?tab=form>. A velocidade do vento foi calculada a partir do comando merge utilizando o Climate Data Operators (CDO). O CDO representa uma ferramenta de comandos estatísticos e aritméticos úteis para processar dados meteorológicos no formato GRIB e NetCDF (SANTOS *et al.*, 2019).

### 3.2 Métodos

Utilizou-se a análise de agrupamento para encontrar áreas homogêneas de velocidade do vento à 100 m de altura durante 1991 a 2020. A avaliação do agrupamento realizou-se a partir do gráfico de Silhueta, desenvolvida por Rousseeuw (1987) e utilizada por inúmeros autores na literatura (BERNARD *et al.*, 2013; SANTOS *et al.*, 2015; AMORIM *et al.*, 2020), em estudos na área de ciências climáticas. Em seguida, calculou-se a produção de energia para o grupo mais homogêneo da região offshore da MEQ.

#### 3.2.1 Análise de Agrupamento

A análise de cluster (AC) é uma técnica multivariada que tem como objetivo agrupar dados de acordo com as similaridades ou dissimilaridades entre eles (WILKS, 2006). Na presente pesquisa, o objetivo de usar essa técnica foi identificar regiões cujo comportamento da velocidade do vento possa ser



considerado homogêneo na Margem Equatorial Brasileira. Aplicou-se a AC aos dados de velocidade do vento à 100m para todos os pontos de grade do domínio da MEQ apresentado na Figura 1. Assim, serão construídos grupos considerando como variáveis as médias das velocidades mensais de 1991 a 2020 em cada ponto de grade.

Diferentes métodos e medidas de dissimilaridade entre os elementos a serem agrupados podem ser usados em uma análise de agrupamento. Aqui se utilizou a distância euclidiana (Equação 1), que é uma medida de dissimilaridade entre as diferentes variáveis comumente usadas em aplicações da AC em dados meteorológicos.

$$d_{i,j} = \left[ \sum_{k=1}^k W_k (X_{i,k} - X_{j,k})^2 \right]^{1/2} \quad (1)$$

em que  $X_{i,k}$  e  $X_{j,k}$  são as séries temporais para cada ponto de grade comparados dentro do grupo  $k$ ;  $W_k = 1, \dots, k$  é um fator de ponderação e os índices  $i$  e  $j$  representam os pontos de grade do grupo.

Além da medida de dissimilaridade é preciso definir o método de agrupamento. Neste caso, utilizou-se o método hierárquico de variância mínima de Ward, que é um método aglomerativo (MINGOTI, 2005). O método de Ward é baseado na partição da Soma de Quadrados Total (SQT) de uma análise de variância. A soma dos quadrados dentro do grupo é utilizada como medida de homogeneidade; portanto, esse método tenta minimizar a soma de quadrados dentro do grupo. Esta técnica equivale a buscar o mínimo desvio padrão entre os dados de cada grupo e definida segundo a Equação 2.

$$W = \sum_{g=1}^G \sum_{i=1}^{n_g} \|X_i - \bar{X}_g\|^2 = \sum_{g=1}^G \sum_{i=1}^{n_g} \sum_{K=1}^K (X_{i,K} - \bar{X}_{g,K})^2 \quad (2)$$

sendo que  $G$  e  $g$  representam os grupos de pontos de grade;  $X_i$  é cada vetor de pontos de grade da variável  $K$ ;  $\bar{X}_g$  é a média de todos os pontos de grade do grupo  $g$  da variável  $K$ .




Figura 1 - Pontos de grade do domínio do Margem Equatorial Brasileira utilizados na Análise de agrupamento.

Após as formações dos grupos é comum a utilização do gráfico de Silhueta (Rousseeuw, 1986) para avaliar a partição de cada agrupamento. As informações do gráfico serão ilustradas em Tabela para a discussão dos resultados. A Silhueta é a média do valor do contorno de cada observação. Observações bem agregadas possuem valores próximos de 1 e observações mal agregadas, valores próximos de -1.

O valor da Silhueta do objeto  $X_i$  (cada observação) é calculado por:

$$S(X_i) = \frac{b(X_i) - a(X_i)}{\max\{a(X_i), b(X_i)\}} \quad (3)$$

Em que  $a(X_i)$  é o comprimento médio de todas as distâncias dentro do mesmo grupo e  $b(X_i)$  é comprimento médio de todas as distâncias das observações do grupo mais próximo.

A qualidade total do aglomerado pode ser calculada pelo coeficiente de silhueta médio pela equação:

$$\bar{S} = \frac{\sum_{i=1}^N S(X_i)}{N} \quad (4)$$

em que  $N$  é o número total de pontos de grade, que neste trabalho envolveu um total de 4292.

### 3.2.2 Estimativa da produção anual de energia eólica offshore

A metodologia adotada para a estimativa da produção de energia levou em consideração a utilização de parâmetros referenciados pela exploração da fonte eólica no Nordeste do Brasil, onde se buscou ponderar sobre as condições de ocorrências dos ventos e, conseqüentemente a adoção de premissas mais ajustadas ao contexto da área de interesse. As simulações foram realizadas na MEQ para uma distância máxima de 300km em relação a linha de costa e restringindo-se a uma faixa que se estende do estado do Rio Grande do Norte a uma parcela do Maranhão, cobrindo aproximadamente 251.400km<sup>2</sup>.

