



ORLANDO EDUARDO CHIPURA

**CARACTERIZAÇÃO MORFOMÉTRICA DA BACIA
HIDROGRÁFICA DO RIBEIRÃO VERMELHO E SUA
RELAÇÃO COM ÍNDICES DE EXPOSIÇÃO AO VENTO E
DESASTRES**

LAVRAS – MG

2025

ORLANDO EDUARDO CHIPURA

**CARACTERIZAÇÃO MORFOMÉTRICA DA BACIA HIDROGRÁFICA DO
RIBEIRÃO VERMELHO E SUA RELAÇÃO COM ÍNDICES DE EXPOSIÇÃO AO
VENTO E DESASTRES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para a obtenção do título de Mestre.

Prof^o. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS – MG
2025**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Chipura, Orlando Eduardo

Caracterização Morfométrica da Bacia Hidrográfica do
Ribeirão Vermelho e sua Relação com Índices de Exposição ao
Vento e Desastres /

Orlando Eduardo Chipura. – 2025.

140 p. : il.

Dissertação(mestrado acadêmico)–Universidade Federal de
Lavras, 2025.

Orientador: Prof^o. Dr. Marcelo de Carvalho Alves.

Coorientador: .

Bibliografia.

1. Geoprocessamento. 2. Séries temporais. 3. Riscos. 4.
Leste 5. Índices de proteção. I. Alves, Marcelo de Carvalho.
II. Título.

ORLANDO EDUARDO CHIPURA

**CARACTERIZAÇÃO MORFOMÉTRICA DA BACIA HIDROGRÁFICA DO
RIBEIRÃO VERMELHO E SUA RELAÇÃO COM ÍNDICES DE EXPOSIÇÃO AO
VENTO E DESASTRES**

**MORPHOMETRIC CHARACTERIZATION OF THE RIBEIRÃO VERMELHO
WATERSHED AND ITS RELATION TO WIND EXPOSURE INDICES AND
DISASTERS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, área de concentração em Sensoriamento Remoto e Geoprocessamento, para a obtenção do título de Mestre.

APROVADA em 13 de Fevereiro de 2025.

Prof^o. Dr. FORTUNATO SILVA DE MENEZES UFLA
Prof^{al}. Dr^{al}. THELMA SÁFADI UFLA
Prof^o. Dr. LUCIANO TEIXEIRA DE OLIVEIRA UFLA

Prof^o. Dr. Marcelo de Carvalho Alves
Orientador

**LAVRAS – MG
2025**

Dedicado a família. Os maiores incentivadores das realizações deste sonho. Muito obrigado!

AGRADECIMENTOS

Agradeço a Deus pela proteção e pelo dom da vida.

Ao meu orientador, Prof. Dr. Marcelo de Carvalho Alves, agradeço pela atenção, apoio acadêmico e moral, bem como pela maestria com que conduziu suas orientações ao longo da minha formação em Engenharia Agrícola.

Agradeço à minha família — Orlando Júnior, Fátima Malate, Aivy de Fátima, meus pais Rui Eduardo e Isabel Malapo de Francisco Madeira, e meus irmãos — por todas as orações nos momentos de dificuldade, pelo apoio incondicional e pela compreensão diante da distância e da ausência durante esses dois anos de mestrado.

À Universidade Federal de Lavras (UFLA), ao Prof. Dr. Fábio Lício Santos, coordenador do Programa de Pós-Graduação em Engenharia Agrícola, estendo meus sinceros agradecimentos. À coordenação no geral, aos funcionários da secretaria e à Direção de Relações Internacionais (DRI), também agradeço pelo apoio acadêmico e pela assistência prestada ao longo do mestrado.

Aos professores do Departamento de Estatística e Experimentação Agropecuária e do Departamento de Engenharia Ambiental, expresso meu reconhecimento e gratidão pelas excelentes aulas e pela valiosa contribuição à minha formação acadêmica.

Aos colegas e amigos Flávio Vanoni Júnior, Viviane Costa Silva, Bernardino Seneta, Santa Helena Suagiba, Horácio Bambo Pacule, João Zicai, Horácio Gundana, Devanir Borges, Elviss Mawoze, Taela Faustino Munguambe, Paula Cristina Xavier, Elias Sabe e Issufo Mecurão, agradeço por tudo o que aprendi com vocês, pelo apoio moral e psicológico, pelas oportunidades proporcionadas, pela amizade e por terem acompanhado minha trajetória com paciência, simplicidade, humanismo e bom humor.

Este trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e da Universidade Federal de Lavras (UFLA), instituições às quais manifesto meus profundos agradecimentos pelo financiamento concedido durante os dois anos deste mestrado.

Somos como o papel e a caneta, depende de quem nos toca.
(Elzira Cotinho)

RESUMO

Vento é uma variável climática chave e de interesse em várias aplicações, incluindo avaliações de danos à infraestrutura, riscos ambientais, socioeconômicos e é importante no aproveitamento eólico. É considerado uma variável meteorológica difícil de prever devido às dinâmicas atmosféricas e à impossibilidade de fornecer uma previsão precisa com modelos tradicionais de previsão estatística. Objetivou-se caracterizar a variação espaço-temporal de velocidade, direção, tendência e os desastres causados pelo vento ao longo da bacia hidrográfica do Ribeirão Vermelho, Estado de Minas Gerais, Brasil. Foram utilizados dados médios diários da velocidade e direção do vento da série histórica 2010 a 2023 e dados mensais do ano 2024, coletados por um anemômetro universal localizado a 10 m acima da superfície, pertencente ao Instituto Nacional de Meteorologia (INMET), disponibilizados através do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP). Com recurso a linguagem computacional R, realizaram-se testes estatísticos básicos e cálculos de frequência das direções do vento, gerando tabelas e figuras para facilitar a caracterização. Com modelos SARIMA e SARIMAX foi previsto a velocidade do vento para os primeiros três meses de 2025. Foram também determinados os índices de exposição e proteção utilizando técnicas de geoprocessamento em R, com recurso ao modelo digital de elevação, velocidade do vento ($1,83 \text{ ms}^{-1}$) e a direção predominante (Leste) para modelar os parâmetros da redistribuição do vento na região, considerando as características do relevo. A média e o teste estatístico de Mann-Kendall evidenciaram redução da velocidade do vento. A velocidade média do vento da série 2010-2023 foi $1,83 \text{ ms}^{-1}$, com uma média mensal mais baixa de $1,54 \text{ ms}^{-1}$ registrada no mês de junho e mais alta de $2,11 \text{ ms}^{-1}$ no mês de setembro. Houve uma redução significativa da velocidade do vento na época chuvosa com forte instabilidade. A direção mais predominante foi leste (31,8%). A região de estudo tem locais de baixo, moderado, alto e muito alto risco a desastres causados por ventos, conforme a variação do relevo. Contudo, em 2022 e 2023 houve um maior coeficiente de variação da velocidade do vento (100,0%), indicando que o vento se tornou mais variável e menos previsível, aumentando o risco de ocorrência de desastres causados por ventos iguais ou superiores a $5,54 \text{ ms}^{-1}$ como ocorreu no dia 27 de Setembro de 2023, afetando a região urbana de Lavras, pertencente à bacia hidrográfica do Ribeirão Vermelho. Cerca de $0,11 \text{ km}^2$ apresenta risco muito alto e $13,57 \text{ km}^2$ apresenta alto risco de ocorrência de desastre, principalmente na época chuvosa. O modelo de previsão do vento SARIMAX é indicado por ser um modelo preferido para previsão do vento em relação ao SARIMA, devido à eficiência e robustez no ajuste à série original e também apresentou menores erros de previsão.

Palavras-chave: Geoprocessamento, série temporal, riscos, leste, exposição topográfica.

ABSTRACT

Wind is a key climatic variable and is of interest in various applications, including infrastructure damage assessments, environmental and socio-economic risks, and is important in wind energy development. It is considered a meteorological element that is difficult to predict due to atmospheric dynamics and the impossibility of providing an accurate forecast with traditional statistical forecasting models. The aim of this study was to characterize the spatio-temporal variation in wind speed, direction, trend and disasters caused by wind along the Ribeirão Vermelho watershed in the state of Minas Gerais, Brazil. We used average daily wind speed and direction data from the historical series 2010 to 2023 and monthly data for the year 2024, collected by a universal anemometer located 10 m above the surface, belonging to the National Institute of Meteorology (INMET), available through the Meteorological Database for Education and Research (BDMEP). Using the R computer language, basic statistical tests and wind direction frequency calculations were carried out, generating tables and figures to facilitate characterization. SARIMA and SARIMAX models were used to forecast wind speeds for 2025. The exposure and protection indices were also determined using geoprocessing techniques in R, using the digital elevation model, wind speed (1.83 ms^{-1}) and the predominant direction (east) to model the wind redistribution parameters in the region. The average and the Mann-Kendall statistical test showed a reduction in wind speed. The average wind speed for the 2010-2023 series was 1.83 ms^{-1} , with the lowest monthly average of 1.54 ms^{-1} recorded in June and the highest of 2.11 ms^{-1} in September. There was a significant reduction in wind speed in the rainy season with strong instability, the most predominant direction being east (31.8%). The study region has locations of low, moderate, high and very high risk of disasters caused by winds, depending on the variation in relief. However, in 2022 and 2023 there was a higher coefficient of variation in wind speed (100.0%), indicating that the wind has become more variable and less predictable, increasing the risk of disasters caused by winds equal to or greater than 5.54 ms^{-1} as occurred on September 27, 2023 affecting the urban region of Lavras, belonging to the Ribeirão Vermelho watershed. Around 0.11 km^2 is at very high risk and 13.57 km^2 is at high risk of disaster, especially during the rainy season. The SARIMAX wind forecasting model is indicated as being a preferred model for wind forecasting over SARIMA, due to its efficiency and robustness in adjusting to the original series and it also showed lower forecast errors.

Keywords: Geoprocessing, time series, risks, east, protection indices.

INDICADORES DE IMPACTO

O estudo demonstra um potencial para impactar a sociedade, especialmente nas áreas de meteorologia, agrometeorologia, climatologia, gestão ambiental e gestão de ocorrência de desastres. Também destaca a compreensão dos fenômenos causadores de desastres e impactos socioeconômicos resultantes de ventos fortes na região do estudo. Portanto, o estudo tem o potencial de contribuir significativamente para o avanço da ciência meteorológica, prevenção de ocorrência de desastres, mapeamento de áreas de riscos a ventos fortes, geração de energia eólica. Fornece métodos eficazes e precisos para estudar e prever as variações climáticas em função do terreno. O estudo também pode beneficiar diversos setores, como estados, governos municipais, agricultura, aviação, ensino, energias renováveis e gestão de ocorrência de desastres naturais.

IMPACT INDICATORS

The study demonstrates the potential to impact society, especially in the areas of meteorology, agrometeorology, climatology, environmental management and disaster management. It also highlights the understanding of disaster-causing phenomena and socio-economic impacts resulting from strong winds in the study region. Therefore, the study has the potential to contribute significantly to the advancement of meteorological science, disaster prevention, mapping of high wind risk areas, wind power generation. It provides effective and accurate methods for studying and predicting climatic variations depending on the terrain. The study can also benefit various sectors, such as states, municipal governments, agriculture, aviation, education, renewable energies and natural disaster management.

SUMÁRIO

| | | |
|----------|---|-----|
| | PRIMEIRA PARTE | 11 |
| 1 | INTRODUÇÃO | 12 |
| | SEGUNDA PARTE - ARTIGOS | 14 |
| | ARTIGO 1 - Caracterização espaço-temporal da direção e velocidade do vento e sua relação com desastres | 15 |
| | ARTIGO 2 - Characterization of Wind Speed and Direction in the Ribeirão Vermelho Catchment Area and its Relationship with Disaster | 53 |
| | ARTIGO 3 - Previsão da velocidade do vento usando modelos SARIMA e SARIMAX na bacia hidrográfica do Ribeirão Vermelho - Minas Gerais | 84 |
| | ARTIGO 4 - Caracterização morfométrica da bacia hidrográfica do Ribeirão Vermelho e suas relação com índices de exposição e proteção a ventos extremos | 109 |
| 2 | CONCLUSÃO | 138 |
| | REFERÊNCIAS | 140 |

PRIMEIRA PARTE

1 INTRODUÇÃO

As características fisiográficas do Brasil são muito particulares, definidas como uma combinação de elementos naturais como relevo, clima e vegetação afetando as características climáticas e apresentam acentuados contrastes espaciais e temporais do vento (LUIZ-SILVA et al., 2021).

O vento é definido como ar em movimento (PEREIRA et al., 2002; BÖHNER; ANTONIĆ, 2009; PITZ et al., 2013; SOUZA; LIBERATO, 2019). É um recurso renovável com importância crescente no mundo contemporâneo (LIU et al., 2024). Ele é um bom regulador da temperatura urbana e do conforto térmico exterior (HE, 2022). Também é o fator mais comum de arrancamento e quebra de árvores (GODZIEK; PAWLIK, 2023; OJO; SADIKU, 2023). Pode estar associado a morte de insetos agentes da polinização, transferências de grãos de pólen. Os ventos fortes danificam muitos edifícios todos os anos e é a principal causa de falhas nas linhas de transmissão em muitas áreas do mundo (ABD-ELAAL et al., 2018).

A velocidade e direção do vento superficial é uma variável climática chave e de interesse em muitas aplicações, incluindo avaliações de danos à infraestrutura relacionados com tempestades, estudos de viabilidade de geração de energia eólica, na engenharia agrícola (CURRY et al., 2012). A caracterização dos padrões temporais e espaciais do vento são importantes para diversos setores energéticos, clima urbano e meteorologia aplicada (FILHO et al., 2022).

A natureza e o regime do vento demonstram que ela é variável (WATSON, 2014; PIMENTA et al., 2023). Essa variação é diferente em diferentes escalas temporais e no espaço, sua magnitude pode mudar drasticamente dependendo da climatologia local, localização geográfica, as características morfométricas do local, uso e ocupação dos solos (WATSON, 2014; PIMENTA et al., 2023). Podendo têm implicações numa variedade de setores como da energia eólica, da engenharia agrícola e o setor industrial (WATSON, 2014).

No entanto, a incerteza estatística associada às estimativas dos vento em terreno montanhoso é tal que os valores quantitativos da tendência não sejam fiáveis (YOUNG et al., 2012). Os autores destacam que para uma determinada série temporal, as atividades operacionais estatísticas exigirão estimativas de amplitudes extremas de vento, podendo ser ultrapassado com a análise da tendência visto que as séries apresentam valores atípicos (outliers). Assim, a compreensão de eventos climáticos extremos incluindo ventos, também requerem a compreensão das condições de superfície terrestre, para desenvolver uma visão geral do fluxo do vento (LIU et al., 2020). Assim, é um desafio integrar a variação temporal e espacial do vento nas regiões montanhosas, disponibilizar mapas para facilitar a compreensão dos avaliadores sobre riscos ambientais, socioeconômicos na agricultura. Portanto, os efeitos causados pelos ventos, o aproveitamento eólico, índices de exposição e de proteção devem ser fornecidos em mapas. A solução para o desafio possivelmente seja o uso de técnicas de sensoriamento remoto, geoprocessamento e sistema de informação geográfica da região com recurso a linguagem e um modelo digital de elevação (GODZIEK; PAWLIK, 2023).

Para se obter uma redução do número dos impactos causados pela variação da velocidade do vento e conseqüente aumento da segurança, foi necessário um estudo detalhado na série histórica, fazer previsões com vista a mitigar ou prevenir situações calamitosas.

Este trabalho teve como objetivo caracterizar a variação espaço-temporal do vento, sua tendência e os desastres a ele relacionados ao longo da bacia hidrográfica do Ribeirão Vermelho, no Estado de Minas Gerais, Brasil, buscando compreender como o relevo e o clima influenciam a dinâmica dos ventos na região. Para isso, foram analisadas séries temporais da velocidade e direção dos ventos, com vistas à identificação de tendências e à realização de previsões. A variação espacial foi descrita com base em variáveis morfométricas da bacia, utilizando-se do

índice de barlavento e sotavento, o que permitiu identificar áreas mais expostas ou protegidas em relação à ação dos ventos. Com base nesses resultados, foram destacados locais potencialmente adequados para práticas agrícolas e para a implantação de empreendimentos do agronegócio, considerando a influência dos fatores anemométricos e topográficos.

SEGUNDA PARTE - ARTIGOS

**REFERENCIAL TEÓRICO - Spatio-Temporal Characterization
of Wind and its Relation to Relief and Climate Disasters**

Redigido conforme as normas da revista *Natural Hazard* (versão submetida à revista *Advances in Space Research*).

Spatio-Temporal Characterization of Wind and its Relation to Relief and Climate Disasters

Orlando Eduardo Chipura^a, Marcelo de Carvalho Alves^{a,1}, Fortunato Silva de Menezes^b

^a*Engineering School (EENG) Agriculture Engineering Department UFLA Campus Lavras 37200-000 Brazil*
^b*Institute of Natural Sciences (ICN) Physics Department UFLA Campus Lavras 37200-000 Brazil.*

Abstract

Wind is a meteorological variable of strategic importance for several sectors, such as wind power generation, agricultural planning, civil engineering, and environmental management. However, its spatiotemporal variability remains a challenge for climate monitoring and forecasting extreme events. This article presents a systematic review of 143 scientific studies to characterize the spatiotemporal variation of wind and its relationship with relief and climate disasters. Wind speed and direction are modulated by morphometric variables, such as slope, slope orientation (aspect), altitude, and meteorological variables, such as atmospheric pressure, temperature, seasonality, and terrain roughness. Integrating radiometric data from digital elevation models (DEM) with remote sensing and geoprocessing techniques is essential for identifying areas more exposed or protected from wind action. However, the analysis of historical series using statistical models such as ARIMA and ARIMAX allows the identification of trends and seasonal patterns and forecasts future scenarios of wind speed and direction variation. From a spatial point of view, the application of the topographic exposure index, windward and leeward indices, deflection, and shelter, all derived from the relief, allow the mapping of critical risk zones and guide the rational use of the territory. However, the spatiotemporal variation of the wind is strongly dependent on morphometric variables, especially altitude, slope, and orientation of the terrain, defining zones of exposure and shelter from the prevailing wind, seasonal patterns and trends that are fundamental for climate monitoring, and territorial and agricultural planning in vulnerable regions.

Keywords:

Digital elevation model, statistical models, morphometric variables, katabatic wind, remote sensing.

1. Article Highlights

- The characterization of wind direction and temporal variation, combined with the use of statistical and geospatial models, is essential for predicting climate impacts and territorial planning in risk contexts.

*Corresponding author

Email address: marcelo.alves@uf1a.br (Marcelo de Carvalho Alves)

¹Corresponding Author

- The joint analysis of morphometric variables and meteorological data allows for the precise identification of areas of greater exposure or protection from wind, especially in regions with rugged terrain.

2. Introduction

The wind is one of the most important meteorological variables in the contemporary world Liu et al. (2020), studied globally and neglected locally (Liu et al., 2024). It is essential for various sectors, such as Agricultural Engineering, Civil Engineering, Agriculture, Economics, Wind Energy, and Ecology (Curry et al., 2012; Molaei and Lashkari, 2020; Andrade et al., 2021). The highlight of the most diverse importance is wind energy generation, which depends mainly on its speed (Curry et al., 2012; Filom et al., 2021; Correia Filho et al., 2022).

Climate is the primary mechanism controlling the nature and intensity of surface processes (Kühni and Pfiffner, 2001). According to Çetin and Meydan (2023), a place's relief refers to the diversity of elevation, aspect, orography, slope, and the most varied forms of relief (such as mountains, deep valleys, steep slopes, plains, and plateaus); all these relief characteristics influence the regional climate and can cause differences in terms of climatic development and general variation.

For Böhner and Antonić (2009), the wind field near the ground, described with direction and speed values for each point in the examined area, is significantly influenced by the Earth's surface resulting from baric differences, the differential distribution of solar radiation across the globe, and other factors such as continentality, altitude, and latitude, which directly influence the heating processes of atmospheric air masses, as explained by Dias et al. (2018) and Liria et al. (2017), becoming null at heights close to the surface (Souza et al., 2003; Martins et al., 2008; Menezes et al., 2014; Corrêa and das Graças Paula, 2017). For Vickery et al. (2023), morphometric effects are known to accelerate wind speed in mountainous or rugged terrain and, consequently, cause or increase wind-induced damage.

Studies point to wind's beneficial effects, but it is also important to highlight disasters and their impacts on the agricultural, socioeconomic, and environmental sectors; therefore, wind is a more common factor in uprooting and breaking trees and destroying infrastructure Godziek and Pawlik (2023) and Ojo and Sadiku (2023). It damages many buildings every year and is also the main cause of failures in power transmission lines and communication systems in many areas of the world (Abd-Elaal et al., 2018).

A variety of research projects can be conducted using digital elevation models (DEMs). Morphometric variables can be viewed as surrogates for factors that control the functioning of processes that cannot be readily modeled on a physical basis (Lapen and Martz, 1993; Chapman, 2000). Martz and de Jong (1991) used slope gradient, surface curvature, catchment area, and depth in a landform classification model that related soil erosion rates to landform configuration in a small agricultural prairie watershed. Pennock et al. (1987) used slope gradient and surface area to discriminate soil properties spatially in a similar landscape.

Murakami and Komine (1983) successfully predicted the regional distribution of surface wind speeds in Japan using a series of simple morphometric variables that express the relative landscape.

As wind resources are rarely consistent and vary by time, day, season, altitude, terrain, and from year to year, careful and thorough research is required Chauke et al. (2021). Thus, wind modeling and future scenario forecasting are used to investigate the identified hotspots where wind farms are viable, with due consideration to land use and topographical requirements. On the other hand, several studies suggest that spatially variable wind maps can be used to aid in the decision-making process when locating the best locations for wind farms or agricultural processing units (Dhunny et al., 2017), implementation of industries, and agricultural production systems.

The raster digital elevation model provides elevation data for a systematic sample of points on the Earth's surface, and algorithms can be used to measure various morphometric variables at these points Lapen and Martz (1993). The authors state that topographic obstacles can strongly influence local wind speed. Moreover, in general, where morphometric obstacles (relay) and wind flow converge, local wind speed will increase, and where morphometric obstacles cause wind flow to diverge, local wind speed will decrease. In this sense, remote sensing technology using a digital elevation model can be applied in research on windbreaks or wind protection (shelter index) (Yang et al., 2021).

Therefore, there are many difficulties in indirectly measuring wind flow in mountainous terrain, which changes the use of numerical methods using computer simulations (Sharma et al., 2020). For the authors, the wind environment in complex terrain presents different climatic conditions compared to flat terrain due to the dynamic change in its relief, height, and wind flow pattern. Although there is an increase in the number of meteorological stations to observe wind characteristics, this increase may not be effective across all complex terrain, making the procedure insufficient and requiring the use of remote wind sensing.

According to Chapman (2000), recent advances in digital elevation models (DEMs) have significantly improved the assessment of topographic exposure. According to Kolejka et al. (2009), traditional derivatives of the digital elevation model exist, such as the shadow map, the elevation (hypsometric) map, and the slope and aspect maps. Thus, more advanced maps can be produced that illustrate terrain ventilation, modeling of exposure indices, protection, wind deflection, and modeling of the temperature field extrapolated from data from meteorological stations.

Therefore, the planimetric variation of relief, orientation, exposure, and climatic dynamics can interfere with the spatial variation of wind speed and direction. This review article aimed to characterize the spatial-temporal variation of the wind and its relationship with relief and climatic disasters.

3. Concept and determining factors of the occurrence of wind

Wind can be defined as the movement of air in relation to the Earth's surface (Pereira et al., 2002; Böhner and AntoniĆ, 2009; Pitz et al., 2013; Souza and Liberato, 2019). Several factors can affect wind speed and direction. Differences in atmospheric pressure and temperature promote the displacement of air masses from regions of higher to lower pressure and temperature; that is, cold and denser air forces hot and humid air upwards, which results in the accelerated development of storm clouds (Pereira et al., 2002; Pitz et al., 2013; Souza and Liberato, 2019; Sarli et al., 2020). However, wind ends up being generated by the action of atmospheric pressure, which acts on the Earth's rotation, the centrifugal force on its movement, and friction with the surface.

Wind is a good regulator of urban temperature and outdoor thermal comfort (He, 2022). Its movement is determined by the spatial and temporal variation of the energy balance on the Earth's surface that causes variations in the atmospheric pressure field, moving from areas of higher pressure (colder areas) to those of lower pressure (hotter areas) and the greater the difference between the pressures of these areas, the greater the speed of displacement (Pereira et al., 2002; Böhner and AntoniĆ, 2009; Costa and Lyra, 2012; Siqueira et al., 2014; Paula Fernando de et al., 2017).

3.1. Types of winds and their characterization

Characterizing winds in different locations is an important aspect that we must consider when installing wind energy conversion systems, rural agricultural properties, residences, or other types of public or private infrastructures due to wind instability both in space and time (Torres et al., 1999). In order to understand the characteristics and spatial-temporal variation of winds, it became necessary in this review to characterize some types of winds, starting with Foehn.

3.1.1. Foehn winds

Mayr and Armi (2010) adopted the definition of the World Meteorological Organization (1992), which defines the Foehn wind as a wind heated and dry by the descent, generally in the lee of a mountain, that for its occurrence, the crucial aspect is that the potential virtual temperature of the descending air mass (leeward) and upstream is at least as low as the potential virtual temperature in the downstream valley, that is, its circulation depends on the potential air temperatures.

According to Richner and Hächler (2013) and Antico et al. (2021), occasionally, when the moisture content of the air is sufficiently high, orographic clouds are observed over the mountain, presenting characteristics particularly typical of the Foehn wind. Drechsel and Mayr (2008) describes Foehn wind as a small-scale phenomenon (meso γ), often dependent on the morphometric characteristics of a scale. Its onset is diagnosed when the wind shifts to the appropriate Foehn wind direction, which is accompanied by an increase in speed and gusts, as well as an increase in temperature and a decrease in relative humidity.

According to Seluchi et al. (2003) and Antico et al. (2020), Foehn winds are occasionally observed descending from the mountains towards a valley or plain. Foehn winds are also characterized by warm and dry winds descending on the leeward side of a mountain. As previously mentioned, the heat and dryness of the air are due to the adiabatic compression of the air descending the slopes of the mountains (Sharples et al., 2010; Plavcan et al., 2014; Antico et al., 2020). For Takane et al. (2017) and Antico et al. (2020), these types of winds increase with height. In geographically complex regions, the Foehn wind is one of the dominant factors in the occurrence of extremely high temperatures.

Sharples et al. (2010) points out the two main mechanisms responsible for Foehn's occurrence. The first involves the forced ascent of moist air over a mountain barrier. As the moist air rises, adiabatic cooling results in condensation and precipitation. The second mechanism involves the upstream blocking of lower-level air by a mountain barrier, with drier upper air flowing down to replace it in the lee of the mountains. Sharples et al. (2010) associates this type of wind with catastrophes, as they figure significantly as factors in severe fire weather in Europe and other regions of the world. For Seluchi et al. (2003), the air on the Lee slopes descends violently over the plains and, at the surface, can exceed 50 kt ($1\text{kt} \approx 0.5 \text{ ms}^{-1}$), causing damage (disasters).

Antico et al. (2020) claims that there has been an occurrence of Foehn-type winds on the eastern slopes of the mountains of southeastern Brazil, particularly detected on July 4, 2015, near the city of Cruzeiro, State of São Paulo, in the Serra da Mantiqueira mountains. The authors concluded that this type of wind in the mountains of southeastern Brazil reveals the complex interaction between the relief and the low and medium-level flow. For Sharples et al. (2010), the mechanism by which these types of winds occur is described by the action of precipitation that removes moisture from the air mass and the latent heat of condensation, increasing the air temperature; the drier air is then heated even further due to adiabatic compression as it descends the leeward slopes.

3.1.2. Katabatic and anabatic winds

Adedokun and Holmgren (1991) supported the research developed by Flohn on local wind systems published in 1969. This research highlighted that katabatic/anabatic winds are wind systems that change diurnally in valleys and on slopes that are thermally activated. They are a type of wind caused by the periodic variation of radiation and the thermal balance of the slopes.

For Poulos and Zhong (2008) and Charrondi re et al. (2022), katabatic winds were first addressed in the scientific literature in the 1840s, becoming a topic of interest due to studies of air quality in the social environment. It means winds flowing down a topographic gradient or out of a valley as a result of surface cooling Poulos and Zhong (2008), Kombara and Cholianawati (2022), and Cintolesi et al. (2021), which gives this air a higher density than free atmospheric air (Poulos and Zhong, 2008; Cintolesi et al., 2021).

Therefore, in complex terrain, slope flows are ubiquitous and are driven by horizontal thermal variations

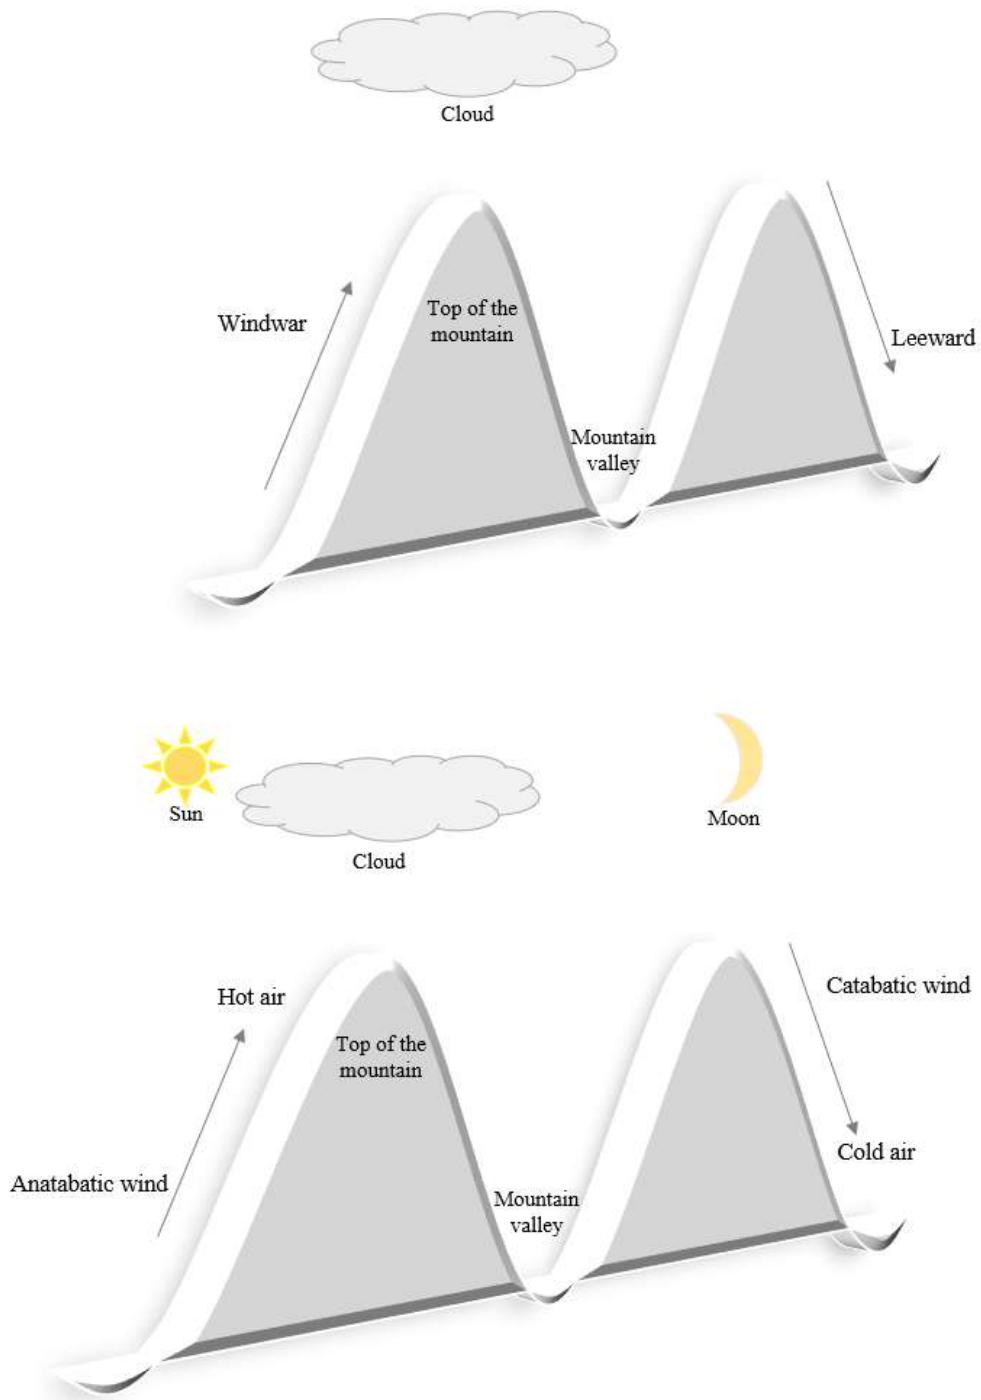


Figure 1: At the top, the circulation of the Fehon wind to the windward (left) and leeward (right). At the bottom, the circulation of the anabatic wind (left) and katabatic winds (right) over a complex surface.
6

resulting from the diurnal heating and cooling of a slope (Monti et al., 2014; Cintolesi et al., 2021). For Monti et al. (2014), during the day, the flow is upward (anabatic wind) and changes to downward at night (katabatic wind). It is driven by the daily cycle of surface sensible heat flux, as explained by Reboita et al. (2014), Hatchett et al. (2020), and Farina et al. (2023), as illustrated in Figure 2.

For Fedorovich and Shapiro (2009), meteorologists distinguish between anabatic winds that are driven by surface heating and katabatic winds as winds that result from surface cooling. Anabatic winds are most common in clear, low-wind conditions in summer when incoming solar radiation is intense. Over a significant fraction of Europe, anabatic wind days have been associated with warmer air temperatures and a change in air mass properties (Griffiths et al., 2014).

Lee and Kimura (2001) argues that anabatic breezes tend to become stronger relative to land breezes during the early morning, while land breezes become stronger than anabatic winds in the late afternoon. They describe how the delay in land breezes is due to the different response times of the pressure gradient to surface heating. The pressure gradient is induced over a heated slope and is often observed over complex terrain.

According to Manins and Sawford (1979), katabatic winds are local winds caused by the flow of air downslope, which is continuously cooled by radiative processes close to the ground. It provides the primary ventilation mechanism in mountainous regions during the night when synoptic pressure gradients are weak. However, descending or katabatic winds cause significant threats to many structural systems. These winds produce the highest velocities at low altitudes, and morphometric variation is one of the main covariates that significantly alter the variation of surface velocity (Abd-Elaal et al., 2018). In mountainous regions, intense solar heating of mountain slopes generates the so-called valley breeze during the day, bringing air from the valley to the mountain tops, generally called anabatic winds. At night, radiation cooling causes a downward flow of cold air, causing a mountain breeze; this descending air can be used for wind energy production in mountain valleys.

3.1.3. *Trade wind and counter-trade wind*

Trade winds correspond to the winds on the ground, and counter-trade winds correspond to the winds at altitude, blowing in the opposite direction to the trade winds. They can be considered the return currents of the trade winds Garcez and Alvarez (1988).

Trade winds are constant and intense, originating from the meeting of winds coming from the two hemispheres (North - Tropic of Cancer and South - Tropic of Capricorn) towards the Equator, where they heat up and form convective currents in the so-called Intertropical Convergence Zone. Counter-trade winds are winds that leave the Equator as they cool, return to the tropics to high altitudes, and deviate to the west (Coriolis force). As a result of the Earth's rotation movement. They are also called southwest trade winds and northeast trade winds (Machado and Pacheco, 2010).

According to Li et al. (2019), the trade winds over the tropical Pacific play an important role in global climate change. For example, the trade winds modulate the El Niño-Southern Oscillation (ENSO) cycle through the Bjerknes feedback. For Santos and e Silva (2013) in northeastern Brazil, in August and September, the land-ocean thermal gradients widen as the Intertropical Convergence Zone migrates northwards. Consequently, the trade winds intensify through their joint action with the sea breeze. On the other hand, in the rainy season, particularly in February and March, the southward movement of the Intertropical Convergence Zone decreases the wind speed. Meteorological stations located on the southeast coast of the northeast region of Brazil present lower wind speed records than those of meteorological stations in the northeast due to the weakening of the trade winds as a result of the location of the stations in relation to the Equator, in combination with a moderate sea breeze (smaller ocean-land thermal gradient).

Sea breezes contribute significantly to an increase in the intensity and variation in the direction of trade winds, large-scale winds that act across the globe. They also affect the temperature and humidity of the air in the region (Liria et al., 2017). The authors consider that the highest incidences of sea breezes generally occur in the summer months, and the relief strongly determines their flow over a given region of the Earth's surface.

4. Temporal variation of wind

The characteristics of wind variation are provided by the variation of the daily, monthly, annual, and interannual average, which is influenced by both the natural climate and human activities. It is important to understand the spatiotemporal variation and analyze the causes of its change (Santos and e Silva, 2013; Diao et al., 2020; Soukissian and Sotiriou, 2022).

Several studies adopt Soukissian's terminology to analyze the temporal variation of the wind regime on hourly, monthly, and annual time scales, a fact that demonstrates the behavior of the historical series, using the basic time index t , $u(t_i) = u_i$ and $\theta(t_i) = \theta_i$, with $i = 1, 2, \dots$, representing the time series of wind speed and direction, respectively, and scale t_i in hours, while the months will be indicated by the letter m and the years by the letter j (Soukissian and Sotiriou, 2022). The calculations can be developed using the R computer language, `rWind` library, after installing and enabling the `terra` library. Equation 1 is used.

$$m_{u,j} = \frac{1}{N} \sum_{i=1}^N u_i, \quad (1)$$

Where, N is the number of observations in a year.

The annual mean wind speed $m_{u,Y}$ is calculated using Equation 2.

$$m_{u,Y} = \frac{1}{J} \sum_{j=1}^J m_{u,j}, \quad (2)$$

Where, j is the total number of years. Similarly, the monthly mean wind speed for a given year j and month m is calculated using Equation 3.

$$m_{u,j,m} = \frac{1}{K} \sum_{i=1}^K u_i, \quad (3)$$

Where, K is the total number of hours for the specific month and year; $m = 1, 2, \dots, 12$. Consequently, the monthly average wind speed for a given month $m, m_{u,M=m}$ is calculated using Equation 4.

$$m_{u,m} = \frac{1}{J} \sum_{j=1}^J m_{u,j,m}, m = 1, 2, \dots, 12. \quad (4)$$

The predominant wind direction is characterized by performing a frequency analysis of the observations of daily averages of the directions, using Equation 5, and using the computer language R, library `openair`, as cited by Grange (2014) for each month of the year.

$$\bar{\theta}_{RV} = \arctan \left(\frac{\bar{u}}{\bar{v}} \right) + flow \quad (5)$$

$$flow = + 180 \text{ for } \arctan \left(\frac{\bar{u}}{\bar{v}} \right) < 180$$

$$flow = - 180 \text{ for } \arctan \left(\frac{\bar{u}}{\bar{v}} \right) > 180$$

where, $\bar{\theta}_{RV}$ represents the wind direction, \bar{u} is used for the horizontal wind measurement, and \bar{v} represents the east-west and north-south components. The frequencies of the wind directions are plotted on a wind rose chart for better visualization (Grange, 2014). They are plotted and represented by north (N), east (E), west (W), south (S), northeast (NE), northwest (NW), southeast (SE), and southwest (SW).

4.1. Wind speed trend

The analysis of the wind speed trend in the historical series can be done based on the nonparametric Mann-Kendall test Goossens and Berger (1986) and Cardoso et al. (2016). With this test, the result is less affected by outliers, since its calculation is based on the signal difference and not directly on the values of the variables, according to the assumptions presented by Cardoso et al. (2016) suggested by the World Meteorological Organization (WMO) and proposed by Sneyers (1975) according to (dos Santos and e Silva, 2013; Pes et al., 2017). The test is used to assess whether there is a monotonic upward or downward trend of the variable over time Kaja Bantha Navas et al. (2024) and Andrade et al. (2021), and consists of comparing each value of the historical series with the remaining values in sequential order, based on the statistical term, using Equation 6 (Andrade et al., 2021; Kaja Bantha Navas et al., 2024).

$$S = \sum_{i=2}^n \sum_{j=1}^{i-1} signal(x_i - x_j), \quad (6)$$

Where, x_j is the first value after x_i and, n is the sample size dos Santos and e Silva (2013); Lima et al. (2024), also consisted of the signal analysis below.

$$signal = \begin{cases} +1, & \text{se } (x_i - x_j) > 0 \\ 0, & \text{se } (x_i - x_j) = 0 \\ -1, & \text{se } (x_i - x_j) < 0 \end{cases}$$

The value of S is used to calculate the Kendall coefficient (τ) based on Equation 7, which is a normalized version of S , ranging between -1 and 1,

$$\tau = \frac{S}{\binom{n}{2}} \quad (7)$$

Where, S measures the absolute number of trend pairs, τ expresses the trend in terms of proportion, making the results comparable between different time series and $\binom{n}{2}$ calculates the total number of pairs of observations (x_i, x_j) where $i > j$.