O cálculo da geração de energia elétrica a partir da fonte eólica offshore avaliou como ponto de partida os aspectos geométricos dos layouts praticados pelos parques eólicos cadastrados, para fins de licenciamento, na base de dados do IBAMA. Analisando os 97 projetos, verifica-se em média uma disposição com espaçamento lateral de  $\approx 1,5$ km e frontal de  $\approx 2,89$ km. Em termos de potência unitária das turbinas é observado que cerca de 52% dos referidos projetos utilizam aerogeradores com potência nominal de 15MW. No sentido de representar essa configuração em um contexto local foi adotada como referência a turbina desenvolvida pelo National Renewable Energy Laboratory (NREL) e a Technical University of Denmark (DTU) através da International Energy Agency (IEA), cuja especificação está apresentada na Tabela 2 e a curva de potência através da Figura 2. Utilizando a informação sobre o diâmetro do rotor, o espaçamento típico, com base nas ocorrências dos projetos com turbinas de mesma potência nominal em cenário nacional, lateral de 6D e frontal 12D. As premissas de indisponibilidade seguem conforme os valores fornecidos por ISI-ER (2022): indisponibilidade em função da rede, aerogerador e manutenção em 5%; perdas elétricas até o ponto de conexão de 3 a 4,5%, perdas por degradação de pás e desempenho de 2%; perdas aerodinâmicas em 8%.

Tabela 2 - Especificações da turbina eólica offshore IEA 15 MW

Potência Nominal	15 MW
Altura de Hub	150 m
Velocidade de vento mínima corte	3 m/s
Velocidade de vento máxima corte	23 m/s
Diâmetro do Rotor	242 m
Área varrida pelas pás	45996 m <sup>2</sup>

Fonte: <https://nrel.github.io/turbine-models/>




Figura 2 - Curva de potência do aerogerador de referência (IEA 15 MW).

Fonte: <https://nrel.github.io/turbine-models/>

Na estimativa da geração de energia foi aplicada a correção da curva de potência indicada na Figura 2, considerando que a avaliação foi realizada em uma área relativamente extensa sobre o oceano, em que a variação da densidade do ar para a altura de referência pode ser observada. Os dados georreferenciados são disponibilizados pela plataforma Global Wind Atlas (DAVIS *et. al*, 2023) que, para a abrangência da área de estudo, resultou em valores da densidade do ar com média de 1,149kg/m<sup>3</sup>, máximo de 1,153kgm<sup>3</sup> e mínimo de 1,141kgm<sup>3</sup>.

Cabe ressaltar que na metodologia de integração do cálculo da geração de energia, toda a região foi considerada como susceptível ao desenvolvimento, ou seja, não se aplicou critérios para a exclusão de áreas com base em limitantes técnicos, ambientais e econômicos. Nesse sentido é plausível concordar que a abordagem adotada pelo presente trabalho sintetiza a avaliação de um potencial ainda teórico.

A partir de recursos computacionais, técnicas de geoprocessamento e uso de bibliotecas em linguagem de programação Python, a série histórica dos valores de direção dos ventos foi investigada em termos de frequência de ocorrência. Os resultados foram padronizados em direções predominantes seguindo o referencial da rosa dos ventos segmentada em doze subsetores. A partir dessa definição, cada célula passa a receber uma grade regular com espaçamento lateral de 6D (1.452 m) e frontal de 12D (2.904 m) cuja orientação/alinhamento é função da direção predominante dos ventos. A Figura 3 mostra o fluxo de processos que sintetiza a metodologia pertinente ao cálculo da geração de energia elétrica a partir da fonte eólica na área de estudo.