Guo et al. (2011) studying the changes in near-surface wind speed in China using the historical series from 1969 - 2005 and calculating the averages based on the previous equations, demonstrated the occurrence of a reduction in wind speed, statistically significant at the 95.0% confidence level. For the authors, the summer wind has the smallest reduction in relation to the winter wind, suggesting that in the winter months, the wind becomes weaker in relation to the summer wind. The trend of reduced wind speed was also observed by Jiang et al. (2010) and Troccoli et al. (2012) in China, parts of the United States and Southern Europe, caused by changes in atmospheric circulation due to climate change.

Gilliland and Keim (2018) demonstrates the occurrence of a reduction in surface wind speed in geographic regions of Brazil. For Alencar et al. (2011), the time series of wind speed had an atypical variation, showing strong reductions throughout all months of the year in Viçosa, Minas Gerais, Brazil. Munhoz and Garcia (2008) analyzed the historical series of the locality of Ituverava, São Paulo, Brazil and concluded that the average annual wind speed during the daytime period was 2.20 ms^{-1} and at night 1.25 ms^{-1} indicating an average increase of 40.0% in wind speeds during the daytime period compared to the nighttime period and, from August to November, the winds blow with higher than average intensity, with September being the month with the highest speeds and April with the lowest average wind speeds.

According to Bueno et al. (2011), considering the historical series from 1988 to 2004 collected at the meteorological station of the National Institute of Meteorology (INMET), located at the Federal University of Lavras (UFLA), Municipality of Lavras, Minas Gerais, they observed that from September to February there was the occurrence of strong winds, with probabilities of occurrence of winds higher than in other months. For the authors, very strong winds above 100.0 kmh^{-1} have minimum probabilities of occurrence in all months of the year.

Although time series analyses using descriptive statistics demonstrate the occurrence of wind speed reduction in some regions of Brazil and some countries mentioned in this review, temporal variation can also be made based on statistical tests using time series analyses, time series models, and predictions of future scenarios as described below.

4.2. Time series

A time series is a sequence of observations made sequentially in time Box et al. (2015). Its analysis also helps in estimating the future values of the series (Lydia et al., 2016). Time series data are widely studied in various scenarios such as weather forecasting, stock market, and consumer behavior analysis (Wang et al., 2020). Univariate or multivariate time series analysis provides crucial information for describing, understanding, and predicting climate variability (Ghil et al., 2002).

In practical applications, we often encounter non-stationary time series. So, we usually need to deal with the differences between the original time series. Suppose the original time series order difference is a smooth sequence. In that case, it states that the sequence has the order, and the moving average (ARIMA) model represents the central part of regression. Accurately predicting wind speed and direction is challenging, especially in areas with complex topography where terrain significantly affects weather patterns (Alves et al., 2024).

According to Tidre et al. (2013), a time series is broken down into the following components: trend, seasonality, and random error. The authors state that the trend represents the gradual increase or decrease in observations over a period, and seasonality indicates possible fluctuations that have occurred, for example, in monthly, quarterly, or half-yearly periods. According to Sáfadi (2004), to understand the behavior of the time series, it is necessary to know the characteristic components, which are: trend, which can be understood as the behavior that the series presents in the long term, including growth and/or decrease, with several possible patterns; seasonality, which shows fluctuations that have occurred in periods; and the random component or error, which are unidentified fluctuations.

4.2.1. Wind forecasting using time series

Wind speed forecasting over different time horizons has gained importance in recent days (Lydia et al., 2016). Wind is considered one of the most difficult meteorological variables to forecast Cadenas et al. (2010); Zhao et al. (2015), not only because of the influence of atmospheric dynamics, but also because it is impossible to provide an accurate forecast with traditional statistical forecasting models (Zhao et al., 2015). Its forecasting plays a vital role in the planning, management, and monitoring of innovative wind power systems Zhao et al. (2015); Yan et al. (2020) and Elsaraiti and Merabet (2021), disaster prevention, early identification of safe housing sites, financing of agricultural and socio-economic projects. Wind speed

forecasting models have become important, as they also help in the effective management and safety of port areas when strong winds are expected (Solari et al., 2012).

Wind speed forecasting has become one of the most attractive topics for researchers in the renewable energy field due to its use in clean energy generation and the ability to integrate it into the power grid. According to Elsaraiti and Merabet (2021), it can also be important for rural and urban areas due to the occurrence of disasters. Kavasseri and Seetharaman (2009) forecasting can be done considering two approaches: (1) climate-based, using hydrodynamic atmospheric models that incorporate physical phenomena such as friction, thermal and convective effects, and (2) time series-based, using only historical wind speed data recorded at the site to build statistical models from which forecasts are derived.

There are several methods and models for time series forecasting at the moment (Elsaraiti and Merabet, 2021). Time series-based wind speed forecasting methods are based on the classical methodology of Box et al. (2015), as per Kavasseri and Seetharaman (2009); Box et al. (2015) and Carmelo et al. (2017) which employs a general class of models, such as the Autoregressive Moving Average $ARMA(p, q)$ or Autoregressive Integrated Moving Average $ARIMA(p, d, q)$ models to obtain forecasts. Carmelo et al. (2017) used Box-Jenkins modeling to make wind speed forecasts, which refers to the systematic method of identifying, adjusting, checking, and using Autoregressive Integrated Moving Average (ARIMA) models. Thus, in this review, two models are highlighted, ARIMA and ARIMAX, as described below.

4.2.2. Autoregressive integrated moving averages (ARIMA) model used in wind forecasting

Since wind speed is essentially a non-stationary process, it is reasonable to use a time-varying autoregressive (AR) model to simulate wind speed (Huang and Chalabi, 1995). The ARIMA model is based on the idea that a non-stationary time series can be modeled from differentiations and the inclusion of an autoregressive component and a moving average component Bressan (2007); it is a method that has been used in modeling and forecasting time series, with application to wind time series, being a systematic method of identification, adjustment, checking and use of Auto-Regressive Integrated Moving Average models, whose abbreviation is commonly given as ARIMA, providing powerful forecasting approaches and can provide highly accurate forecasts (Nascimento Camelo et al., 2018; Eymen and Köylü, 2019). This model is commonly represented by the notation $ARIMA(p, d, q)$, where (p, d, q) is the representation of the order of the model. A representation $ARIMA(1, 2, 0)$ indicates a model of order 1 for the AR (Auto-Regressive) component, order 2 for the I (Integration or differentiation) component, and the last 0 for the moving average component).

The ARIMA method has three parts: autoregressive (AR), moving average (MA), and the order of difference is the integration term (I) of AR and MA . The ARIMA model has four steps for estimation. Model definition with $ARIMA(p, d, q)$; p is the AR term, d is the order of difference term and q is the order term MA . The second step is the estimation of the model parameters with the Autocorrelation Function (ACF) and the Partial Autocorrelation Function (PACF). The third and fourth steps are, respectively, the

determination of the model fitness and the estimation (Eymen and Köylü, 2019). Therefore, a representation ARIMA(1, 2, 0) indicates a model of order 1 for the autoregressive component, order 2 for the I (Integration or differencing) component, and the last 0 for the moving average component. Consequently, ARIMA(p, d, q) has the following structure (Equation 8),

$$y_t = \alpha + \sum_{i=1}^p \beta_i y_{t-i} + \sum_{i=1}^q \theta_i u_{t-i} + u_t \quad (8)$$

Where, y_t is the contemporary process modeled, u_t is the residual (model error), α is the constant (or intercept), β is the coefficient of the autoregressive term (AR), θ is the coefficient of the moving average (MA) term, d is the number of differentiations ($y_t - y_{t-1}$) performed on the data, usually to achieve stationarity.

Using ARIMA mathematical models, we aim to capture the behavior of serial correlation or autocorrelation between the time series values; based on this, future predictions can be made (Nascimento Camelo et al., 2018). To determine the adequacy of the ARIMA model, the scatterplot of the model residual values and the Autocorrelation Factor (ACF) and Partial Autocorrelation Factor (PACF) plots are examined to determine the presence of significant autocorrelation in the time series. The absence of significant autocorrelation implies the adequacy of the model for the time series data under analysis. If there is autocorrelation at the significance level, the model parameters should be renewed by running the model again. Autocorrelation values below the significance thresholds (blue line) will indicate that there is no significant autocorrelation for residuals, which means that the model is successful in modeling the time series under analysis (Eymen and Köylü, 2019).

In general, ARIMA modeling is used in non-stationary linear processes, assuming that the time series is not stationary (that there are trend movements, whether of growth or decay of any nature) Nascimento Camelo et al. (2018); such series can be transformed into stationary series by differentiation, that is, working with the difference of the series from (t) to ($t - 1$) (Bressan, 2007).

4.2.3. Autoregressive integrated moving averages and exogenous (ARIMAX) model used in wind forecasting

Wind speed behavior can be affected by several factors, such as temperature, humidity, obstacles and terrain, and mechanical and thermal turbulence (Yan et al., 2020). ARIMAX, a deterministic predictive model for forecasting ensembles of time series, is a multivariate autoregressive integrated model that adds a linear component as a function of the observations of the covariates (also called exogenous variables). It is also known as a combination of a primary linear regression model and an existing single-variable ARIMA model (Nascimento Camelo et al., 2018; Ahn and Hur, 2023).

According to Nascimento Camelo et al. (2018), the ARIMAX model is derived from ARIMA and can be understood as the combination of the Auto-Regressive AR(p), Integrated (d), Moving Average MA(q) models and an Exogenous variable X(r). This model can then be symbolized by ARIMA(p, d, q, r). A simplified way to mathematically represent this model is described in Equation 9:

$$y_t = \rho + \sum_{i=1}^p \beta_i y_{t-i} + \sum_{j=1}^s \omega_j w_j + \sum_{j=1}^q (\theta_j - \varepsilon_{t-j}) + \varepsilon_t \quad (9)$$

Where y_t is the dependent variable at time t that is intended to be projected (i.e., the wind speed); ρ is a constant; y_{t-i} is the dependent variable (also the wind speed) lagged by i time steps; β_i is the coefficient of y_{t-i} ; p is the maximum number of time intervals considered; w_j represents the exogenous variables (atmospheric pressure, temperature, air humidity and precipitation) to obtain adjustments and forecasts with monthly averages that will be included in the model; ω_j represents the coefficients of the exogenous variables; s is the maximum number of exogenous variables; θ_j is the coefficient associated with the lagged error term ε_{t-j} , which represents the error in time t lagged by j ; and ε_t is the error component of the model, with $\varepsilon_t \sim \mathcal{N}(0, \sigma^2)$ (Nascimento Camelo et al., 2018).

Nascimento Camelo et al. (2018) highlights the efficiency of the ARIMAX model with exogenous variables (pressure, temperature, and precipitation) executed in the free software R to forecast monthly average wind speed in regions of northeastern Brazil based on low values of the error statistics determining. With the inclusion of the exogenous variable precipitation, it is possible to reduce these errors further, thus providing adjustments closer to the observed data; it was possible to demonstrate that the model used can follow the profile of the time series obtained in the study region, through similarities of minimum and maximum wind speed values, capturing the seasonality of the time series.

Therefore, Tibulo et al. (2018) states that forecasting future values is one of the objectives of time series modeling. To do so, it is necessary to verify the efficiency and good adjustment of the model, as will be analyzed in this study. Since it was mentioned that the relief influences the characteristics of the wind, it is necessary to understand its relationship with the wind, as described below.

5. Spatial variation of wind

The physiographic characteristics of Brazil are very particular, defined as a combination of natural elements such as relief, climate and vegetation that affect the climatic characteristics and present marked spatiotemporal contrasts of the wind (Luiz-Silva et al., 2021). According to Martins et al. (2008), Cardoso et al. (2012), Calil et al. (2012), and Tong et al. (2021), the very rugged relief and the presence of obstacles caused by vegetation and buildings influence the speed and direction of the wind over the Earth's surface, causing a reduction, as well as generating turbulence in its circulation, following the natural slope of the terrain.

According to Liria et al. (2017), wind speed and direction in complex terrains are mainly influenced by spatial variation of local relief, especially in the region of the border between the surface and the atmosphere. Wind speed becomes zero at heights close to the surface and approximately geostrophic in the free atmosphere (Souza et al., 2003; Martins et al., 2008; Cardoso et al., 2012; Menezes et al., 2014;

Corrêa and das Graças Paula, 2017). Therefore, wind flow tends to follow the natural planimetric variation of the terrain relief (Calil et al., 2012; Tong et al., 2021; López and Arboleya, 2022). López and Arboleya (2022) states that wind speed increases with height above the ground, and great wind potential exists in mountainous regions.

However, the northeast, southeast, and south regions of Brazil are considered to have the greatest wind potential in Brazil, especially on the coast, where strong and constant winds are observed throughout the year (Andrade et al., 2021). According to Silva et al. (2002), Brazil's northeast region's predominant wind direction is from the east. Munhoz and Garcia (2008) state that the predominant wind direction for the location of Ituverava, São Paulo, Brazil is southeast, with the exception of the summer period (December, January, and February) varying its predominance with characteristic winds from the northwest. In the region, northeast and southwest winds are also observed in second place in most months, except from December to March, when northwest winds predominate. Bueno et al. (2011) states that in Lavras, there was a predominance of gusts from east and west directions in relation to the other directions between 1988 and 2004.

This review article demonstrates the spatial variation of wind in relation to the variation of relief. To this end, the Digital Elevation Model (DEM) is described to understand the local modeling of wind to identify places protected and exposed to disaster risks caused by this climate variable.

6. Digital Elevation Model (DEM) and the study of spatial variation of wind

6.1. Digital Elevation Model

On February 11, 2000, the Shuttle Radar Topography Mission (SRTM) was launched into space (Garcia and Boulanger, 2006). According to Kovalchuk et al. (2019), Digital Elevation Models (DEMs) built from SRTM are powerful resources for use in geological studies, geomorphology, water resource monitoring, and natural hazard assessment through the integration of remote sensing images from multiple sources, generating a merged image. They represent an essential type of geospatial data in analyzing and modeling different hydrological and ecological phenomena (Isioye and Jobin, 2012). They can be applied in modeling climate phenomena necessary to preserve our environment, disaster protection, and wind power.

Isioye and Jobin (2012) states that a digital elevation model is a continuous representation of elevation values over a land surface through a regular set of z-values, referenced to a common datum. They can be created from various technologies, such as terrestrial surveying, aerial photogrammetry, Light Detection and Ranging (LiDAR), and Interferometric Synthetic Aperture Radar (InSAR). Remote sensing techniques for obtaining them include stereoscopic photogrammetry using airborne or satellite, laser scanning, Interferometric Synthetic Aperture Radar (InSAR) or SAR and Light Detection and Ranging (LiDAR) (Hawker et al., 2018; Chang et al., 2019; Pakoksung and Takagi, 2021).

For Chang et al. (2019), the quality of digital elevation models, as well as their spatial resolution, are important issues in geomorphic studies, geomorphometric feature extraction, hydrological modeling, geohazard inventory, light vision analysis, landscape modeling, and ecosystem management. These can be applied in the Ribeirão Vermelho river basin region, Minas Gerais, Brazil, to model climate phenomena such as spatial wind variation, considering the variation of local relief.

6.2. Application of digital elevation model and disaster risk mapping

The digital elevation model and its derived attributes (slope, curvature, roughness, local relief, topographic index) are easily derived from digital elevation model data, and they are important for assessing any process using digital terrain analysis and urban planning (Athmania and Achour, 2014; Li et al., 2017; Pakoksung and Takagi, 2021). There are freely available global digital elevation model products, notably the Shuttle Radar Topographic Mission version 4.1 (SRTM V4.1) (Li et al., 2017).

Resolution is the ability of the DEM to discriminate objects, for example, in a geological landscape with periodic shapes (Polidori and El Hage, 2020). For the authors, a small mesh size (meters per pixel) is a necessary condition to ensure high resolution. The availability of the 1" SRTM (30 m) as a replacement for the 3" SRTM (90 m) resulted in an improved resolution. Therefore, according to Mesa-Mingorance and Ariza-López (2020), there are several cases of resolutions (10×10 m, 30×30 m or 90×90 m) with application in the most varied extensions, from national territories to a few km^2 . This review described the 30×30 m digital elevation model because it has an improved resolution and is freely available.

Although Han et al. (2021) demonstrated that TanDEM-X DEMs have the best overall quality, followed by SRTM and ASTER GDEM has the worst quality, Li et al. (2017) demonstrated that SRTM V4.1 presented the best mean square error accuracy compared to four freely available global digital elevation model products, which reinforces the need for its use in wind modeling in the Ribeirão Vermelho watershed region.

According to Chang et al. (2019), susceptibility zoning maps can be the first step towards a complete risk assessment that helps authorities and decision-makers initiate appropriate disaster mitigation measures. These risks can include strong winds, floods, or drought in a given region. For Li et al. (2017), the slope calculation of the relief is performed on the digital elevation model using a 3×3 cell neighborhood in the most commonly used algorithms. Therefore, the quality of digital elevation models, as well as their spatial resolution, are important issues in geomorphic studies (Chang et al., 2019). For the authors, the highest accuracy was obtained from the model derived from the resampled 30 m LiDAR DEM.

6.2.1. Morphometric variables and their influence on spatial wind variation

Morphometrics deals with establishing the geometric characteristics of landforms based on measurements (Szypuła, 2017). Studies in mountainous terrain require the use of a high-quality, high-resolution digital

elevation model, which is used to derive slope angle, aspect, and altitude, important variables for the study of spatial wind variation (Tappeiner et al., 2001).

For Antonić and Legović (1999), the digital elevation model is a basis for calculating spatial variables that can be used in ecological, environmental, and geomorphometric studies as independent estimators. Morphometric variables can be derived from the standard digital elevation model, such as terrain slope, aspect, and curvature. Some variables are results of more complex interactive calculations, such as terrain exposure to wind. For Arcidiacono (2012), a digital elevation model is a constant two-dimensional *raster* that provides information about the altitude of a specific surface so that each cell of the *raster* can include an altitude value, as can be seen in Figure 3.

Böhner and Antonić (2009) states that the near-ground wind field is described with speed and direction values for each point in the area examined; it is significantly influenced by the terrain surface, especially in areas of rugged terrain, which is why data on the terrain surface are usually involved in the dynamic and direct modeling of the near-ground wind field, which can be important for weather forecasting purposes or for estimating wind energy potential.

6.2.2. Maximum Upwind Slope Variable

The maximum upwind slope variable (S_x) is calculated as the greatest upwind slope between the cell of interest and any cell along a search vector in a specific direction, with the aim of quantifying the extent of shelter or exposure provided by the terrain upstream of each pixel (Winstral et al., 2002). To determine this, all cells along a vector emanating from the cell of interest are examined and the cell that has the greatest upwind slope relative to the cell of interest is determined, and the slope between this cell defining shelter is returned. Thus, determining the contribution of wind redistribution variables based on terrain and wind data collected at the weather station can be defined based on an analysis window extending downwind of each pixel using Figure 2.

For wind modeling, Winstral et al. (2002) and Böhner and Antonić (2009) consider A_1 , A_2 as the two azimuths and d_{max} represents a maximum search distance or defines the upwind window. ASP is the terrain aspect, and the relative terrain aspect (RTA) is the absolute angular distance between the terrain aspects. Therefore, Winstral et al. (2002) considers that the window is laterally bounded by two azimuths separated by an arbitrarily chosen width of 60° ($A_1 = 235^\circ$, $A_2 = 295^\circ$). According to Antonić and Legović (1999), 300 m is chosen as the search distance because a further increase in the study area does not change the horizon angle significantly.

The algorithm, called the maximum upwind slope parameter (S_x), searches along directional vectors separated by an input increment, slope (inc), for the cell with the greatest upward slope relative to the cell of interest. The lateral width of the window allows the inclusion of terrain that was not directly upstream of the cell, based on the studies of Winstral et al. (2002), using Equation 10, which is the maximum slope equation,

$$Sx_{A,d_{max}}(x_i, y_i) = \max \left[\tan \left(\frac{\text{ELEV}(x_v, y_v) - \text{ELEV}(x_i, y_i)}{[(x_v - x_i)^2 + (y_v - y_i)^2]^{0.5}} \right) \right], \quad (10)$$

$: x \in S$

where: A is the azimuth of the search direction; (x_i, y_i) are the coordinates of the cell of interest, (x_v, y_v) are the set of all coordinates of the cells located along the search vector defined by (x_i, y_i) , A and d_{\max} . And d_{\max} is the search distance (Winstral et al., 2002).

Neighboring pixels in a sampling window are typically defined relative to a central pixel, i.e., the location for which a parameter or object association is derived. In principle, there are several ways to designate neighboring pixels, usually by an identifier or their position relative to the central pixel (Pike et al., 2009). Calculating a derivative of the digital elevation model can be a simple repetition of a given formula over the area of interest. Using a sampling window of 3×3 , the slope gradient at the central pixel can be obtained as the mean elevation change (Pike et al., 2009).

For Böhner and Antonić (2009), the simplest variable that constitutes a potential estimator of topographic exposure to wind is the angular distance in relation to the wind direction azimuth α_r , that is, the relative terrain aspect (RTA) taking into account only the orientation of the surface, neglecting the influence of the distant terrain in the direction of shelter, as well as the influence of the slope.

6.2.3. Wind deflection

Etienne et al. (2010) states that aerodynamic drag in the atmospheric boundary layer is affected by the structure and density of obstacles present at the site and by the nature of the terrain (relief variation). In other words, wind flow is affected by the terrain's undulations, which explains why all mountain shapes need to be taken into account to accurately describe the wind speed.

Taking topography into account, since it produces the effect of wind rotation, the wind flow is modeled based on the equation proposed by Ryan (1977), a simple equation for the deflection of wind in a steep gradient blowing through a slope where the slope was less than 45° (Purves et al., 1998). For this purpose, Equation 11 is used to determine the deviation of the easterly wind, based on Figure 2, generating the maps in Figure 3.

$$F_d = -255s_d \sin [2(A - \theta)] \quad (11)$$

where, F_d is the wind deflection (in degrees), s_d is the slope (in percent), A is the slope aspect (in degrees), and θ is the wind direction (in degrees).

For Ryan (1977), the deflection factor is negative, and the flow is deflected counterclockwise if A is less than 90° clockwise from θ . For example, wind from 150° hitting a slope with an aspect of 180° will be deflected in a direction counterclockwise from 150° . When the aspect is less than 90° counterclockwise from

the wind direction, the wind flow is deflected clockwise. Based on the deflection, wind indices are determined, considering the morphometric variables, the slope's orientation, and the direction of the predominant wind.

6.2.4. *Windward and leeward index*

The calculation of a windward-leeward index (hereinafter wind effect) requires a projected coordinate system (Karger et al., 2020). The windward index is a metric derived from digital elevation models that allow the assessment of the influence of relief on the variation of wind speed and direction. This index quantifies the relationship between the orientation of slopes and the direction of the prevailing wind, identifying areas of acceleration and deceleration of the wind flow. The leeward index represents the change in wind speed and direction due to the interaction with the relief. This index is calculated from the angular difference between the wind direction and the aspect of the slope.

According to Ruel (1995), relief characteristics largely determine the relative exposure to wind at a local level. The authors state that wind turbulence and speed increase when passing over a mountain ridge. The shape of the ridge influences the behavior of the wind when crossing a ridge. When the wind blows perpendicular to the crest, the velocity increases upwards, being maximum at the summit. Whereas, if the wind direction is oblique, the wind blows around and over the downwind shoulder, so that the wind often becomes turbulent, changing direction mid-slope (Robertson, 1986; Ruel, 1995). Based on the effect of the wind, the wind exposure and protection indices can be determined as follows.

6.2.5. *Topographic Wind Exposure Index*

Topographic exposure is a geomorphometric relief variable that represents the degree of protection by a variation in the surrounding relief of a given site (Chapman, 2000; Mikita and Klimánek, 2010). The authors argue that detailed knowledge of exposure is helpful for a wide variety of applications, particularly the optimal siting of wind farms and the study of wind damage.

According to Mikita and Klimánek (2010), the topographic exposure factor is primarily used to assess the threats posed by wind. This study describes the method for creating a topographic exposure based on a digital elevation model using geographic information systems (GIS). In combination with climatic data on wind speed and direction, this factor is used to define the degree of terrain ventilation, as described by Mikita and Klimánek (2010).

According to Miller (1985), Chapman (2000), and Mikita and Klimánek (2010), the degree of exposure can be estimated considering the relative heights and distances of the horizon around the study point. Several approaches have been developed to measure this useful variable. These approaches have been replaced by the use of computers and, in particular, by the application of digital terrain models, which provide a quick office-based solution, virtually eliminating the need for fieldwork.

Thus, different metrics based on the slope and orientation of the terrain can estimate topographic exposure

to wind. Therefore, according to Antonić and Legović (1999), four main estimators can be used. Namely, the first estimator is the relative terrain aspect (RTA) of a given point for a given wind flow azimuth (AWF), calculated from the digital elevation model in the usual way, using a regression plane through the 3×3 neighborhood of each point, as can be seen in Figure 2.

where, N denotes north. The terrain around point A has slope (SLP) and aspect (ASP). The relative terrain aspect (RTA) is the absolute angular distance between the terrain aspect and the wind azimuth (AWF). Point A's horizon angle (HNA) (see Figure 2) for a given wind azimuth is determined with the chosen search distance (SDS). The angle between a plane that locally represents the terrain (P_1) and the plane orthogonal to the wind (P_2) is denoted by APO, the point A' is a projection of point A onto the orthogonal plane) according to Antonić and Legović (1999) and Böhner and Antonić (2009). Therefore, a change in the search distance can change the horizon angle (Antonić and Legović, 1999).

In this review, the equation proposed by Antonić and Legović (1999), similar to the equation adopted by Böhner and Antonić (2009), was used to determine the second estimator, which is the exposure of the terrain towards the horizontal component of the wind flow. It is defined as a cosine of α , between the regression plane through the neighborhood 3×3 of a terrain point and the plane orthogonal to the wind flow, and is calculated based on Equation 12.

$$\cos \alpha = \cos \mu \sin \beta + \sin \mu \cos \beta \cos \delta - \gamma \quad (12)$$

where: μ is the terrain slope, γ is the terrain aspect, δ is the wind flow azimuth, and β is the wind flow horizon angle (it is zero for all points because horizontal wind flow is hypothesized). Henceforth, in order to fit Equation 12 to Figure 2, consider μ as SLP - terrain slope; γ as ASP - terrain aspect; δ as AWF - wind flow azimuth and β as HNA - wind flow horizon angle.

Böhner and Antonić (2009) consider γ_w as the angle between a plane orthogonal to the wind and the plane that locally represents the Earth's surface; φ as the angle of inclination of the surface in relation to the horizontal (slope); β as the angle of incidence of the wind in relation to the surface (can be interpreted as the zenith angle of the wind) and α_r as the angle between the wind direction and the line of greatest slope of the terrain (angular difference between the wind direction and the aspect of the slope).

According to Antonić and Legović (1999) and Böhner and Antonić (2009), the third estimator is the horizon angle β . In Figure 2, for a given point A, β is the maximum vertical angle in the azimuth of the hypothetical wind flow, for the chosen search distance α . Finding the horizon angle for each point requires searching the digital elevation model in the azimuth of the wind flow. For Antonić and Legović (1999), the fourth estimator becomes the exposure of the terrain towards the inclined wind flow, where β is the horizon angle of the wind flow for the search distance of 300 m (the third estimator). The authors state that when the search distance is set to zero, the horizon angle is zero, and consequently, the fourth estimator becomes




Figure 2: Estimators of topographic exposure to wind flow for the Ribeirão Vermelho watershed, Minas Gerais, Brazil.

the exposure of the terrain toward the horizontal component of the wind flow.

Topographic exposure is a geomorphometric feature of the topography and characterizes a site in terms of its protection by the surrounding landscape (Mikita and Klimánek, 2010). The authors state that the degree of topographic exposure of a site depends on the relative height and distance from the surrounding horizon. According to Ruel (1995), wind speed in a specific stand is strongly influenced by the local relief. The topographic exposure factor is mainly used to assess the threats posed by wind. However, it is also applied in the field of modeling meteorological phenomena, as highlighted by Chapman (2000) and in monitoring the impact of wind on railways (Baker, 1985).

Wind speed increases with elevation, and it is not uncommon for exposed locations such as hilltops to modify wind speed further (Quine and White (1994) and Chapman (2000)). Some landforms, such as ridges and hilltops, can further modify wind speed. Landform features dominate local airflow, and wind damage has been closely linked to the influence of surrounding topography (Ruel et al., 1997; Chapman, 2000). Therefore, the aspect term is a sinusoidal function of the slope orientation, with the effect assumed to be greater on steeper slopes than on shallower slopes (Ruel et al., 1997).

For Chapman (2000), the prediction of wind hazard or shelter locations provides a useful case study in how knowledge of topographic exposure and shelter can be applied. This knowledge controls the distribution of minimum temperatures and can then be translated into wind hazard forecast maps that can be used for decision-making exercises such as the location of sensitive species, wind farms, agricultural fields, agribusiness investments and determine many socio-economic applications that depend on an understanding of topographic exposure to wind.

6.2.6. Topographic Wind Protection Index

Ideally, exposure should be taken into account during the environmental planning or land use phases. However, when exposure remains a problem, artificially generated barriers or windbreaks can be used to provide shelter. The degree of protection is related to the height and thickness of the barrier (Chapman, 2000), which can be estimated using information obtained from the digital elevation model. A barrier will affect the airflow up to a height of about $3h$, where h is the height of the barrier. Similarly, the density of the barrier determines the impact that the barrier will have downwind.

Remote sensing and geographic information system (GIS) techniques have proven to be efficient in interpolating thematic maps and in producing slope safety factor maps (Tabalipa and Fiori, 2008). The reason for this is the combined effect of gentle slopes, strong wind environments, erodible soil, and sparse vegetation cover; since gentle slopes facilitate the transport of sediments by wind, strong and frequent winds provide the driving force for wind erosion.

Based on Equation 13 the shelter index (Protection index) (Du et al., 2017) can be determined.

$$\text{Índice de proteção } (S) = \arctan \left(\max_{x \in S} \left(\frac{z(x_0) - z(x)}{|x_0 - x|} \right) \right), \quad (13)$$

where: $S = S(x_0, a, \Delta a, d)$ is the set of grid nodes within a distance $\leq d$ in the direction range $a \pm \Delta a$ from x_0 .

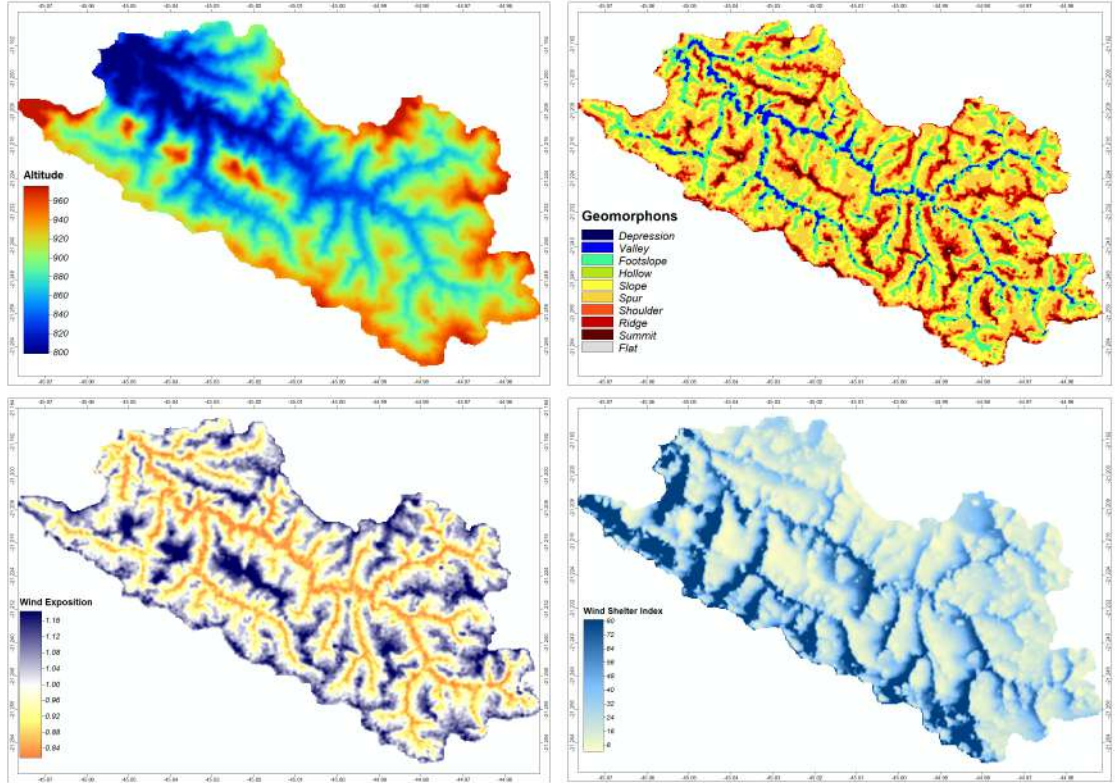


Figure 3: The altitude maps (left) and geomorphic maps (right) are at the top. At the bottom are the exposure index map (left) and protection index map (right) on winds from the predominant direction (east) in the Ribeirão Vermelho river basin, Minas Gerais, Brazil.

Based on the calculation and assumptions of Purves et al. (1998), a simple shelter index strategy is developed to illustrate the ideas of windward and leeward slopes. Cells are examined for their aspect and slope, and a remapping function is applied to them according to the values. If a cell is in an aspect range within 45° of the mean aspect of a leeward slope and its slope is greater than 5° , then it is given an index, $0 < \text{cell index} \leq 1$, according to the remapping function. The highest values will be directly leeward, with the index decreasing toward zero when the slope aspect is 45° of the mean aspect of the leeward slope. These analyses can be performed using the digital elevation model applied in R or SAGA GIS software, as in Figure

3, generating very important protection results (maps) for the Ribeirão Vermelho watershed region.

The density of the windbreak determines the impact the barrier will have downwind. The optimum solution is a medium-density windbreak that can affect the airflow 15 to 20 hours downwind. Medium-density windbreaks are better than high-density windbreaks because the sheer protection provided by dense windbreaks creates an air cushion that actually improves wind aerodynamics (Oke, 2002; Chapman, 2000). However, trees can also adapt to wind-induced pressures (Baker, 1985).

7. Disasters and socioeconomic impacts caused by extreme winds

Terezo et al. (2022) understands that, to be considered a natural disaster, an event such as heavy rain, cyclone, hail, or earthquake, among others, which can be called natural threats, must first occur. It is also necessary for populations to be exposed to conditions of vulnerability, including prevention and response capabilities, as well as those related to the population's living conditions (work, income, health and education, aspects related to infrastructure such as health, and housing insurance, roads, sanitation, land use, and occupation, among others).

Brazil is one of the countries most affected by dangerous natural phenomena (Almeida and Pascoalino, 2009). In recent decades, winds have been a major contributor to severe damage to residential buildings in the country, the United States of America, Indonesia, Mozambique, Madagascar, Malawi, Zimbabwe, and Tanzania. However, the West Java province in Indonesia has the highest recorded wind-related damage in the country (Sarli et al., 2020). Terezo et al. (2022) highlights that in Brazil, there is no clear evidence of an increase in extreme weather events in the last 20 years despite many windstorms and even hailstorms being recorded annually. The region of Minas Gerais, specifically in the Ribeirão Vermelho river basin, is common for annual records of strong winds.

Since 1980, the United States of America has experienced more than 330 climate and meteorological disasters (Ali et al., 2023). Terezo et al. (2022) highlights that the NatCatSERVICE database (2019) has records of around 850 extreme events related to winds and rains worldwide between 2013 and 2017. In Brazil, according to the EM-DAT database (2019), approximately 22 major extreme weather events occurred in the same period. However, the previous information needed to be updated.

For Marengo et al. (2024), the wind was responsible for the greatest climate disaster caused by rain and flooding in the state of Rio Grande do Sul, Brazil, between April and May 2024. The authors state that the air was compressed by the high variation in the relief of the wall formed by the Andes Mountains; the wind deflected and accelerated the air toward the South. Upon reaching the South, the hot and humid air encountered colder air that served as a ramp, forcing the hot and humid air to rise and form storm clouds, a process that is already well known and frequently occurs in that region.

Every year, extreme windstorms (hurricanes, typhoons, cyclones), severe storms, tornadoes, and gusts

cause the destruction of infrastructure in local communities (Yang et al., 2018; Chmielewski et al., 2020). According to Sarli et al. (2020) and Abdillah et al. (2022), the wind is consistently the second or third source of risk and destruction of homes and public and private infrastructure (Figure 4), a fact that demonstrates the need to understand its spatiotemporal variation as is the case in this review article. Therefore, Abdillah et al. (2022) highlights that not only infrastructure, energy, and communication networks are particularly vulnerable to extreme winds, but their impacts are also significant socioeconomically.

According to Miller (1985) and Ruel (1995), wind damage can be catastrophic or endemic. The authors suggest that catastrophic damage results from extremely severe storms and is influenced more by wind speed, direction, and morphometric features of the relief than by silvicultural actions. Endemic damage occurs as small pockets of wind enlarge over time, particularly in boreal softwood forests.

Wind direction can also have an effect on the number of disasters (Ruel, 1995). Infrequent winds from a non-predominant direction can cause more severe damage than prevailing winds of the same speed and direction to which trees have become more or less adapted (Robertson, 1987, and Ruel (1995)). For Ruel (1995) the direction of the strong wind is more important than the direction of the prevailing wind. Extremely high wind speeds can cause severe damage to crops, both in unstable locations and in locations at risk of strong winds. The degree of damage is more influenced by the speed and direction as well as the morphometric characteristics of the predominant relief in the region than by soil conditions or silvicultural practices (Miller, 1985).

According to Ruel (1995), gusts greater than 30 ms^{-1} , or (108 km/h^{-1}) can cause severe damage. These gusts are, in fact, related to the turbulence caused by the interactions between wind, relief, and forest cover. Therefore, despite the many cases of destruction due to strong winds, the destruction data are not supported by wind speed data from the areas in question, which makes it difficult to understand how severe the wind conditions are at the actual time they occur (Sarli et al., 2020).

However, Sarli et al. (2020) highlights that wind speeds of 5.0 ms^{-1} and 8.0 ms^{-1} represent a 50.0% and 90.0% possibility of damage induced by this climate variable, respectively. However, extreme winds exhibit a clear annual cycle, and their occurrences are mainly affected by small-scale weather systems, independent of seasons and locations (Abdillah et al., 2022). Their clear annual cycle and knowledge of the central regions of disaster occurrence can be the main points for studying ways to mitigate disaster occurrence, protect lives, and mitigate socioeconomic damages. The orientation of downed trees can signal potentially damaging winds (Steinblums et al., 1984; Ruel, 1995), as observed in Figure 4.

8. Discussion

This review highlights the complexity of wind dynamics as a function of relief, using an integrated approach involving topographic, meteorological, and statistical variables. Based on the analysis of the



26

Figure 4: At the top, the destruction of public infrastructure (left) and private infrastructure (right) is at the top. Tree breakage caused by strong winds in the urban region of Lavras (Jardim Glória square), Ribeirão Vermelho river basin, Minas Gerais, Brazil, on September 27, 2023 (Public domain photo).

compiled studies, wind speed and direction are shaped by factors such as slope, slope orientation, altitude, and terrain roughness, whose representation is facilitated by the use of Digital Elevation Models (DEMs) (Antonić and Legović, 1999; Böhner and AntoniĆ, 2009; Chapman, 2000).

Figure 1 illustrates the circulation mechanisms of Foehn winds and anabatic/katabatic winds over complex surfaces. This representation helps to understand how relief interferes with the rise or fall of air masses, modifying temperature, humidity, and wind intensity. For example, katabatic winds descend slopes during the night, causing cooling and possible intensification of strong winds in valleys. Foehn winds, when heated, descend from the leeward side and are associated with temperature peaks and extreme events such as forest fires (Sharples et al., 2010; Antico et al., 2020).