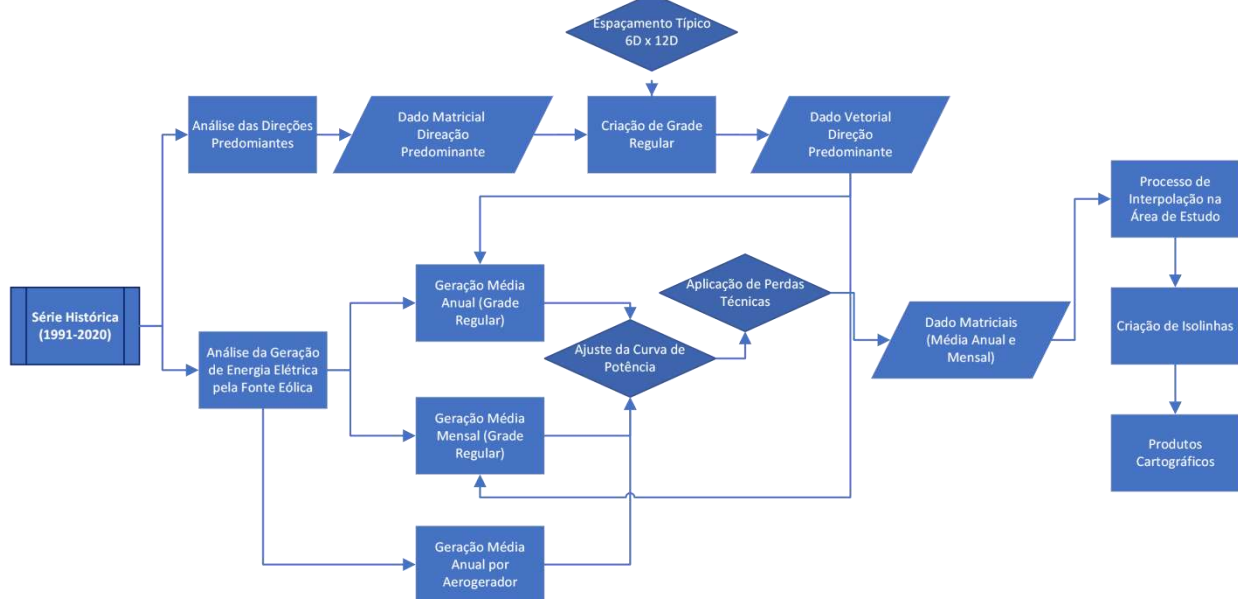


Figura 3 – Representação do fluxo de processos no cálculo da geração de energia elétrica. Fonte: Instituto SENAI de Inovação em Energias Renováveis - ISI-ER.

## 5. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Os resultados partiram da análise de agrupamento sugerindo seis áreas homogêneas (Figura 4 C) para o MEQ. Em seguida, aplicaram-se cálculos para geração de energia para a área com velocidade do vento considerada mais homogênea.

### 5.1 Análise de Agrupamento

A análise de agrupamento se iniciou a partir de quatro regiões homogêneas (Figura 4A). A região offshore ao norte do NEB (Figura 4D), consistente com áreas que já possuem potencial para instalação de usinas eólicas offshore (WORLD BANK GROUP, 2024), surgiu com agrupamento para seis regiões homogêneas (Figura 4C). Os resultados obtidos a partir da análise de qualidade dos agrupamentos mostram que os coeficientes médios de Silhueta (S) tendem a diminuir conforme a quantidade de grupos aumenta, conforme indicado na Tabela 1. Essa tendência é um padrão frequentemente discutido na literatura (Santos et al., 2015; Amorim et al., 2020). Apesar dessa diminuição, os valores de Silhueta se mantêm positivos, variando entre 0,45 e 0,50, o que sugere uma boa qualidade dos grupos formados.

Entre os agrupamentos com quatro e cinco áreas homogêneas (G4 e G5), a mudança é no grupo que envolve a região onshore. No G4, a região onshore que compõe o grupo C1 possui um coeficiente de silhueta  $S(X_i)$  de 0,60, indicando uma forte homogeneidade dentro desse agrupamento. Ao passar para o G5, a divisão do grupo C1 em dois novos grupos (C1 e C1\*) resulta em coeficientes menores, sugerindo uma diminuição na homogeneidade. No entanto, mesmo com a redução, os novos grupos ainda mantêm características distintas.

As outras áreas homogêneas (C2, C3 e C4) permanecem consistentes entre os agrupamentos G4 e G5, o que sugere que as características dessas regiões não foram suficientemente afetadas pela divisão do grupo C1. O grupo C2 é descrito como litorâneo, abrangendo estados como Pará, Maranhão, Piauí, Ceará e parte do Rio Grande do Norte. O C3 é relacionado à presença da Zona de Convergência Intertropical (ZCIT), e o C4 está localizado no extremo norte da área estudada.

No G6, ocorre uma nova divisão com o surgimento da região offshore do norte do Nordeste brasileiro. O grupo C2\* nesse novo agrupamento apresenta um coeficiente de silhueta individual de 0,63, que é considerado o maior entre todos os grupos do G6, onde a média dos coeficientes é de 0,45. Isso indica que a homogeneidade do C2\* é superior aos dos demais grupos, evidenciando uma estrutura

espacial mais coesa na região offshore em comparação aos demais grupos. Essa análise de agrupamentos e a avaliação dos coeficientes de silhueta são importantes para compreender a organização espacial das áreas e suas características homogêneas.

**Tabela 1 – Análise da qualidade total do aglomerado dado pelo Coeficiente de Silhueta médio e a qualidade dos grupos individuais.**

Grupos	$S(X_i)$		
	G4	G5	G6
C1	0,60	0,56	0,56
C1*	-	0,39	0,38
C2	0,34	0,33	0,18
C2*	-	-	0,63
C3	0,44	0,43	0,38
C4	0,55	0,55	0,55
$\bar{S}$	0,5	0,47	0,45

## 5.2 Ciclo anual da velocidade do vento dos grupos

A descrição da Figura 5 fornece uma visão detalhada do ciclo anual da velocidade do vento em diferentes regiões homogêneas da MEQ. Na Figura 5A é possível observar o ciclo anual da velocidade do vento offshore da região equatorial, representados pelos grupos C4 e C2 que enfraquecem e intensificam de maneira inversas ao longo do ano, além do grupo C3 que indica a presença da ZCIT.

Na região equatorial, os grupos C4 e C2 estão associados aos ventos alísios de nordeste e sudeste, respectivamente. Observou-se que os alísios de nordeste (C4) são mais fracos durante os meses de inverno e primavera austral, enquanto se intensificam no verão e outono. Em contraste, os alísios de sudeste (C2) apresentam um padrão inverso, com ventos mais fortes de junho a novembro e uma redução de intensidade nos meses restantes.

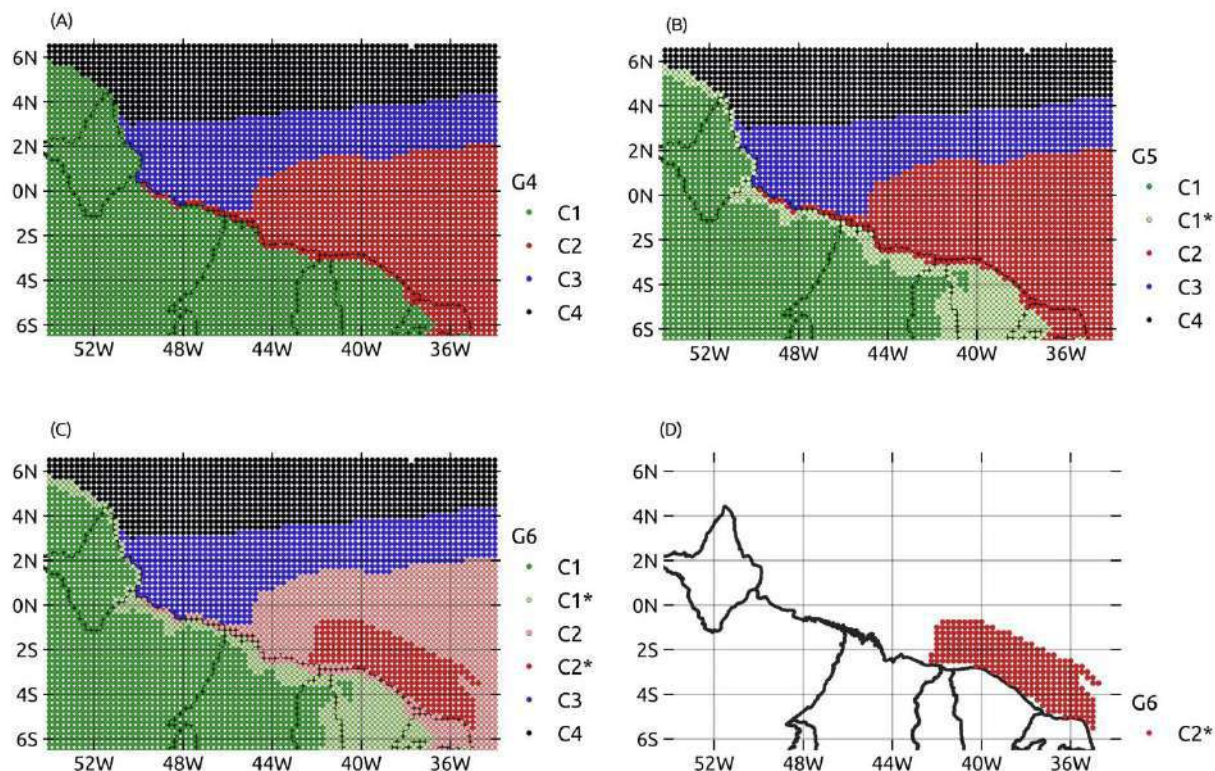


Figura 4 - Resultados da análise de agrupamento da Velocidade do vento a 100m na Margem Equatorial Brasileira com dados do ERA5, de 1991 a 2020: A) quatro, B) cinco e C) seis áreas homogêneas; D) grupo mais homogêneo da região offshore.

O grupo C3 corresponde à Zona de Convergência Intertropical (ZCIT), onde ocorre a interseção dos ventos alísios. Neste grupo, a velocidade do vento demonstra pouca variação ao longo do ano, indicando uma região do encontro entre os alísios.

Por outro lado, os grupos onshore (C1 e C1\*, Figura 5B), que se localizam em grande parte em regiões continentais próximas à costa, exibem baixa variabilidade na velocidade do vento a partir de 100 metros de altura. No entanto, eles apresentam um comportamento anual similar ao do grupo C2, refletindo as características dos ventos alísios no Norte e Nordeste do Brasil. O grupo C2\* (Figura 5C), em particular, destaca-se, mostrando velocidades de vento em torno de 6 m/s apenas em fevereiro e março, enquanto nos demais meses a velocidade média ultrapassa 7 m/s, atingindo picos superiores a 10 m/s em agosto, setembro e outubro.

Esse comportamento dos ventos tem implicações importantes para a climatologia regional, em especial a geração de energia eólica. A partir do mapeamento do recurso eólico é possível calcular a produção de energia, utilizando curvas de potência disponibilizadas, publicamente, de turbinas eólicas idealizadas, com desempenho próximo aos aerogeradores comercialmente disponíveis.

### 5.3 Produção de energia eólica offshore

A geração de energia eólica foi estimada a partir dos dados de velocidade do vento à 100 m, considerando um período de 30 anos apenas para área do grupo C2\*. A Figura 6, além de ilustrar a geração anual de energia eólica por aerogerador (em GWh), também traz a direção predominante do vento na área estudada, caracterizando a influência dos ventos alísios de leste/sudeste em toda região de estudo.

Ainda na Figura 6 é possível observar que região em análise apresenta geração de energia acima de 55 GWh/ano, se destacando dois núcleos com valores acima de 65 GWh na costa do Maranhão, parte do Ceará e Rio Grande do Norte (RN). O máximo de geração de energia eólica encontra-se na costa do RN, ultrapassando os 75 GWh/ano por aerogerador. Os resultados confirmam a disposição privilegiada do

estado, para a energia eólica offshore, no qual o estado ocupa a primeira posição no ranking nacional de geração eólica.