In addition, Figure 2 summarizes the main geomorphometric estimators used to calculate topographic exposure to wind flow: relative aspect (RTA), horizon angle (HNA), and orthogonal projection angle (APO). This schematic representation is crucial to understanding how the orientation and inclination of the surface in relation to the prevailing wind directly influence the acceleration or deceleration of the airflow (Antonić and Legović, 1999; Böhner and AntoniĆ, 2009). These parameters are essential for the construction of exposure and shelter indices, which guide the zoning of vulnerable areas or areas suitable for the installation of wind infrastructure using remote sensing techniques (Chapman, 2000; Zeng et al., 2007).

The exposure of the terrain to wind, modeled by the cosine equation of α and illustrated in Figure 2, allows us to estimate the vulnerability or natural protection of an area. This equation considers the angle between the surface and the wind flow, adjusting for factors such as slope (μ), aspect (γ), and wind azimuth (δ), as described by Böhner and AntoniĆ (2009) and applied by AntoniĆ and Legović (1999). This metric is particularly important in mountainous regions, such as the Ribeirão Vermelho basin (MG), where the relief generates distinct atmospheric circulation patterns.

In Figure 3, maps derived from the wind deflection indices Ryan (1977), maximum upwind slope Winstral et al. (2002), and topographic exposure Chapman (2000) demonstrate the practical applicability of these indicators. These tools allow mapping areas of greater risk or shelter and are valuable for urban planning, positioning windbreaks, and locating wind farms.

In addition to spatial aspects, temporal wind analysis is essential to assess trends that may indicate climate change, changes in atmospheric dynamics, or effects of land use and occupation. Studies such as those by Yan et al. (2020) and Elsaraiti and Merabet (2021) indicate that, over the last few decades, variations in the average, frequency, and intensity of winds have been observed in different regions, which can directly impact energy security, agriculture, and disaster risk. In many tropical regions, such as Brazil, there are signs that wind variability has increased in recent years, especially during seasonal transition months. This trend, although still lacking more detailed investigations with long-series data, is a growing concern in the context of global climate change. Through statistical tests such as Mann-Kendall or linear regression associated with ARIMA modeling, trend analysis can help identify significant patterns and support adaptation policies.

In addition to spatial aspects, temporal analysis of wind regimes is essential. The application of statistical models such as ARIMA and ARIMAX in forecasting wind speed has proven to be efficient, especially when combined with exogenous variables such as pressure, temperature, and precipitation. ARIMAX modeling, in particular, allows the integration of climate and topographic data, resulting in greater predictive accuracy (Yan et al., 2020; Elsaraiti and Merabet, 2021).

Therefore, integrating terrain morphometry, statistical modeling, and remote sensing proves to be a robust approach to understanding and predicting wind dynamics. The review shows that wind-related disasters (tree breakage, roof loss, power grid failures) are strongly influenced by local relief and that knowledge of topographic exposure can be crucial to reducing damage and improving territorial planning (Quine and White, 1994; Ruel, 1995; Chapman, 2000).

The analysis of maps of exposure and topographic protection to wind, combined with maps of altitude and landforms (geomorphons), allows us to understand in greater depth the effects of relief on air circulation on a local scale. Considering that the predominant wind comes from the east (azimuth of 90°), areas facing west tend to have greater natural protection. In contrast, areas facing east are more exposed to the direct impact of winds.

The altitude maps reveal that higher regions act as natural barriers to the wind, redirecting or accelerating the flow on ridges and peaks. On the other hand, valleys and areas of lower altitudes, especially when oriented in the direction of the predominant wind, act as funneling and intensifying wind channels. This behavior is consistent with the patterns described by Winstral et al. (2002) and Böhner and AntoniĆ (2009), in which the slope (μ) and the orientation of the surface (γ) modulate the energy of the wind received.

The use of geomorphons, when classifying the relief into features such as ridges, slopes, plateaus, valleys, and depressions, allows the identification of areas that, even at similar altitudes, present different behaviors in terms of exposure to wind. For example, east-facing ridges are high-impact zones, while west-facing slopes function as shelter areas. Integrating these layers makes it possible to develop risk zones and refuge zones, which are essential for territorial, energy (location of wind turbines), and environmental (reforestation of degraded areas) planning.

The spatial overlap of exposure indices with altitude and relief shape data increases the model's analytical capacity. It allows the identification of recurring patterns of vulnerability and critical areas where the morphology accentuates the effects of the prevailing wind. This type of analysis is essential for proposing risk mitigation and climate adaptation strategies, especially in mountainous or highly anthropized regions.

Therefore, it is necessary to advance in identifying vulnerable zones, considering not only wind averages but also their interaction with morphometric variables and their temporal variation. The use of the metrics discussed here should be encouraged in future studies, especially in tropical regions where the density of meteorological stations is still limited, and the risks of extreme weather events are increasing.

9. Conclusions

The spatial-temporal variation of wind is strongly dependent on morphometric variables, especially altitude, slope, and orientation of the terrain. These variables define zones of exposure and shelter from the prevailing wind, seasonal patterns, and trends that are fundamental for climate monitoring and territorial and agricultural planning in vulnerable regions.

The integration of morphometric and climatic variables through digital elevation models is an effective approach to characterize the spatial-temporal variation of wind in complex relief environments. Spatial-temporal characterization is essential to understanding local atmospheric circulation patterns and supporting agricultural, environmental, urban, and energy planning in risk regions.

The correlation between morphometric and climatic variables reinforces the importance of geospatial tools in identifying risk areas and guiding mitigation measures in the face of extreme climate events associated with wind.

10. Disclosures

11. Competing interests

The authors declare that they have no competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

12. Funding

The first author received a scholarship from the Coordination for the Improvement of Higher Education Personnel (CAPES).

13. Availability of data and materials

The datasets generated during and/or analyzed during the current study are available from the corresponding author upon request.

References

- Abd-Elaal, E.S., Mills, J.E., Ma, X., 2018. Numerical simulation of downburst wind flow over real topography. *Journal of Wind Engineering and Industrial Aerodynamics* 172, 85–95. doi:10.1016/j.jweia.2017.10.026.
- Abdillah, M.R., Sarli, P.W., Firmansyah, H.R., Sakti, A.D., Fajary, F.R., Muharsyah, R., Sudarman, G.G., 2022. Extreme wind variability and wind map development in western java, indonesia. *International Journal of Disaster Risk Science* 13, 465–480. doi:10.1007/s13753-022-00420-7.

- Adedokun, J., Holmgren, B., 1991. Acoustic sounder detection of anabatic/katabatic winds in abisko, n. sweden. *Renewable energy* 1, 77–89.
- Ahn, E., Hur, J., 2023. A short-term forecasting of wind power outputs using the enhanced wavelet transform and arimax techniques. *Renewable Energy* 212, 394–402. doi:10.1016/j.renene.2023.05.048.
- Alencar, L.P.d., Sediyaama, G.C., Mantovani, E.C., Martinez, M.A., 2011. Tendências recentes nos elementos do clima e suas implicações na evapotranspiração da cultura do milho em viçosa-mg. *Engenharia Agrícola* 31, 631–642. doi:10.1590/S0100-69162011000400002.
- Ali, J., Wahl, T., Enriquez, A.R., Rashid, M.M., Morim, J., Gall, M., Emrich, C.T., 2023. The role of compound climate and weather extreme events in creating socio-economic impacts in south florida. *Weather and Climate Extremes* 42, 100625. doi:10.1016/j.wace.2023.100625.
- Almeida, L.d., Pascoalino, A., 2009. Gestão de risco, desenvolvimento e (meio) ambiente no brasil—um estudo de caso sobre os desastres naturais de santa catarina. *Simpósio Brasileiro de Geografia Física Aplicada* 13, 2009.
- Alves, D., Mendonça, F., Mostafa, S.S., Morgado-Dias, F., 2024. A computer vision approach for satellite-driven wind nowcasting over complex terrains. *Environmental Research Communications* 6, 055014. doi:10.1088/2515-7620/ad4984.
- Andrade, A.R.d., Melo, V.F.M.B., Lucena, D.B., Abrahão, R., 2021. Tendências da velocidade do vento e o potencial de geração de eletricidade em novas usinas eólicas no nordeste do brasil. *Revista da Sociedade Brasileira de Ciências e Engenharia Mecânica* 43, 1–11. doi:10.1007/s40430-021-02911-y.
- Antico, P.L., Chou, S.C., Seluchi, M.E., Sueiro, G., 2020. Foehn-like wind in the mountains of southeastern brazil as seen by the eta model simulation. *Revista Brasileira de Meteorologia* 36, 79–86. doi:10.1590/0102-77863540074.
- Antico, P.L., Chou, S.C., Seluchi, M.E., Sueiro, G., 2021. Vento tipo foehn nas serras do sudeste do brasil visto pela simulação do modelo eta. *Revista Brasileira de Meteorologia* , 79–86doi:10.1590/0102-77863540074.
- Antonić, O., Legović, T., 1999. Estimating the direction of an unknown air pollution source using a digital elevation model and a sample of deposition. *Ecological Modelling* 124, 85–95. doi:10.1016/S0304-3800(99)00149-0.
- Arcidiacono, S.A., 2012. Gis-based site potential analysis for small-scale wind power plants. Bachelor Thesis. Carinthia University of Applied Sciences School of Geoinformation and Environmental Technologies .
- Athmania, D., Achour, H., 2014. External validation of the aster gdem2, gmted2010 and cgiar-csi-srtm v4. 1 free access digital elevation models (dems) in tunisia and algeria. *Remote Sensing* 6, 4600–4620.
- Baker, C., 1985. The determination of topographical exposure factors for railway embankments. *Journal of Wind Engineering and Industrial Aerodynamics* 21, 89–99. doi:10.1016/0167-6105(85)90035-2.
- Box, G.E., Jenkins, G.M., Reinsel, G.C., Ljung, G.M., 2015. *Time Series Analysis: Forecasting and Control*. John Wiley & Sons.
- Bressan, A.A., 2007. Tomada de decisao em futuros agropecuarios com modelos de previsao de series temporais. *RAE eletrônica* 3. doi:10.1590/S1676-56482004000100005.
- Bueno, R.C., Carvalho, L.G.d., Vianello, R.L., Marques, J.J.G.d.S., et al., 2011. Estudo de rajadas de ventos e direções predominantes em lavras, minas gerais, por meio da distribuição gama. *Ciência e Agrotecnologia* 35, 789–796. doi:10.1590/S1413-70542011000400019.
- Böhner, J., AntoniĆ, O., 2009. Land-surface parameters specific to topo-climatology. *Developments in Soil Science* 33, 195–226. doi:10.1016/S0166-2481(08)00008-1.
- Cadenas, E., Jaramillo, O.A., Rivera, W., 2010. Analysis and forecasting of wind velocity in chetumal, quintana roo, using the single exponential smoothing method. *Renewable Energy* 35, 925–930. doi:10.1016/j.renene.2009.10.037.
- Calil, P.M., de Oliveira, L.F.C., Kliemann, H.J., Oliveira, V.A.d., 2012. Caracterização geomorfométrica e do uso do solo da bacia hidrográfica do alto meia ponte, goiás. *Revista Brasileira de Engenharia Agrícola e Ambiental* 16, 433–442. doi:10.1590/S1415-43662012000400014.
- Cardoso, C.d.S., Bitencourt, D.P., Mendonça, M., 2012. Comportamento do vento no setor leste de santa catarina sob influência

- de ciclones extratropicais. *Revista Brasileira de Meteorologia* 27, 39–48. doi:10.1590/S0102-77862012000100005.
- Cardoso, L.F.N., Silva, W.L., da Silva, M.G.J., 2016. Long-term trends in near-surface wind speed over the southern hemisphere: A preliminary analysis. *International Journal of Geosciences* 7, 938–943. doi:10.4236/ijg.2016.77070.
- Carmelo, H.d.N., Lucio, P.S., Leal Junior, J.B.V., Carvalho, P.C.M.d., 2017. Previsão de velocidade do vento no nordeste brasileiro através do modelo arimax, *Revista Ciência e Tecnologia (Campinas. Online)-http://www.revista.unisal...*
- Çetin, M., Meydan, A., 2023. Topography and climate of mount karanfil (pozanti/adana). *Environmental Systems Research* 12, 1. doi:10.1186/s40068-022-00280-6.
- Chang, K.T., Merghadi, A., Yunus, A.P., Pham, B.T., Dou, J., 2019. Evaluating scale effects of topographic variables in landslide susceptibility models using gis-based machine learning techniques. *Scientific reports* 9, 12296.
- Chapman, L., 2000. Assessing topographic exposure. *Meteorological Applications* 7, 335–340. doi:10.1017/S1350482700001729.
- Charrondière, C., Brun, C., Cohard, J.M., Sicart, J.E., Obligado, M., Biron, R., Coulaud, C., Guyard, H., 2022. Katabatic winds over steep slopes: Overview of a field experiment designed to investigate slope-normal velocity and near-surface turbulence. *Boundary-Layer Meteorology* 182, 29–54. doi:10.1007/s10546-021-00644-y.
- Chauke, M.D., Prinsloo, L., Pratt, L.E., Roro, K.T., 2021. Wind speed trend analysis and inter-annual variability in south africa.
- Chmielewski, T., Szer, J., Bobra, P., 2020. Derecho wind storm in poland on 11–12 august 2017: results of the post-disaster investigation. *Environmental Hazards* 19, 508–528. doi:10.1080/17477891.2020.1730154.
- Cintolesi, C., Di Santo, D., Barbano, F., Di Sabatino, S., 2021. Anabatic flow along a uniformly heated slope studied through large-eddy simulation. *Atmosphere* 12, 850. doi:10.3390/atmos12070850.
- Corrêa, P.S.G., das Graças Paula, M., 2017. A gestão dos recursos hídricos na sub-bacia hidrográfica vertentes do rio grande. *Revista Jurídica da Escola Superior do Ministério Público de São Paulo* 11.
- Correia Filho, W.L.F., Souza, P.H.d.A., Oliveira-Júnior, J.F.d., Santiago, D.d.B., Lyra, G.B., Zeri, M., Cunha-Zeri, G., 2022. The wind regime over the brazilian southeast: Spatial and temporal characterization using multivariate analysis. *International Journal of Climatology* 42, 1767–1788. doi:10.1002/joc.7334.
- Costa, G.B., Lyra, R.F.d.F., 2012. Análise dos padrões de vento no estado de alagoas. *Revista Brasileira de Meteorologia* 27, 31–38. doi:10.1590/S0102-77862012000100004.
- Curry, C.L., van der Kamp, D., Monahan, A.H., 2012. Statistical downscaling of historical monthly mean winds over a coastal region of complex terrain. i. predicting wind speed. *Climate dynamics* 38, 1281–1299. doi:10.1007/s00382-011-1173-3.
- Dhunny, A., Lollchund, M., Rughooputh, S., 2017. Wind energy evaluation for a highly complex terrain using computational fluid dynamics (cfd). *Renewable Energy* 101, 1–9. doi:10.1016/j.renene.2016.08.032.
- Diao, W., Zhao, Y., Dong, Y., Zhai, J., Wang, Q., Gui, Y., 2020. Spatiotemporal variability of surface wind speed during 1961–2017 in the jing-jin-ji region, china. *Journal of Meteorological Research* 34, 621–632. doi:10.1007/s13351-020-9119-5.
- Dias, G.F.d.M., Sousa, A.M.L.d., Pontes, A.K.d.S., et al., 2018. Caracterização da velocidade e direção predominante dos ventos no litoral do nordeste paraense., *Revista Brasileira de Iniciação Científica (RBIC)*.
- Drechsel, S., Mayr, G.J., 2008. Objective forecasting of foehn winds for a subgrid-scale alpine valley. *Weather and Forecasting* 23, 205–218. doi:10.1175/2007WAF2006021.1.
- Du, H., Wang, T., Xue, X., 2017. Potential wind erosion rate response to climate and land-use changes in the watershed of the ningxia-inner mongolia reach of the yellow river, china, 1986–2013. *Earth Surface Processes and Landforms* 42, 1923–1937. doi:10.1002/esp.4146.
- Elsaraiti, M., Merabet, A., 2021. A comparative analysis of the arima and lstm predictive models and their effectiveness for predicting wind speed. *Energies* 14, 6782. doi:10.3390/en14206782.
- Etienne, C., Lehmann, A., Goyette, S., Lopez-Moreno, J.I., Beniston, M., 2010. Spatial predictions of extreme wind speeds over switzerland using generalized additive models. *Journal of Applied Meteorology and Climatology* 49, 1956–1970.

- doi:10.1175/2010JAMC2206.1.
- Eymen, A., Köylü, Ü., 2019. Seasonal trend analysis and arima modeling of relative humidity and wind speed time series around yamula dam. *Meteorology and Atmospheric Physics* 131, 601–612.
- Farina, S., Marchio, M., Barbano, F., Di Sabatino, S., Zardi, D., 2023. Characterization of the morning transition over the gentle slope of a semi-isolated massif. *Journal of Applied Meteorology and Climatology* 62, 449–466. doi:10.1175/JAMC-D-22-0011.1.
- Fedorovich, E., Shapiro, A., 2009. Structure of numerically simulated katabatic and anabatic flows along steep slopes. *Acta Geophysica* 57, 981–1010. doi:10.2478/s11600-009-0027-4.
- Filom, S., Radfar, S., Panahi, R., Amini, E., Neshat, M., 2021. Exploring wind energy potential as a driver of sustainable development in the southern coasts of iran: The importance of wind speed statistical distribution model. *Sustainability* 13, 7702. doi:10.3390/su13147702.
- Garcez, L.N., Alvarez, G.A., 1988. *Hidrologia*. Editora Blucher.
- Garcia, M., Boulanger, P., 2006. Low altitude wind simulation over mount saint helens using nasa srtm digital terrain model, in: *Third International Symposium on 3D Data Processing, Visualization, and Transmission (3DPVT'06)*, IEEE. pp. 535–542.
- Ghil, M., Allen, M.R., Dettinger, M.D., Ide, K., Kondrashov, D., Mann, M.E., Robertson, A.W., Saunders, A., Tian, Y., Varadi, F., et al., 2002. Advanced spectral methods for climatic time series. *Reviews of geophysics* 40, 3–1. doi:10.1029/2000RG000092.
- Gilliland, J.M., Keim, B.D., 2018. Surface wind speed: trend and climatology of brazil from 1980–2014. *International Journal of Climatology* 38, 1060–1073. doi:10.1002/joc.5237.
- Godziek, J., Pawlik, Ł., 2023. Indicators of wind-driven forest disturbances–pit–mound topography, its automatic detection and significance. *Catena* 221, 106757. doi:10.1016/j.catena.2022.106757.
- Goossens, C., Berger, A., 1986. Annual and seasonal climatic variations over the northern hemisphere and europe during the last century. *Geophys. J.:(France)* 4.
- Grange, S.K., 2014. Averaging wind speeds and directions. no. October , 12.
- Griffiths, A., Conen, F., Weingartner, E., Zimmermann, L., Chambers, S.D., Williams, A., Steinbacher, M., 2014. Surface-to-mountaintop transport characterised by radon observations at the jungfraujoeh. *Atmospheric Chemistry and Physics* 14, 12763–12779. doi:10.5194/acp-14-12763-2014, 2014.
- Guo, H., Xu, M., Hu, Q., 2011. Mudanças na velocidade do vento próximo à superfície na china: 1969–2005. *International Journal of Climatology* 31, 349–358. URL: <https://doi.org/10.1002/joc.2091>, doi:10.1002/joc.2091.
- Han, H., Zeng, Q., Jiao, J., 2021. Quality assessment of tandem-x dems, srtm and aster gdem on selected chinese sites. *Remote Sensing* 13, 1304.
- Hatchett, B.J., Kaplan, M.L., Nauslar, N.J., Smith, C.M., Nelson, K., 2020. Slope winds. *Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires* , 922–930.
- Hawker, L., Bates, P., Neal, J., Rougier, J., 2018. Perspectives on digital elevation model (dem) simulation for flood modeling in the absence of a high-accuracy open access global dem. *Frontiers in Earth Science* 6, 233.
- He, B.J., 2022. Urban morphology, urban ventilation and urban heat island mitigation: A methodological framework, in: *Climate Change and Environmental Sustainability*. Springer, pp. 131–136.
- Huang, Z., Chalabi, Z., 1995. Use of time-series analysis to model and forecast wind speed. *Journal of Wind Engineering and Industrial Aerodynamics* 56, 311–322. doi:10.1016/0167-6105(94)00093-S.
- Isioye, A., Jobin, P., 2012. An assessment of digital elevation models (dems) from different spatial data sources. *Asian Journal of Engineering, Sciences & Technology (AJEST)* 2.
- Jiang, Y., Luo, Y., Zhao, Z., Tao, S., 2010. Changes in wind speed over china during 1956–2004. *Theoretical and Applied Climatology* 99, 421–430. doi:10.1007/s00704-009-0152-7.
- Kaja Bantha Navas, R.M., Prakash, S., Molnar, V., 2024. Análise da variação, tendências e previsão da velocidade do vento a curto prazo: Um estudo de caso de tamil nadu, Índia. *Journal of Intelligent Systems* 33, 20230051. doi:10.1515/jisys-2023-0051.

- Karger, D.N., Schmatz, D.R., Dettling, G., Zimmermann, N.E., 2020. High-resolution monthly precipitation and temperature time series from 2006 to 2100. *Scientific data* 7, 248. doi:10.6084/m9.figshare.12593735.
- Kavasseri, R.G., Seetharaman, K., 2009. Day-ahead wind speed forecasting using f-arima models. *Renewable Energy* 34, 1388–1393. doi:10.1016/j.renene.2008.09.006.
- Kolejka, J., Kana, D., Plsek, V., Klimanek, M., Navratil, V., Svoboda, J., et al., 2009. Tematicke mapy zalozene na digitalnim modelu reliefu. *Geomorphologia Slovaca et Bohemica* 2, 13–27.
- Kombara, P.Y., Cholianawati, N., 2022. Influence of local wind respect to the pm2. 5 dispersion in bandung basin, in: *Proceedings of the International Conference on Radioscience, Equatorial Atmospheric Science and Environment and Humanosphere Science*, 2021, Springer. pp. 315–325.
- Kovalchuk, I., Lukianchuk, K., Bogdanets, V., 2019. Assessment of open source digital elevation models (srtm-30, aster, alos) for erosion processes modeling. *Journal of geology, geography and geoecology* 28, 95–105.
- Kühni, A., Pfiffner, O.A., 2001. The relief of the swiss alps and adjacent areas and its relation to lithology and structure: topographic analysis from a 250-m dem. *Geomorphology* 41, 285–307. doi:10.1016/S0169-555X(01)00060-5.
- Lapen, D.R., Martz, L.W., 1993. The measurement of two simple topographic indices of wind sheltering-exposure from raster digital elevation models. *Computers & Geosciences* 19, 769–779.
- Lee, S.H., Kimura, F., 2001. Comparative studies in the local circulations induced by land-use and by topography. *Boundary-Layer Meteorology* 101, 157–182.
- Li, X., Zhang, Y., Jin, X., He, Q., Zhang, X., 2017. Comparison of digital elevation models and relevant derived attributes. *Journal of Applied Remote Sensing* 11, 046027–046027.
- Li, Y., Chen, Q., Liu, X., Li, J., Xing, N., Xie, F., Feng, J., Zhou, X., Cai, H., Wang, Z., 2019. Long-term trend of the tropical pacific trade winds under global warming and its causes. *Journal of Geophysical Research: Oceans* 124, 2626–2640.
- Lima, G.C., Rodrigues, D.T., Santos E Silva, C.M., de Sousa Costa, P.C., 2024. Evolution of wind speed observed in brazil between 1961 and 2020. *International Journal of Climatology* 44, 1932–1954. doi:10.1002/joc.8433.
- Liria, M.A.T., Moita, J.M., Loiola, J.V.L.d., Silva, E.M.d., Alves, J.M.B., 2017. Caracterização do regime de ventos no piauí para o aproveitamento de energia eólica. *Revista Brasileira de Meteorologia* 32, 77–88. doi:10.1590/0102-778632120150712.
- Liu, Y.S., Yigitcanlar, T., Guaralda, M., Degirmenci, K., Liu, A., 2024. Spatial modelling of urban wind characteristics: Review of contributions to sustainable urban development. *Buildings* 14, 737. doi:10.3390/buildings14030737.
- Liu, Z., Shie, C.L., Li, A., Meyer, D., 2020. Nasa global satellite and model data products and services for tropical meteorology and climatology. *Remote Sensing* 12, 2821. doi:10.3390/rs12172821.
- López, G., Arboleya, P., 2022. Short-term wind speed forecasting over complex terrain using linear regression models and multivariable lstm and narx networks in the andes mountains, ecuador. *Renewable Energy* 183, 351–368. doi:10.1016/j.renene.2021.10.070.
- Luiz-Silva, W., Oscar-Júnior, A.C., Cavalcanti, I.F.A., Treistman, F., 2021. An overview of precipitation climatology in brazil: space-time variability of frequency and intensity associated with atmospheric systems. *Hydrological Sciences Journal* 66, 289–308. doi:10.1080/02626667.2020.1863969.
- Lydia, M., Kumar, S.S., Selvakumar, A.I., Kumar, G.E.P., 2016. Linear and non-linear autoregressive models for short-term wind speed forecasting. *Energy conversion and management* 112, 115–124. doi:10.1016/j.enconman.2016.01.007.
- Machado, A.L.S., Pacheco, J.B., 2010. Serviços ecossistêmicos e o ciclo hidrológico da bacia hidrográfica amazônica-the biotic pump. *Revista Geonorte* 1, 71–89.
- Manins, P., Sawford, B., 1979. A model of katabatic winds. *Journal of Atmospheric Sciences* 36, 619–630.
- Marengo, J.A., Dolif, G., Cuartas, A., Camarinha, P., Gonçalves, D., Luiz, R., Silva, L., Alvala, R.C.S., Seluchi, M.E., Moraes, O.L., et al., 2024. O maior desastre climático do brasil: chuvas e inundações no estado do rio grande do sul em abril-maio 2024. *Estudos Avançados* 38, 203–228. doi:10.1590/s0103-4014.202438112.012.

- Martins, F.R., Guarnieri, R.A., Pereira, E.B., 2008. O aproveitamento da energia eólica. *Revista Brasileira de Ensino de Física* 30, 1304–1.
- Martz, L.W., de Jong, E., 1991. Using cesium-137 and landform classification to develop a net soil erosion budget for a small canadian prairie watershed. *Catena* 18, 289–308. doi:10.1016/0341-8162(91)90027-U.
- Mayr, G.J., Armi, L., 2010. The influence of downstream diurnal heating on the descent of flow across the sierras. *Journal of Applied Meteorology and Climatology* 49, 1906–1912. doi:10.1175/2010JAMC2516.1.
- Menezes, J.P.C., Franco, C.S., de Oliveira, L.F.C., Bittencourt, R.P., de Sá Farias, M., Fia, R., 2014. Morfometria e evolução do uso do solo e da vazão de máxima em uma micro bacia urbana. *Revista Brasileira de Geomorfologia* 15. doi:10.20502/rbg.v15i4.597.
- Mesa-Mingorance, J.L., Ariza-López, F.J., 2020. Accuracy assessment of digital elevation models (dems): A critical review of practices of the past three decades. *Remote Sensing* 12, 2630.
- Mikita, T., Klimánek, M., 2010. Topographic exposure and its practical applications. *Journal of Landscape Ecology* 3, 42–51. doi:10.2478/v10285-012-0022-3.
- Miller, K., 1985. Windthrow hazard classification. HM Stationery Office.
- Molaei, A., Lashkari, H., 2020. Investigation of wind speed trend changes in central iran using ecmwf reanalysis data. *Physical Geography Research* 52, 481–498. doi:10.22059/jphgr.2020.295406.1007476.
- Monti, P., Fernando, H., Princevac, M., 2014. Waves and turbulence in katabatic winds. *Environmental Fluid Mechanics* 14, 431–450. doi:10.1007/s10652-014-9348-1.
- Munhoz, F.C., Garcia, A., 2008. Caracterização da velocidade e direção predominante dos ventos para a localidade de ituverava-sp. *Revista Brasileira de Meteorologia* 23, 30–34. doi:10.1590/S0102-77862008000100003.
- Murakami, S., Komine, H., 1983. Prediction method for surface wind velocity distribution by means of regression analysis of topographic effects on local wind speed. *Journal of Wind Engineering and Industrial Aerodynamics* 15, 217–230. doi:10.1016/0167-6105(83)90192-7.
- Nascimento Camelo, H.d., Lucio, P.S., Leal Junior, J.B.V., Carvalho, P.C.M.d., 2018. Proposta para previsao de velocidade do vento atraves de modelagem hibrida elaborada a partir dos modelos arimax e rna. *Revista Brasileira de Meteorologia* 33, 115–129. doi:10.1590/0102-7786331005.
- Ojo, A.R., Sadiku, N.A., 2023. Slenderness coefficient and growth characteristics of africa giant bamboo: *Bambusa vulgaris* schrad. ex jc wendl. *Advances in Bamboo Science* 2, 100017. doi:10.1016/j.bamboo.2023.100017.
- Oke, T.R., 2002. *Boundary layer climates*. Routledge.
- Pakoksung, K., Takagi, M., 2021. Assessment and comparison of digital elevation model (dem) products in varying topographic, land cover regions and its attribute: a case study in shikoku island japan. *Modeling Earth Systems and Environment* 7, 465–484.
- Paula Fernando de, D.L.P., Cardoso, A.C., Cardoso, R.B., de Paula, G., Cunha, Q., Vieira, E.M., 2017. Modelagem espacial da velocidade do vento a 50, 75 e 100 metros de altura para o estado de minas gerais, brasil, empregando geoestatística. *Revista Brasileira de Geografia Física* 10, 1281–1295.
- Pennock, D.J., Zebarth, B., De Jong, E., 1987. Landform classification and soil distribution in hummocky terrain, saskatchewan, canada. *Geoderma* 40, 297–315. doi:10.1016/0016-7061(87)90040-1.
- Pereira, A.R., Angelocci, L.R., Sentelhas, P.C., 2002. *Agrometeorologia: fundamentos e aplicações práticas*.
- Pes, M.P., Pereira, E.B., Marengo, J.A., Martins, F.R., Heinemann, D., Schmidt, M., 2017. Climate trends on the extreme winds in brazil. *Renewable Energy* 109, 110–120. doi:10.1016/j.renene.2016.12.101.
- Pike, R.J., Evans, I.S., Hengl, T., 2009. Geomorphometry: a brief guide. *Developments in soil science* 33, 3–30. doi:10.1016/S0166-2481(08)00001-9.
- Pitz, I., Neves, L., Pitz, J., Eli, K., Oliveira, E., 2013. Caracterização da velocidade e direção predominante dos ventos para a

- localidade de rio do sul-sc. ENCICLOPEDIA BIOSFERA 9.
- Plavcan, D., Mayr, G.J., Zeileis, A., 2014. Automatic and probabilistic foehn diagnosis with a statistical mixture model. *Journal of Applied Meteorology and Climatology* 53, 652–659. doi:10.1175/JAMC-D-13-0267.1.
- Polidori, L., El Hage, M., 2020. Digital elevation model quality assessment methods: A critical review. *Remote sensing* 12, 3522.
- Poulos, G., Zhong, S., 2008. An observational history of small-scale katabatic winds in mid-latitudes. *Geography Compass* 2, 1798–1821. doi:10.1111/j.1749-8198.2008.00166.x.
- Purves, R., Barton, J., Mackaness, W., Sugden, D., 1998. The development of a rule-based spatial model of wind transport and deposition of snow. *Annals of Glaciology* 26, 197–202. doi:10.3189/1998AoS26-1-197-202.
- Quine, C.P., White, I.M.S., 1994. Using the relationship between rate of tatter and topographic variables to predict site windiness in upland britain. *Forestry: An International Journal of Forest Research* 67, 245–256. doi:10.1093/forestry/67.3.245.
- Reboita, M.S., Assireu, A., da Silva, L.C., Rios, N., 2014. Evidências de circulação de brisa vale-montanha na serra da mantiqueira: Cidade de itajubá-mg. *Ciência e Natura* 36, 61–71.
- Richner, H., Hächler, P., 2013. Understanding and forecasting alpine foehn. *Mountain Weather Research and Forecasting: Recent Progress and Current Challenges*, 219–260.
- Robertson, A., 1986. Estimating mean windflow in hilly terrain from tamarack (*larix lancina* (du roi) k. koch) deformation. *International journal of Biometeorology* 30, 333–349.
- Robertson, A., 1987. The use of trees to study wind. *Arboricultural Journal* 11, 127–143.
- Ruel, J., Pin, D., Spacek, L., Cooper, K., Benoit, R., 1997. The estimation of wind exposure for windthrow hazard rating: comparison between strongblow, mc2, topex and a wind tunnel study. *Forestry: An International Journal of Forest Research* 70, 253–266. doi:10.1093/forestry/70.3.253.
- Ruel, J.C., 1995. Understanding windthrow: silvicultural implications. *The Forestry Chronicle* 71, 434–445.
- Ryan, B.C., 1977. A mathematical model for diagnosis and prediction of surface winds in mountainous terrain. *Journal of Applied Meteorology and Climatology* 16, 571–584.
- dos Santos, A.T.S., e Silva, C.M.S., 2013. Seasonality, interannual variability, and linear tendency of wind speeds in the northeast brazil from 1986 to 2011. *The Scientific World Journal* 2013, 490857. doi:10.1155/2013/490857.
- Santos, A.T.S.d., e Silva, C.M.S., 2013. Seasonality, interannual variability, and linear tendency of wind speeds in the northeast brazil from 1986 to 2011. *The Scientific World Journal* 2013. doi:10.1155/2013/490857.
- Sarli, P., Abdillah, M., Sakti, A., 2020. Relationship between wind incidents and wind-induced damage to construction in west java, indonesia, in: *IOP Conference Series: Earth and Environmental Science*, IOP Publishing. p. 012001.
- Seluchi, M.E., Norte, F.A., Satyamurty, P., Chou, S.C., 2003. Analysis of three situations of the foehn effect over the andes (zonda wind) using the eta-cptec regional model. *Weather and Forecasting* 18, 481–501.
- Sharma, P.K., Warudkar, V., Ahmed, S., 2020. Application of a new method to develop a cfd model to analyze wind characteristics for a complex terrain. *Sustainable Energy Technologies and Assessments* 37, 100580. doi:10.1016/j.seta.2019.100580.
- Sharples, J.J., Mills, G.A., McRae, R.H., Weber, R.O., 2010. Foehn-like winds and elevated fire danger conditions in southeastern australia. *Journal of Applied Meteorology and Climatology* 49, 1067–1095. doi:10.1175/2010JAMC2219.1.
- Silva, B.B.d., Alves, J.J.A., Cavalcanti, E.P., Dantas, R.T., 2002. Potencial eólico na direção predominante do vento no nordeste brasileiro. *Revista Brasileira de Engenharia Agrícola e Ambiental* 6, 431–439. doi:10.1590/S1415-43662002000300009.
- Siqueira, L.F., Querino, C.A.S., da Silva Querino, J.K.A., Pavão, V.M., de Oliveira Leite, L., de Azevedo Passos, L., da Costa, T.A.C.R., Machado, N.G., Nogueira, M.C.d.J.A., Biudes, M.S., 2014. Caracterização do regime de ventos nos municípios de humaitá-am e apuí-am. *EDUCAmazônia* 12, 99–112.
- Solari, G., Repetto, M.P., Burlando, M., De Gaetano, P., Pizzo, M., Tizzi, M., Parodi, M., 2012. The wind forecast for safety management of port areas. *Journal of Wind Engineering and Industrial Aerodynamics* 104, 266–277. doi:10.1016/j.jweia.2012.03.029.

- Soukissian, T., Sotiriou, M.A., 2022. Long-term variability of wind speed and direction in the mediterranean basin. *Wind* 2, 513–534. doi:10.3390/wind2030028.
- Souza, C.J.d., Liberato, A.M., 2019. Análise da velocidade e direção do vento em vilhena, rondônia. *Revista de Administração e Negócios da Amazônia* 11, 344–361.
- Souza, J.S., Espírito-Santo, F.D.B., Fontes, M.A.L., Oliveira-Filho, A.T.d., Botezelli, L., 2003. Análise das variações florísticas e estruturais da comunidade arbórea de um fragmento de floresta semidecídua às margens do rio capivari, lavras-mg. *Revista Árvore* 27, 185–206. doi:10.1590/S0100-67622003000200009.
- Steinblums, I.J., Froehlich, H.A., Lyons, J.K., 1984. Designing stable buffer strips for stream protection. *Journal of Forestry* 82, 49–52. doi:10.1093/jof/82.1.49.
- Szypuła, B., 2017. Digital elevation models in geomorphology. *Hydro-geomorphology-models and trends* , 81–112.
- Sáfadi, T., 2004. Uso de séries temporais na análise de vazão de água na represa de furnas. *Ciência e Agrotecnologia* 28, 142–148. doi:10.1590/S1413-70542004000100019.
- Tabalipa, N.L., Fiori, A.P., 2008. Influência do vento na estabilidade dos taludes da bacia do rio ligeiro, município de pato branco (pr). *Caminhos da Geografia* 9, 82–98.
- Takane, Y., Kondo, H., Kusaka, H., Katagi, J., Nagafuchi, O., Nakazawa, K., Kaneyasu, N., Miyakami, Y., 2017. Foehnlike wind with a traditional foehn effect plus dry-diabatic heating from the ground surface contributing to high temperatures at the end of a leeward area. *Journal of applied meteorology and climatology* 56, 2067–2079. doi:10.1175/JAMC-D-16-0257.1.
- Tappeiner, U., Tappeiner, G., Aschenwald, J., Tasser, E., Ostendorf, B., 2001. Gis-based modelling of spatial pattern of snow cover duration in an alpine area. *Ecological Modelling* 138, 265–275. doi:10.1016/S0304-3800(00)00407-5.
- Terezo, R.F., de Paiva Sampaio, C.A., Funfgelt, K., Rosa, G.O., Liesenberg, V., 2022. Cargas de vento e granizo e combinação última: estudo de caso. *Conjecturas* 22, 1345–1357.
- Tibulo, C., Zanini, R.R., Tibulo, V.D.C., 2018. Comparação do desempenho dos modelos estatísticos aplicados a séries temporais de umidade relativa do ar. *Revista Thema* 15, 808–821. doi:10.15536/thema.15.2018.808-821.874.
- Tidre, P., Biase, N., SILVA, M.d.S., 2013. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região norte do brasil. *Matemática e Estatística em Foco* 1, 57–66.
- Tong, Z., Luo, Y., Zhou, J., 2021. Mapping the urban natural ventilation potential by hydrological simulation, in: *Building Simulation*, Springer. pp. 351–364. doi:10.1007/s12273-020-0755-6.
- Torres, J., García, A., Prieto, E., De Francisco, A., 1999. Characterization of wind speed data according to wind direction. *Solar energy* 66, 57–64.
- Trocchi, A., Muller, K., Coppin, P., Davy, R., Russell, C., Hirsch, A.L., 2012. Long-term wind speed trends over australia. *Journal of Climate* 25, 170–183. doi:10.1175/2011JCLI4198.1.
- Vickery, P.J., Liu, F., Lin, J.X., 2023. Development of topographic wind speedups and hurricane hazard maps for puerto rico. *Journal of Structural Engineering* 149, 04023130.
- Wang, X., Chen, W., Xia, J., Chen, Z., Xu, D., Wu, X., Xu, M., Schreck, T., 2020. Conceptexplorer: Visual analysis of concept drifts in multi-source time-series data, in: *2020 IEEE Conference on Visual Analytics Science and Technology (VAST)*, IEEE. pp. 1–11.
- Winstral, A., Elder, K., Davis, R.E., 2002. Spatial snow modeling of wind-redistributed snow using terrain-based parameters. *Journal of hydrometeorology* 3, 524–538.
- Yan, B., Chan, P., Li, Q., He, Y., Shu, Z., 2020. Characterising the fractal dimension of wind speed time series under different terrain conditions. *Journal of Wind Engineering and Industrial Aerodynamics* 201, 104165. doi:10.1016/j.jweia.2020.104165.
- Yang, Q., Gao, R., Bai, F., Li, T., Tamura, Y., 2018. Damage to buildings and structures due to recent devastating wind hazards in east asia. *Natural Hazards* 92, 1321–1353. doi:10.1007/s11069-018-3253-8.
- Yang, X., Li, F., Fan, W., Liu, G., Yu, Y., 2021. Evaluating the efficiency of wind protection by windbreaks based on remote

- sensing and geographic information systems. *Agroforestry Systems* 95, 353–365. doi:10.1007/s10457-021-00594-x.
- Zeng, H., Talkkari, A., Peltola, H., Kellomäki, S., 2007. A gis-based decision support system for risk assessment of wind damage in forest management. *Environmental Modelling & Software* 22, 1240–1249.
- Zhao, E., Zhao, J., Liu, L., Su, Z., An, N., 2015. Hybrid wind speed prediction based on a self-adaptive arimax model with an exogenous wrf simulation. *Energies* 9, 7. doi:10.3390/en9010007.