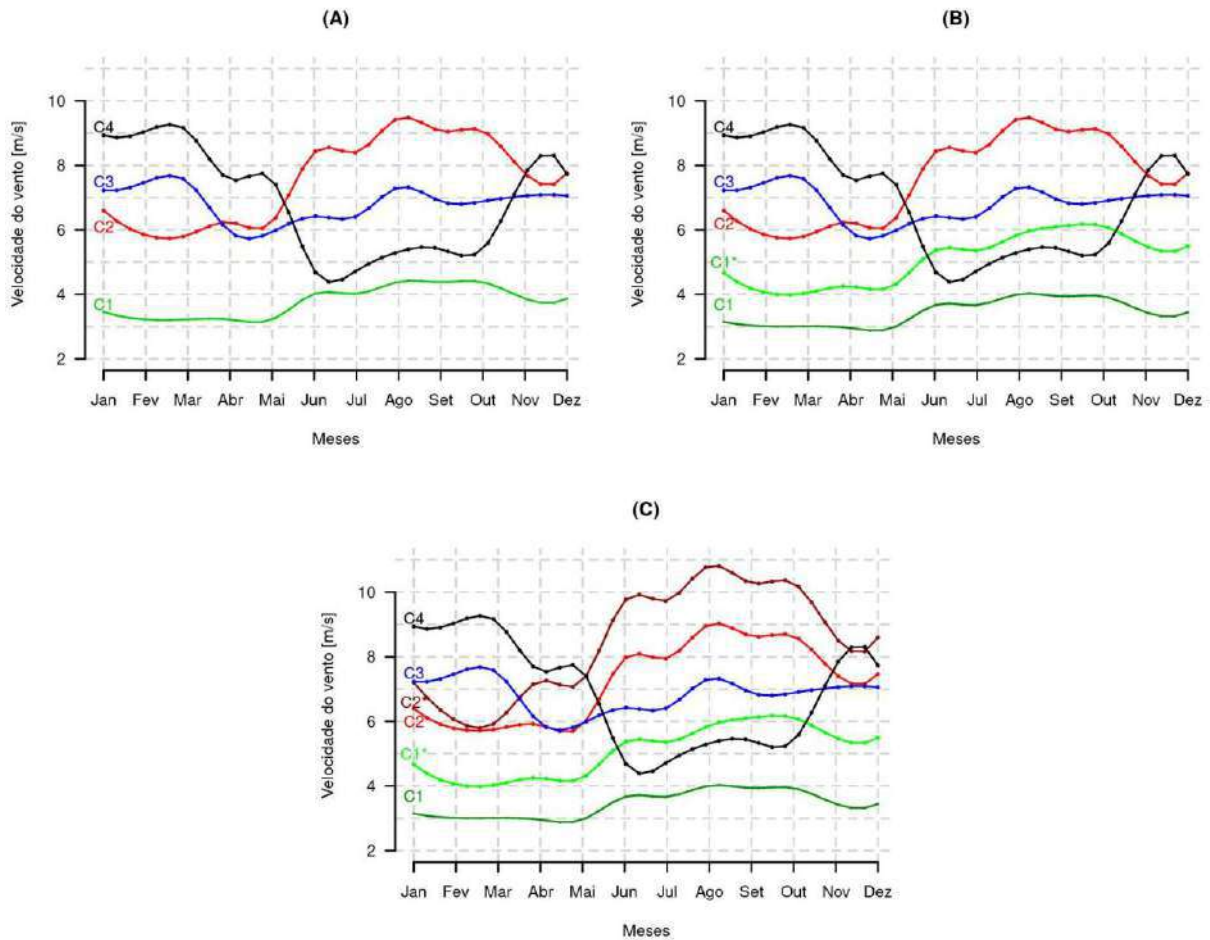


Figura 5 – Ciclo anual da velocidade média do vento [m/s] à 100m de altura do solo em cada grupo da Margem Equatorial Brasileira, com dados entre 1991 e 2020.

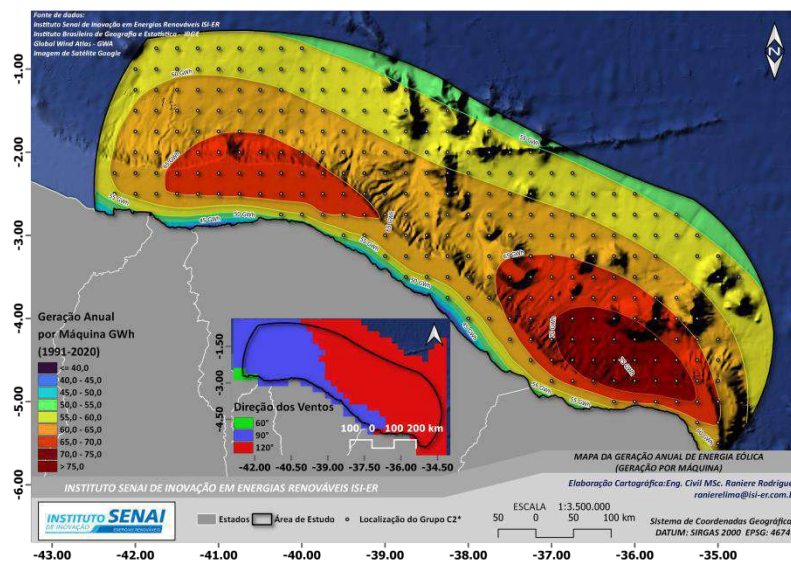


Figura 6 - Geração anual de energia eólica [GWh] por aerogerador para o grupo C2\*. Fonte: Instituto SENAI de Inovação em Energias Renováveis - ISI-ER.

A Figura 7 traz a geração anual de energia eólica (em GWh) considerando a quantidade de aerogeradores que foi definida pela grade regular, mediante o espaçamento típico adotado na direção predominante para preencher toda a região. É possível verificar a distribuição espacial semelhante ao que foi considerado por aerogerador, no entanto em termos de produção de energia, tem-se um valor estimado superior a 10TWh/ano em toda região, e dois núcleos de 12 TWh/ano e ao norte do RN encontra-se uma região de 13TWh/ano.

A variabilidade sazonal de produção de energia também foi capturada a partir dos dados de velocidade do vento do ERA5. Os resultados são exibidos na Figura 8, em que são observadas as médias mensais de geração de energia para o período de 30 anos.

Mesmo no mês de menor produção de energia (março com média de  $\approx 400$ GWh), a região ao norte do RN se apresenta com maior valor de produção da região estudada, trazendo valores de 600 GWh em março e abril. Em maio, a produção aumenta para 900 GWh e ultrapassa 1 TWh no mês de junho. A partir do segundo semestre (julho em diante), quase toda a região de C2\* apresenta valores de produção superiores a 1,3 TWh, e em agosto e setembro o valor 1,4TWh predomina em toda a região. A região que estava produzindo 1,4 TWh começa a diminuir, mas ainda mantém uma distribuição espacial significativa. Em novembro e dezembro, ainda existem dois núcleos de máxima produção de energia, com valores variando entre 1,3 TWh e 1,1 TWh. Essa análise indica variações sazonais na produção de energia ao longo do ano, com picos observados de julho e uma tendência de queda em dezembro, com variações espaciais significativas entre o primeiro e o segundo semestre. Considerando toda a área de estudo, os meses de agosto e setembro possuem média 3,5 vez maior em relação ao mês de março. Em termos objetivos, a região ao norte do RN, a produção de energia elétrica média mensal varia entre 0,6 e 1,4TWh.

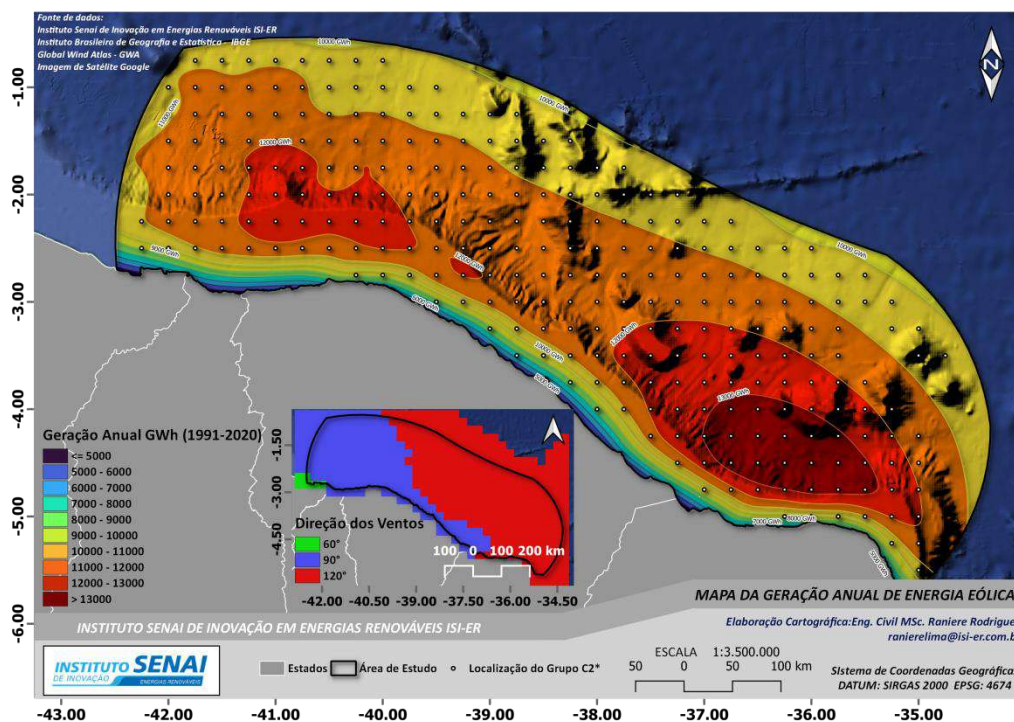


Figura 7 - Geração anual de energia eólica [GWh] para o grupo C2\*. Fonte: Instituto SENAI de Inovação em Energias Renováveis ISI-ER.