**ARTIGO 2 - Characterization of Wind Speed and Direction in the
Ribeirão Vermelho Catchment Area and its Relationship with
Disaster**

Redigido conforme as normas da revista *Natural Hazard* (versão submetida).

1 Characterization of Wind Speed and Direction in the Ribeirão Vermelho
 2 Watershed During Disaster Event

3 Orlando Eduardo Chipura^a, Marcelo de Carvalho Alves^{a,1}, Luiz Gonsaga de Carvalho^a, Fortunato Silva de
 4 Menezes^b

^aEngineering School (EENG) Agriculture Engineering Department UFLA Campus Lavras 37200-000 Brazil

^bInstitute of Natural Sciences (ICN) Physics Department UFLA Campus Lavras 37200-000 Brazil.

5 **Abstract**

Wind is a key climate variable of interest in many applications, from infrastructure damage assessments to environmental and socioeconomic risks, including wind power utilization. The objective was to analyze the temporal variation in wind speed and direction recorded between 2010 and 2023 in the Ribeirão Vermelho watershed, Minas Gerais, Brazil, in order to identify long-term trends and statistically characterize extreme events potentially associated with natural disasters. The data were obtained from the Meteorological Database for Teaching and Research (BDMEP) and the Automatic Meteorological Station located at the Federal University of Lavras (UFLA). Descriptive analyses were performed, the coefficient of variation was calculated, and the Mann-Kendall test was applied to detect significant temporal trends in the BDMEP data. A statistically consistent reduction in average wind speed was observed over the period analyzed, concomitant with the occurrence of isolated events of sudden intensification. The average speed was 1.83 ms^{-1} , with minimum values in June (1.54 ms^{-1}) and maximum values in September (2.11 ms^{-1}), with prevailing easterly winds (31.8%). The disastrous event recorded on September 27, 2023, due to the extreme event, at a wind speed of 5.54 ms^{-1} , corresponding to a Z-score of +2.40 and positioning above the 99th percentile of the historical distribution, constitutes a disastrous event, rare with a probability of less than 1% of occurrence. However, the correlation between the statistical anomaly and the observed material damage highlights the importance of standardization by standard deviations and probabilistic quantification for weather risk assessment. The results highlight the need to incorporate robust statistical methodologies and local historical data into early warning systems, as well as into the planning of mitigation and adaptation strategies in the face of extreme winds.

6 *Keywords:*

7 Temporal variability, Extreme events, Z-score, Mann-Kendall test, Risk assessment.

*Corresponding author

Email address: marcelo.alves@ufla.br (Marcelo de Carvalho Alves)

¹Corresponding Author

8 1. Article Highlights

- 9 • There has been a 25% reduction in wind speed in the historical series from 2010 to 2023. In terms of
10 monthly variations, winds from the east and southeast are predominant, while winds from the south
11 are the least common.
- 12 • The study region faces a 50% increased susceptibility to disasters caused by winds at speeds of 5.0
13 ms^{-1} during the rainy season.

14 2. Introduction

15 Wind is one of the most important meteorological variables in the contemporary world Liu et al. (2020),
16 being studied globally yet often neglected locally. It plays a crucial role in various socioeconomic and ecological
17 sectors (Molaei and Lashkari, 2020; Bodas Terassi et al., 2022). Agricultural activities are particularly
18 vulnerable to risks and failures due to changes in climatic elements (Dantas et al., 2007; Ferreira et al.,
19 2024). Among these elements, wind speed and direction can exhibit significant variability Ferreira et al.
20 (2024), which may adversely impact wind energy generation, potentially due to the weakening of this natural
21 resource. Alongside its benefits, wind can also lead to recurring disasters as a result of its variations.

22 Numerous studies emphasize that wind is a fundamental resource for generating wind energy, influencing
23 atmospheric stability and agriculture. Wind can be defined as the movement of air masses from one region to
24 another, driven by differences in atmospheric pressure. Essentially, air moves from areas of higher pressure to
25 areas of lower pressure (Pereira et al., 2002; Böhner and AntoniĆ, 2009; Pitz et al., 2013; Souza and Liberato,
26 2019). The denser cold air forces warmer, humid air upwards, leading to the accelerated development of
27 storm clouds (Sarli et al., 2020). Wind patterns are also affected by the Earth's rotation, centrifugal forces,
28 and the topographical variations of the land, which cause friction with the Earth's surface (Sarli et al., 2020).
29 Additionally, the incompatibility between oceanic and continental influences further impacts wind dynamics
30 (Pitz et al., 2013).

31 In agriculture, wind significantly influences the application of pesticides and the implementation of
32 windbreaks. It is also a key factor in studies that explore the spread of diseases and pollination on farms
33 (Munhoz and Garcia, 2008; Pitz et al., 2013; He, 2022). Wind affects a region's microclimate, which in turn
34 impacts the growth of crops and animals, presenting both favorable and unfavorable effects (Pereira et al.,
35 2002).

36 As the agricultural sector continues to evolve, there is an increasing need to characterize wind speed
37 and direction. This information supports projects that utilize wind for solar dryer construction, enhance
38 water savings, and promote wind as a renewable energy source (Pereira et al., 2002). It is also crucial
39 for developing more efficient irrigation systems Schubert et al. (2022), regulating urban temperatures, and

40 improving outdoor thermal comfort (He, 2022). Wind speed is a critical component in the equations used to
41 estimate evapotranspiration, and any trends in wind flow can affect the water requirements of plants (Molaei
42 and Lashkari, 2020).

43 Extreme winds can have adverse effects on plant growth, influencing processes such as transpiration
44 and photosynthesis. They can also cause mechanical damage, including breaking trees, branches, and
45 leaves, lodging cash crops, and in extreme cases, leading to the death of insects (Munhoz and Garcia, 2008;
46 Godziek and Pawlik, 2023; Ojo and Sadiku, 2023). Additionally, strong winds can inflict significant damage
47 on buildings and agricultural infrastructure, particularly in 2022, 2023, and 2024, affecting many regions
48 worldwide, including Brazil. These strong winds can disrupt communication and power transmission lines
49 (Abd-Elaal et al., 2018).

50 In the energy sector, global demand for energy is rapidly growing, and wind energy plays a vital role in
51 meeting this demand, both worldwide and in Brazil. The northeast, southeast, and southern regions of Brazil
52 Kaja Bantha Navas et al. (2024), especially along the coast, exhibit the highest wind potential, characterized
53 by strong and consistent winds throughout the year (Andrade et al., 2021).

54 Research conducted in the Brazilian northeast Silva et al. (2002) indicates that the predominant wind
55 direction is typically from the east (Munhoz and Garcia, 2008). For the town of Ituverava in São Paulo,
56 studies show that southeast winds dominate for most of the year, with higher-than-average wind intensities
57 observed from August to November. September records the highest wind speeds, while April shows the lowest
58 average speeds.

59 A study by a researcher Bueno et al. (2011) investigating wind gusts and predominant directions in
60 Lavras, Minas Gerais, covering the years 1988 to 2004, revealed strong winds from September to February,
61 which were more probable during these months than in others. Winds exceeding 100.0 kmh^{-1} showed
62 minimal probability across all months. It was also observed that winds generally came from the east and
63 west directions more frequently than from others.

64 In a study conducted in China from 1969 to 2005 Guo et al. (2011), a statistically significant decrease
65 in wind speed was recorded, particularly notable at a 95.0% confidence level. Summer winds showed less
66 reduction compared to winter winds, with winters experiencing weaker winds. This overall decrease in annual
67 average wind speed over the years is attributed to a weakening pressure gradient in the lower troposphere.
68 Similar trends of declining wind speed have been noted Jiang et al. (2010), Troccoli et al. (2012) in China,
69 in parts of the United States and Southern Europe due to changes in atmospheric circulation linked to
70 climate change. Gilliland and Keim (2018) demonstrated the occurrence of reductions in surface wind speeds
71 across various regions in Brazil. According to Alencar et al. (2011), the wind speed has an unusual behavior,
72 presenting strong reductions throughout the series and along the months in the region of Viçosa, Minas
73 Gerais, Brazil.

74 Characterizing wind speed and direction in the Ribeirão Vermelho river basin can improve the placement

75 of agricultural and industrial projects, as well as public and private infrastructure in urban and rural settings.
76 It can also aid in the preventive planting of cash crops and help mitigate disaster risks. This study aims
77 to characterize wind speed and direction, time series trends, and the impact of wind-induced disasters in
78 the river basin region, contributing valuable insights for future research on climate change, agricultural
79 production, renewable energy, and effective disaster prevention systems.

80 **3. Material and Methods**

81 *3.1. Characterization of the Study Area*

82 The Ribeirão Vermelho River basin is located entirely in the state of Minas Gerais, Brazil, between the
83 coordinates of 21°26' to 21°18' South latitude and 44°95' to 45°07' West longitude (See Figure 1). This basin
84 includes the tributary that flows through the urban area of Lavras, extending approximately 15 km before it
85 merges with the Rio Grande. According to the Köppen classification, the region's climate is classified as
86 Cwb, which is characterized as temperate rainy (mesothermal), exhibiting dry winters and rainy summers.
87 The average annual temperature is 19.3 °C, with the hottest month averaging 21.3 °C, while the coldest
88 month averages 15.1 °C. The average annual total precipitation is 1.530 mm (Alvares et al., 2013).

89 *3.2. Computer language and packages used for wind speed data analysis*

90 The statistical programming language R, widely used for data analysis, was employed in this study.
91 RStudio, an Integrated Development Environment (IDE) for R, is freely accessible (Hengl et al., 2010). The
92 packages listed in Table 2 and the functions detailed in Table 3 were utilized to characterize and statistically
93 analyze the wind speed and direction data.

94 *3.3. Collection and Processing of Meteorological Data*

95 Hourly data (at 12:00 p.m., 6:00 p.m., and 00:00 UTC) from the study area's wind speed and direction
96 time series were utilized. The data covered the period from January 1, 2010, to December 31, 2023, during
97 which daily averages were calculated. Data were collected at the conventional meteorological station of the
98 National Institute of Meteorology (INMET), located on the campus of the Federal University of Lavras
99 (UFLA) at the coordinates of 21°13'34"S, 44°58'46"W, at an altitude of 916 m. This data is available in the
100 Meteorological Database for Teaching and Research (BDMEP) in *Excel* format. Wind speed and direction
101 were measured by an anemometer positioned 10 m above the ground, following the guidelines set forth by the
102 World Meteorological Organization (WMO) regarding the global observing system and technical regulations
103 on meteorological observations. Additionally, data collected from an automatic station located at the Federal

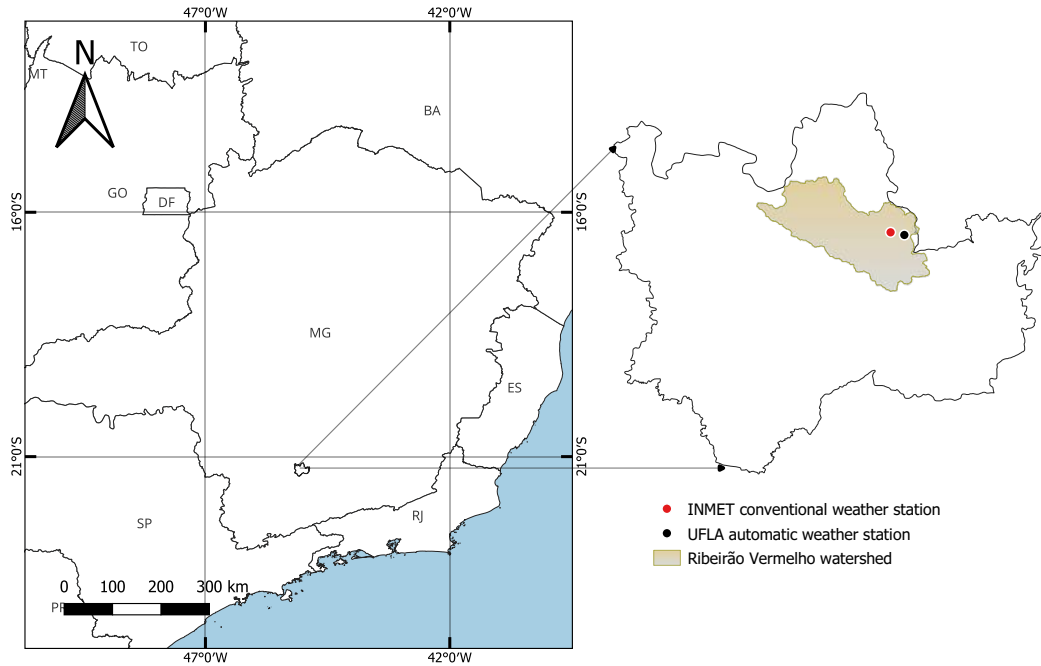


Figure 1: Location of the Ribeirão Vermelho catchment area, Lavras, Minas Gerais, Brazil.

104 University of Lavras, at coordinates $21^{\circ}13'41''S$, $44^{\circ}58'10''W$ and 940 m above sea level, were included since
 105 some data from the BDMEP were missing, particularly on September 27, 2023, which was notable for strong
 106 winds that caused disasters in the urban region of Lavras within the hydrographic basin.

107 Moreover, wind speed and direction data can also be obtained from the Global Forecast System (GFS)
 108 of the National Weather Service (NWS) of the United States, which collects atmospheric model data from
 109 NOAA/NCEP. This data features a geospatial resolution of 0.5° (approximately 50 km), with measurements
 110 taken 10 m above the Earth's surface (Alves and Sanches, 2023).

111 Tests were conducted to evaluate the monthly, annual, and inter-annual variations in wind speed and
 112 direction. Monthly average speeds were calculated from daily averages, while the annual average wind
 113 across the Ribeirão Vermelho River basin was derived from the daily averages of the National Institute of
 114 Meteorology dataset. The data were imported into R using the `xlsx` library, along with equations applied by
 115 (dos Santos and e Silva, 2013; Soukissian and Sotiriou, 2022).

116 The basic time index was represented as t , where $u(t_i) = u_i$ and $\theta(t_i) = \theta_i$, for $i = 1, 2, \dots$. The time
 117 series of wind speed and direction are denoted as such. The scale for t_i is in hours, with months indicated

Table 2: R packages of interest in research on the characterization of wind speed and direction in the Ribeirão Vermelho river basin, Minas Gerais, Brazil from 2010-2023.

| Package | Description | Reference |
|------------------------|---|-------------------------------|
| <code>rWind</code> | Used to manage wind data and calculate averages. | Fernández-López et al. (2022) |
| <code>ggplot2</code> | Used in the implementation of graph grammar and for mapping survey data. | Wickham et al. (2016) |
| <code>openair</code> | Used to analyze, interpret and understand meteorological data as the function <code>windRose</code> , that visualizes the wind direction. | Carslaw and Ropkins (2014) |
| <code>xlsx</code> | Provided functions to read, write and format the wind database in Excel 2007 format using R. | Dragulescu et al. (2020) |
| <code>tidyverse</code> | Made it easy to install and load multiple "tidyverse" packages in a single step applied in the study. | Wickham and Wickham (2019) |
| <code>psych</code> | It was used to perform basic descriptive statistics on the data. | Revelle and Revelle (2015) |
| <code>dplyr</code> | A fast library and was used for manipulating data frame type objects. | Wickham and Wickham (2020) |

118 as m and years as j . Consequently, the mean annual wind speed for a given year j was calculated using
 119 Equation 1 (Soukissian and Sotiriou, 2022).

$$m_{u,j} = \frac{1}{N} \sum_{i=1}^N u_i, \quad (1)$$

120 where, N is the number of observations in a year. The mean annual wind speed $m_{u,Y}$ was then calculated
 121 using Equation 2.

$$m_{u,Y} = \frac{1}{J} \sum_{j=1}^J m_{u,j}, \quad (2)$$

122 where, J is the total number of years. Similarly, the monthly mean wind speed for a given year j and
 123 month m was calculated using Equation 3.

$$m_{u,j,m} = \frac{1}{K} \sum_{i=1}^K u_i, \quad (3)$$

124 where, K is the total number of hours for the given month and year and $m = 1, 2, \dots, 12$. Consequently,
 125 the monthly mean wind speed for a given month $m, m_{u,M=m}$ is calculated using Equation 4.

Table 3: Functions of the `openair` and `rWind` libraries of interest in research on the characterization of wind speed and direction in the Ribeirão Vermelho river basin, Minas Gerais, Brazil from 2010-2023.

| Function | Description | Reference |
|------------------------|---|-------------------------------|
| <code>windRose</code> | Function from the <code>openair</code> package, was used to build the wind rose, showing the wind direction and to obtain the values corresponding to the observed frequencies. | Carslaw and Ropkins (2014) |
| <code>wind.mean</code> | Used to calculate the average wind speed and perform the processing of the historical series data set. | Fernández-López et al. (2022) |

$$m_{u,m} = \frac{1}{J} \sum_{j=1}^J m_{u,j,m}, m = 1, 2, \dots, 12. \quad (4)$$

126 According to Schubert et al. (2022), the variation in the hourly mean wind speed in the different intervals
 127 of the analyzed period is characterized by means of the standard deviation (σ) and coefficient of variation
 128 (CV (%)) given respectively by:

129 Calculation of standard deviation using Equation 5,

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (5)$$

130 where, σ is the Standard deviation, \bar{x} is the average wind speed in the month, x_i is the wind speed of the
 131 region, N representing the number of hourly data in that interval of the total analysis period (Schubert et al.,
 132 2022). Calculation of the coefficient of variation considering Equation 6.

$$CV = \frac{\sigma}{\bar{x}} \times 100 \quad (6)$$

133 where, CV (%) is the coefficient of variation, σ is the standard deviation and \bar{x} representing the monthly
 134 average of the wind speed (Schubert et al., 2022).

135 The trend of the wind speed in the historical series was analyzed based on the nonparametric Mann-
 136 Kendall test, that is, the data did not need to belong to a specific distribution according to (Goossens and
 137 Berger, 1986; Cardoso et al., 2016). Another advantage is that the result is less affected by outliers, since
 138 its calculation is based on the sign of the differences and not directly on the values of the variables as per
 139 Cardoso et al. (2016), suggested by the World Meteorological Organization (WMO) and proposed by Sneyers
 140 (1975) according to (dos Santos and e Silva, 2013; Pes et al., 2017). The test is used to assess whether there
 141 is a monotonic upward or downward trend of the variable over time Kaja Bantha Navas et al. (2024) through
 142 a nonparametric trend regression analysis (Andrade et al., 2021). The test consisted of comparing each value

143 of the historical series with the remaining values in sequential order, based on the statistical term, using
 144 Equation 5 (Andrade et al., 2021; Kaja Bantha Navas et al., 2024).

$$S = \sum_{i=2}^n \sum_{j=1}^{i-1} sinal(x_i - x_j), \quad (7)$$

145 where, x_j is the first value after x_i and n is the sample size (dos Santos and e Silva, 2013; Lima et al.,
 146 2024). It also consisted of analyzing the signal below

$$sinal = \begin{cases} +1, & \text{se } (x_i - x_j) > 0 \\ 0, & \text{se } (x_i - x_j) = 0 \\ -1, & \text{se } (x_i - x_j) < 0 \end{cases}$$

147 The value of S was used to calculate the Kendall coefficient (τ) using Equation 8, which is a normalized
 148 version of S , ranging from -1 to 1.

$$\tau = \frac{S}{\binom{n}{2}} \quad (8)$$

149 where, S measures the absolute number of pairs with trends, τ expresses the trend in terms of proportion,
 150 making the results comparable between different time series and $\binom{n}{2}$ calculates the total number of pairs of
 151 observations (x_i, x_j) where $i > j$.

152 Equation 9 was considered to calculate the percentage of calm winds, taking as a basis wind speeds below
 153 0.5 ms^{-1} as calm according to (Pavanate and Fleischfresser, 2017).

$$\text{Calm_winds (\%)} = \frac{N_{\text{calm}}}{N_{\text{total}}} \quad (9)$$

154 where, N_{calm} is the number of observations where the wind speed is lower than the defined threshold (0.5
 155 ms^{-1}). N_{total} is the total number of observations. The *openair* package has a function called *windRose()*,
 156 which was used to create wind rose graphs and also reports the frequency of calm winds and the monthly
 157 average in the Grange (2014) graph considering the historical series from 2010 to 2023 for the river basin
 158 region.

159 3.3.1. Determining the relationship between wind speed and the occurrence of disasters

160 In order to relate wind speed and the occurrence of disasters in the Ribeirão Vermelho watershed,
 161 statistical standardization was adopted through the calculation of standardized anomalies (Z-score), described
 162 in Wilks (2011) to characterize the relative intensity of the wind observed on September 27, 2023. The
 163 calculation of the Z-score of 5.54 ms^{-1} (wind speed at the time of the disaster) is a clear approach compared
 164 to September's mean and standard deviation.

$$Z = \frac{X - \mu}{\sigma} \quad (10)$$

165 where, $X = 5.54 \text{ ms}^{-1}$ is the observed wind speed, $\mu = 2.11 \text{ ms}^{-1}$ is the standard deviation for September,
 166 and $\sigma = 1.43 \text{ ms}^{-1}$ is the mean for September.

$$Z = \frac{X - \mu}{\sigma} \quad (11)$$

167 where, X is the observed wind speed, μ is the average wind speed in September, σ is the standard
 168 deviation of wind speed in September.

169 The prevailing wind direction was demonstrated using the wind rose based on Equation 12, *openair* library
 170 and *windRose* function proposed by (Grange, 2014). The data collected and made available through BDMEP
 171 are encoded as synop messages, following the codes NE/5, E/09, SE/14, S/18, SW/23, W/27, NW/32, N/36.
 172 The synop message was converted into degrees from the north direction, following the command of the code
 173 in Figure 2 in R.

```

dados$Dir[dados$Dir=="E"]<-90
dados$Dir[dados$Dir=="N"]<-360
dados$Dir[dados$Dir=="NE"]<-45
dados$Dir[dados$Dir=="NW"]<-315
dados$Dir[dados$Dir=="W"]<-270
dados$Dir[dados$Dir=="S"]<-180
dados$Dir[dados$Dir=="SE"]<-135
dados$Dir[dados$Dir=="SW"]<-225

#convert to numeric
dados$Dir<-as.numeric(dados$Dir)
dados$Vel.<-as.numeric(dados$Vel.)

#change variable names (columns)
colnames(dados)<-c("wd","ws")

x11() #create extra window
windRose(dados,paddle = FALSE)

```

Figure 2: Example code to replace synop messages in degrees from the north direction and create a wind rose for the Ribeirão Vermelho river basin region, Minas Gerais, Brazil.

174 The predominant wind direction was characterized by performing a frequency analysis of the daily average
 175 observations, using Expression 10 according to Grange (2014) for each month of the year.

$$\bar{\theta}_{RV} = \arctan\left(\frac{\bar{u}}{\bar{v}}\right) + flow \quad (12)$$

176 $flow = + 180$ for $\arctan\left(\frac{\bar{u}}{\bar{v}}\right) < 180$

177 $flow = - 180$ for $\arctan\left(\frac{\bar{u}}{\bar{v}}\right) > 180$

178 where, $\bar{\theta}_{RV}$ represents the wind direction, \bar{u} is used for the horizontal wind measurement and \bar{v} represents
179 the east-west and north-south components.

180 The direction frequencies were plotted on radar charts (Figure 7) for better visualization. The directions
181 were put in acronyms and represented by: north (N), east (E), west (W), south (S), northeast (NE), northwest
182 (NW), southeast (SE), southwest (SW). To facilitate visualization of the variation in wind direction throughout
183 the year, the predominant wind direction was considered without interference from speed, through the radar
184 chart and frequency analysis according to the study by (Costa and Lyra, 2012).

185 The calculation of wind direction frequencies for daily averages was described probabilistically through
186 the simple relative frequency (fr_d) for each month in the year of the period considered, whose estimate is
187 given by Equation 11 used by Schubert et al. (2022):

$$fr_d = \frac{f_d}{n} \times 100 \quad (13)$$

188 where, f_d is the absolute frequency of each direction and n is the number of observations within the
189 month analyzed.

190 In general, the characterization of wind speed was performed through summary measures (averages,
191 standard deviation, coefficient of variation) and the Mann-Kendall test. Therefore, it was possible to
192 characterize the average wind speed, as well as its variation, to understand the risk and disasters observed in
193 the region.

194 4. Results

195 4.1. Descriptive statistics of the historical wind speed series in the Ribeirão Vermelho river basin

196 The historical wind speed series presents maximum and minimum data ranging from 0.0 to 13.6 ms^{-1}
197 according to Tables 4 and 5. It was found that the mean, median, standard deviation and coefficient of
198 variation for the historical series were 1.83, 2.0, 1.31 and 71.58 ms^{-1} , respectively. Figure 1 shows the
199 asymmetric distribution of the data according to the histogram in Figure 3 (on the left) and the presence of
200 extreme values (outliers), represented by the symbol ($^{\circ}$), according to the boxplot in Figure 3 (right) and
201 Figure 4.




Figure 3: Asymmetric distribution represented by the histogram (left) and boxplot (right) of wind speed data in the Ribeirão Vermelho watershed, Minas Gerais, Brazil.

202 4.2. Monthly variation of wind speed in the Ribeirão Vermelho watershed

203 The results in Table 4 represent averages of the statistical tests of wind speed, expressed in ms^{-1} for the
 204 period corresponding to January to December. The characterization of wind speed in the study region is
 205 subdivided into: windier and more stable months include the months with a high average, low coefficient of
 206 variation and less calm winds. Namely, September (2.11 ms^{-1}) and August (2.07 ms^{-1}) were the months that
 207 presented the highest averages, low wind speed variability $\text{CV} < 70.0\%$, in relation to the standard deviation,
 208 August (1.38 ms^{-1}) and September (1.43 ms^{-1}) also show greater dispersion, suggesting windier periods.
 209 This fact corroborates the analysis of calm winds, demonstrating that August (13.0%), September (13.2%)
 210 and November (13.0%) have fewer occurrences of calms, indicating greater persistence and continuity of the
 211 winds. Therefore, higher averages are more promising for wind power generation, as occurs in the months of
 212 August and September, due to the combination of strong winds, moderate variability and few calms.

213 The monthly wind variation in the region is also characterized by less windy conditions, represented
 214 by low mean, high coefficient of variation, and calmer winds. June (1.54 ms^{-1}) and January (1.67 ms^{-1})
 215 suggest calmer conditions, with reduced speeds. These months showed high CV values ($> 70\%$), with June
 216 (79.22%) and January (76.04%) showing high relative variability, even with low averages. This suggests that,

Table 4: Monthly variation of wind characteristics in the Ribeirão Vermelho watershed, Minas Gerais, Brazil, from 2010 to 2023. Measurements include mean, standard deviation (SD), coefficient of variation (CV), and percentage of calm winds (ms^{-1}).

| Month | Minimum | Maximum | Average | Median | SD | CV (%) | % Calm Winds |
|-----------|---------|---------|---------|--------|------|--------|--------------|
| January | 0.0 | 9.1 | 1.67 | 1.60 | 1.27 | 76.04 | 18.1 |
| February | 0.0 | 10.0 | 1.69 | 1.80 | 1.16 | 68.63 | 15.6 |
| March | 0.0 | 6.0 | 1.73 | 1.80 | 1.23 | 71.09 | 15.3 |
| April | 0.0 | 6.1 | 1.79 | 2.00 | 1.21 | 67.60 | 14.6 |
| May | 0.0 | 6.1 | 1.70 | 1.60 | 1.60 | 94.12 | 15.3 |
| June | 0.0 | 6.6 | 1.54 | 1.30 | 1.22 | 79.22 | 20.7 |
| July | 0.0 | 7.5 | 1.80 | 2.00 | 1.30 | 72.22 | 17.0 |
| August | 0.0 | 7.8 | 2.07 | 2.00 | 1.38 | 66.67 | 13.0 |
| September | 0.0 | 7.1 | 2.11 | 2.00 | 1.43 | 67.77 | 13.2 |
| October | 0.0 | 6.3 | 2.07 | 2.00 | 1.40 | 67.63 | 13.2 |
| November | 0.0 | 13.6 | 2.01 | 2.00 | 1.37 | 68.16 | 13.0 |
| December | 0.0 | 8.3 | 1.73 | 1.80 | 1.28 | 73.99 | 17.2 |

217 although the winds are weaker, they are highly unpredictable, with significant variations in short periods.
 218 However, these months were the ones with calmer winds ($> 18.0\%$). June (20.7%) and January (18.1%)
 219 showed weaker winds and stable conditions, which may be unfavorable months for wind power generation,
 220 but useful for activities that depend on less turbulence, such as agricultural practices in the river basin region.
 221 In general, June and January are characterized by weaker winds, high variability and a higher frequency of
 222 calms, making them less suitable for wind-dependent applications.

223 Still regarding characterization, the months of April and October are characterized by intermediate speeds.
 224 The average wind speed for April was 1.79 ms^{-1} and for October it was 2.07 ms^{-1} . The standard deviation
 225 for April (1.21 ms^{-1}) and October (1.40 ms^{-1}) and a CV are close to 67.0%. Both months present moderate
 226 speeds, with October being slightly more intense. The standard deviation suggests controlled dispersions,
 227 with April being more stable. However, the CV suggests the occurrence of low relative variability of the
 228 wind, being more predictable and consistent. The occurrence of relatively calm winds was also observed in
 229 April (14.6%) and October (13.2%), which reinforces the continuity of the wind throughout the month.

230 Thus, the difference between the averages ($2.11 - 1.54 = 0.57 \text{ ms}^{-1}$) shows that the average wind speed
 231 in September is about 37.0% higher than in June. This contrast reinforces the seasonal variation in wind
 232 patterns throughout the year. The months of February (1.69 ms^{-1}) and April (1.79 ms^{-1}) show intermediate
 233 averages, suggesting smooth (stable) transitions between periods of higher and lower wind intensity.

234 *4.3. Annual and interannual variation of wind speed in the Ribeirão Vermelho river basin*

235 The annual characterization of wind speed (ms^{-1}) based on the average reveals important patterns over
 236 the period from 2010 to 2023, highlighting significant trends and variations, ranging from 2010 (2.30 ms^{-1})
 237 and 2023 (1.29 ms^{-1}), indicating a general trend of weakening winds over the period. Higher averages were
 238 observed at the beginning of the historical series (2010-2014). Average values range from 2.22 ms^{-1} (2013)
 239 to 2.37 ms^{-1} (2011), presenting the highest average wind speeds in the analyzed period. Speeds above 2.0
 240 ms^{-1} suggest favorable conditions for wind applications. The average wind speed drops to 1.94 ms^{-1} (2015)
 241 and reaches 1.79 ms^{-1} (2017), characterized by a progressive decrease in wind speed, signaling a period of
 242 transition to weaker winds. The reduction in wind speed was also observed in the following years, reaching
 243 1.43 ms^{-1} (2018) and 1.57 ms^{-1} (2020), characterized by weak winds, which may be insufficient for efficient
 244 use of wind energy. The continuous reduction in averages is also observed at the end of the historical series,
 245 1.46 ms^{-1} (2021) to the lowest average value recorded of 1.29 ms^{-1} (2023) consolidating a trend of weak
 246 winds.

Table 5: Monthly variation of wind characteristics in the Ribeirão Vermelho watershed, Minas Gerais, Brazil, from 2010 to 2023. Measurements include mean, standard deviation (SD), coefficient of variation (CV), and percentage of calm winds (ms^{-1}).

| Year | Minimum | Maximum | Average | Median | SD | CV (%) | % Calm Winds |
|-----------|---------|---------|---------|--------|------|--------|--------------|
| 2010 | 0.0 | 13.6 | 2.30 | 2.10 | 1.31 | 56.96 | 2.5 |
| 2011 | 0.0 | 7.8 | 2.37 | 2.30 | 1.25 | 52.74 | 1.7 |
| 2012 | 0.0 | 9.1 | 2.35 | 2.30 | 1.30 | 55.32 | 1.7 |
| 2013 | 0.0 | 7.5 | 2.22 | 2.10 | 1.20 | 54.05 | 1.7 |
| 2014 | 0.0 | 8.0 | 2.31 | 2.30 | 1.24 | 53.68 | 1.6 |
| 2015 | 0.0 | 10.0 | 1.94 | 2.00 | 1.20 | 61.85 | 6.2 |
| 2016 | 0.0 | 6.0 | 1.57 | 1.00 | 1.12 | 71.33 | 14.5 |
| 2017 | 0.0 | 6.0 | 1.79 | 2.00 | 1.12 | 62.57 | 14.5 |
| 2018 | 0.0 | 5.0 | 1.43 | 1.00 | 1.06 | 74.12 | 22.1 |
| 2019 | 0.0 | 6.0 | 1.52 | 1.00 | 1.31 | 86.18 | 28.5 |
| 2020 | 0.0 | 6.0 | 1.57 | 1.00 | 1.41 | 89.80 | 30.4 |
| 2021 | 0.0 | 6.0 | 1.46 | 1.00 | 1.24 | 84.93 | 27.7 |
| 2022 | 0.0 | 6.0 | 1.35 | 1.00 | 1.36 | 100.0 | 36.0 |
| 2023 | 0.0 | 6.17 | 1.29 | 1.00 | 1.30 | 100.0 | 34.9 |
| 2010-2023 | 0.0 | 13.6 | 1.83 | 2.00 | 1.31 | 71.58 | 15.5 |

247 However, the mean speed in 2023 (1.29 ms^{-1}) is about 45.0% lower than the mean recorded in 2011 (2.37
 248 ms^{-1}). Overall, the inter-annual mean was 1.83 ms^{-1} , corresponding to a gradual decline in wind speed over

249 the years 2010 to 2023.

250 Calm winds range from 1.6% (2014) to 2.5% (2010), characterized by the majority of days marked by
 251 active winds. The low occurrence of calms in this period is a sign that the winds were relatively consistent
 252 and frequent. There was a gradual increase in calm winds to 6.2% (2015) and 14.5% (2017), characterized
 253 by a gradual increase from 2015 onwards and a sharp increase in the following years, as occurred in 2018
 254 (22.1%) and 2020 (30.4%), indicating that, in more than a third of the time, the wind was practically absent.
 255 The maximum values of calm winds were 36.0% (2022) and 34.9% (2023), indicating that in the last years of
 256 the series, the frequency of calm winds remains high, with approximately 35.0% of the days with almost no
 257 winds. However, in 2022, the value of 36% represents the highest percentage recorded, suggesting a high
 258 incidence of calms. The continuation of this trend suggests that weak or absent winds are becoming an
 259 increasingly frequent pattern along the Ribeirão Vermelho watershed. The monthly and annual variation of
 260 wind speed in the study region can also be characterized based on the analysis of the boxplot in Figure 4.

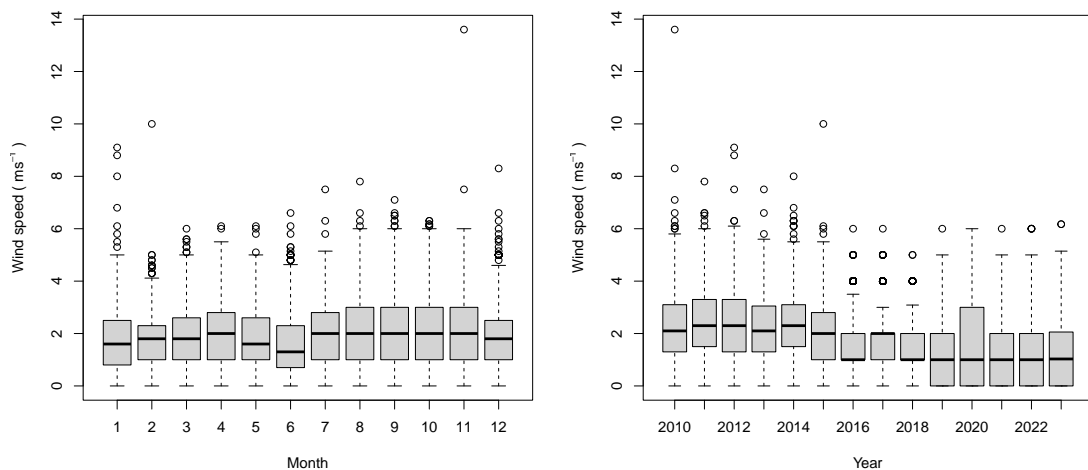


Figure 4: Boxplot of monthly (left) and annual (right) wind speed variation in the Ribeirão Vermelho river basin, Minas Gerais, Brazil from 2010 to 2023.

261 Through the calculations of the statistical tests, it was demonstrated that there was an increase in the
 262 coefficient of variation of the wind over the years, ranging from 56.96% in the year 2010 to 100.0% in the years
 263 2022 and 2023 indicating that the wind speed became more variable and less predictable. A higher coefficient
 264 of variation suggests that there is a greater dispersion of values in relation to the average, which may be
 265 indicative of more unstable weather conditions. Regarding the standard deviation, the results indicate that
 266 the wind speed remained relatively constant over time, with values around 1.06 to 1.36 ms^{-1} , suggesting that,
 267 despite the reduction in the average, the variation around the average has been relatively stable. However,

268 the inter-annual analysis showed that the average speed of the historical series was 1.83 ms^{-1} .

269 As we mentioned, the beginning of the series (2010-2014) presents average wind speeds above 2.0 m^{-1} , with
 270 an average corresponding to 2.28 m^{-1} in the period under analysis. In the second period (2015-2023), the
 271 average wind speed was lower (1.72 m^{-1}), the average of the initial period. Thus, in the final period the wind
 272 speed was 25.0% lower than in the initial period, which suggests a significant decrease in wind intensity over
 273 the years.

274 4.4. Monthly trend of wind speed in the Ribeirão Vermelho river basin

275 According to Table 5, the results indicate that there was a consistent trend of reduced wind speed in all
 276 months under analysis, which may be related to regional climate changes, altered meteorological patterns,
 277 including environmental ones that may affect atmospheric circulation.

278 The Mann-Kendall test demonstrated a statistically significant trend of reduced wind speed for all months
 279 according to the p-value, suggesting that there was a decrease in wind speed, characterized as being significant
 280 for the data set. However, although all months demonstrate a trend of reduced wind speed, the intensity
 281 of this trend varies. It can be seen that in January there was the greatest downward trend (-0.294), while
 282 in May there was a smaller downward trend (-0.158), suggesting that changes in wind speed may be more
 283 pronounced at certain times of the year, as can also be seen in Table 3.

Table 6: Monthly trend of wind speed in the Ribeirão Vermelho river basin

| Month | Kendall's coefficient | p-value |
|-----------|-----------------------|----------------|
| January | -0.294 | 2.22e-16 *** |
| February | -0.229 | 2.22e-16 *** |
| March | -0.252 | 2.22e-16 *** |
| April | -0.199 | 2.22e-16 *** |
| May | -0.158 | 7.5551e-16 *** |
| June | -0.196 | 2.22e-16 *** |
| July | -0.170 | 2.22e-16 *** |
| August | -0.159 | 3.8672e-16 *** |
| September | -0.178 | 2.22e-16 *** |
| October | -0.198 | 2.22e-16 *** |
| November | -0.184 | 2.22e-16 *** |
| December | -0.216 | 2.22e-16 *** |

Significance: *** (0.01)

284 4.5. Annual and inter-annual trend of wind speed in the Ribeirão Vermelho river basin

285 Regarding the variation in the annual average wind speed, it was possible to observe an increasing trend
 286 in the data variation, with the exception of 2015, where a decreasing trend was observed. Significance levels
 287 ranged from non-significant in the years 2014, 2017, 2018 with a p-value greater than 0.05, highly significant
 288 at the 1% level in the years 2011, 2013, 2015, 2019, 2020, 2021 and 2022, presenting a p-value ≤ 0.01 and
 289 statistically significant at the 5% level in the years 2012, 2016 and 2023, presenting a p-value ≤ 0.05 .