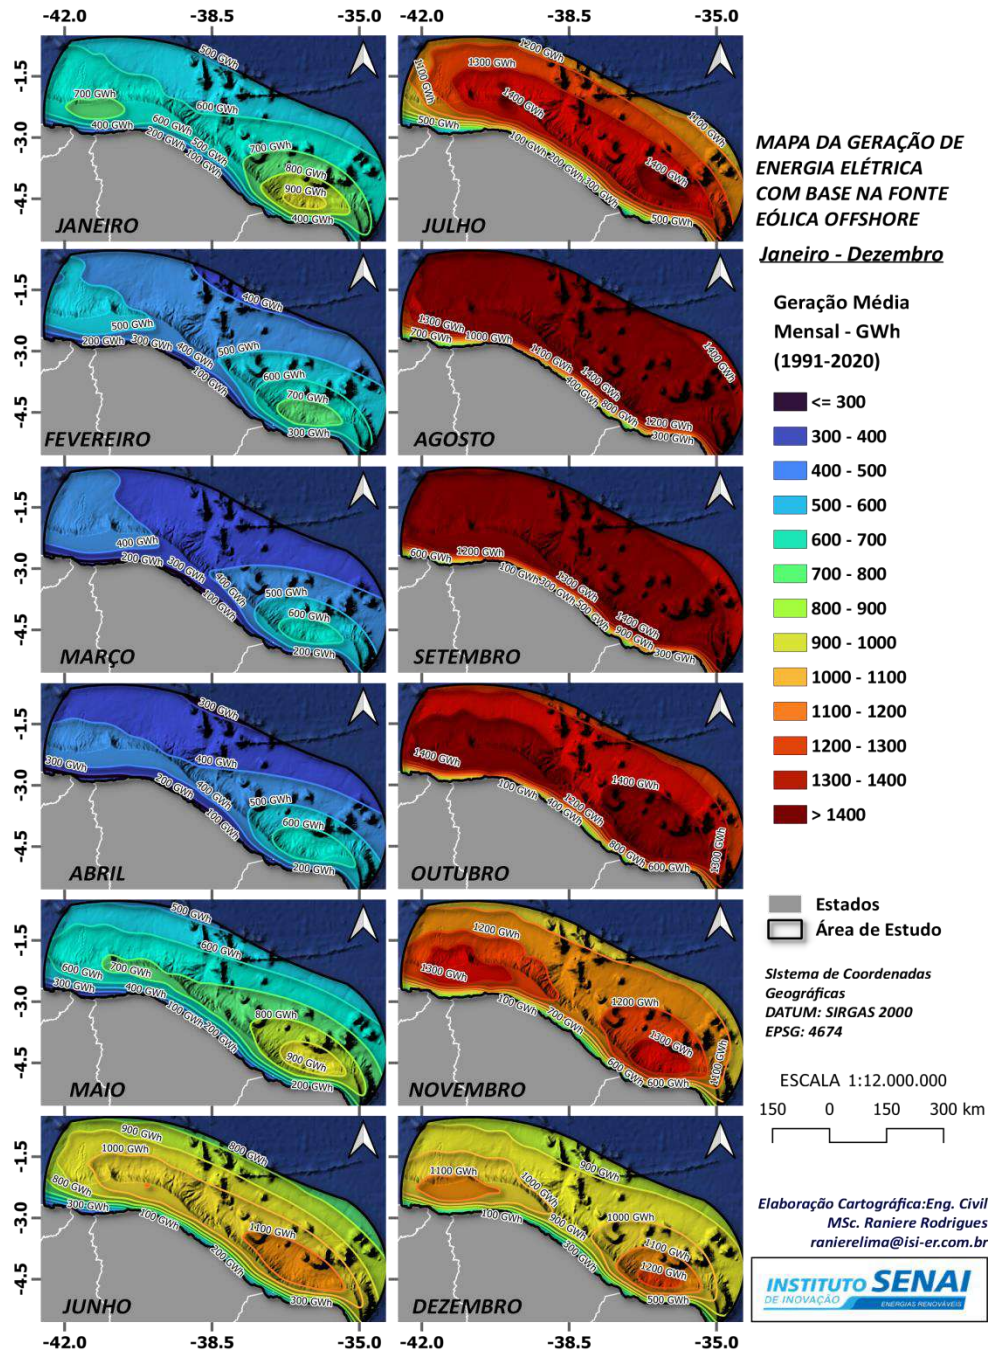


Figura 8 – Geração de energia média mensal [GWh] para 100 m de altura do solo, entre 1991 e 2020.  
Fonte: Instituto SENAI de Inovação em Energias Renováveis ISI-ER

## 6. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

A avaliação da geração de energia eólica utilizando dados da reanálise ERA5 tem sido uma abordagem eficaz para entender o potencial eólico de uma região. Os dados da ERA5, que fornecem informações climáticas e meteorológicas, possibilitaram uma análise detalhada das características do vento, fundamentais para o desenvolvimento de projetos eólicos.

As áreas homogêneas identificadas pela análise de agrupamento podem ser essenciais para o planejamento e desenvolvimento de projetos de energia eólica, pois permitem direcionar investimentos e esforços de forma mais eficaz. A identificação de áreas com características semelhantes à velocidade do

vento sugere um padrão que pode ser explorado para maximizar a eficiência das turbinas eólicas instaladas. Além disso, a consistência dos resultados com a literatura existente sobre recursos eólicos na região reforça a confiabilidade dos resultados obtidos. Isso é relevante não só para investidores e desenvolvedores de projetos, mas também para formuladores de políticas, que podem utilizar essas informações para criar um ambiente regulatório favorável ao desenvolvimento de energia renovável.

A informação sobre a variabilidade espacial da velocidade do vento também aponta para a necessidade de estudos adicionais, como medições de campo e modelagens mais detalhadas, para uma compreensão mais profunda do potencial energético e seus impactos ambientais e sociais. Essa abordagem será fundamental para garantir que o desenvolvimento da energia eólica na região seja sustentável e eficiente, contribuindo para a matriz energética e para a mitigação das mudanças climáticas.

Em resumo, a utilização de dados de reanálise, como os do ERA5, é uma ferramenta poderosa para a caracterização do potencial eólico e pode fornecer subsídios para a tomada de decisão em projetos de energia eólica, especialmente em áreas com grande potencial como a região offshore do Nordeste do Brasil.

## REFERÊNCIAS

AMORIM, A. C. B.; LÚCIO, P. S.; SANTOS E SILVA, C. M.; RODRIGUES, D. T.; BRITO NETO, F. A. Regionalização e Análise da Tendência da Precipitação do Rio Grande do Norte Associados a Padrões de TSM. *Revista Brasileira de Meteorologia*, v. 35, n. 2, 269 – 280, 2020. DOI <http://dx.doi.org/10.1590/0102-7786352024>

BERNARD, E.; NAVEAU, P.; VRAC, M.; MESTRE, O. Clustering of maxima: Spatial dependencies among heavy rainfall in France. *Journal of Climate*, v. 26, n. 20, p. 7929- 7937, 2013.

DAVIS, N. N., et al. The Global Wind Atlas: A high-resolution dataset of climatologies and associated web-based application. *Bulletin of the American Meteorological Society*, 104(8), E1507-E1525, 2023. <https://doi.org/10.1175/BAMS-D-21-0075.1>

DEE, D.P. et al. The ERA Interim reanalysis: configuration and performance of the data assimilation system. *Quarterly Journal of the Royal Meteorological Society*, v. 137, n. 1, p. 553-597, 2011.

FREITAS, I. G. F. et al. Avaliação da Velocidade do Vento Utilizando Hindcast Desenvolvido pela Climatempo para a Aplicação dos Recursos Eólicos no Brasil. In: *Brazil Windpower 2023 Conference and Exhibition*. 2023. p. 28-39.

FREITAS, I. G. F. et al. Evaluation of Wind and Wave Estimates from CMEMS Reanalysis for Brazil's Offshore Energy Resource Assessment. *Wind*, v. 2, n. 3, p. 586-598, 2022.

GALVÃO, Luiz Claudio Ribeiro et al. Análise procedimental da energia contida no recurso do vento verificada através de tecnologias consolidadas de geração eólica. In: *Brazil Windpower 2019 Conference and Exhibition*. 2019. p. 1-12.

GWE, Global Wind Report: Annual Market Update 2017. GWEC/Global Wind Energy Council, 2018.

HERSBACH, H.; DEE, D. J. E. N. ERA5 reanalysis is in production. *ECMWF newsletter*, v. 147, n. 7, p. 5-6, 2016.

Instituto SENAI de Inovação – Energias Renováveis (ISI-ER). Atlas Eólico e Solar do estado do Rio Grande do Norte, Governo do Estado do Rio Grande do Norte, SEDEC, COORDENADORIA DE DESENVOLVIMENTO ENERGÉTICO, Natal, 2022.

JONKMAN, J.; BUTTERFIELD, S.; MUSIAL, W.; SCOTT, G. Definition of a 5-MW Reference Wind Turbine for Offshore System Development; National Renewable Energy Lab. (NREL): Golden, CO, USA, 2009.

MAUAD, F. F.; FERREIRA, L. C.; TRINDADE, T. C. G. Energia renovável no Brasil: análise das principais fontes energéticas renováveis brasileiras. São Carlos: EESC/USP, 2017.

MINGOTI, S. A. Análise de dados de métodos de estatística multivariada: uma abordagem aplicada. Belo Horizonte: Editora UFMG, 297 p, 2005.

---

National Renewable Energy Laboratory - NREL. Available online: <https://www.nrel.gov/about/> (accessed on 17 July 2024).

ROUSSEEUW, P.J. Silhouettes: a Graphical Aid to the Interpretation and Validation of Cluster Analysis. *Computational and Applied Mathematics*, v. 20, n. 1, p. 53-65, 1987.

SANTOS, E.B.; LUCIO, S.; SANTOS E SILVA, C.M. Seasonal Analysis of Return Periods for Maximum Daily Precipitation in the Brazilian Amazon. *Journal of Hidrometeorology*, v. 16, n. 3, p. 973-984, 2015.

SANTOS, J.G.M. *Introdução ao Climate Data Operators*. Instituto Nacional de Pesquisas Espaciais - INPE, - São José dos Campos. 2019.

SIEFERT, Cesar Augusto Crovador et al. Avaliação de Séries de Velocidade do Vento de Produtos de Reanálises Climáticas para o Brasil. *Revista Brasileira de Meteorologia*, v. 36, p. 689-701, 2022.

VENTER, Z. S., BARTON, D. N., CHAKRABORTY, T., SIMENSEN, T., & SINGH, G. (2022). Global 10 m Land Use Land Cover Datasets: A Comparison of Dynamic World, World Cover and Esri Land Cover. *Remote Sensing*, 14(16), 4101.

WILKS, D.S. *Statistical methods in the atmospheric sciences*. London: Academic Press, 2006. 648 p.

WORLD BANK GROUP. *Scenarios for Offshore Wind development in Brazil*. Offshore Wind Development Program. July 2024.