Table 7: Annual wind speed trend in the Ribeirão Vermelho river basin

| Year | Kendall's coefficient | p-valor |
|-----------|-----------------------|--------------|
| 2010 | 0.076 | 0.00022 *** |
| 2011 | 0.103 | 5.96e-07 *** |
| 2012 | 0.056 | 0.00625 ** |
| 2013 | 0.074 | 0.00036 *** |
| 2014 | 0.002 | 0.9264 NS |
| 2015 | -0.087 | 3.15e-05 *** |
| 2016 | 0.067 | 0.00294 ** |
| 2017 | 0.011 | 0.61175 NS |
| 2018 | 0.007 | 0.76971 NS |
| 2019 | 0.112 | 8.34e-07 *** |
| 2020 | 0.121 | 1.43e-06 *** |
| 2021 | 0.089 | 9.76e-05 *** |
| 2022 | 0.138 | 2.22e-16 *** |
| 2023 | 0.066 | 0.00474 ** |
| 2010-2023 | -0.196 | 2.22e-16 *** |

Significance: *** (0.01), ** (0.05)

NS - not significant at 5% probability

290 The wind speed in the years 2010, 2011, 2019, 2020 and 2022 was characterized by a moderate increasing
 291 trend. In this period, the Kendall coefficient ranged from 0.076 to 0.138. For the years 2012, 2013, 2016 and
 292 2023 the wind speed trend was weakly increasing where the Kendall coefficient ranged from 0.056 to 0.074.
 293 In 2014, no significant trend in wind speed was observed, with the magnitude of Kendall's coefficient being
 294 very close to zero (0.002). In 2015, there was a weak decreasing trend, with the magnitude of Kendall's
 295 coefficient being -0.087. Between 2017 and 2018, there was a very weak increasing trend in wind speed, with
 296 the Kendall coefficient being 0.011 and 0.007, respectively. Only in 2021 was there a weak to moderate wind
 297 speed trend with a Kendall coefficient of 0.089.

298 *4.6. Disasters caused by extreme winds in the Ribeirão Vermelho river basin*

299 The meteorological results for the river basin region demonstrate a significant reduction in wind speed
 300 from 2015-2023 (25.0%) compared to 2010-2014. Despite the occurrence of a reduction in wind speed,
 301 on September 27, 2023, an event characterized as extreme winds occurred at the level of the Ribeirão
 302 Vermelho river basin, a dangerous meteorological phenomenon that caused destruction of public and private
 303 infrastructure, mainly in the urban area of Lavras, a region belonging to the river basin. A speed equal to
 304 or above 5.54 ms^{-1} and a gust of 17.38 ms^{-1} were observed, according to data collected at the automatic
 305 meteorological station belonging to the Federal University of Lavras - UFLA, at approximately 3:26 pm.
 306 The destruction of infrastructure occurred mainly along the Dr. Jorge square, Jardim Glória, the university
 307 campus of the Federal University of Lavras, among other locations, as can be seen in Figures 5 and 6, showing
 308 electricity transmission poles, communication systems being knocked down, access roads being blocked, trees
 309 being uprooted, tree branches being broken, roofs being ripped off houses, vehicles being destroyed, and
 310 traffic lights being knocked down.

311 *4.6.1. Relationship between wind speed and the occurrence of disasters in the Ribeirão Vermelho river basin*

312 A standard deviation of 2.4 was observed, above the September mean, indicating a very extreme event
 313 (above the approximate 98% percentile, assuming a normal distribution). This means that 98% of all historical
 314 observations were less than or equal to this value. Only 2% of the records were equal to or greater than this
 315 value. Thus, a wind speed of 5.54 ms^{-1} is stronger than approximately 98% of historical values for September.
 316 This indicates that this event was very rare and unusual. Therefore, in terms of risk, it shows that it is an
 317 extreme event, statistically outside the expected normality. With a Z-score of 2.4, the cumulative probability
 318 (p-value) was estimated, and the corresponding percentile assuming a standard normal distribution was
 319 0.9918.

$$P(Z \leq 2.40) = 0.9918$$

320 where, $P(Z \leq 2.40)$ represents the probability of a value being less than or equal to 5.54 ms^{-1} (given the
 321 September history). This probability was obtained by the cumulative distribution function of the standard
 322 normal. The probability of occurrence of values higher than the observed value was 0.0082, demonstrated by:

$$P(Z > 2.40) = 1 - P(Z \leq 2.40) = 1 - 0.9918 = 0.0082$$

323 This probability indicates that only 0.82% of historical records would have equal or higher values. Thus,
 324 the corresponding percentile can be expressed as 99.18%. The observed value is above approximately 99% of
 325 all historical records for September, characterizing the event as statistically extreme.

326 Table 9 shows hourly data on wind speed and gust recorded by the automatic anemometer on the days of
 327 disasters caused by this climate variable.

Table 8: Statistical summary of extreme wind speed events

| Indicator | Value | Interpretation |
|---------------------------------|------------------------|---------------------------------------|
| Observed speed (X) | 5.54 ms^{-1} | Value recorded on September 27, 2023 |
| Historical mean (μ) | 2.11 ms^{-1} | September mean (2010–2023) |
| Standard deviation (σ) | 1.43 ms^{-1} | Standard deviation for September |
| Z-score | +2.40 | 2.4 standard deviation above the mean |
| Cumulative probability | 99.18% | Corresponding percentile |
| Higher probability | 0.82% | Occurrence of higher values |

Table 9: Date and time of occurrence of disasters under the influence of wind speed (ms^{-1}) in the Ribeirão Vermelho river basin, Minas Gerais, Brazil from 2023-2024.

| Date | Time | Wind speed | Gust |
|------------|-------|------------|-------|
| 09.27.2023 | 15:26 | 5.54 | 17.38 |
| 01.23.2024 | 20:26 | 3.78 | 10.32 |
| 01.31.2024 | 13:41 | 3.27 | 15.86 |
| 02.04.2024 | 19:11 | 3.02 | 7.30 |

328 On January 23rd, 31st, and February 4th, 2024, extreme wind conditions at the level of the river basin
 329 region were repeated, as shown in Table 9, causing disasters such as uprooting trees, breaking branches,
 330 damaging power lines, blocking access roads, and destroying municipal infrastructure such as destroying
 331 sidewalks, with moderate effects compared to those observed on September 27th. However, the effects of
 332 strong winds that resulted in disasters in the affected areas, there were restrictions on the supply of electricity
 333 in some neighborhoods in the river basin region, mainly in the urban area, as shown in figures 5.

334 Figure 6 shows the normal distribution of wind speed in September, with mean of 2.11 m s^{-1} and standard
 335 deviation of 1.43 m s^{-1} , constructed from the historical series between 2010 and 2023. The value observed
 336 at the time of the disaster on September 27, 2023 (5.54 m s^{-1}) is highlighted by a red dashed line, clearly
 337 located at the right end of the probability curve.

338 The area shaded in red represents the cumulative probability of higher speeds occurring, equivalent to only
 339 0.82% of historical records. This position in the 99.18% percentile confirms that the event was statistically
 340 rare and exceptional. Therefore, analysis of the figure reinforces the evidence that the magnitude of the wind
 341 speed observed at the time of the disaster greatly exceeded normal climatological behavior, characterizing
 342 an extreme event with a high impact capacity, which can be considered statistically very anomalous, with
 343 wind speed values significantly higher than the climatological mean, whose occurrence is strongly correlated
 344 with recorded disasters, corroborating the relevance of monitoring and statistical characterization of such
 345 phenomena.



Figure 5: Effect of wind speed on the Ribeirão Vermelho river basin, Minas Gerais, Brazil, on September 27, 2023 (Public domain photo).

346 4.7. Wind direction variation in the Ribeirão Vermelho river basin

347 In the Ribeirão Vermelho river basin region, eastward winds predominate, as shown in Table 9. In general,
 348 southward winds are less predominant throughout the months. The results demonstrate the occurrence of
 349 monthly direction variation, with the exception of the east direction. From April to November, southeasterly
 350 winds also predominate, ranging from 19.9 to 25.9%. From December to March, in addition to eastward
 351 winds, northeasterly winds also predominate, ranging from 20.3 to 22.5%. Likewise, the least predominant
 352 winds were southerly (1.3 to 2.0%) from May to November and southwesterly (2.1 to 2.5%) from December
 353 to April. Northwest, north and west winds are also evident, respectively.

354 The results presented in Table 10 demonstrate the annual variation of wind direction. East winds (31.8%)
 355 were predominant and south (1.9%) was the least predominant direction in the river basin region. For the
 356 annual variation, only southeast winds predominated in the years 2012 (31.1%), 2013 (32.8%) and 2014
 357 (31.8%), for the other periods (years) east winds prevailed, ranging from 30.0% in the year 2011 to 38.0%
 358 in the year 2013, followed by the east direction. As we have stated, in 2023, winds from the east (30.2%),
 359 followed by the northeast (25.8%) direction, with a lower occurrence of winds from the south (0.9%).

360 Regarding the annual variation, northeasterly winds also predominated between 2016 (21.0%) and 2023
 361 (25.8%), followed by southeasterly winds from 2016 (9.9%) to 2023 (15.5%). Contrary to previous trends, as

Table 10: Monthly variation of wind direction in the Ribeirão Vermelho river basin, Minas Gerais, Brazil from 2010-2023 (%).

| Month | N | NE | E | SE | S | SW | W | NW |
|-----------|------|------|------|------|-----|-----|-----|------|
| January | 12.8 | 21.9 | 28.2 | 14.6 | 2.6 | 1.8 | 6.5 | 11.7 |
| February | 8.8 | 22.5 | 32.2 | 15.6 | 2.3 | 2.2 | 5.1 | 11.5 |
| March | 8.5 | 22.0 | 33.9 | 16.4 | 2.3 | 2.6 | 4.9 | 9.5 |
| April | 7.2 | 18.9 | 33.2 | 19.9 | 2.5 | 2.3 | 5.1 | 10.9 |
| May | 5.6 | 18.1 | 32.8 | 18.3 | 1.3 | 2.1 | 8.2 | 13.6 |
| June | 6.8 | 18.9 | 32.8 | 20.5 | 2.0 | 2.0 | 6.0 | 11.0 |
| July | 6.7 | 18.8 | 31.7 | 21.7 | 1.1 | 2.6 | 5.0 | 12.3 |
| August | 4.4 | 17.1 | 34.0 | 25.9 | 1.5 | 2.7 | 5.1 | 9.3 |
| September | 6.2 | 17.4 | 33.6 | 23.3 | 1.8 | 2.5 | 6.0 | 9.2 |
| October | 10.6 | 17.4 | 32.0 | 23.4 | 2.0 | 2.2 | 6.2 | 6.2 |
| November | 6.2 | 17.4 | 33.6 | 23.3 | 1.8 | 2.5 | 6.0 | 9.2 |
| December | 11.0 | 20.3 | 24.4 | 17.3 | 2.1 | 2.9 | 7.1 | 15.0 |

Table 11: Annual variation in wind direction in the Ribeirão Vermelho river basin, Minas Gerais, Brazil from 2010-2023 (%)

| Year | N | NE | E | SE | S | SW | W | NW |
|-----------|------|------|------|------|-----|-----|-----|------|
| 2010 | 9.7 | 17.6 | 30.6 | 16.1 | 2.3 | 3.3 | 7.8 | 12.8 |
| 2011 | 7.6 | 15.5 | 31.0 | 19.9 | 3.0 | 2.8 | 7.0 | 13.2 |
| 2012 | 7.7 | 12.3 | 27.1 | 31.1 | 3.0 | 3.4 | 4.8 | 10.6 |
| 2013 | 9.3 | 11.3 | 24.0 | 32.8 | 3.3 | 2.6 | 3.5 | 13.3 |
| 2014 | 7.8 | 11.6 | 30.3 | 31.8 | 3.7 | 1.4 | 3.4 | 9.9 |
| 2015 | 10.4 | 17.4 | 26.9 | 26.5 | 2.7 | 1.3 | 4.1 | 10.7 |
| 2016 | 7.6 | 22.1 | 38.0 | 9.9 | 1.1 | 2.4 | 8.1 | 10.8 |
| 2017 | 5.3 | 22.5 | 43.8 | 12.0 | 0.8 | 2.1 | 4.9 | 8.6 |
| 2018 | 6.1 | 21.0 | 35.0 | 15.0 | 0.6 | 2.6 | 6.9 | 12.7 |
| 2019 | 5.2 | 23.8 | 36.3 | 14.2 | 1.3 | 1.7 | 6.1 | 11.4 |
| 2020 | 3.5 | 23.9 | 31.9 | 16.8 | 1.1 | 3.5 | 7.3 | 12.0 |
| 2021 | 7.8 | 22.1 | 31.7 | 17.1 | 1.1 | 2.0 | 6.9 | 11.2 |
| 2022 | 7.5 | 22.6 | 31.3 | 16.8 | 0.3 | 1.7 | 6.8 | 13.1 |
| 2023 | 7.4 | 25.8 | 30.2 | 15.5 | 0.9 | 2.9 | 5.5 | 11.7 |
| 2010-2023 | 7.8 | 18.5 | 31.8 | 20.2 | 1.9 | 2.4 | 5.8 | 11.5 |




Figure 6: Normal distribution of wind speed in September from 2010 to 2023 in the Ribeirão Vermelho watershed, Minas Gerais, Brazil, confirming that the event was rare and outside the expected climatological norm, which justifies its association with the occurrence of a disaster.

362 occurred in 2011, the southeasterly direction (19.9%) was recorded as the second most predominant direction
 363 and the northeasterly (15.5%) as the third. There was also a variation in the direction of the less predominant
 364 winds, assuming the southerly direction (0.8 to 3.7%) as the least predominant direction for the series.

365 Therefore, the wind roses of the monthly variation obtained can be used as subsidies for projects that are
 366 based on wind direction, such as the implementation of windbreaks, study of the spread of diseases and pests
 367 in agricultural fields, urban areas and installation of industrial parks in the basin region.

368 5. Discussion

369 Based on the results presented, it can be observed that the wind characteristics of the Ribeirão Vermelho
 370 river basin region are variable, presenting moments of stability and instability, favoring the occurrence of
 371 disasters and uncertainties for wind power use. Statistical tests and Mann-Kendall tests show that during the
 372 transition months from winter to summer, wind speed increased and peaked in September, with an average
 373 of 2.11 ms^{-1} , and the interannual average was 1.83 ms^{-1} , while in winter the average speeds were below 1.83
 374 ms^{-1} , mainly in June (1.54 ms^{-1}). The annual averages of wind speed indicate that curves with increases

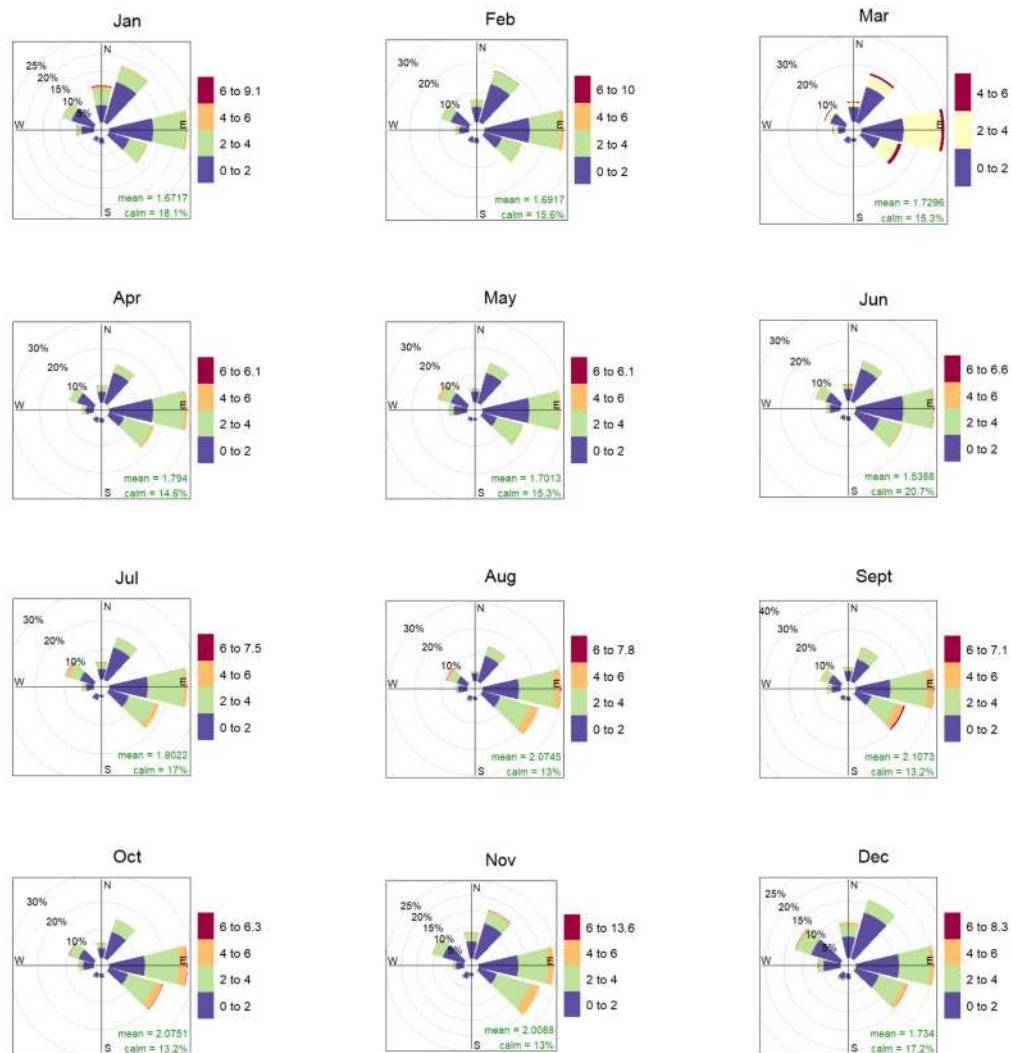


Figure 7: Monthly variation of wind direction from 2010 to 2023, data from the Ribeirão Vermelho river basin, Minas Gerais, Brazil.

375 and decreases in speed occurred at the beginning and end of the historical series, as can be seen in Table 4,
 376 and that we experienced a large peak in speed in the period from 2010 to 2014, reaching averages above 2.0
 377 ms^{-1} . From 2015 to 2023, the average wind speed was below the average observed in the previous period,
 378 which demonstrates a reduction of this climatic variable in the region, as shown in Table 6 on the state of
 379 the wind trend. The monthly characterization of wind speed also matches the studies by Munhoz and Garcia

380 (2008), Bueno et al. (2011), Oliveira and Costa (2011), Pitz et al. (2013) and Gilliland and Keim (2018) when
 381 it states that between the months of August to November, winds above 2.0 ms^{-1} can be recorded. Therefore,
 382 the results of this study match studies carried out by Bueno et al. (2011) and Oliveira and Costa (2011),
 383 when it is found that strong winds (maximum) are predominant in the months of September to February.
 384 The study shows that in the river basin region, winds tend to be stronger at the beginning of the rainy season
 385 (September) and gradually decrease during the dry season, similar to several studies conducted in the region,
 386 in Brazil and in the world in general, as stated by (Jiang et al., 2010; Alencar et al., 2011; Troccoli et al.,
 387 2012).

388 The coefficients of variation for January (76.04%) and June (79.22%) suggest high variation in wind
 389 speed during these months. For May (94.12%), highly variable winds are suggested, and for August (66.67%)
 390 and September (67.77%), low variation was observed. In the months of March (71.09%), July (72.22%) and
 391 December (73.99%), the wind speed variation was characterized by moderate to high variability, and in
 392 relation to the months of April (67.60%), October (67.63%) and November (68.19%), the wind speed was
 393 characterized by moderate stability.

394 For the months of December, January, June and July, the occurrence of calm winds (moderate) prevailed
 395 and high in June in the study region, as shown in Table 3, despite the occurrence of high variability, possibly
 396 due to the association of convective storms common in the rainy season (Lira et al., 2011, dos Santos and
 397 e Silva (2013)). In general, there was a reduction in wind speed in the river basin region, ranging from 2.30
 398 ms^{-1} in 2010 to 1.29 ms^{-1} in 2023, corroborating studies by Guo et al. (2011), Cardoso et al. (2016) and
 399 Gilliland and Keim (2018) and may be associated with climate change, such as a decrease in wind strength
 400 due to changes in atmospheric patterns. The variation in wind speed during the dry season may be associated
 401 with the occurrence of decreased cloudiness, increasing the incidence of solar radiation, factors that cause an
 402 increase in air temperature and promote a high deficit between high and low pressure centers, causing higher
 403 wind speeds in relation to the rainy season according to (Lira et al., 2011; dos Santos and e Silva, 2013).
 404 Another factor may be the action of the Intertropical Convergence Zone (Lira et al., 2011).

405 Regarding the average wind speed, it was observed that in all months of the year there was a statistically
 406 significant reduction in wind speed of 1.0%. For Cardoso et al. (2016) it was also observed that the average
 407 wind speed is decreasing significantly at a rate greater than $-5 \times 10^{-4} \text{ ms}^{-1}$ per month over the Atlantic
 408 Ocean adjacent to Argentina, in Paraguay, in the west of Southern Brazil and in the state of Mato Grosso
 409 do Sul, Brazil. In the study, summer stood out as statistically significant by the Kendall coefficient (τ).
 410 The nonparametric Mann-Kendell test, applied due to the greater statistical power, as it was robust against
 411 outliers and missing data according to (Chauke et al., 2021). According to Watson (2014) and Pimenta
 412 et al. (2023), it was observed that the nature of the wind regime of the analyzed series was variable, being
 413 different in different temporal and spatial scales and its magnitude changes drastically depending on the
 414 local climatology, geographic location of the station or river basin, morphometric characteristics of the study

415 site, land use and occupation. The month of May showed the smallest tendency of reduction in wind speed
416 in relation to the other months analyzed, therefore, it presented a higher Kendall coefficient (-0.158), and a
417 smaller decline in the month of August (-1.59). The lowest Kendall coefficient was observed in the month of
418 January (-0.294), indicating that in this month there was the greatest tendency of reduction in wind speed,
419 indicating a more pronounced increase over time.

420 The factors that promote the difference in the seasonal reduction in wind speed may be seasonal and
421 climatological influences. January is the peak of summer in the Southern Hemisphere, the region of the study,
422 characterized by higher temperatures and increased convective activity, which can lead to a weakening of
423 high-pressure systems, reducing wind intensity. May, on the other hand, marks the transition to winter, with
424 more stable atmospheric systems and less thermal variation, resulting in a smaller reduction in wind speed
425 over time. However, regional weather patterns also suggest that during January, the presence of low-pressure
426 systems, such as the South Atlantic Convergence Zone (SACZ), can intensify rainfall and reduce the strength
427 of average winds due to increased vertical turbulence. Thus, in May, the establishment of post-summer
428 high-pressure systems tends to stabilize the atmosphere, maintaining more consistent wind speeds (Lira
429 et al., 2011; dos Santos and e Silva, 2013). According to Cardoso et al. (2016), changes in wind speed may be
430 associated with changes in this north-south temperature gradient due to the warming observed in all regions
431 of the world during the 20th century.

432 Therefore, even with a lower average in June, the reduction trend (-0.196) is not as expressive as in
433 January, where temperatures are high. This suggests that June already had lower wind values from the
434 beginning, with little room for large reductions over time. And, January, with initially higher speeds,
435 presented more noticeable reductions. Regarding the variation in the annual and interannual trend of wind
436 speed, from 2010 to 2023, the magnitude of -0.196 suggests a moderate decreasing trend in wind speed in the
437 historical series. The p-value is very low ($2.22e-16$), practically zero, indicating that the observed decreasing
438 trend is highly statistically significant, according to (Kaja Bantha Navas et al., 2024). The annual and
439 interannual variations of global wind speed trends were also observed by Jiang et al. (2010), Guo et al. (2011)
440 and Troccoli et al. (2012) demonstrating a certain reduction highlighting the reasons for the weakening of
441 the pressure gradient strength of the lower troposphere, changes in atmospheric circulation due to climate
442 change as a factor in the reduction of wind speed. The annual significance levels observed in the historical
443 series resemble the results observed by dos Santos and e Silva (2013) and Pes et al. (2017), demonstrating
444 that the wind speed of the meteorological stations of the southern and southeastern regions of Brazil (river
445 basin region) showed a predominant trend for a reduction in the frequency of extreme maximum over time
446 and, mainly, non-significant trends for extreme minimum winds. They are also in agreement with the facts
447 observed by (Jiang et al., 2010; Alencar et al., 2011; Troccoli et al., 2012). The reduction in wind speed was
448 also observed by (Guo et al., 2011). Several factors can explain the reduction in wind speed in the Ribeirão
449 Vermelho river basin, and the weakening of the southeast trade winds in this region can be considered,

450 as per the view of (Bueno et al., 2011; Júnior et al., 2019). The authors state that from a macroclimatic
451 perspective, the geographic position of the state of Minas Gerais (where the basin is located) and under the
452 influence of the Atlantic tropical air mass in the summer, create favorable conditions for easterly winds and
453 the occurrence of heavy rains, affecting the wind.

454 Although there is a reduction in wind speed, its variation causes disasters as mentioned in this study.
455 According to Sarli et al. (2020), wind speeds of 5.0 ms^{-1} and 8.0 ms^{-1} represent a 50.0% and 90.0% chance
456 of wind-induced damage, respectively; this fact was observed in the study region, as shown in Table 7
457 and by the maximum values observed in Table 3. According to Mardiyono et al. (2021) and Yang et al.
458 (2018), strong winds allow trees to be uprooted and cause human victims to be injured or killed, causing
459 damaging environmental and socioeconomic disasters, as observed on September 27, 2023. Strong winds
460 cause restrictions on the supply of electricity and communication systems in some neighborhoods in the
461 river basin region, mainly in the urban area caused by strong winds (5.54 ms^{-1}). Restrictions on the supply
462 of electricity and communication caused by strong winds were also observed by Chmielewski et al. (2020),
463 uprooting and breaking of trees, branches, lodging of cash crops as stated by Godziek and Łukasz Pawlik
464 (2023) and Ojo and Sadiku (2023) and death of insects that are agents of pollination, transfer of pollen grains.
465 We have also seen the destruction of many buildings every year as Abd-Elaal et al. (2018) claims.

466 In this study, statistical standardization was adopted by calculating standardized anomalies (Z-score) to
467 characterize the relative intensity of the wind observed on September 27, 2023. According to Wilks (2011),
468 standardized anomalies are obtained by subtracting the historical mean of the variable under analysis and
469 dividing it by the corresponding sample standard deviation. For the authors, this transformation, also called
470 normalization, enables the magnitude of the event to be expressed in terms of standard deviations from the
471 expected climatological behavior, facilitating comparison between periods or locations with different means
472 and variability. In climatology, this approach is widely used to identify events that deviate substantially
473 from the mean, without the need to assume that data follow a normal distribution (Wilks, 2011).

474 The wind recorded on September 27, 2023 had a Z-score of +2.40, indicating that its average daily speed
475 was more than two standard deviations above the historical mean for September (2.11 ms^{-1}), characterizing
476 it as a statistically extreme event. This methodology contributes to the quantitative validation of the rarity of
477 the phenomenon, reinforcing the association between anomalous events and the occurrence of urban disasters,
478 as also reported by (Sarli et al., 2020; Chmielewski et al., 2020). Thus, the analysis by standardized anomalies
479 enables the objective assessment of the relative severity of intense wind events and provides important inputs
480 for the development of preventive and early warning strategies.

481 The results obtained, notably the Z-score of +2.40 and the approximate percentile ranking of 98%, show
482 that the wind speed observed on the day of the disaster was a statistically extreme event in relation to the
483 climatological history of September. This finding demonstrates that events of this magnitude occur rarely,
484 with an expected frequency of less than 2% in the analysis period, which also reinforces their potential impact

485 on urban infrastructure and vegetation (Figure 5). However, the identification of extreme episodes through
486 statistical standardization and percentile calculations contributes significantly to the improvement of risk
487 management strategies and the development of early warning systems.

488 As Wilks (2011) points out, data normalization allows meteorology, civil defense, and management
489 professionals to objectively compare events from different periods and regions, in addition to establishing
490 attention and emergency thresholds based on quantitative evidence, since Yan et al. (2021) considers that
491 global warming is increasing the frequency and intensity of extreme weather events worldwide. The extreme
492 climate in plateaus and mountainous areas is sensitive and fragile. The relief characteristics presented by
493 Yan et al. (2021) are also observed in the Ribeirão Vermelho watershed region, which may also explain the
494 occurrence of extreme winds on the day of the disaster, as demonstrated in this study.

495 Regarding the characterization of the monthly wind direction, Figure 7 shows that the predominant wind
496 direction was east, prevailing for all months of the year. The prevalence of southeast winds follows for 8
497 months (April to November) and northeast winds for 4 months (December to March). The results also
498 demonstrate some other monthly directions. East and southeast winds are in agreement with the studies of
499 Silva et al. (2002) and Munhoz and Garcia (2008) when they demonstrate that in the northeast region of
500 Brazil and in the state of São Paulo, east and southeast winds predominate. They are also in agreement with
501 studies by Bueno et al. (2011) when they state that in the municipality of Lavras (urban region belonging
502 to the hydrographic basin) east winds predominate, although they do not corroborate with the researchers
503 when they state that west winds also predominate, with southeast winds having been evidenced in this study.
504 However, the stability of wind direction may be related to seasonal climate patterns, with the passage of cold
505 fronts, convergence zones or the influence of large high or low pressure systems. The predominance of winds
506 in the east and southeast direction may still be influenced by geographic factors and the planialtimetric
507 variation of the specific relief of the study region, such as the proximity of mountains, plateaus or bodies of
508 water. Similar to the characterization of wind speed, the monthly average of the direction shows a higher
509 frequency of east winds from August to November, as occurs in the months of March to June. There was a
510 reduction in the frequency of the east direction in the rainy season (December to February), as shown in
511 Table 8. In general, the frequency analysis shows that southerly winds are the least frequent, followed by
512 southwest, north and northeast, respectively; these results contradict what was found by (Pitz et al., 2013).

513 Given the significance of the trends, their instability and easterly direction may be important in ongoing
514 studies on continuous monitoring of their occurrence, investigating the underlying causes of their spatiotem-
515 poral variation in wind instability in the region. The reason for monitoring is supported by the environmental,
516 agricultural and socioeconomic importance that this climate variable represents, since it has implications in
517 these sectors, including wind energy, according to the study by (Watson, 2014). This research can also be
518 used as a subsidy for preventing disasters caused by this climate element, improving the planning of projects
519 that are based on wind speed, such as the installation of windbreaks, planning of sowing season, irrigation,

520 studies on the spread of pests and diseases, spraying of agricultural fields, civil construction, installation of
521 industrial and wind generation parks, thermal comfort in the region of the river basin and future studies.

522 **6. Conclusions**

523 The wind speed in the study region is characterized by a downward trend over the years. Over the
524 months, the speed is lowest in the month of June. From August to November, the wind speed is higher,
525 decreasing during the rainy season, and being more unstable during this period, causing disasters such as
526 those that occurred in September 2023 and January and February 2024 in the urban region of the river basin.
527 During the dry season, the wind speed is more stable.

528 In general, the predominant wind direction in the region is east. From April to November, the predominant
529 directions are east and southeast, and from December to March, east and northeast winds predominate,
530 which can be beneficial for wind power use in the dry season due to the stability of the speed.

531 The correlation between statistical anomalies and observed material damage highlights the importance of
532 standardization by standard deviations and probabilistic quantification for weather risk assessment. The
533 results underscore the need to incorporate robust statistical methodologies and local historical data into early
534 warning systems, as well as into the planning of mitigation and adaptation strategies for extreme winds.

535 **7. Conflit of interests**

536 The authors declare that they have no competing financial interests or personal relationships that could
537 appear to influence the work reported in this paper.

538 **8. Funding**

539 The first author received a scientific grant from the Coordination for the Improvement of Higher Education
540 Personnel (CAPES).

541 **9. Availability of data and materials**

542 The datasets generated during and/or analyzed during the present study are available from the corre-
543 sponding author upon request.

544 **References**

545 Abd-Elaal, E.S., Mills, J.E., Ma, X., 2018. Numerical simulation of downburst wind flow over real topography. *Journal of Wind*
546 *Engineering and Industrial Aerodynamics* 172, 85–95. doi:10.1016/j.jweia.2017.10.026.

- 547 Alencar, L.P.d., Sediya, G.C., Mantovani, E.C., Martinez, M.A., 2011. Tendências recentes nos elementos do clima e suas
548 implicações na evapotranspiração da cultura do milho em viçosa-mg. *Engenharia Agrícola* 31, 631–642. doi:10.1590/S0100-
549 69162011000400002.
- 550 Alvares, C.A., Stape, J.L., Sentelhas, P.C., de M. Gonçalves, J.L., Sparovek, G., et al., 2013. Köppen's climate classification
551 map for brazil. *Meteorologische Zeitschrift* 22, 711–728. doi:10.1127/0941-2948/2013/0507.
- 552 Alves, M.d.C., Sanches, L., 2023. Remote sensing and digital image processing with r.
- 553 Andrade, A.R., Melo, V.F.M.B., Lucena, D.B., Abrahão, R., 2021. Wind speed trends and the potential of electricity generation
554 at new wind power plants in northeast brazil. *Journal of the Brazilian Society of Mechanical Sciences and Engineering* 43,
555 1–11. doi:10.1007/s40430-021-02911-y.
- 556 Bodas Terassi, P.M., Correia Filho, W.L.F., de Oliveira-Júnior, J.F., Sobral, B.S., Galvani, E., Júnior, A.C.d.S.O., de Gois,
557 G., Biffi, V.H.R., 2022. Wind characteristics and temporal trends in eastern paraná state, brazil doi:10.21203/rs.3.rs-
558 1585039/v1.
- 559 Böhner, J., Antonić, O., 2009. Land-surface parameters specific to topo-climatology. *Developments in Soil Science* 33, 195–226.
560 doi:10.1016/S0166-2481(08)00008-1.
- 561 Bueno, R.C., Carvalho, L.G.d., Vianello, R.L., Marques, J.J.G.d.S., et al., 2011. Estudo de rajadas de ventos e direções
562 predominantes em lavras, minas gerais, por meio da distribuição gama. *Ciência e Agrotecnologia* 35, 789–796. doi:10.1590/
563 S1413-70542011000400019.
- 564 Cardoso, L.F.N., Silva, W.L., da Silva, M.G.J., 2016. Long-term trends in near-surface wind speed over the southern hemisphere:
565 A preliminary analysis. *International Journal of Geosciences* 7, 938–943.
- 566 Carslaw, D., Ropkins, K., 2014. Package 'openair' .
- 567 Chauke, M.D., Prinsloo, L., Pratt, L.E., Roro, K.T., 2021. Wind speed trend analysis and inter-annual variability in south
568 africa URL: <http://hdl.handle.net/10204/12301>.
- 569 Chmielewski, T., Szer, J., Bobra, P., 2020. Derecho wind storm in poland on 11–12 august 2017: results of the post-disaster
570 investigation. *Environmental Hazards* 19, 508–528. doi:10.1080/17477891.2020.1730154.
- 571 Costa, G.B., Lyra, R.F.d.F., 2012. Análise dos padrões de vento no estado de alagoas. *Revista Brasileira de Meteorologia* 27,
572 31–38. doi:10.1590/S0102-77862012000100004.
- 573 Dantas, A.A.A., Carvalho, L.G.d., Ferreira, E., 2007. Classificação e tendências climáticas em lavras, mg. *Ciência e Agrotecnologia*
574 31, 1862–1866. doi:10.1590/S1413-70542007000600039.
- 575 Dragulescu, A.A., Dragulescu, M.A.A., Provide, R., 2020. Package 'xlsx'. *Cell* 9.
- 576 Fernández-López, J., Schliep, K., Arjona, Y., 2022. 2 rwind-package. Package 'rWind' , 2.
- 577 Ferreira, P.F.S., Araujo, J.E., Pereira, N.A.S., do Patrocínio Figueiró, L.S., da Costa Santos, L., 2024. Caracterização da
578 direção predominante e velocidade do vento em diamantina/mg. *Contribuciones a las Ciencias Sociales* 17, e5474–e5474.
579 doi:10.55905/revconv.17n.3-301.
- 580 Gilliland, J.M., Keim, B.D., 2018. Surface wind speed: trend and climatology of brazil from 1980–2014. *International Journal of*
581 *Climatology* 38, 1060–1073. doi:10.1002/joc.5237.
- 582 Godziek, J., Lukasz Pawlik, 2023. Indicators of wind-driven forest disturbances—pit—mound topography, its automatic detection
583 and significance. *Catena* 221, 106757. doi:10.1016/j.catena.2022.106757.
- 584 Godziek, J., Pawlik, Ł., 2023. Indicators of wind-driven forest disturbances—pit—mound topography, its automatic detection and
585 significance. *Catena* 221, 106757. doi:10.1016/j.catena.2022.106757.
- 586 Goossens, C., Berger, A., 1986. Annual and seasonal climatic variations over the northern hemisphere and europe during the
587 last century. *Geophys. J.:(France)* 4.
- 588 Grange, S.K., 2014. Averaging wind speeds and directions. no. October , 12.
- 589 Guo, H., Xu, M., Hu, Q., 2011. Changes in near-surface wind speed in china: 1969–2005. *International Journal of Climatology*

- 590 31, 349–358. doi:10.1002/joc.2091.
- 591 He, B.J., 2022. Urban morphology, urban ventilation and urban heat island mitigation: A methodological framework, in:
592 Climate Change and Environmental Sustainability. Springer, pp. 131–136. doi:10.1007/978-981-16-8325-9_14.
- 593 Hengl, T., Heuvelink, G., Van Loon, E., 2010. On the uncertainty of stream networks derived from elevation data: the error
594 propagation approach. *Hydrology and Earth System Sciences* 14, 1153–1165. doi:10.5194/hess-14-1153-2010.
- 595 Jiang, Y., Luo, Y., Zhao, Z., Tao, S., 2010. Changes in wind speed over china during 1956–2004. *Theoretical and Applied*
596 *Climatology* 99, 421–430. doi:10.1007/s00704-009-0152-7.
- 597 Júnior, G.d.N.A., de Queiroz, M.G., Jardim, A.M.d.R.F., da Silva, M.J., de Caldas Pereira, P., da Silva, T.G.F., 2019.
598 Caracterização da direção predominante, velocidade máxima e média do vento do município de petrolina-pe. *Pensar*
599 *Acadêmico* 17, 43–49. doi:10.21576/pa.2019v17i1.363.
- 600 Kaja Bantha Navas, R.M., Prakash, S., Molnar, V., 2024. Analysis of short-term wind speed variation, trends and prediction: A
601 case study of tamil nadu, india. *Journal of Intelligent Systems* 33, 20230051. doi:10.1515/jisys-2023-0051.
- 602 Lima, G.C., Rodrigues, D.T., Santos E Silva, C.M., de Sousa Costa, P.C., 2024. Evolution of wind speed observed in brazil
603 between 1961 and 2020. *International Journal of Climatology* 44, 1932–1954. doi:10.1002/joc.8433.
- 604 Lira, M.A.T., Silva, E.M.d., Alves, J.M.B., 2011. Estimativa dos recursos eólicos no litoral cearense usando a teoria da regressão
605 linear. *Revista Brasileira de Meteorologia* 26, 349–366. doi:10.1590/S0102-77862011000300003.
- 606 Liu, Z., Shie, C.L., Li, A., Meyer, D., 2020. Nasa global satellite and model data products and services for tropical meteorology
607 and climatology. *Remote Sensing* 12, 2821. doi:10.3390/rs12172821.
- 608 Mardiyono, M., Sari, R.E., Dini, O.N., 2021. Wind speed monitoring and alert system using sensor and weather forecast 1108,
609 012029. doi:10.1088/1757-899X/1108/1/012029.
- 610 Molaei, A., Lashkari, H., 2020. Investigation of wind speed trend changes in central iran using ecmwf reanalysis data. *Physical*
611 *Geography Research* 52, 481–498. doi:10.22059/jphgr.2020.295406.1007476.
- 612 Munhoz, F.C., Garcia, A., 2008. Caracterização da velocidade e direção predominante dos ventos para a localidade de ituverava-sp.
613 *Revista Brasileira de Meteorologia* 23, 30–34. doi:10.1590/S0102-77862008000100003.
- 614 Ojo, A.R., Sadiku, N.A., 2023. Slenderness coefficient and growth characteristics of africa giant bamboo: *Bambusa vulgaris*
615 *schrad. ex jc wendl.* *Advances in Bamboo Science* 2, 100017. doi:10.1016/j.bamboo.2023.100017.
- 616 Oliveira, J.L., Costa, A.A., 2011. Estudo de variabilidade do vento em escala sazonal sobre o nordeste brasileiro utilizando o rams:
617 os casos de 1973-1974 e 1982-1983. *Revista Brasileira de Meteorologia* 26, 53–66. doi:10.1590/S0102-77862011000100006.
- 618 Pavanate, A.L., Fleischfresser, L., 2017. Análise sazonal dos ventos de superfície utilizando estação meteorológica automática.
619 *Revista Brasileira de Geomática* 5, 291–305. doi:10.3895/rbgeo.v5n2.5499.
- 620 Pereira, A.R., Angelocci, L.R., Sentelhas, P.C., 2002. Agrometeorologia: fundamentos e aplicações práticas .
- 621 Pes, M.P., Pereira, E.B., Marengo, J.A., Martins, F.R., Heinemann, D., Schmidt, M., 2017. Climate trends on the extreme
622 winds in brazil. *Renewable Energy* 109, 110–120. doi:10.1016/j.renene.2016.12.101.
- 623 Pimenta, F.M., Saavedra, O.R., Oliveira, D.Q., Assireu, A.T., Júnior, A.R.T., de Freitas, R.M., Neto, F.L.A., Lopes, D.C.P.,
624 Oliveira, C.B.M., de Lima, S.L., et al., 2023. Characterization of wind resources of the east coast of maranhão, brazil.
625 *Energies* 16, 5555. doi:10.3390/en16145555.
- 626 Pitz, I., Neves, L., Pitz, J., Eli, K., Oliveira, E., 2013. Caracterização da velocidade e direção predominante dos ventos para a
627 localidade de rio do sul-sc. *ENCICLOPEDIA BIOSFERA* 9.
- 628 Revelle, W., Revelle, M.W., 2015. Package ‘psych’. *The comprehensive R archive network* 337, 161–165.
- 629 dos Santos, A.T.S., e Silva, C.M.S., 2013. Seasonality, interannual variability, and linear tendency of wind speeds in the northeast
630 brazil from 1986 to 2011. *The Scientific World Journal* 2013, 490857. doi:10.1155/2013/490857.
- 631 Sarli, P.W., Abdillah, M.R., Sakti, A.D., 2020. Relationship between wind incidents and wind-induced damage to construction
632 in west java, indonesia, in: *IOP Conference Series: Earth and Environmental Science*, IOP Publishing, p. 012001. doi:10.

- 633 1088/1755-1315/592/1/012001.
- 634 Schubert, A.N., Pai, A.D., Sarnighausen, V.C.R., Rodrigues, S.A., 2022. Direção e velocidade do vento em botucatu-sp. *Tekhne*
635 e Logos 13, 50–64. doi:<https://orcid.org/0000-0002-4111-2127>.
- 636 Silva, B.B.d., Alves, J.J.A., Cavalcanti, E.P., Dantas, R.T., 2002. Potencial eólico na direção predominante do vento no nordeste
637 brasileiro. *Revista Brasileira de Engenharia Agrícola e Ambiental* 6, 431–439. doi:10.1590/S1415-43662002000300009.
- 638 Soukissian, T., Sotiriou, M.A., 2022. Long-term variability of wind speed and direction in the mediterranean basin. *Wind* 2,
639 513–534. doi:10.3390/wind2030028.
- 640 Souza, C.J., Liberato, A.M., 2019. Análise da velocidade e direção do vento em vilhena, rondônia. *Revista de Administração e*
641 *Negócios da Amazônia* 11, 344–361. doi:10.18361/2176-8366/rara.
- 642 Troccoli, A., Muller, K., Coppin, P., Davy, R., Russell, C., Hirsch, A.L., 2012. Long-term wind speed trends over australia.
643 *Journal of Climate* 25, 170–183. doi:10.1175/2011JCLI4198.1.
- 644 Watson, S., 2014. Quantifying the variability of wind energy. *Wiley Interdisciplinary Reviews: Energy and Environment* 3,
645 330–342. doi:10.1002/wene.95.
- 646 Wickham, H., Chang, W., Wickham, M.H., 2016. Package ‘ggplot2’. Create elegant data visualisations using the grammar of
647 graphics. Version 2, 1–189.
- 648 Wickham, H., Wickham, M.H., 2019. Package ‘tidyverse’. See <http://tidyverse.tidyverse.org> , 1–5.
- 649 Wickham, H., Wickham, M.H., 2020. Package ‘plyr’. Obtenido <https://cran.r-project.org/web/packages/dplyr/dplyr.Pdf> .
- 650 Wilks, D.S., 2011. *Statistical methods in the atmospheric sciences*. volume 100. Academic press.
- 651 Yan, W., He, Y., Cai, Y., Cui, X., Qu, X., 2021. Analysis of spatiotemporal variability in extreme climate and potential driving
652 factors on the yunnan plateau (southwest china) during 1960–2019. *Atmosphere* 12, 1136.
- 653 Yang, Q., Gao, R., Bai, F., Li, T., Tamura, Y., 2018. Damage to buildings and structures due to recent devastating wind
654 hazards in east asia. *Natural Hazards* 92, 1321–1353. doi:10.1007/s11069-018-3253-8.

**ARTIGO 3 - Previsão da velocidade do vento usando modelos
SARIMA e SARIMAX na bacia hidrográfica do Ribeirão
Vermelho - Minas Gerais**

Redigido conforme as normas da revista *Natural Hazard* (versão a ser submetida).

Previsão da velocidade do vento usando modelos SARIMA e SARIMAX na bacia hidrográfica do Ribeirão Vermelho - Minas Gerais

Orlando Eduardo Chipura^a, Marcelo de Carvalho Alves^{a,1}, Thelma Sáfiadi^a, Viviane Costa Silva^a, Fortunato Silva de Menezes^b

^aEngineering School (EENG) Agriculture Engineering Department UFLA Campus Lavras 37200-000 Brazil

^bInstitute of Natural Sciences (ICN) Physics Department UFLA Campus Lavras 37200-000 Brazil.

Abstract

A capacidade de antecipar a velocidade do vento é um elemento importante para prever e mitigar os riscos ambientais e socioeconômicos provocados pelos desastres causados por esta variável climática. Nesse estudo objetivou-se avaliar o desempenho dos modelos *Seasonal Autoregressive Integrated Moving Average* (SARIMA) e *Seasonal Autoregressive Integrated Moving Average with Exogenous variables* (SARIMAX) na previsão da velocidade do vento da bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil, comparando-os. Os dados correspondem à Estação Climatológica de Lavras - MG, os quais foram obtidos no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP), mantido pelo Instituto Nacional de Meteorologia (INMET). Para determinar quantitativamente o melhor modelo, três medidas de erro de previsão foram empregadas para avaliação e comparação dos modelos, sendo elas: o Erro Médio Absoluto (MAE), Raiz do Erro Quadrático Médio (RMSE) e o AIC, utilizando-se a metodologia Box-Jenkins. O melhor modelo usado no estudo foi o SARIMAX, visto que apresentou menor Erro Médio Absoluto (0,1927) e menor AIC (31.18), destacando as variáveis exógenas, temperatura média e umidade relativa, influenciam na velocidade do vento. Além disso, as previsões realizadas para os três primeiros meses de 2025 com ambos modelos mostraram que os valores reais estiveram contidos dentro dos intervalos de confiança de 95%, com o SARIMAX se destacando por apresentar valores centrais mais próximos dos dados observados. Com base no estudo, conclui-se que, dada a precisão nas especificações quanto à eficiência do modelo, o SARIMAX é o mais adequado neste contexto.

Keywords:

Pressão atmosférica, autocorrelação, variáveis exógenas, software R, sazonalidade.

*Corresponding author

Email address: marcelo.alves@uf1a.br (Marcelo de Carvalho Alves)

¹Corresponding Author

1. Destaque do artigo

- As variáveis temperatura média e umidade relativa do ar contribuem significativamente na mudança da velocidade do vento na região da bacia hidrográfica de Ribeirão Vermelho.
- A modelagem SARIMAX incorporando as variáveis exógenas temperatura média e umidade relativa do ar destacou-se como uma abordagem preditiva mais robusta, capturando tanto a dinâmica sazonal quanto a influência significativa dessas variáveis exógenas, resultando em previsão precisa e eficiente.

2. Introdução

As mudanças climáticas podem afetar direta e indiretamente os setores agrícola, industrial, geográfico e tecnológico em nossa sociedade (Mehta et al., 2023). Elas são predominantemente governadas pelas mudanças de temperatura e precipitação (Dimri et al., 2020). Gunawardhana et al. (2017) afirmam que estudos sobre mudanças climáticas têm se concentrado em mudanças nos regimes de temperatura e precipitação, em grande medida, mas muito menos atenção é dada à umidade, provavelmente ao vento também. O vento é um recurso renovável dependente das condições climáticas, sua variabilidade ocorre em escalas de tempo que variam de minutos a horas, dias e vários anos (Kavasseri and Seetharaman, 2009).

O vento é frequentemente considerado um dos parâmetros meteorológicos mais difíceis de prever, não apenas por causa da influência da dinâmica atmosférica, mas também pela impossibilidade de fornecer uma previsão precisa com modelos tradicionais de previsão estatística (Sfetsos, 2002; Cadenas et al., 2010; Zhao et al., 2015). É resultado de interações complexas entre mecanismos de força em larga escala, como pressões e gradientes de temperatura, a rotação da Terra e características locais da superfície (Sfetsos, 2002; Pereira et al., 2002; Böhner and AntoniĆ, 2009a; Pitz et al., 2013; Souza and Liberato, 2019). Porém, sua previsão desempenha um papel vital no planejamento, gerenciamento e monitoramento de sistemas inteligentes de energia eólica, prevenção de ocorrência de desastres, identificação prévia de locais de risco e seguros para habitação e financiamento de projetos agrícolas e socioeconômicos (Carmelo et al., 2017; Zhao et al., 2015; Elsaraiti and Merabet, 2021).

Em termos gerais, existem duas abordagens para a previsão da velocidade do vento: (I) baseada no clima e (II) baseada em séries temporais (Kavasseri and Seetharaman, 2009). Enquanto a primeira utiliza modelos atmosféricos hidrodinâmicos que incorporam fenômenos físicos como efeitos de atrito, térmicos e convectivos, a segunda (tema deste artigo) utiliza apenas dados históricos da velocidade do vento registrados no local para construir modelos estatísticos a partir dos quais as previsões são derivadas.

Na ciência atmosférica, a umidade relativa refere-se à quantidade de umidade no ar e é um aspecto importante do ciclo hidrológico que afeta o tempo e o clima. Gunawardhana et al. (2017) descreve a quantidade de vapor de água no ar em relação à quantidade de vapor de água que o ar pode conter a uma temperatura específica (Fattah et al., 2023). Ela é essencial para pesquisas climáticas e ambientais e

influencia outros parâmetros climáticos, como precipitação e temperatura (Mehta et al., 2023). Portanto, Gunawardhana et al. (2017) afirmam que umidade relativa aumenta em direção ao verão à medida que a temperatura aumenta. À medida que o ar se torna mais e mais saturado, a taxa de evaporação diminui.

A umidade relativa e a velocidade do vento são fatores extremamente importantes no crescimento de muitas culturas agrícolas (Mehta et al., 2023). Atualmente, o vento tem sido uma fonte alternativa de geração de energia, mas é necessário garantir a continuidade de sua produção Kavasseri and Seetharaman (2009); Mehta et al. (2023). Para isso, é preciso investir em pesquisas para a sua caracterização e previsão, como uma forma de garantir a sua expansão (Kavasseri and Seetharaman, 2009).

Os métodos de previsão baseados em séries temporais dependem da metodologia clássica de Box-Jenkins, que emprega uma classe geral de modelos, como os modelos de Autoregressive Moving Average (ARMA(p, q)) ou Autoregressive Integrated Moving Average (ARIMA(p, d, q)) para obter previsões (Box et al., 2015). A previsão da velocidade do vento tornou-se um dos tópicos mais atraentes para pesquisadores na área de energia renovável devido ao seu uso na geração de energia limpa e à capacidade de integrá-la à rede elétrica (Elsaraiti and Merabet, 2021; Dalton and Bekker, 2022). Para Zhao et al. (2015), as previsões desempenham um papel essencial na meteorologia, economia e geração de energia. Também pode ser importante para o meio rural e urbano devido a previsão de cenários de ocorrência de desastres. Mulla et al. (2024) afirmam que o objetivo principal da modelagem de séries temporais é criar modelos eficazes que possam prever com precisão os valores futuros de uma variável com base em dados históricos.

O modelo ARIMA com entrada exógena (ARIMAX) é uma variante avançada do modelo ARIMA que usa séries temporais multivariadas para prever a variável dependente e usa múltiplas séries temporais dadas como variáveis exógenas (Alharbi and Csala, 2022). Um outros modelos importantes são *Seasonal Autoregressive Integrated Moving Average* (SARIMA) e o *Seasonal AutoRegressive Integrated Moving Average with exogenous variables* (SARIMAX), modelos de séries temporais usados para analisar e prever dados que exibem padrões sazonais (Mulla et al., 2024), que serão utilizados esse estudo. Os modelos SARIMA são uma adaptação dos modelos Autoregressive Integrated Moving Average (ARIMA) para se adequar especificamente a séries temporais sazonais. Ou seja, sua construção leva em consideração a natureza sazonal subjacente da série a ser modelada (Afrifa-Yamoah, 2015). Cadenas et al. (2010) afirmam que, para fazer previsão, o modelo empregado depende das informações disponíveis e da escala de tempo em questão.

A maioria dos métodos de previsão de velocidade do vento relatados na literatura recente usam observações históricas univariadas da velocidade do vento para prever os valores futuros, limitando os métodos de previsão a apenas modelar as características temporais desses dados defasados e ignorando as possíveis correlações espaço-temporais de outras variáveis exógenas multivariadas (Noman et al., 2021). No entanto, uso de variáveis meteorológicas exógenas na previsão da velocidade do vento atualmente está recebendo muita atenção, particularmente com a proliferação contínua da energia eólica em redes elétricas (Dalton and Bekker, 2022) provavelmente devido a possíveis correlação dessas variáveis ou a integração de variáveis

exógenas ao modelo SARIMAX permite capturar o impacto de eventos ou informações fora dos conjuntos de dados meteorológicos típicos, proporcionando uma visão mais holística dos fatores que afetam as condições climáticas (Shah et al., 2024). A análise de séries temporais invariavelmente envolve a avaliação de tendências e sazonalidade nos dados (Dimri et al., 2020).

A inclusão de variáveis exógenas (pressão atmosférica, temperatura média, umidade relativa do ar e a precipitação média mensal) na avaliação do desempenho dos modelos de previsão da velocidade do vento podem melhorar o desempenho dos modelos de previsão devido a prováveis fortes correlações entre algumas variáveis meteorológicas. No entanto, a seleção dessas variáveis exógenas baseou-se nos pressupostos teóricos que revelam o seu impacto significativo na variação temporal da velocidade do vento. Nesse sentido, objetivou-se avaliar o desempenho dos modelos SARIMA e SARIMAX na previsão da velocidade do vento da bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil, comparando-os.

3. Material e Métodos

3.1. Localização e caracterização da área de estudo

A bacia hidrográfica do Ribeirão Vermelho localiza-se no estado de Minas Gerais, Brasil, entre as coordenadas 21°26' a 21°18' de latitude Sul e 44°95' a 45°07' de longitude Oeste, incluindo a área urbana do município de Lavras (Figura 1). Segundo a classificação climática de Köppen, o clima da região é classificado como Cwa, temperado chuvoso (mesotérmico) com inverno seco e verão chuvoso, subtropical e temperatura anual variando em torno de 19,3°C. Nos meses mais quente e mais frio, as temperaturas médias são 22,1°C e 15,8°C, respectivamente (Fia et al., 2015).

A característica do relevo da região da bacia hidrográfica do Ribeirão Vermelho demonstra que predomina declive da classe ondulado, com 67,24% da área de contribuição e suave ondulado tem uma representatividade significativa, com 22,46%. A elevação varia de 772 a 1084 m (Menezes et al., 2014).

3.2. Fonte e obtenção de dados climáticos da bacia hidrográfica do Ribeirão Vermelho

Foram considerados os dados da série temporal correspondente à média mensal da velocidade do vento (variável dependente, medida em ms^{-1}), pressão atmosférica, temperatura média, precipitação média mensal e umidade relativa do ar (variáveis independentes que também são chamadas de variáveis exógenas) medidas em hectopascal (hPa), graus Celsius (°C), milímetro (mm) e porcentagem (%), respectivamente. Os dados correspondem ao período de 01.01.2010 a 31.12.2024 utilizados para aferir o desempenho dos modelos. Também foram coletados dados médios diários de 01.01.2025 a 31.03.2025 utilizados para comparar a eficiência e eficácia dos modelos de previsão. Os dados foram coletados na estação climatológica convencional de Lavras-MG, localizada na Universidade Federal de Lavras (UFLA), embora exista a estação meteorológica automática pertencente a UFLA. Os dados foram obtidos através do Banco de Dados Meteorológicos para

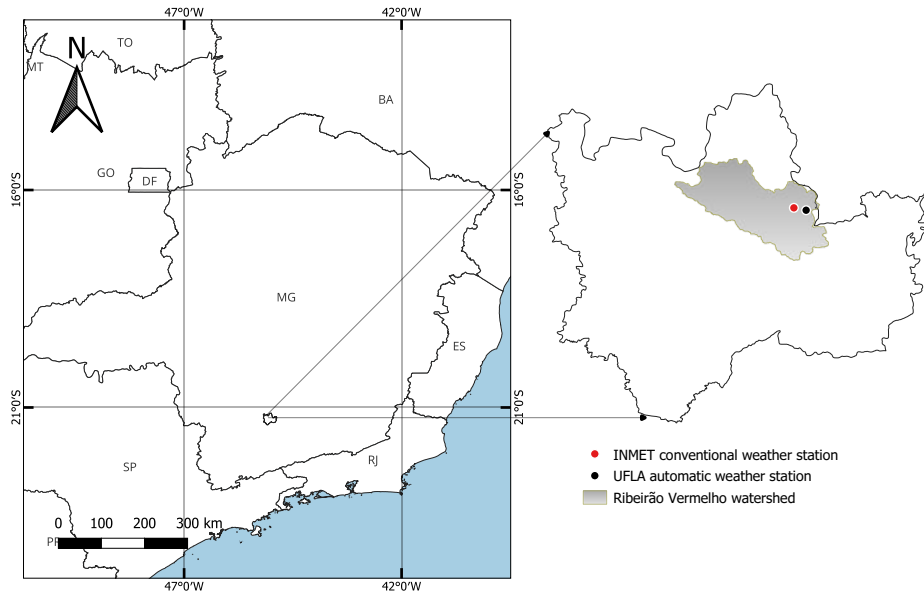


Figure 1: Localização da bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

Ensino e Pesquisa (BDMEP), mantidos pelo Instituto Nacional de Meteorologia (INMET), coletados em três períodos diários UTC (12:00h, 18:00h e 00:00h), medidos ao nível de 10 m de altura. Estes foram transformados em médias diárias e posteriormente em médias mensais usando o pacote *rWind* e linguagem computacional R, utilizado para de fazer a estatística descritiva, as previsões, comparar os modelos de séries temporais e gerar gráficos das previsões.

3.3. Linguagem computacional e pacotes utilizados para tratamento de dados

Foi utilizado a linguagem computacional R, v. 4.3.3, com recurso aos pacotes da Tabela 1 e as funções da Tabela 2, de acesso livre (Carmelo et al., 2017). Inicialmente, determinou-se a estatística descritiva da variável de interesse (média, mediana, desvio padrão, coeficiente de variação, mínimo e máximo) com o objetivo de caracterizá-la. Posteriormente foram ajustados inicialmente o SARIMA, a posterior e o modelo SARIMAX à série temporal. Para realizar a modelagem SARIMA, quanto o SARIMAX utilizou-se o mesmo procedimento metodológico no começo. No caso da modelagem SARIMAX foi incluído as variáveis exógena, como é descrito a seguir:

Identificou-se o conjunto de dados que foram utilizados para a modelagem. Verificou-se a estacionariedade para o conjunto de dados. Procedeu-se a diferenciação, pelo que a série não era estacionária (aplicando uma diferenciação). Realizou-se a análise da função de auto-correlação (ACF) e a função de autocorrelação parcial

(PACF), definindo os parâmetros (p, d, q) para os modelos escolhidos, baseando-se nos gráficos da ACF e da PACF. Portanto, para Taoussi et al. (2025) o ACF quantifica a correlação entre a velocidade do vento e seu passo de tempo anterior. Coeficientes significativos no gráfico do ACF são observados até a ordem q . Similarmente, o PACF auxilia na determinação da ordem p , com coeficientes significativos presentes até o atraso p . O gráfico do ACF indica um decaimento geométrico após o primeiro atraso, sugerindo que a velocidade do vento exibe forte dependência de curto prazo, com o valor atual sendo altamente influenciado por seu valor passado imediato.

Table 1: Pacotes de interesse para análise da série temporal e previsão da velocidade do vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil de 2010-2023.

| Pacote | Descrição | Referência |
|-----------------------|--|-------------------------------|
| <code>tseries</code> | Foi utilizada para usar a equação de regressão geral incorporando uma constante e uma tendência linear e calculou a estatística t para um coeficiente autorregressivo de primeira ordem igual a um. | Trapletti et al. (2015) |
| <code>ggplot2</code> | Foi usado na implementação da gramática de gráficos e para mapear dados da pesquisa. | Wickham et al. (2016) |
| <code>starts</code> | Foram utilizadas funções para calcular a matriz de covariância e simular dados do modelo STARTS univariado, podendo ser estimado com máxima verossimilhança. | Robitzsch et al. (2022) |
| <code>readr</code> | Foi utilizado por fornecer uma forma rápida e amigável de ler dados retangulares csv e analisa de forma flexível os dados usando R. | Wickham et al. (2024) |
| <code>forecast</code> | Foi utilizado uso de métodos e ferramentas para a visualização e análise de previsões de séries temporais univariadas e exponenciais, modelos de suavização do espaço de estados-vivos e modelação automática ARIMA. | Hyndman et al. (2020) |
| <code>rWind</code> | Foi usado para gerenciar dados de vento e calcular as médias. | Fernández-López et al. (2022) |

3.4. Modelos estatísticos univariados

Taoussi et al. (2025) consideram o ARIMA, SARIMA e SARIMAX como técnicas de previsão de séries temporais para dados univariados. Nesse estudo, a modelagem da série temporal da velocidade do vento será

Table 2: Funções dos pacotes de interesse para análise da série temporal e previsão da velocidade do vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil de 2010-2023.

| Função | Descrição | Referência |
|------------------------|---|-------------------------------|
| <code>arma()</code> | Foi usado para ajustar um modelo ARMA a uma série temporal univariada por mínimos quadrados condicionais. | Trapletti et al. (2015) |
| <code>accuracy</code> | Foi utilizado para calcular os erros realizando o pacote do software R <code>forecast</code> . | Fernández-López et al. (2022) |
| <code>wind.mean</code> | Foi utilizado para calcular a média da velocidade do vento e realizar o tratamento do conjunto de dados da série histórica. | Fernández-López et al. (2022) |

com base nos modelos SARIMA e SARIMAX segundo os objetivos.

As modelagens têm as suas bases fundamentadas no método ARIMA (Box et al., 2015). Segundo Elsaraiti and Merabet (2021), elas consistem em três processos principais: controle diagnóstico, identificação e estimativa. Para os autores, no primeiro estágio, chamado de controle diagnóstico, o controle de estacionariedade é exercido sobre os dados da série temporal fornecida. Para analisar a série temporal baseando-se no modelo $ARIMA(p, d, q)$, foi utilizado a Equação 1 também utilizada por Elsaraiti and Merabet (2021):

$$\Phi(B)(1 - B)^d x_t = \delta + \Theta(B)a_t \quad (1)$$

em que, x_t : valor observado da série temporal no tempo t . B : operador defasagem, tal que $Bx_t = x_{t-1}$. $(1 - B)^d$, operador de diferenciação de ordem d , utilizado para tornar a série estacionária. $\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$, polinômio autoregressivo (AR) de ordem p . $\Theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$, polinômio de médias móveis (MA) de ordem q . δ , constante opcional (drift), presente quando $d = 0$ ou $d = 1$, erro aleatório (ruído branco), assumido com média zero e variância constante (Elsaraiti and Merabet, 2021).

3.5. Modelo SARIMA

O modelo *Seasonal Autoregressive Integrated Moving Average* (SARIMA) é uma ferramenta estatística crucial para a análise de séries temporais que apresentam padrões sazonais. Ele é uma extensão do modelo *Autoregressive Integrated Moving Average* (ARIMA), conforme explicitado anteriormente, de modo específico, adaptado para capturar e modelar as flutuações periódicas que ocorrem em intervalos regulares ao longo do tempo (Dubey et al., 2021). O modelo SARIMA(p,d,q)(P,D,Q)[S], em que p é uma ordem autorregressiva não sazonal, P é uma ordem autorregressiva sazonal, q é uma ordem de média móvel não sazonal, Q é uma ordem autorregressiva sazonal, d e D são a ordem da diferença comum e da diferença sazonal (Pepple and Harrison, 2017), são escritos como (Equação 2):

$$\phi(B)\Phi(B^s)(1-B)^d(1-B^s)^D y_t = \theta(B)\Theta(B^s)\epsilon_t \quad (2)$$

em que $\phi(B)$, Operador autorregressivo não sazonal, modela dependência em valores passados recentes; $\Phi(B^s)$, operador autorregressivo sazonal, captura influência de valores passados em intervalos sazonais; $(1-B)^d$, aplica diferenciação não sazonal para tornar a série estacionária; $(1-B^s)^D$, aplica diferenciação sazonal para remover a sazonalidade; y_t , a série temporal sendo modelada no instante t ; $\theta(B)$, operador de médias móveis não sazonal, modela o erro atual como combinação de erros passados recentes; $\Theta(B^s)$, operador de médias móveis sazonal, considera erros passados em intervalos sazonais e ϵ_t , termo de erro aleatório (ruído branco) no instante t .

Para Vautard et al. (2010), uma etapa importante da previsão envolve a escolha de um modelo adequado. A plotagem da série temporal, bem como de seus correlogramas, é informativa e fornece uma estimativa inicial do modelo potencial. No entanto, antes da seleção do modelo, é necessário tirar conclusões com relação ao próprio processo. As séries temporais podem ser estacionárias ou não estacionárias e, portanto, determinar a natureza do processo pode ajudar a simplificar algumas suposições que, no caso de não estacionariedade, não podem ser feitas.

3.6. Modelo SARIMAX

O maior interesse nesse estudo foi dado ao modelo SARIMAX, o qual é derivado do modelo SARIMA, conforme cita Vautard et al. (2010); Alharbi and Csala (2022). O modelo representado pela Equação 3, é um modelo *Seasonal AutoRegressive Integrated Moving Average with eXogenous variables* (SARIMAX). Trata-se de uma generalização dos modelos SARIMA, incorporando componentes sazonais e variáveis exógenas. Ele é composto por termos autorregressivos (AR), de médias móveis (MA), diferenciações não sazonais e sazonais, além de permitir a inclusão de co-variáveis explicativas $x_{j,t}$, que podem influenciar diretamente a variável dependente y_t . Esse tipo de modelo é amplamente utilizado para modelagem e previsão de séries temporais em que há influência externa e padrão sazonal bem definido, como em dados meteorológicos, econômicos ou epidemiológicos.

$$\phi(B)\Phi(B^s)(1-B)^d(1-B^s)^D y_t = \delta + \sum_{j=1}^k \beta_j x_{j,t} + \theta(B)\Theta(B^s)\epsilon_t \quad (3)$$

em que y_t : variável dependente (série temporal observada); $x_{j,t}$, variáveis explicativas (exógenas), com $j = 1, \dots, k$; $\phi(B)$, polinômio autorregressivo não sazonal da parte AR do modelo; $\Phi(B^s)$, polinômio autorregressivo sazonal da parte SAR; $(1-B)^d$, operador de diferenciação não sazonal de ordem d ; $(1-B^s)^D$: operador de diferenciação sazonal de ordem D , com periodicidade s (ex: $s = 12$ para dados mensais); δ , constante do modelo; $\sum_{j=1}^k \beta_j x_{j,t}$, componente de regressão com variáveis exógenas; $\theta(B)$, polinômio de

médias móveis não sazonal da parte MA; $\Theta(B^s)$, polinômio de médias móveis sazonal da parte SMA; ϵ_t , termo de erro aleatório (ruído branco).

A adição de variáveis exógenas ao modelo SARIMAX permite que o modelo incorpore informações adicionais à previsão.

3.7. Medidas estatísticas para determinar a precisão dos modelos de previsão da velocidade do vento

Para determinar quantitativamente o melhor modelo, duas medidas de erro de previsão foram empregadas para avaliar e comparar o desempenho dos modelos, sendo elas: o Erro Médio Absoluto (MAE) e o Raiz do Erro Quadrático Médio (RMSE), com base nas Equações 4 e 5, respectivamente (Cadenas et al., 2010; Alharbi and Csala, 2022; Mehta et al., 2023; Shah et al., 2024; Uzair et al., 2024; Taoussi et al., 2025). A fórmula da Média do Erro Absoluto (MAE) é dada por:

$$\text{MAE} = \frac{1}{n} \sum_{t=1}^n |e_t|. \quad (4)$$

Foram utilizados o Erro Absoluto Médio (MAE) e a raiz do Erro Quadrático Médio (RMSE) (Elsaraiti and Merabet, 2021; Alharbi and Csala, 2022; Mehta et al., 2023; Shah et al., 2024; Uzair et al., 2024; Taoussi et al., 2025).

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_c(i) - y_a(i))^2}. \quad (5)$$

Para a escolha do melhor modelo, pode ser utilizado o método AIC, como ocorreu no estudo de (Albuquerque et al., 2014; Carmelo et al., 2017). Segundo Akaike (1974) e Carmelo et al. (2017), o menor AIC será o modelo de maior confiabilidade, o qual, teoricamente, resulta no melhor modelo para ajustar-se aos dados observados. Portanto, também determinou-se o modelo com maior verossimilhança (minimizando $-2\log FV$) e menor quantidade de parâmetros (minimizar $2p$) (Akaike, 1974). O critério de informação de Akaike foi obtido usando a Equação 6.

$$AIC = -2\log FV + 2p, \quad (6)$$

em que FV é a função verossimilhança do modelo e p , o número total de parâmetros. Quanto maior a verossimilhança, menor e melhor AIC; e quanto mais parâmetros, parcimonioso o modelo será, pois, com muitos parâmetros, a previsão se torna cada vez mais precisa, porém menos objetiva e de difícil interpretação (Akaike, 1974; Albuquerque et al., 2014).

A estatística de teste Ljung-Box é dada por Mehta et al. (2023):

$$Q = n(n+2) \sum_{k=1}^m \frac{T_k^2}{n-k} \quad (7)$$

em que Q é a estatística de teste Ljung-Box, n é o tamanho da amostra, m é o número de defasagens (lags), e T_k é a autocorrelação amostral no lag k .

4. Resultados

Neste estudo, os dados horários da velocidade do vento na bacia hidrográfica do Ribeirão Vermelho são analisados de forma descritiva e o desempenho dos modelos SARIMA e SARIMAX são comparados.

4.1. Estatística descritiva da série temporal da velocidade do vento da bacia hidrográfica do Ribeirão Vermelho

Para melhor compreender as características da variável velocidade do vento, são apresentadas na Tabela 3, as medidas descritivas (média, mediana, desvio padrão, coeficiente de variação, mínimo e máximo) dessa variável climática, como forma de caracterizar o clima local. O gráfico (Figura 2) demonstra o comportamento da série original buscando identificar a tendência e a sazonalidade existente na série. Com vista a confirmar a presença dos componentes da série temporal. A decomposição da série original (Figura 3) sugere a existência de componentes importantes como a sazonalidade, podendo caracterizar a série, necessitando de testes para sua confirmação.

Table 3: Medidas descritivas da velocidade do vento (ms^{-1}) na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil, 2010 a 2024.

| Med. descritivas | Máximo | Mínimo | Média | Mediana | Desvio padrão | Coeficiente de variação (%) |
|------------------|--------|--------|-------|---------|---------------|-----------------------------|
| | 3,00 | 0,70 | 1,77 | 1,75 | 0,51 | 29,3 |

Na Figura 4, são apresentados a Função de Autocorrelação (FAC) e a Função de Autocorrelação Parcial (FACP) da série temporal. O gráfico da FAC mostra um decaimento gradual da autocorrelação ao longo dos lags crescentes, indicando uma persistência na série, onde os valores passados estão correlacionados com os valores atuais por um período extenso. Especificamente, as autocorrelações permanecem acima do limiar de significância por vários lags. Em contraste, o gráfico da FACP exhibe um pico significativo apenas no primeiro lag, com os lags subsequentes caindo dentro dos limites de significância. Esse padrão sugere que a relação direta é principalmente com o valor imediatamente precedente, e as correlações de longo prazo observadas na FAC são amplamente devidas a essa autocorrelação de lag-1.

A aplicação do teste de Box-Cox teve como objetivo identificar uma transformação adequada para estabilizar a variância e aproximar a distribuição dos dados da normalidade. O gráfico da log-verossimilhança indicou um valor ótimo de λ próximo de zero, sugerindo a transformação logarítmica como potencialmente benéfica. No entanto, observou-se que o valor $\lambda = 1$, que corresponde à ausência de transformação, encontra-se dentro do intervalo de confiança de 95%. Isso indica que não há evidências estatísticas suficientes para




Figure 2: Série temporal original da velocidade do vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil de 2010 a 2023.




Figure 3: Decomposição da série temporal em componentes de ciclo, sazonalidade, tendência e aleatoriedade da velocidade do vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil de 2010 a 2023.




Figure 4: Funções de autocorrelação (esquerda) e Função de autocorrelação parcial (direita) para dados de velocidade do vento da série original.

rejeitar o uso dos dados originais. Dessa forma, optou-se por utilizar a série original, uma vez que ela já atende adequadamente aos pressupostos da modelagem subsequente.

Foi realizada a diferenciação na série temporal para garantir a estacionariedade. Para verificar essa condição, aplicou-se o Teste de Dickey-Fuller Aumentado (ADF), que avalia a presença de raiz unitária na série, tendo como hipótese nula a não estacionariedade. O teste foi aplicado à série diferenciada, resultando em uma estatística de teste de $-7,53$, com ordem de defasagem igual a 5 e valor-p de 0,01. Como o valor-p é inferior ao nível de significância usual de 0,05, rejeita-se a hipótese nula, indicando que a série diferenciada pode ser considerada estacionária. Na Figura 6 são apresentados os gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF) da série transformada, os quais evidenciam características compatíveis com estacionariedade, pois a maioria dos coeficientes está dentro dos limites de significância. Entretanto, observa-se a presença de picos nos lags 12 e 24 na ACF, sugerindo a existência de um possível componente sazonal. Já a PACF exibe várias defasagens significativas nos primeiros lags, indicando dependência de curto prazo que pode ser modelada adequadamente por termos autorregressivos.

4.2. Modelagem SARIMA

A escolha da ordem do modelo foi orientada pela análise dos gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF) da série diferenciada. O modelo selecionado, apresentado na Tabela 4, é um SARIMA(1, 1, 1)(1, 0, 0)₁₂, que incorpora componentes não sazonais e sazonais. A parte não sazonal inclui




Figure 5: Gráfico da função de log-verossimilhança do teste de Box-Cox para determinação do parâmetro λ .




Figure 6: Funções de autocorrelação (esquerda) e Função de autocorrelação parcial (direita) da série diferenciada

um termo autorregressivo de primeira ordem (AR(1)), com coeficiente estimado em 0,4966 e erro padrão de 0,0783, indicando influência moderada dos valores passados sobre os atuais. O componente de média móvel de primeira ordem (MA(1)), com coeficiente de $-0,9305$, revela um efeito expressivo dos erros passados, contribuindo para a estabilidade da série.

Além disso o modelo inclui um componente sazonal autorregressivo de ordem 1 (SAR(1)) com coeficiente estimado em 0,3326 e erro padrão de 0,0732. Esse termo sazonal captura a dependência dos valores da série defasados de 12 períodos, ou seja, um ano no caso de dados mensais, refletindo um padrão repetitivo anual na série temporal. A magnitude positiva do coeficiente indica que os valores atuais da série tendem a ser positivamente influenciados pelos valores observados no mesmo mês do ano anterior, evidenciando a presença de sazonalidade anual moderada na série.

Table 4: Parâmetros estimados do modelo SARIMA(1, 1, 1)(1, 0, 0)₁₂ para a série velocidade do vento

| Parâmetro | Estimativa | Erro Padrão | Valor z |
|--------------------|------------|-------------|-----------|
| ϕ_1 (AR(1)) | 0,4966 | 0,0783 | 6,34 |
| θ_1 (MA(1)) | -0,9305 | 0,0303 | -30,70 |
| Φ_1 (SAR(1)) | 0,3326 | 0,0732 | 4,54 |

Para avaliar a adequação do modelo SARIMA ajustado à série temporal da velocidade do vento, aplicou-se o teste de Box-Ljung aos resíduos do modelo. Esse teste tem como objetivo verificar a presença de autocorrelação serial nos resíduos até uma determinada defasagem. O resultado obtido foi uma estatística $Q = 29,746$, com 24 graus de liberdade, e um valor $p = 0,1933$. Como o valor p é consideravelmente superior ao nível de significância usual de 5%, não se rejeita a hipótese nula de ausência de autocorrelação nos resíduos. Portanto, conclui-se que os resíduos do modelo SARIMA podem ser considerados não correlacionados, o que reforça a adequação do modelo ajustado à estrutura temporal dos dados analisados. Para complementar a análise dos resíduos, as funções de autocorrelação (ACF) e autocorrelação parcial (PACF) dos resíduos do modelo ajustado são apresentadas a seguir na Figura 7.

4.3. Modelagem SARIMAX

Para a realização da modelagem SARIMAX, foram utilizados os mesmos procedimentos iniciais para a modelagem SARIMA, verificação da estacionariedade e sazonalidade, análise da função de autocorrelação e a função da autocorrelação parcial.

A seleção das variáveis explicativas foi conduzida por meio do critério C_p de Mallows, utilizando o método de seleção de subconjuntos. Dentre os modelos avaliados, aquele que apresentou melhor equilíbrio entre qualidade de ajuste e parcimônia foi composto pelas variáveis precipitação média, temperatura média e umidade relativa. Esse resultado indica que o modelo fornece uma boa aproximação da variância dos erros,




Figure 7: Funções de autocorrelação (à esquerda) e autocorrelação parcial (à direita) para o modelo SARIMA(1, 1, 1)(1, 0, 0)₁₂.

sem incluir variáveis irrelevantes, sendo, portanto, o mais apropriado para a modelagem da série de velocidade do vento.


Na modelagem da série temporal da velocidade do vento (*vento_ts*) utilizando um modelo SARIMAX, inicialmente foram incluídas quatro variáveis explicativas: precipitação mensal, temperatura média, umidade relativa do ar e a pressão atmosférica. Após ajuste do modelo com estrutura SARIMAX, observou-se que apenas a temperatura média e umidade relativa do ar apresentaram coeficientes estatisticamente significativos para o ajuste.

Dessa forma, realizou-se um processo de simplificação, com a remoção das variáveis não significativas e o ajuste de um modelo mais parcimonioso SARIMAX(1, 1, 1)(1, 0, 0)₁₂, incluindo a temperatura média e a umidade relativa como variáveis exógenas. Ambas se mantiveram estatisticamente significativas, demonstrando influência relevante sobre a série da velocidade do vento. Os resultados indicam que tanto a umidade relativa quanto a temperatura média estão associadas à variação da velocidade do vento no período analisado, reforçando a importância das condições climáticas no comportamento da série.

Para avaliar a adequação do modelo ajustado, foi realizado o teste de Ljung-Box sobre os resíduos, com 24 defasagens. O valor do teste foi $Q = 31,021$, com $p\text{-valor} = 0,1532$, indicando que não há evidências estatísticas de autocorrelação nos resíduos ao nível de significância de 5%. Esse resultado é corroborado pelas funções de autocorrelação (ACF) e autocorrelação parcial (PACF) dos resíduos (Figura 8), que mostram todos os coeficientes dentro dos limites de confiança, confirmando a hipótese de que os resíduos comportam-se como ruído branco.

Table 5: Parâmetros estimados do modelo SARIMAX(1,1,1)(1,0,0)₁₂ para a série de velocidade do vento

| Parâmetro | Estimativa | Erro Padrão | Valor z |
|-------------------|------------|-------------|-----------|
| ϕ_1 | 0,5258 | 0,0807 | 6,51 |
| θ_2 | -0,9428 | 0,0269 | -35,05 |
| Θ_1 | 0,4125 | 0,1031 | 4,00 |
| Temperatura média | -0,0622 | 0,0237 | -2,62 |
| Umidade relativa | -0,0095 | 0,0039 | -2,44 |

Figure 8: Funções de autocorrelação (à esquerda) e autocorrelação parcial (à direita) para o modelo SARIMAX(1, 1, 1)(1, 0, 0)₁₂.

4.4. Comparação dos modelos ajustados SARIMA e SARIMAX

Um dos objetivos de uma modelagem de séries temporais é fazer previsões de valores futuros. Para tanto, se fez necessário verificar a eficiência e o bom ajuste do modelo. Na Tabela 6, estão expostos os resultados encontrados para os modelos que melhor se ajustaram à série de dados.

Table 6: Estatísticas de erro para avaliação da acurácia dos modelos SARIMA e SARIMAX ajustados à série de velocidade do vento.

| Modelo | MAE | RMSE | AIC |
|-------------------------------------|--------|--------|-------|
| SARIMA(1,1,1)(1,0,0) ₁₂ | 0,2011 | 0,2651 | 43,89 |
| SARIMAX(1,1,1)(1,0,0) ₁₂ | 0,1927 | 0,2525 | 31,18 |

A Tabela 6 apresenta as estatísticas de erro utilizadas para avaliar a acurácia dos modelos SARIMA e SARIMAX ajustados à série de velocidade do vento. Observa-se que o modelo SARIMAX obteve menor erro médio absoluto (MAE = 0,1927) e menor raiz do erro quadrático médio (RMSE = 0,2525), o que evidencia um desempenho preditivo superior em comparação ao modelo SARIMA. Além disso, o critério de informação de Akaike (AIC), que penaliza a complexidade do modelo em relação ao ajuste, também foi significativamente menor no SARIMAX (AIC = 31,18) do que no SARIMA (AIC = 43,89), reforçando a adequação do modelo com variáveis exógenas.

4.5. Previsões dos modelos

A Tabela 7 apresenta a comparação entre as previsões dos modelos SARIMA e SARIMAX para os meses de janeiro a março de 2025, com respectivos intervalos de confiança de 95% e os valores reais observados da velocidade do vento. Observa-se que ambos os modelos produziram previsões próximas aos valores reais, com os valores observados situando-se dentro dos respectivos intervalos de confiança de 95%. No entanto, o modelo SARIMAX apresentou previsões ligeiramente mais próximas dos valores observados em fevereiro e março, sugerindo uma leve superioridade em termos de precisão preditiva, possivelmente devido à inclusão das variáveis exógenas de temperatura média e umidade relativa.

Table 7: Comparação das previsões dos modelos SARIMA e SARIMAX com os valores reais observados (intervalo de 95%).

| Mês | Modelo | Previsão | IC 95% Inferior | IC 95% Superior | Valor Real |
|-----------|---------|----------|-----------------|-----------------|------------|
| Janeiro | SARIMA | 1,22 | 0,69 | 1,75 | 0,80 |
| | SARIMAX | 1,25 | 0,75 | 1,75 | 0,80 |
| Fevereiro | SARIMA | 1,26 | 0,66 | 1,87 | 1,30 |
| | SARIMAX | 1,32 | 0,74 | 1,90 | 1,30 |
| Março | SARIMA | 1,25 | 0,62 | 1,88 | 1,50 |
| | SARIMAX | 1,31 | 0,70 | 1,92 | 1,50 |

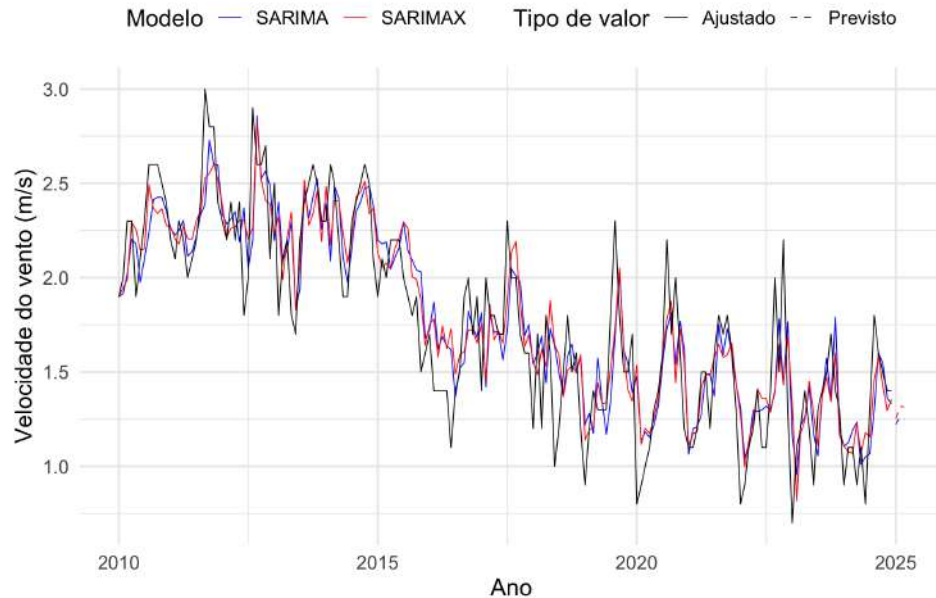


Figure 9: Previsões da velocidade do vento para os três primeiros meses de 2025 com os modelos SARIMA e SARIMAX, comparadas aos valores observados.

5. Discussão

Foi constatado que as variáveis climáticas temperatura e umidade relativa do ar foram variáveis que influenciam negativamente a velocidade do vento na bacia hidrográfica do Ribeirão Vermelho de 2010 a 2024, fato que corrobora com os fundamentos de Dec et al. (2018) destacando que durante os dias muito quentes, especialmente à tarde, quando ocorrem as temperaturas diárias mais altas do ar, o vento atinge as velocidades mais altas, o que afeta positivamente a sensação térmica humana, resultando em um agradável resfriamento do corpo. De entre outros fatores, (Morales-Acuña et al., 2019; Zhen et al., 2022), a formação do vento é o resultado do fluxo de ar horizontal, que é causado pelo calor radiante solar. Esse fator pode estar associado a variação da temperatura e da umidade relativa do ar durante o dia, influenciando, consecutivamente na velocidade do vento.

Dec et al. (2018) afirmam que temperatura instantânea do ar, medida a cada hora, atinge os valores mais altos por volta do meio-dia. A relação exatamente oposta pode ser observada para a umidade relativa do ar. Seu valor é mais alto à noite, enquanto durante o dia, especialmente ao meio-dia, ele cai significativamente. Fattah et al. (2023) afirmam que a redução da umidade relativa durante um aumento simultâneo da temperatura ambiente é vantajosa do ponto de vista do conforto térmico. Portanto, estes fatos explicam

a relação ou influência da temperatura média e a umidade relativa do ar, visto que durante os dias muito quentes, especialmente à tarde (quando ocorrem as temperaturas diárias mais altas do ar e umidade relativa do ar mais baixo), o vento atinge as velocidades mais altas.

O vento é fundamentalmente causado pelo gradiente de temperatura da atmosfera devido ao aquecimento solar variável da superfície terrestre (Tamura, 2009). Porém, (Lopez-Villalobos et al., 2022) afirmam que os perfis de velocidade do vento dependem da estabilidade atmosférica, isso não deve ser assumido como constante ao longo do dia e do ano. Para Dec et al. (2018), diariamente, o aumento da velocidade do vento ocorreu nas horas da tarde, o que é consistente com as características da temperatura.

A umidade relativa é um aspecto crucial do clima, e a maior variabilidade da umidade relativa tem impactos de longo alcance na saúde humana, agricultura, meio ambiente e infraestrutura. Toda via, a umidade relativa é a razão entre o conteúdo real de vapor de água do ar e o conteúdo de vapor de água do ar saturado na mesma temperatura (Gunawardhana et al., 2017). A umidade relativa quantifica a saturação fracionária do ar em relação ao vapor de água (Shakespeare and Roderick, 2024). Sherwood et al. (2010) demonstraram que o aumento das temperaturas globais está associado a pequenas, mas significativas mudanças na umidade relativa.

Precipitação e temperatura são os principais fatores que regem a estrutura dinâmica do clima, resultando em mudanças climáticas (Dimri et al., 2020). Afetada por vários fatores ambientais, a velocidade do vento apresenta características de altas flutuações, autocorrelação e volatilidade estocástica; portanto, é difícil prever com um único modelo (Liu et al., 2014).

Zakaria et al. (2020) demonstram que foi realizada a análise de correlação entre a velocidade do vento, a umidade e a temperatura, observando que a relação entre a velocidade do vento e a umidade foi de 0,278, demonstrando a baixa significância entre os dois parâmetros. A relação entre a velocidade do vento e a temperatura foi de -0,256, demonstrando a relação negativa baixa entre a velocidade do vento e a umidade no contexto do estudo que realizaram. Entretanto, para os pesquisadores, o resultado mostra que a velocidade do vento não depende realmente dos parâmetros de umidade e temperatura. Deve haver outros fatores que influenciam a velocidade do vento. Mas para a umidade e a temperatura, a correlação é de 0,908, o que é alto.

A grande contribuição desse estudo é a confirmação da presença de sazonalidade e redução da velocidade do vento na região da bacia hidrográfica do Ribeirão Vermelho, como foi observado na pesquisa sobre caracterização da velocidade e direção do vento na bacia hidrográfica do Ribeirão Vermelho e sua relação com desastres, um estudo desenvolvido pelos autores, visto que a incorporação de um componente sazonal de média móvel de ordem 1 (SMA(1)) com periodicidade anual (12 meses), estimado em $-0,7447$ com erro padrão de $0,0633$ permitiu capturar adequadamente a sazonalidade na série para o modelo SARIMA e $-0,6908$ com erro padrão de $0,0673$ para o modelo ARIMAX. Portanto, os componentes sazonais observados reforçam a perspectiva de existência de riscos de desastres causados pelo vento entre os meses de agosto a

novembro, época que se observa variação da temperatura e da pressão atmosférica na região do estudo, como foi descrito no estudo citado.

Na Figura 9, observa-se que a previsão utilizando o modelo SARIMAX apresentou o melhor desempenho em relação ao modelo SARIMA, o valor previsto é sempre consideravelmente superior. Portanto, pode-se constatar que as variáveis exógenas melhoram o desempenho do modelo de previsão e podem ser utilizadas para fazer previsões usando dados de outras regiões. Alharbi and Csala (2022) consideram que o modelo SARIMAX tem a capacidade de minimizar os valores de erro e aumentar a precisão geral, mesmo quando os comprimentos do conjunto de dados de entrada e saída são muito próximos um do outro e estão em direções semelhantes. Mulla et al. (2024) afirmam que a adição de variáveis exógenas ao modelo SARIMAX permite que o modelo incorpore informações adicionais à previsão. Os autores destacam que variáveis exógenas são tipicamente elementos externos que podem influenciar os dados de séries temporais, como indicadores das condições climáticas.

Para Shah et al. (2024), a análise comparativa elucidou o panorama diferenciado de desempenho dos diversos modelos de previsão, enfatizando os avanços significativos alcançados pela metodologia SARIMAX proposta na obtenção de valores superiores de RMSE. Portanto, nesse estudo constatou-se que o modelo SARIMAX obteve menor erro médio absoluto ($MAE = 0,1927$) e menor raiz do erro quadrático médio ($RMSE = 0,2525$), o que evidencia um desempenho preditivo superior em comparação ao modelo SARIMA. Além disso, o critério de informação de Akaike (AIC), que penaliza a complexidade do modelo em relação ao ajuste, também foi significativamente menor no SARIMAX ($AIC = 31,18$) do que no SARIMA ($AIC = 43,89$), reforçando a adequação do modelo com variáveis exógenas, principalmente a temperatura média e a umidade relativa do ar.

A análise dos coeficientes estimados indica que a temperatura média exerce efeito negativo sobre a velocidade do vento, com coeficiente de $-0,0622$ e valor z de $-2,62$. Isso significa que, mantidas as demais variáveis constantes, um aumento na temperatura está associado a uma redução na velocidade do vento, sendo esse efeito estatisticamente significativo. De forma semelhante, a umidade relativa do ar apresentou coeficiente negativo de $-0,0095$, com valor z de $-2,44$, sugerindo que o aumento da umidade também tende a reduzir a velocidade do vento. Ambos os resultados apontam para uma relação inversa entre essas variáveis ambientais e a dinâmica dos ventos, o que pode estar relacionado à diminuição do gradiente de pressão atmosférica em condições de maior calor e umidade. Contudo, a velocidade do vento é determinado pela variação espacial e temporal da temperatura ou seja, o balanço de energia na superfície terrestre, que causam variações no campo da pressão atmosférica, deslocando-se das regiões de maior pressão (áreas mais frias) para regiões de menor pressão (áreas mais quentes) e, portanto, quanto maior a diferença entre as pressões dessas regiões, maior será a velocidade do vento Pereira et al. (2002); Böhner and Antonić (2009b); Costa and Lyra (2012); Siqueira et al. (2014); de Paula1 Fernando et al. (2017); demonstrando a eficiência do modelo de previsão SARIMAX.

A temperatura do ar aumenta ligeiramente com o aumento da insolação Cha et al. (2015). A pressão atmosférica é um indicador do clima. O resfriamento do ar faz com que a pressão atmosférica aumente, porque o ar mais frio é mais denso e, portanto, mais pesado, enquanto o valor da pressão do solo diminui à medida que o ar se aquece, à medida que se torna menos frequente e mais leve. O ar na atmosfera está em constante movimento (Spiridonov et al., 2021). As velocidades do vento são amplamente regidas pelo gradiente de pressão (Klink, 2007). Portanto, a capacidade de investigar a previsão do vento fornecida por modelos de séries temporais são importante para compreender os processos que influenciam a velocidade do vento como ocorre na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

O aquecimento global afeta não apenas o aumento dos oceanos ou o derretimento do gelo polar, mas também a velocidade do vento (Kritharas, 2014). Um clima mais quente afeta a densidade do ar e a velocidade do vento (Ren, 2010). Os autores afirmam que há uma correlação inversa entre a temperatura e a velocidade do vento. No mesmo estudo, Ren afirma que um aumento da magnitude de 2 a 4 °C resultaria em uma circulação atmosférica mais fraca na maioria das regiões de latitude mais alta, o que, por sua vez, poderia resultar em uma redução de 4 a 12% na velocidade do vento.

6. Conclusões

Com base nos resultados obtidos, o modelo SARIMAX demonstrou desempenho superior em relação ao SARIMA na modelagem da velocidade do vento, apresentando menores valores de MAE (0,1927) e RMSE (0,2525), além do menor AIC (31,18), o que indica um ajuste mais parcimonioso e preciso aos dados observados.

A incorporação de variáveis exógenas ao modelo SARIMAX contribuiu para o ganho de desempenho. A temperatura média apresentou coeficiente estimado de $\beta = -0,0622$, revelando uma relação inversa com a variável dependente: aumentos de temperatura estão associados à redução da velocidade do vento. De forma semelhante, a umidade relativa do ar também apresentou efeito estatisticamente significativo ($\beta = -0,0095$), sugerindo que níveis mais elevados de umidade tendem a reduzir a velocidade do vento. Essas variáveis explicativas exerceram influência significativa sobre as previsões, ainda que com magnitudes distintas.

Além do bom ajuste, o modelo SARIMAX também demonstrou melhor desempenho preditivo nos três primeiros meses do ano quando comparado ao SARIMA. As previsões do SARIMAX apresentaram intervalos de confiança mais centrados em torno dos valores reais observados, enquanto o modelo SARIMA superestimou os valores para todos os meses avaliados. Por exemplo, em janeiro, o valor real foi 0,80, enquanto o SARIMAX previu 1,25 (IC 95%: [0,75;1,75]), mais próximo do observado do que a previsão do SARIMA previu 1,22 (IC 95%: [0,69;1,75]). Essa tendência se repetiu em fevereiro e março, evidenciando a maior acurácia preditiva do modelo com variáveis exógenas.

Em síntese, os resultados confirmam a robustez do modelo SARIMAX tanto em termos de ajuste quanto

de capacidade preditiva, reforçando a importância da incorporação de variáveis climáticas relevantes no processo de modelagem estatística da velocidade do vento.

7. Declarações

8. Interesses concorrentes

Os autores declaram que não têm interesses financeiros concorrentes ou relações pessoais que possam parecer influenciar o trabalho relatado neste documento.

9. Financiamento

O primeiro autor recebeu uma bolsa científica da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

References

- Afrifa-Yamoah, E., 2015. Application of arima models in forecasting monthly average surface temperature of brong ahafo region of ghana. *International journal of statistics and applications* 5, 237–246.
- Akaike, H., 1974. A new look at the statistical model identification. *IEEE transactions on automatic control* 19, 716–723.
- Albuquerque, P.H., Silva, L.d.C., Maluf, Y.S., 2014. Estimativa da influência de variáveis macroeconômicas sobre o faturamento de organizações siderúrgicas usando o armax. *Gestão & Produção* 21, 648–659.
- Alharbi, F.R., Csala, D., 2022. A seasonal autoregressive integrated moving average with exogenous factors (sarimax) forecasting model-based time series approach. *Inventions* 7, 94.
- Böhner, J., Antonić, O., 2009a. Land-surface parameters specific to topo-climatology. *Developments in Soil Science* 33, 195–226. doi:10.1016/S0166-2481(08)00008-1.
- Böhner, J., Antonić, O., 2009b. Land-surface parameters specific to topo-climatology. *Developments in soil science* 33, 195–226.
- Box, G.E., Jenkins, G.M., Reinsel, G.C., Ljung, G.M., 2015. *Time series analysis: forecasting and control* .
- Cadenas, E., Jaramillo, O.A., Rivera, W., 2010. Analysis and forecasting of wind velocity in chetumal, quintana roo, using the single exponential smoothing method. *Renewable Energy* 35, 925–930.
- Carmelo, H.d.N., Lucio, P.S., Leal Junior, J.B.V., Carvalho, P.C.M.d., 2017. Previsão de velocidade do vento no nordeste brasileiro através do modelo arimax .
- Cha, W.C., Park, J.H., Cho, U.R., Kim, J.C., 2015. A study on solar power generation efficiency empirical analysis according to temperature and wind speed. *The Transactions of the Korean Institute of Electrical Engineers P* 64, 1–6.
- Costa, G.B., Lyra, R.F.d.F., 2012. Análise dos padrões de vento no estado de alagoas. *Revista Brasileira de Meteorologia* 27, 31–38.
- Dalton, A., Bekker, B., 2022. Exogenous atmospheric variables as wind speed predictors in machine learning. *Applied Energy* 319, 119257.
- Dec, E., Babiartz, B., Sekret, R., 2018. Analysis of temperature, air humidity and wind conditions for the needs of outdoor thermal comfort, in: *E3S Web of Conferences*, EDP Sciences. p. 00028.
- Dimri, T., Ahmad, S., Sharif, M., 2020. Time series analysis of climate variables using seasonal arima approach. *Journal of Earth System Science* 129, 1–16.

- Dubey, A.K., Kumar, A., García-Díaz, V., Sharma, A.K., Kanhaiya, K., 2021. Study and analysis of sarima and lstm in forecasting time series data. *Sustainable Energy Technologies and Assessments* 47, 101474.
- Elsaraiti, M., Merabet, A., 2021. A comparative analysis of the arima and lstm predictive models and their effectiveness for predicting wind speed. *Energies* 14, 6782.
- Fattah, M.A., Gupta, S.D., Farouque, M.Z., Ghosh, B., Morshed, S.R., Chakraborty, T., Kafy, A.A., Rahman, M.T., 2023. Spatiotemporal characterization of relative humidity trends and influence of climatic factors in bangladesh. *Heliyon* 9.
- Fernández-López, J., Schliep, K., Arjona, Y., 2022. 2 rwind-package. Package 'rWind' , 2.
- Fia, R., Tadeu, H.C., Menezes, J.d., Fia, F.R.L., OLIVEIRA, L.d., 2015. Qualidade da água de um ecossistema lótico urbano. *Revista Brasileira de Recursos Hídricos* 20, 267–275.
- Gunawardhana, L.N., Al-Rawas, G.A., Kazama, S., 2017. An alternative method for predicting relative humidity for climate change studies. *Meteorological Applications* 24, 551–559.
- Hyndman, R.J., Athanasopoulos, G., Bergmeir, C., Caceres, G., Chhay, L., O'Hara-Wild, M., Petropoulos, F., Razbash, S., Wang, E., 2020. Package 'forecast'. Online] <https://cran.r-project.org/web/packages/forecast/forecast.pdf> .
- Kavasseri, R.G., Seetharaman, K., 2009. Day-ahead wind speed forecasting using f-arima models. *Renewable energy* 34, 1388–1393.
- Klink, K., 2007. Atmospheric circulation effects on wind speed variability at turbine height. *Journal of applied meteorology and climatology* 46, 445–456.
- Kritharas, P., 2014. Developing a SARIMAX model for monthly wind speed forecasting in the uk. Ph.D. thesis. Loughborough University.
- Liu, D., Niu, D., Wang, H., Fan, L., 2014. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm. *Renewable energy* 62, 592–597.
- Lopez-Villalobos, C.A., Martinez-Alvarado, O., Rodriguez-Hernandez, O., Romero-Centeno, R., 2022. Analysis of the influence of the wind speed profile on wind power production. *Energy Reports* 8, 8079–8092.
- Mehta, V., Rai, V., et al., 2023. Stochastic modelling and forecasting of relative humidity and wind speed for different zones of kerala. *MAUSAM* 74, 1053–1064.
- Menezes, J.P.C., Franco, C.S., de Oliveira, L.F.C., Bittencourt, R.P., de Sá Farias, M., Fia, R., 2014. Morfometria e evolução do uso do solo e da vazão de máxima em uma micro bacia urbana. *Revista Brasileira de Geomorfologia* 15.
- Morales-Acuña, E., Torres, C.R., Linero-Cueto, J.R., 2019. Surface wind characteristics over baja california peninsula during summer. *Regional Studies in Marine Science* 29, 100654.
- Mulla, S., Pande, C.B., Singh, S.K., 2024. Times series forecasting of monthly rainfall using seasonal auto regressive integrated moving average with exogenous variables (sarimax) model. *Water Resources Management* 38, 1825–1846.
- Noman, F., Alkaws, G., Alkahtani, A.A., Al-Shetwi, A.Q., Tiong, S.K., Alalwan, N., Ekanayake, J., Alzahrani, A.I., 2021. Multistep short-term wind speed prediction using nonlinear auto-regressive neural network with exogenous variable selection. *Alexandria Engineering Journal* 60, 1221–1229.
- de Paula Fernando, D.L.P., Cardoso, A.C., Cardoso, R.B., de Paula, G., Cunha, Q., Vieira, E.M., 2017. Modelagem espacial da velocidade do vento a 50, 75 e 100 metros de altura para o estado de minas gerais, brasil, empregando geoestatística. *Revista Brasileira de Geografia Física* 10, 1281–1295.
- Pepple, S.U., Harrison, E.E., 2017. Comparative performance of garch and sarima techniques in the modeling of nigerian board money. *CARD Int J Soc Sci Confl Manag* 2, 258–270.
- Pereira, A.R., Angelocci, L.R., Sentelhas, P.C., 2002. Agrometeorologia: fundamentos e aplicações práticas.
- Pitz, I., Neves, L., Pitz, J., Eli, K., Oliveira, E., 2013. Caracterização da velocidade e direção predominante dos ventos para a localidade de rio do sul-sc. *ENCICLOPEDIA BIOSFERA* 9.
- Ren, D., 2010. Effects of global warming on wind energy availability. *Journal of Renewable and Sustainable Energy* 2.

- Robitzsch, A., Luedtke, O., Robitzsch, M.A., 2022. Package ‘starts’ .
- Sfetsos, A., 2002. A novel approach for the forecasting of mean hourly wind speed time series. *Renewable energy* 27, 163–174.
- Shah, V., Patel, N., Shah, D., Swain, D., Mohanty, M., Acharya, B., Gerogiannis, V.C., Kanavos, A., 2024. Forecasting maximum temperature trends with sarimax: A case study from ahmedabad, india. *Sustainability* 16, 7183.
- Shakespeare, C.J., Roderick, M.L., 2024. What controls near-surface relative humidity over the ocean? *Journal of Advances in Modeling Earth Systems* 16, e2023MS004168.
- Sherwood, S.C., Ingram, W., Tsushima, Y., Satoh, M., Roberts, M., Vidale, P.L., O’Gorman, P.A., 2010. Relative humidity changes in a warmer climate. *Journal of Geophysical Research: Atmospheres* 115.
- Siqueira, L.F., Querino, C.A.S., da Silva Querino, J.K.A., Pavão, V.M., de Oliveira Leite, L., de Azevedo Passos, L., da Costa, T.A.C.R., Machado, N.G., Nogueira, M.C.d.J.A., Biudes, M.S., 2014. Caracterização do regime de ventos nos municípios de humaitá-am e apuí-am. *EDUCAmazônia* 12, 99–112.
- Souza, C.J.d., Liberato, A.M., 2019. Análise da velocidade e direção do vento em vilhena, rondônia. *Revista de Administração e Negócios da Amazônia* 11, 344–361.
- Spiridonov, V., Čurić, M., Spiridonov, V., Čurić, M., 2021. Atmospheric pressure and wind. *Fundamentals of Meteorology* , 87–114.
- Tamura, Y., 2009. Wind-induced damage to buildings and disaster risk reduction. *Proceedings of the APCWE-VII, Taipei, Taiwan* .
- Taoussi, B., Boudia, S.M., Mazouni, F.S., 2025. Wind speed forecasting using univariate and multivariate time series models. *Stochastic Environmental Research and Risk Assessment* 39, 547–579.
- Trapletti, A., Hornik, K., LeBaron, B., Hornik, M.K., 2015. Package ‘tseries’. R project .
- Uzair, M., Shah, I., Ali, S., 2024. An adaptive strategy for wind speed forecasting under functional data horizon: a way towards enhancing clean energy. *IEEE Access* .
- Vautard, R., Cattiaux, J., Yiou, P., Thépaut, J.N., Ciais, P., 2010. Northern hemisphere atmospheric stilling partly attributed to an increase in surface roughness. *Nature geoscience* 3, 756–761.
- Wickham, H., Chang, W., Wickham, M.H., 2016. Package ‘ggplot2’. Create elegant data visualisations using the grammar of graphics. Version 2, 1–189.
- Wickham, H., Hester, J., Francois, R., Bryan, J., Bearrows, S., Jylänki, J., Jørgensen, M., 2024. Package ‘readr’. Read Rectangular Text Data. Available online: <https://cran.r-project.org/web/packages/readr/readr.pdf> (accessed on 23 August 2023) .
- Zakaria, N.H., Salleh, S., Asmat, A., Chan, A., Isa, N.A., Hazali, N.A., Islam, M., 2020. Analysis of wind speed, humidity and temperature: variability and trend in 2017, in: *IOP Conference Series: Earth and Environmental Science*, IOP Publishing. p. 012013.
- Zhao, E., Zhao, J., Liu, L., Su, Z., An, N., 2015. Hybrid wind speed prediction based on a self-adaptive arimax model with an exogenous wrf simulation. *Energies* 9, 7.
- Zhen, Z., Qiu, G., Mei, S., Wang, F., Zhang, X., Yin, R., Li, Y., Osório, G.J., Shafie-khah, M., Catalão, J.P., 2022. An ultra-short-term wind speed forecasting model based on time scale recognition and dynamic adaptive modeling. *International Journal of Electrical Power & Energy Systems* 135, 107502.

ARTIGO 4 - Caracterização morfométrica da bacia hidrográfica do Ribeirão Vermelho e suas relação com índices de exposição e proteção a ventos extremos

Redigido conforme as normas da revista *Natural Hazard* (versão não submetida)

Caracterização morfométrica da bacia hidrográfica do Ribeirão Vermelho e sua relação com índices de exposição e proteção ao vento

Orlando Eduardo Chipura^a, Marcelo de Carvalho Alves^{a,1}, Fortunato Silva de Menezes^b

^aEngineering School (EENG) Agriculture Engineering Department UFLA Campus Lavras 37200-000 Brazil

^bInstitute of Natural Sciences (ICN) Physics Department UFLA Campus Lavras 37200-000 Brazil.

Abstract

A modelagem espacial do vento é essencial e útil durante o estágio inicial da seleção do local de qualquer projeto agrícola e de energia eólica. Ventos fortes causam perdas desastrosas para o tecido social e econômicos em vários países do mundo incluindo o Brasil. Nesse estudo objetivou-se caracterizar as variáveis morfométrica da bacia hidrográfica do Ribeirão Vermelho, relacionar os índices de exposição e proteção aos riscos de desastres eólicos. Foram utilizados dados médios diários de velocidade e direção do vento obtidos através da estação meteorológica convencional do Instituto Nacional de Meteorologia (INMET), localizada no campus da Universidade Federal de Lavras (UFLA) que serviram de dados de entrada para a modelagem do vento. Foi utilizado o modelo digital de elevação da região para obter as variáveis morfométricas, calcular e determinar os índices e gerar mapas de exposição e proteção ao vento em R. Os resultados demonstram que a variação do planialtimétrica do relevo, a declividade e o aspecto influenciam na variação espacial do vento, relacionando-se com a ocorrência de desastres. As regiões onde o relevo varia de 900 a 1081.9 m apresenta maior exposição e vulnerabilidade a desastres ao vento de direção leste. Cerca de 0.10 m² apresenta risco muito alto para ocorrência de desastre e 13.57 m² está em alto risco. Os locais de alto risco e muito alto risco tornaram-se sugestivos para implantação de sistemas de proteção com recurso a quebra-ventos. Contudo, a metodologia aplicada, com recurso ao modelo digital de elevação permitiu caracterizar a morfometria da região do estudo e apresentar a variação espacial do vento e sua relação com os índices de exposição e proteção ao vento na bacia hidrográfica. o estudo contribuiu para o entendimento dos fenômenos ambientais causados pela variação espacial do vento, análises de riscos de desastres, identificação de locais para implantação de quebra-ventos, planejamento sustentável do uso do solo e instalação de parques eólicos.

Keywords:

Geoprocessamento, relevo ondulado, declividade, quebra-vento, ventos de Leste.

*Corresponding author

Email address: marcelo.alves@ufla.br (Marcelo de Carvalho Alves)

¹Corresponding Author

1. Destaques do artigo

- Para ventos predominantes (Leste), 0.10 km² da bacia hidrográfica tem muito alto risco de ocorrência de desastres, visto que o relevo favorece a ocorrência do fenômeno.
- As características morfométricas do terreno influenciam consideravelmente na variação espacial do vento na bacia hidrográfica do Ribeirão Vermelho.

2. Introdução

As bacias hidrográficas são os elementos importantes da forma de relevo fluvial e uma grande quantidade de estudos se concentrou em analisar seus comportamentos e as características geométricas, que contêm a topologia das redes de fluxo, análise quantitativa da textura de drenagem, padrão, forma e características de relevo (Magesh et al., 2013; Rai et al., 2017). As características morfométricas são a dimensão e a avaliação matemática da configuração da superfície terrestre (Pareta and Pareta, 2011).

Modelo digital de elevação (MDE) tem sido utilizado como um dos principais bancos de dados em muitas aplicações de sistema de informação geográfica (SIG), pelo que fornecem a descrição da superfície tridimensional e base de dados para uma visualização tridimensional impressionante de dados geográficos, mas também estabelece a base para a derivação de outras variáveis morfológicas da superfície, como declividade, aspecto, curvatura, perfil de talude e áreas de captação (Zhou and Liu, 2004). Rai et al. (2017) afirmam que a compreensão da distribuição das classes de declividade é importante; pois, um mapa de declividade fornece dados para o planejamento de bacias hidrográficas para o assentamento, agricultura, desmatamento ou reflorestamento, planejamento de construção de estruturas de coleta de água, estruturas de engenharia, práticas de morfoconservação e riscos eólicos.

As variáveis morfométricas como área, altitude, volume, declividade, aspecto, curvatura, áreas de captação, perfil e textura de formas de relevo compreendem parâmetros importantes da vários estudos e têm sido amplamente utilizados em modelagem hidrológica, estudos de erosão do solo, simulação de ambientes ecológicos, entre outros (Zhou and Liu, 2004; Rai et al., 2017). Para Zhou and Liu (2004), entre os parâmetros morfológicos, declividade e aspecto têm sido indiscutivelmente os mais utilizados em aplicações de sistema de informação geográfica; como será a abordagem dominante neste artigo para modelar a variação espacial do vento e na análise de locais vulneráveis a riscos de desastres eólicos.

O aspecto de um terreno é a direção para a qual ele está voltado (Magesh et al., 2011, 2013). Ela influencia o tipo de vegetação, os padrões de precipitação, o derretimento da neve e a exposição ao vento. Segundo (Magesh et al., 2013), a direção da bússola do aspecto foi derivado do valor dos dados *raster* de saída. A inclinação de um terreno refere-se à quantidade de inclinação de uma característica física, relevo topográfico em relação à superfície horizontal.

De acordo com, Magesh et al. (2011, 2013) relevo é definido como a diferença de elevação entre o ponto mais baixo e o mais alto de uma bacia. Para Liu et al. (2024b), o modelo digital de elevação oferece uma representação abrangente das características do terreno, encapsulando não apenas as pegadas de edifícios, mas também elementos verticais adicionais, como alturas de edifícios, vegetação e elevações de superfície.

As características topográficas como escarpas, cumes, aterros e colinas, o fluxo de ar podem acelerar e desacelerar o vento (Ngo and Letchford, 2009). Os efeitos topográficos na velocidade do vento são ainda mais importantes na exploração de energia eólica, uma vez que as turbinas eólicas devem ser localizadas em regiões onde a energia eólica ideal é obtida. Assim, é necessário investigar os efeitos das características topográficas nos fluxos de vento para abordar essas questões.

Tempestades de vento causam danos substanciais a edifícios e perdas econômicas no mundo todo ano (Jiang et al., 2023). O mapeamento de locais de ocorrência de riscos de desastres causados pelos ventos podem desempenhar um papel importante na gestão de desastres (Tan and Fang, 2018). Além da velocidade, também deve ser dada atenção à sua direção predominante para sugerir sistemas de proteção para evitar a ocorrência de desastres. A localização de proteções vegetais (quebra-ventos), tão úteis na área agrícola, socioeconômico, meteorológico e ambiental, dependendo principalmente do conhecimento das direção predominante do vento.

Nas últimas décadas, os sistemas de informação geográfica permitiram a análise detalhada da superfície terrestre, enquanto o desenvolvimento em sensoriamento remoto proporcionou modelos digitais de elevação e imagens multi-espectrais cada vez mais detalhadas (Schillaci et al., 2015). A variação espacial do vento pode ser caracterizada através da utilização de uma rede densa de anemômetros, ou métodos de interpolação sofisticados que combinam informação topográfica com alguns pontos de observação para gerar campos de vento espacialmente variáveis (Rueda et al., 2005).

Estruturas meteorológicas dinâmicas na troposfera e as características topográficas causam variações temporais e espaciais na velocidade do vento (Şen, 2001). Porém, ventos descendentes são fenômenos meteorológicos de montanha que contribuem para extremos de temperaturas localizadas e também contribuem para vários impactos sociais e ambientais (Abatzoglou et al., 2021). A mudança na inclinação do terreno produz pequenas flutuações na temperatura potencial virtual Peckham and Wicker (2000) favorecendo o fluxo do vento, tornando as características topográficas um dos fatores mais comuns que contribuem para a variação espacial do vento.

Todavia, ainda existe uma grande lacuna na melhoria da avaliação global de riscos eólicos (Tan and Fang, 2018). Em geral, os riscos eólicos são espacialmente heterogêneos, os fatores locais como altitude, declividade e o aspecto, uso e cobertura do solo influenciam muito os perfis de vento em escala local. Portanto, geoprocessamento com recurso a modelo digital de elevação podem ter uma contribuição significativa como ferramenta de apoio à decisão na identificação de locais ambientalmente viáveis de riscos de desastres eólicos que exigem gestão estratégica e preventiva. Objetivou-se caracterizar as variáveis morfométrica da bacia hidrográfica do Ribeirão Vermelho, relacionar os índices de exposição e proteção aos riscos de desastres.

3. Material e Métodos

3.1. Caracterização da área de estudo

O estudo foi desenvolvido na bacia hidrográfica do Ribeirão Vermelho, localizada no estado de Minas Gerais, Brasil, situada entre as coordenadas 21°26' a 21°18' de latitude Sul e 44°95' a 45°07' de longitude Oeste, incluindo a área urbana do município de Lavras Figura 1. O clima predominante é classificado como Cwb, temperado chuvoso, com inverno seco e verão chuvoso, subtropical. A temperatura média anual é de 19.3°C, tendo nos meses mais quente e mais frio temperaturas médias de 21.3 e 15.1°C, respectivamente. A precipitação total anual média de 1.530 mm (Alvares et al., 2013).

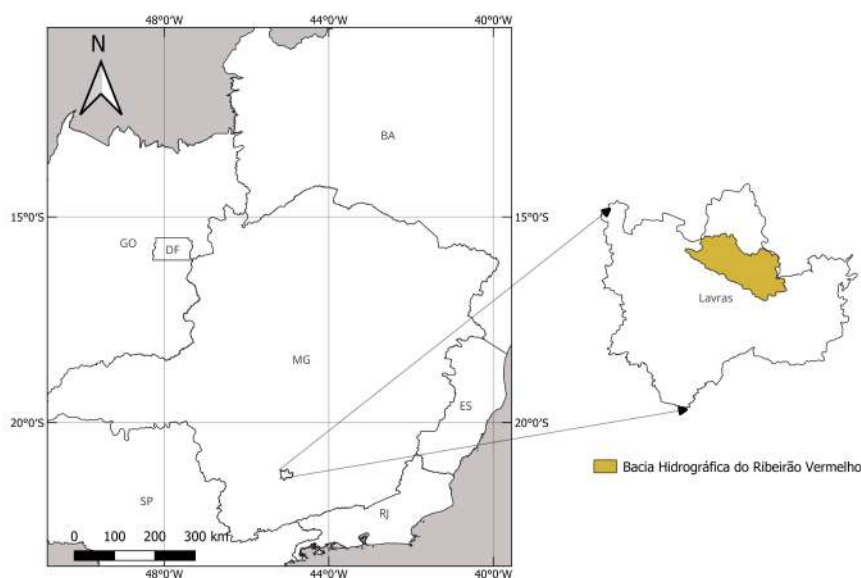


Figure 1: Localização da bacia do Ribeirão Vermelho, Minas Gerais, Brasil

A região compreende o afluente que percorre a zona urbana de Lavras, com cerca de 15 km e deságua no Rio Grande.

3.2. Obtenção e tratamento de dados *in situ* e radiométricos

Os dados da direção e velocidade do vento foram obtidos através da estação meteorológica convencional do Instituto Nacional de Meteorologia (INMET), localizada no campus da Universidade Federal de Lavras (UFLA) entre as coordenadas 21°13'34" S, 44°58'46" W, 916 m de altitude, disponíveis para o acesso público através do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP), no formato *Excel*.

Para obter a variação do regime do vento nas escalas de tempo anual foi usado o índice de tempo básico t , $u(t_i) = u_i$ e $\theta(t_i) = \theta_i$, com $i = 1, 2, \dots$, representando a série temporal de velocidade e direção do vento, respectivamente e escala t_i são em horas, enquanto os meses foram indicados pela letra m e os anos pela letra j . A velocidade média anual do vento $m_{u,Y}$ é calculada usando a Equação 1 de acordo com (Schubert et al., 2022).

$$m_{u,Y} = \frac{1}{J} \sum_{j=1}^J m_{u,j}, \quad (1)$$

A direção predominante do vento é caracterizada através da realização de uma análise de frequência das observações média diária, utilizando a expressão da Equação 2 conforme Grange (2014) para cada mês do ano.

$$\bar{\theta}_{RV} = \arctan\left(\frac{\bar{u}}{\bar{v}}\right) + flow \quad (2)$$

$$flow = + 180 \text{ for } \arctan\left(\frac{\bar{u}}{\bar{v}}\right) < 180$$

$$flow = - 180 \text{ for } \arctan\left(\frac{\bar{u}}{\bar{v}}\right) > 180$$

em que $\bar{\theta}_{RV}$ representa a direção do vento, \bar{u} é usado para a medição horizontal do vento e \bar{v} representando os componentes leste-oeste e norte-sul. As frequências de direção é plotado em gráfico de rosa-do-vento para melhor visualização. As direções são colocadas em siglas e representadas por: norte (N), leste (E), oeste (W), sul (S), nordeste (NE), noroeste (NW), sudeste (SE), sudoeste (SW).

Foram determinados os atributos topográficos primários (elevação, declividade e o aspecto) para determinar a influência dessas variáveis morfométricas na variação espacial da velocidade e direção, índices de exposição e de proteção da bacia hidrográfica do Ribeirão Vermelho ao vento. Os dados radiométricos são provenientes da conversão ou cálculos de resolução espacial do pixel obtidos do modelo digital de elevação. Para a área de estudo, o o modelo digital de elevação foi obtido da Shuttle Radar Topography Mission (SRTM) numa resolução de 30 m.

3.3. Linguagem computacional e pacotes utilizados para processamento de dados

Nesse estudo foi utilizado a linguagem R, v. 4.3.3, com recurso aos pacotes apresentados na Tabela 1 que foram utilizados para manipular e processar dados provenientes do modelo digital de elevação através de técnicas de geoprocessamento para realizar a caracterização morfométrica da bacia hidrográfica e demonstrar a variação espacial do vento. Também forma aplicados para a identificação de locais vulneráveis a riscos de desastres eólicos. Também foram utilizados para realizar a estatística descritiva da série temporal das médias de velocidade e direção do vento na região do estudo.

Table 1: Pacotes R de interesse na pesquisa sobre a caracterização da morfométrica da bacia do hidrográfica do Ribeirão Vermelho e sua relação com índices de exposição e proteção ao vento.

| Pacote | Descrição | Referência |
|----------------------|--|-------------------------------|
| <code>rWind</code> | Foi usado para gerenciar dados de vento e calcular as médias. | Fernández-López et al. (2022) |
| <code>ggplot2</code> | Foi usado na implementação da gramática de gráficos e para mapear dados da pesquisa. | Wickham et al. (2016) |
| <code>openair</code> | Foi usado para analisar, interpretar e entender os dados meteorológicos como a função <code>windRose</code> , que visualiza a direção do vento. | Carslaw and Ropkins (2014) |
| <code>xlsx</code> | Forneceu funções para ler, gravar e formatar a base de dados do vento no formato <i>Excel</i> 2007 usando o R. | Dragulescu et al. (2020) |
| <code>Terra</code> | Forneceu métodos para análise de dados espaciais e tratamento de <i>raster</i> (grelha). Os métodos <i>raster</i> inclui operações locais e os métodos de previsão e interpolação facilitam a utilização de modelos do tipo aprendizagem automática. | Hijmans et al. (2022) |
| <code>raster</code> | Forneceu funções gerais de manipulação de dados <i>raster</i> que foram facilmente utilizados para desenvolver funções no tratamento dos dados. | Hijmans et al. (2013) |

3.4. Atributos morfométricas da bacia hidrográfica do Ribeirão Vermelho

O primeiro parâmetro mais simples que é um possível estimador da exposição topográfica ao vento é a distância angular do azimute da direção do vento α_r , ou seja, aspeto do terreno. O segundo potencialmente útil para estimar a exposição topográfica ao vento é o ângulo do horizonte φ na direção do vento. A combinação dos dois parâmetros identificados da superfície do terreno, juntamente com a consideração da influência da inclinação β , pode ser feita com o uso da Equação,

$$\cos \gamma_w = \sin \varphi \cos \beta + \cos \varphi \sin \beta \cos \alpha_r \quad (3)$$

em que γ_w é o ângulo entre um plano ortogonal ao vento e o plano que representa localmente a superfície terrestre (Böhner and AntoniĆ, 2009).

Todos os parâmetros da superfície terrestre sugeridos aqui como possíveis estimadores da exposição da superfície terrestre ao vento podem ser aplicados de duas maneiras gerais: (1) usando exposição topográfica ao vento de uma direção predominante selecionada inicialmente, mais frequentemente com base em uma rosa dos ventos local extraída de dados coletados na estação meteorológica mais próxima, (2) usando várias exposições topográficas ao vento de diferentes direções hipotéticas (por exemplo, para cada 45°). A direção que apresentar a maior capacidade de explicar uma variabilidade espacial do fenômeno visado pode então ser usada como a direção mais adequada (Böhner and AntoniĆ, 2009). Nesse estudo foi aplicado o uso exposição do relevo (topográfica) ao vento de uma direção predominante selecionada previamente (Leste), com base nos dados meteorológicos.

3.5. Algoritmos de declividade e aspecto

Para determinar a declividade e o aspecto, baseou-se em um dado ponto de uma superfície $z = f(x, y)$. A declividade (S) e o aspecto (A) foram definidos como funções dos gradientes nas direções x e y , ou seja, direções Leste-Oeste (W-E) e Norte-Sul (N-S),

$$S = \arctan \left(\sqrt{f_x^2 + f_y^2} \right) \quad (4)$$

$$A = 270^\circ + \arctan \left(\frac{f_y}{f_x} \right) - 90^\circ \frac{f_x}{|f_x|} \quad (5)$$

em que f_x e f_y são os gradientes da função $f(x, y)$ nas direções x (Leste-Oeste) e y (Norte-Sul), respectivamente; \arctan é a função arco-tangente; o aspecto A é ajustado para refletir a orientação angular em graus com base na convenção cartográfica.

De fato, fica claro que a chave para o cálculo do declividade (S) e do aspecto (A) é a obtenção dos gradientes f_x e f_y . Quando se utiliza um modelo digital de elevação baseado em grade, uma abordagem comum para estimar esses gradientes é a aplicação de uma janela móvel 3×3 ao redor de cada célula. Essa

janela permite o uso de métodos numéricos como o diferencial finito ou o ajuste de polinômios de superfície local, que fornecem aproximações para as derivadas parciais da elevação nas direções x (Leste-Oeste) e y (Norte-Sul). A partir desses gradientes, calculam-se então a declividade e o aspecto conforme definido nas Equações (4) e (5).

3.6. Determinação da deflexão do vento na bacia hidrográfica do Ribeirão Vermelho

Para determinar o índice de barlavento e sotavento (efeito do vento) na bacia hidrográfica do Ribeirão Vermelho procedeu-se a modelagem do fluxo do vento baseando-se na Equação 6, proposta por (Ryan, 1977), uma equação simples para a deflexão do vento de gradiente soprando através de uma encosta, onde a declividade era inferior a 45° . Sabe-se que a topografia produz o efeito de rotação do vento como foi proposto por (Purves et al., 1998).

$$Fd = -255s_d \text{Sin}(2(A - \theta)) \quad (6)$$

em que F_d é o desvio do vento (graus), s_d é a inclinação (%), A é o aspecto da encosta (graus) e θ é a direção do vento (graus).

Esta equação permitiu que a direção do vento em células individuais fosse modificada de acordo com o aspecto e a declividade de uma célula em relação à direção do vento. Como os cálculos da deflexão do vento (Equação 2) afeta a direção do vento, que é uma variável utilizada no cálculo do índice de abrigo, então os vetores desviados são calculados antes do índice de abrigo ou proteção (Purves et al., 1998).

3.6.1. Determinação do índice de sotavento e barlavento

Verificou-se a coerência geométrica e a compatibilidade dos sistemas de projeção entre os dados vetoriais e *raster*, para limitar a análise à área da bacia hidrográfica. O modelo digital de elevação foi recortado e mascarado com base nos limites da bacia. A orientação das encostas foi determinada utilizando a função *terrain* da biblioteca *raster*, gerando um *raster* de aspecto em graus. A direção do vento predominante foi 90° (Leste), e o índice foi calculado com base na deflexão angular entre a orientação da encosta e a direção predominante do vento. Portanto, os índices de barlavento e sotavento foram armazenados como um novo *raster* e visualizado para análise espacial da influência do relevo sobre a circulação do vento na bacia.

O índice de barlavento (Windward Index) é uma métrica que mede a exposição do relevo ao vento predominante. Foi calculado a partir da diferença angular entre a direção do vento e o aspecto da encosta, usando a Equação 7.

$$WI = \cos(A - \theta) \quad (7)$$

em que WI é o índice de barlavento, A = e a direção do vento em radianos e θ é o aspecto da encosta em radianos.

O índice de sotavento (Leeward Index), representa a alteração na intensidade e direção do vento devido à interação com o relevo. Esse índice é calculado a partir da diferença angular entre a direção do vento e o aspecto da encosta, conforme a Equação 8,

$$LI = -\cos(A_{\text{rad}} - \theta_{\text{rad}}) \quad (8)$$

em que LI é o índice de sotavento, A_{rad} é a direção do vento convertida para radianos e θ_{rad} é o aspecto da encosta convertida para radianos.

No entanto, o ângulo da direção do vento (A) é fornecido como um parâmetro de entrada, representando a orientação do vento (em graus). Neste caso, o valor utilizado foi de (90°), posição que o vento é proveniente do Leste a Oeste. O aspecto da encosta foi extraído diretamente do modelo digital de elevação e representa a orientação da superfície do terreno. A partir dessa informação, identificou-se a direção das encostas (para montanhas ou vales) e, conseqüentemente, inferir as áreas de barlavento e sotavento. Com base na diferença angular entre a direção do vento e o aspecto da encosta, calculou-se a deflexão do vento, com seu valor foi estimado a intensidade do vento em áreas de sotavento.

3.6.2. Determinação do índice de exposição ao vento na bacia hidrográfica do Ribeirão Vermelho

Utilizaram-se variáveis morfométricas (altitude, declividade e o aspecto) para analisar a redistribuição do vento (variação espacial) baseados no terreno. Os cálculos dos parâmetros de redistribuição do vento basearam-se nos estudos de Winstral et al. (2002); Paraschaki and Eriksson (2019), utilizando modelo digital de elevação e dados médios de velocidade e direção do vento predominante na bacia hidrográfica. Para o efeito, foi escolhido uma janela de análise contra o vento centrada na direção predominante até 90° , conforme demonstra-se na Figura 2, e com base na Equação 9.

em que linha a negrito representa a superfície terrestre. N, indica o norte. O terreno à volta do ponto A tem a declividade (SLP) e o aspeto (ASP). O aspecto relativo do terreno (RTA) é a distância angular absoluta entre o aspecto do terreno e o azimute do fluxo de vento (AWF), o ângulo do horizonte (HNA) do ponto A . Para um dado azimute do fluxo de vento é determinado pelo ponto mais alto com a distância de procura escolhida (SDS), o ângulo entre um plano que localmente representa o terreno (P_1) e o plano ortogonal ao vento (P_2) é denotado por APO (o ponto A' é uma projeção do ponto A no plano ortogonal) conforme (Böhner and AntoniĆ, 2009).

Portanto, uma alteração da distância de busca pode alterar o ângulo do horizonte. Estendendo-se contra vento de cada pixel, a janela foi limitada lateralmente por dois azimutes separados por uma largura escolhida arbitrariamente de 135° ($A1 = 0^\circ$ e $A2 = 135^\circ$) observados no R, podem ser observados no software SAGA GIS. A largura lateral da janela escolhida (300 metros) permitiu a inclusão do terreno que não esteja diretamente contra o vento da célula com base nas observações dos dados climáticos, consoante a pesquisa de Winstral et al. (2002); Paraschaki and Eriksson (2019), utilizando a Equação 9.




Figure 2: Representação esquemática da modelagem do vento de direção leste na bacia do Ribeirão Vermelho, Minas Gerais, Brasil considerando a célula de interesse

$$Sx_{A.dmax}(x_i, y_i) = \max \left[\tan \left(\frac{\text{ELEV}(x_v, y_v) - \text{ELEV}(x_i, y_i)}{\sqrt{(x_v - x_i)^2 + (y_v - y_i)^2}} \right) \right], \quad x \in S \quad (9)$$

em que A é o azimute da direção de pesquisa, (x_i, y_i) são as coordenadas da célula de interesse e (x_v, y_v) são o conjunto de todas as coordenadas das células localizadas ao longo do vetor de pesquisa definido por (x_i, y_i) , A e d_{max} (distância de busca). Foi especificado de uma distância de busca d_{max} de 300 metros que controla a extensão do terreno a ser analisado contra o vento, como ocorreu no estudo de Winstral et al. (2002).

3.6.3. Determinação do índice de proteção ao vento na bacia hidrográfica do Ribeirão Vermelho

Foi aplicado a técnica de geoprocessamento para determinar o índice de proteção contra vento. À semelhança da definição proposta por Winstral et al. (2002), utilizou-se o gradiente máximo num determinado raio na direção do vento a montante como medida de proteção topográfica contra o vento utilizando a Equação 10 proposta por Plattner et al. (2004):

$$\text{Índice de proteção}(S) = \arctan \left(\max \left\{ \frac{z(x_0) - z(x)}{|x_0 - x|} \right\} \right), \quad x \in S \quad (10)$$

em que $z(x_0)$ é a altitude ou elevação do ponto de referência onde o índice está sendo calculado, $z(x)$ são as altitudes dos pontos vizinhos ao redor do ponto central, usadas para comparar a variação de altura, $|x_0 - x|$ mede a distância horizontal entre o ponto central (x_0) e cada vizinho (x), $\frac{z(x_0) - z(x)}{|x_0 - x|}$ calcula a taxa de variação vertical (diferença de altitude) dividida pela distância horizontal (declive ou gradiente) entre o ponto central e seus vizinhos. O valor quantifica a especificação entre os pontos, $x \in S$ são os pontos x locais pertencentes ao conjunto espacial S ao redor do ponto central, o \arctan converte a orientação calculada em um ângulo (graus ou radianos), facilitando a interpretação da proteção ou exposição e o max seleciona a maior especificação entre o ponto específico e os pontos vizinhos, destacando o local mais exposto ao redor.

Portanto, índice de abrigos é uma métrica usada em estudos de topografia e geociências para quantificar o grau de proteção ou exposição de um ponto em relação à relevo circundante. Esse índice mede o ângulo máximo de elevação em relação a um ponto de referência (x_0).

3.7. Variação espacial de velocidade do vento e análise de riscos de desastres na bacia hidrográfica

A variação espacial do vento e a análise de riscos de desastres foram feitos com base nos algoritmos apresentados anteriormente, baseados no modelo digital de elevação, velocidade média da série temporal e na direção do vento predominante. No entanto, os resultados serão apresentados no mapa da região da bacia hidrográfica com as respectivas classes de riscos de desastres. Procedeu-se a coleta das coordenadas geográficas com recurso a um telefone celular conectado ao Google Earth Pro os pontos considerados críticos a ventos fortes com base no histórico de desastres (de 27 de Setembro de 2023 a 02 de Abril de 2024) nos pontos identificados. Também foram coletadas coordenadas em outros pontos de forma aleatória como

forma de validar o mapa de classes de riscos desastres. Com base numa câmara fotográfica da marca Canon, modelo T3 foram registradas imagens dos locais em riscos de desastre demonstrando infraestruturas públicas e privadas em riscos.

Table 2: Pontos identificados para validação do mapa de velocidade do vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

| Pontos | Elevação (m) | Latitude | Longitude |
|--|--------------|------------|------------|
| Nutrili | 801.17 | 21°12'34'' | 45°01'51'' |
| Proximidades da Nutrili | 810.65 | 21°12'41'' | 45°02'00'' |
| Estação de tratamento de água (Copasa) | 813.73 | 21°12'58'' | 45°00'59'' |
| Nova rodovia para Ijaci | 818.57 | 21°13'10'' | 45°00'38'' |
| Jardim Campestre 2 | 925.45 | 21°13'43'' | 45°00'44'' |
| Avenida (vale do moro) | 869.39 | 21°13'53'' | 45°00'40'' |
| Jardim Campestre 1 | 883.93 | 21°13'59'' | 45°00'42'' |
| Praça do Jardim Glória | 895.38 | 21°14'06'' | 45°00'17'' |
| Rodovia BR 265 (vale do moro) | 842.81 | 21°14'01'' | 45°00'00'' |
| Praça DR. Jorge | 861,1 | 21°13'56'' | 45°59'50'' |

4. Resultados

A metodologia aplicada no estudo, com recurso ao modelo digital de elevação vão permitir caracterizar a morfometria da região do estudo e apresentar a sua relação com a variação espacial do vento gerando mapa detalhado sobre influência do relevo na ocorrência de desastres eólicos, podendo contribuir para o entendimento de processos ambientais causados pela variável climática de interesse (vento). Contribui para a análises de riscos de desastres, identificação de locais de implantação de quebra-ventos, planejamento sustentável do uso e ocupação do solo e instalação de parques eólicos.

4.1. Dados meteorológicos da bacia hidrográfica do Ribeirão Vermelho

A estatística descritiva dos dados meteorológicos demonstram que a média da velocidade do vento da série temporal é 1.83 ms^{-1} e a direção predominante é Leste (90°) e 15.5% de ventos calmos na bacia hidrográfica. Essas informações meteorológicas foram consideradas como dados de entrada para determinar os índices de variação espacial do vento em função do relevo aplicado ao modelo digital de elevação.

Para a modelagem do vento, o modelo digital de elevação foi convertido para formato terra de modo que fosse aplicado com eficiência nos cálculos do aspecto e da declividade em graus usando a função *terrain*. As variáveis morfométricas da bacia hidrográfica do Ribeirão Vermelho apresentadas neste estudo para




Figure 3: Característica dos dados meteorológicos (média e direção) do vento da bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil de 2010-2023.

permitirem caracterizar a variação espacial do vento pelo fato de serem co-variáveis explicativas de interesse para compreender o fluxo do vento na região. Assim, determinaram-se as variáveis meteorológicas que serão correlacionadas com a variável climática vento.

4.2. Variação do relevo da bacia hidrográfica do Ribeirão Vermelho

A altitude da bacia hidrográfica do Ribeirão Vermelho varia entre 769.7 m e 1081.9 m, conforme a Figura 4. A análise do relevo da bacia é um fator relevante, pois é o delimitador dos cursos de água. Além disso, a variação da elevação de uma bacia está fortemente associada à temperatura do ar, precipitação e características do vento, e essas variáveis influenciam diretamente nos processos de ocorrência de desastres ou de geração de energia eólica.

4.3. Variação da declividade da bacia hidrográfica do Ribeirão Vermelho

A partir do modelo digital de elevação, foi determinado a declividade do terreno. Foi observado que na bacia hidrográfica do Ribeirão Vermelho a declividade predominante está entre 3 a 20°, representadas pelas classes suave ondulado e ondulado ocupando 45.4 e 44.9°, respectivamente (Tabela 3).

As classes de relevo mais acidentado, suavemente ondulado e ondulado ocupam 90.3° da área da bacia, indicando que 8.56° da bacia são ocupadas por áreas planas e 1.15° por área forte ondulado. Esses resultados




Figure 4: Variação planialtimétrica do relevo da bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

Table 3: Classificação da declividade e áreas ocupadas por classes na Bacia Hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

| Classe | Declividade (graus) | Área (km ²) |
|--------------------------|---------------------|-------------------------|
| Plano (0 a 3) | 8.56 | 4.77 |
| Suave ondulado (3 a 8) | 45.40 | 25.30 |
| Ondulado (8 a 20) | 44.90 | 25.00 |
| Forte ondulado (20 a 45) | 1.15 | 0.64 |
| Montanhoso (> 45) | 0.00 | 0.00 |

são fundamentais para compreender a influência da declividade na variação espacial do vento e a identificação de locais de permanente riscos de desastres na região do estudo, conforme é descrito nesse estudo.

4.3.1. Variação do aspecto da bacia hidrográfica do Ribeirão Vermelho

A variação do aspecto (θ) da bacia hidrográfica do Ribeirão Vermelho foi calculado com base nos dados de entrada (radiométricos) do modelo digital de elevação. Para determinar o aspecto do terreno foi ajustado o intervalo do aspecto para garantir que os valores estivessem entre 0° a 360° . Foi aplicado a função atan2 para calcular o ângulo em radianos, de seguida, converteu-se para graus, tendo sido obtido 153.43° valor relacionado ao eixo x (leste-oeste) e encontra-se no segundo quadrante (nordeste), conforme esperado para gradientes negativos em ambos os eixos x e y . O valor calculado de A_{graus} , nos dá a direção do declive a partir do ponto central (x, y) em relação aos seus vizinhos, e o valor estará entre 0° e 360° . Este cálculo é repetido para todas as células do *raster*, e o resultado é um mapa de aspecto, que representa a direção de declividade do terreno em cada ponto da bacia hidrográfica.

4.4. Deflexão do vento na bacia hidrográfica do Ribeirão Vermelho

A deflexão do vento (Wind Deflection), uma variável que descreve o desvio ou mudança na direção do vento devido à interação com a encosta do relevo. Este apresentou valores negativos e positivos. Sistemáticamente, o valor negativo indica que a deflexão do vento é direcionada de forma oposta ao ângulo de incidência do vento, ao contrário dos valores positivos. Para o ajuste da magnitude da deflexão foi usado -255 para representar um fator de escala, que foi ajustado para calibrar a proposta de acordo com observações, dependendo das condições locais (o relevo, solo e a vegetação) predominante na região. A orientação A correspondeu a 1.57 radianos, representando a intensidade ou o coeficiente que descreveu como a encosta influencia a deflexão do vento. Para modelar a interação do vento com a interface da encosta foi usado $(2(A - \theta))$, um termo trigonométrico, gerando o mapa da Figura 5.

O fator 2, que indica a deflexão do vento não ser simplesmente uma função linear da diferença entre o ângulo de direção do vento e a orientação da encosta. O ângulo da direção do vento (A) descreveu a direção de onde o vento sopra. θ correspondeu o ângulo da encosta e, diferença entre A e θ determinaram como o vento foi desviado pela encosta local.

A deflexão do vento é uma especificidade que ocorre devido à interação entre o fluxo de ar e a topografia do terreno, especificamente a orientação das encostas. O valor calculado da deflexão do vento, aproximadamente $-26737,08$ graus ($-466,7$ radianos). O alto valor absoluto da deflexão sugere que a orientação da encosta está gerando uma forte alteração na trajetória do vento.

Portanto, os locais com uma deflexão positiva ($F_d > 0$) são zonas propensas à erosão por vento ou aceleração do fluxo de ar, sendo indicadas para energia eólica ou consideradas áreas vulneráveis à desertificação e ocorrência de desastres. Em locais que observa uma deflexão negativa ($F_d < 0$) são consideradas áreas

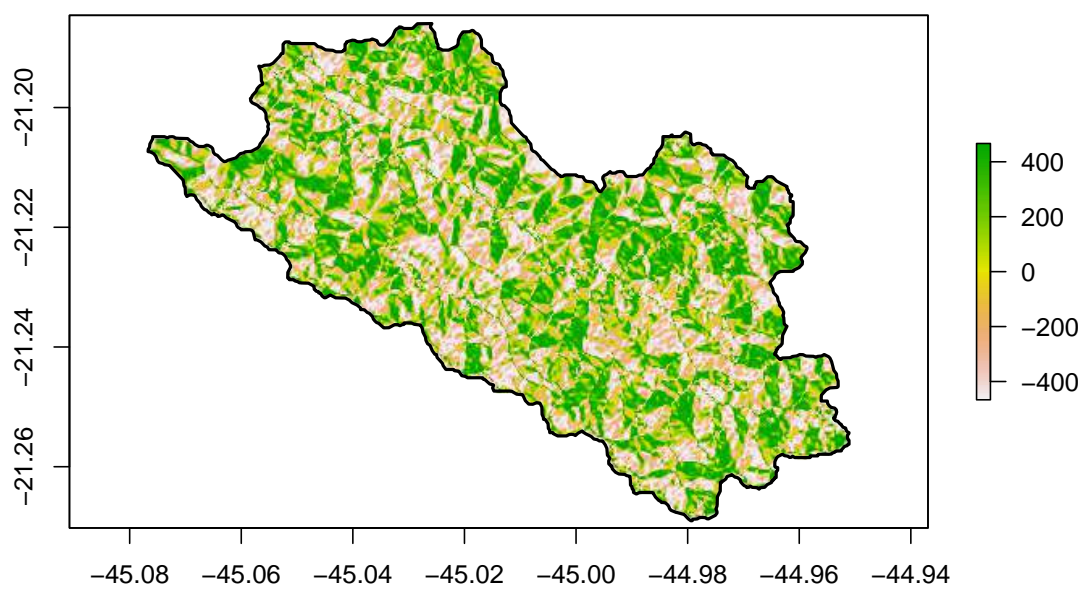


Figure 5: Deflexão topográfica indicando a variação espacial do vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

protegidas do vento pelo relevo, úteis para agricultura ou conservação ambiental, também são consideradas regiões com potencial de acúmulo de sedimentos. Por último, locais onde se registram deflexão igual a zero ($F_d = 0$) são consideradas áreas neutras, geralmente planas ou onde o ângulo da encosta está alinhado à direção do vento. Através da deflexão pode se assumir que na região do estudo predominam ventos de leste e sudeste, respectivamente visto que o aspecto e a declividade permitem esta deflexão do vento e torna-o catabático.

4.4.1. Variação espacial do vento utilizando o índice de barlavento e sotavento

O Índice de Barlavento (Windward Index) foi calculado a partir do cosseno do ângulo formado entre o vetor do vento predominante (90° , direção leste) e a orientação das superfícies do terreno (aspecto), obtido a partir do modelo digital de elevação. Este índice varia entre -1 e $+1$, em que valores próximos de $+1$ indicam superfícies voltadas diretamente ao vento (*barlavento*), enquanto valores próximos de -1 representam superfícies opostas ao vento (*sotavento*).

A Tabela 4 apresenta as estatísticas descritivas do índice obtidas para a bacia hidrográfica do Ribeirão Vermelho.

Table 4: Estatísticas do Índice de Barlavento

| | Pixels | Média | Mínimo | Máximo |
|-----------|--------|---------|---------|---------|
| Positivos | 29.288 | +0,6294 | +0,0001 | +1,0000 |
| Negativos | 32.659 | -0,6427 | -1,0000 | -0,0002 |

Para o índice de sotavento (*Leeward Index*) foi calculado a partir do valor negativo do cosseno do ângulo formado entre o vetor do vento predominante (90° , direção leste) e a orientação das superfícies do terreno (aspecto), obtido a partir do modelo digital de elevação. Este índice varia entre -1 e $+1$, em que valores próximos de $+1$ indicam superfícies orientadas contrariamente ao vento (*sotavento*), enquanto valores próximos de -1 representam superfícies voltadas diretamente ao vento (*barlavento*).

A Tabela 5 apresenta as estatísticas descritivas do índice obtidas para a bacia hidrográfica do Ribeirão Vermelho.

Table 5: Estatísticas do Índice de Sotavento

| | Pixels | Média | Mínimo | Máximo |
|-----------|--------|---------|---------|---------|
| Positivos | 32.659 | +0,6427 | +0,0002 | +1,0000 |
| Negativos | 29.288 | -0,6294 | -1,0000 | -0,0001 |

No entanto, para índice de barlavento, a média de $+0.6294$ indica que, em média, o ângulo de incidência entre o vento e a superfície é aproximadamente 51° (pois $\cos(51^\circ) \approx 0.63$). O valor máximo de $+1.0$ corresponde a encostas diretamente viradas para o vento (incidência de 0°). Esses resultados indicam que

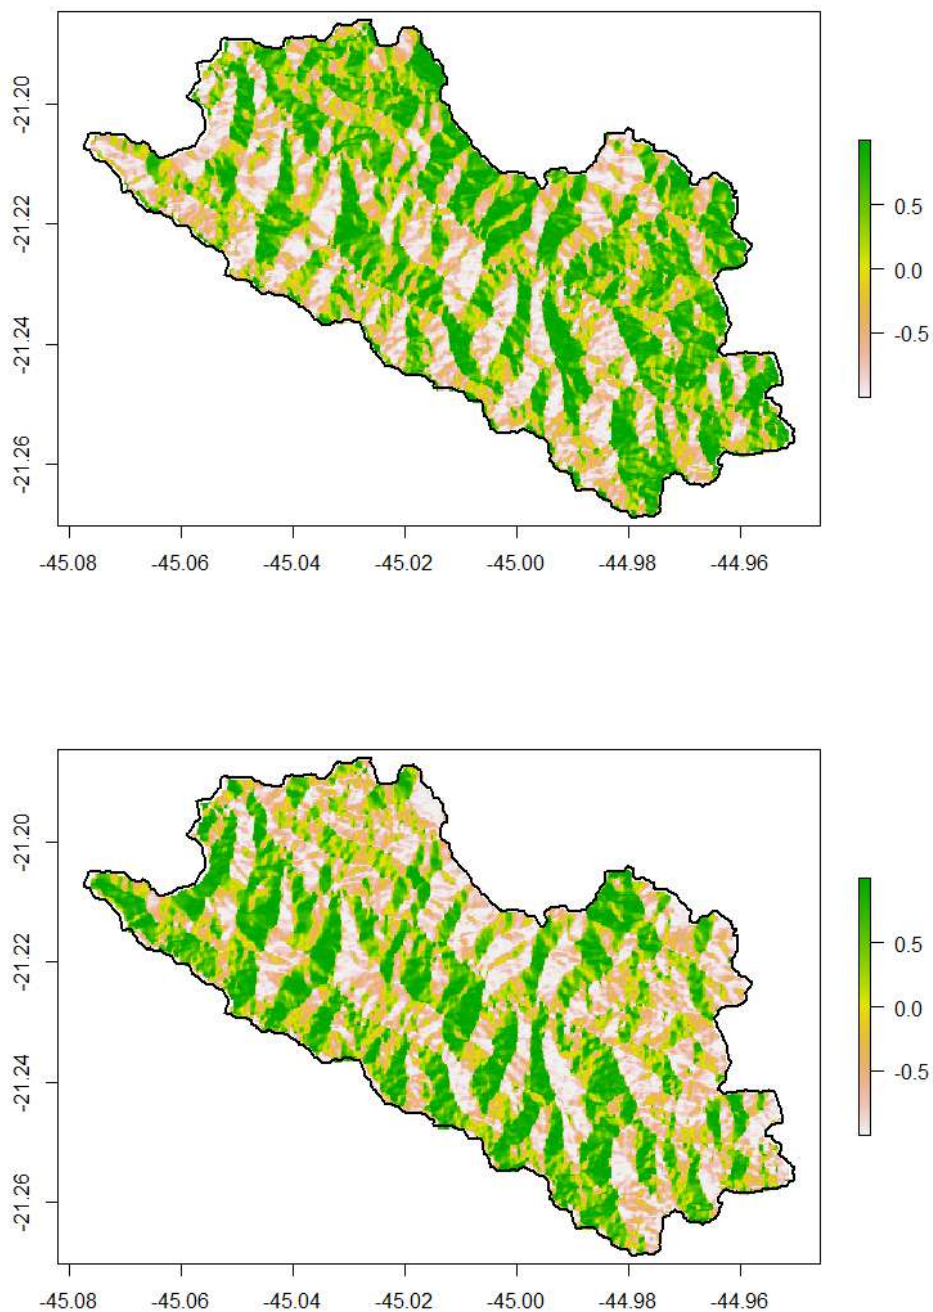


Figure 6: O mapa de cima representa o índice de sotavento e o mapa de baixo representa o índice de barlavento da bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil. 18

47% da área da bacia está orientada favoravelmente ao vento predominante, com média de exposição de +0,63. Enquanto superfícies voltadas contra o vento (*sotavento*). A média de -0.6427 indica que o ângulo médio entre vento e orientação da superfície é cerca de 130° (pois $\cos(130^\circ) \approx -0.64$). O mínimo de -1.0 corresponde a superfícies totalmente opostas ao vento (incidência de 180°). 53% da área apresenta orientação sotavento, com média de $-0,64$. Esta heterogeneidade morfométrica sugere diferentes graus de suscetibilidade à desastres eólicos, erosão eólica e à deposição de partículas. Assim, cerca de 53% dos pixels (32.659) são negativos (sotavento) e 47% (29.288) são positivos (barlavento), evidenciando a heterogeneidade topográfica, com áreas bem expostas e áreas protegidas.

Na determinação do índice de sotavento, a média de $+0,6427$ indica que, em média, o ângulo de incidência entre o vento e a superfície é aproximadamente 130° , pois $\cos(130^\circ) \approx -0,64$, e o sinal negativo foi invertido no cálculo, resultando em um índice positivo. O valor máximo de $+1,0$ corresponde a superfícies totalmente opostas ao vento (incidência de 180°), caracterizando áreas de sotavento máximo e potencial redução da velocidade do vento próximo ao solo. Estes resultados indicam que aproximadamente 53% da área da bacia está orientada em sotavento, com média de proteção de $+0,64$.

Por outro lado, as superfícies voltadas ao vento predominante apresentaram valores negativos, com média de $-0,6294$, indicando que o ângulo médio de incidência entre o vento e essas encostas é em torno de 51° , pois $\cos(51^\circ) \approx +0,63$, resultando em índice negativo após a inversão do sinal. O valor mínimo de $-1,0$ corresponde a encostas diretamente voltadas para o vento (incidência de 0°), caracterizando áreas de exposição máxima (*barlavento*). Assim, cerca de 53% dos pixels (32.659) apresentaram valores positivos (sotavento) e 47% (29.288) apresentaram valores negativos (barlavento), evidenciando uma heterogeneidade topográfica marcante, com áreas potencialmente protegidas da ação eólica e áreas expostas. Essa distribuição espacial do índice de sotavento fornece subsídios relevantes para avaliações de suscetibilidade à erosão eólica, deposição de partículas e microclimas diferenciados na bacia hidrográfica.

4.5. Exposição da bacia hidrográfica do Ribeirão Vermelho aos ventos extremos

O índice de exposição topográfica da bacia hidrográfica foi determinado com base no cálculo de inclinação para a célula central e seus vizinhos, considerando elevação, calculando o valor da tangente de inclinação com base no modelo digital de elevação. Foi obtido um RasterLayer com 140304 elementos, foi gerado o mapa da Figura 8 sobre a exposição topográfica da bacia hidrográfica do Ribeirão Vermelho originado pelos ventos de direção leste. Foram determinadas as classes de riscos ao vento para a região, determinando as áreas expostas ao desastres de acordo com a variação da direção do vento. Constatou-se que ventos do leste proporcionam muito alto risco em 0.10 km^2 e 12.02 km^2 com alto risco e 18.37 km^2 não apresenta a ocorrência de riscos de desastres.

Ventos do sudeste podem gerar muito alto riscos de desastres em 0.09 km^2 , muito risco em 10.29 km^2 e 13.84 km^2 com baixo risco. Embora os ventos de direção leste e sudeste sejam mais predominantes, o

maior risco (risco muito alto a desastres) observado na bacia hidrográfica são ventos de direção nordeste, expondo a bacia hidrográfica em cerca de 0.11 km², 13.57 km² ao alto risco e ainda, 17.18 km² com baixo risco, conforme a Tabela 4 e o mapa da Figura 8. Ventos de direção oeste representa menor risco de desastres 0.001 km² (muito alto risco) e 1.49 km² (alto risco), são moderados para 49.31 km² de área total, embora os mais estáveis sejam ventos de sentido norte, criando estabilidade em 52.11 km² de área e pondo em alto risco 0.004 km² e alto risco a 2.37 km².

Table 6: Área de risco por causados por vento na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

| Classe de risco | N | NE | E | SE | S | SW | W | NW |
|-----------------|-------|-------|-------|-------|-------|-------|-------|-------|
| Baixo | 1.23 | 17.18 | 18.37 | 13.84 | 5.73 | 5.56 | 4.95 | 3.41 |
| Moderado | 52.15 | 24.90 | 25.27 | 31.54 | 40.93 | 47.93 | 49.31 | 50.56 |
| Alto | 2.37 | 13.57 | 12.02 | 10.29 | 9.02 | 2.27 | 1.49 | 1.79 |
| Muito alto | 0.004 | 0.11 | 0.10 | 0.09 | 0.07 | 0.002 | 0.001 | 0.001 |

Os locais de riscos de desastres provocado por ventos fortes na bacia hidrográfica do Ribeirão Vermelho podem ser visualizados detalhadamente através do mapa da Figura 9. Nesse estudo, foram coletados os pontos de ocorrência de desastres de ventos forte, como é o caso dos pontos 1, 2, 3 e 4, correspondendo a praça do Jardim Glória, praça Dr. Jorge, Avenida Norte pertencente a UFLA e floresta localizada próximo viveiro florestal do Departamento de Ciências Florestais da UFLA, respectivamente. Também foram considerados os pontos 5, 6, 7, 8 e 9 pertencentes a de frente a unidade de produção Nutrili, Estação de Tratamento de Esgotos de Lavras (COPASA), Avenida Ministro Alysson Paolinelli (Terceira Alça do Anel Viário), Jardim Campestre-2 e Vale do moro da Avenida Prefeito Sylvio de Castro, respectivamente.

Com base na modelagem da velocidade do vento, nos pontos 1, 2 e 5, o modelo definiu como locais de ocorrência de elevado riscos de desastre, o que corrobora com os fatos (desastres) observado no dia 27 de setembro de 2023 nos pontos 1 e 2; e provavelmente com a quebra de Bambus observados no local das coordenadas da Nutrili (ponto 5). No ponto 9 a modelagem indica a existência de riscos moderados a desastres, o que pode ser devido a existência de cobertura de vegetação existente no local (área de preservação permanente) e ou, pelo fato de ser num vale do moro. Embora nos pontos 3 e 4 tenha ocorrido a queda de árvores, esses locais são considerados de baixo riscos a ocorrência de desastres para ventos de direção leste, principalmente devido a ocorrência da floresta no ponto 3, existência de infraestruturas e da vegetação no ponto 4 e 6, conforme a Figura 10 (imagem inferior).

Nesse artigo foi considerado a variação do relevo, um aspecto importante que foi utilizado na modelagem. Constatou-se a variação espacial do vento, o que indica a variação de locais de ocorrência de riscos. No ponto 5 demonstra-se a vulnerabilidade da empresa Nutrili ao risco dos ventos anabático, exposto ao barlavento, conforme pode ser observado através da figura 10 (imagem superior), pelo que localiza-se no topo de um

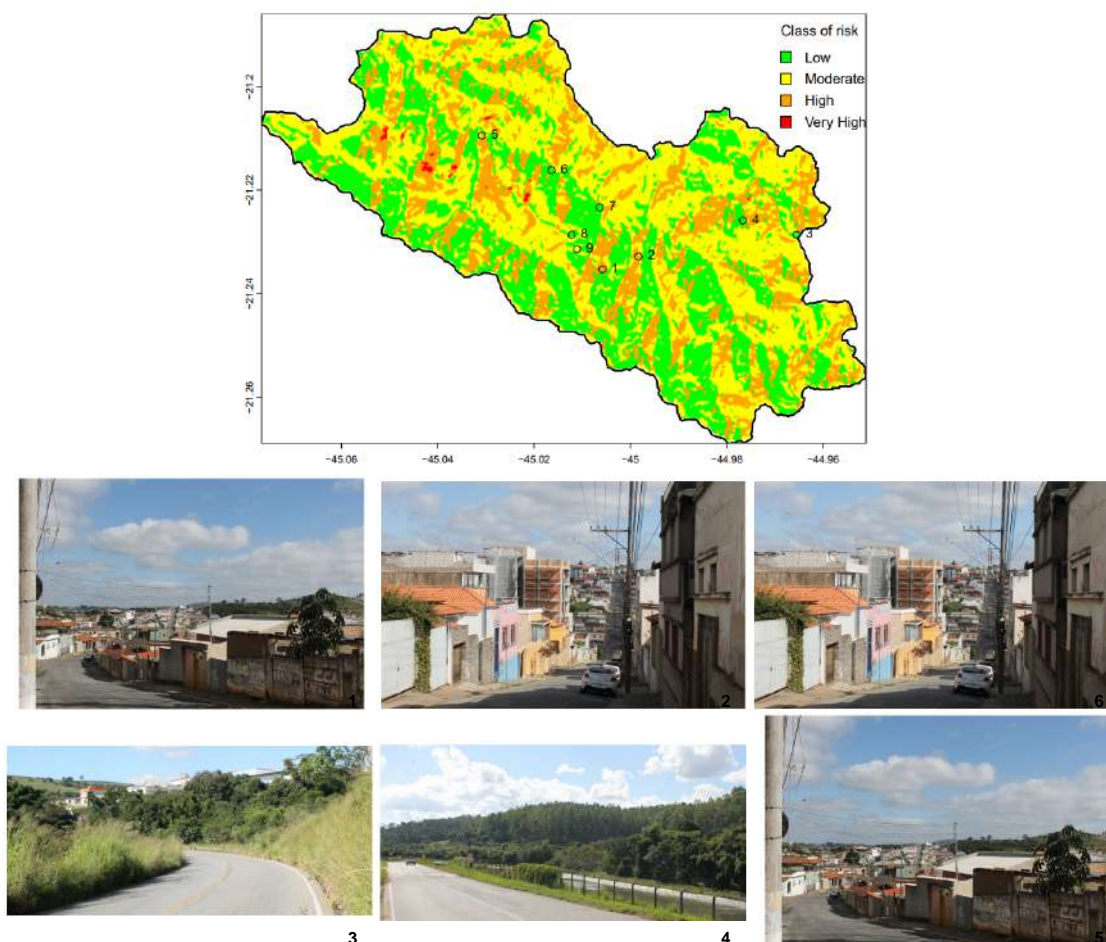


Figure 7: Bairro Jardim Glória (imagem superior) e Rua do Instituto junto a praça Dr. Jorge (imagem inferior), locais de ocorrência de desastre provocados pelo vento no dia 27 de Setembro de 2023. Unidade de processamento de carne - Nutrili (imagem superior) vulnerável a desastres por vento e local da unidade de tratamento de água da COPASA (imagem inferior) local com baixo risco de ocorrência de desastre.

moro, a seguir a um vale. Porém, este fato também podem ser observados nos pontos 1 e 2, conforme as imagens da Figura 9, sugerindo a colocação de quebra ventos nesses locais de elevado riscos visto que são locais habitacionais, atividades econômicas ou de concentração da população como empresa (Nutrili) e escolas (junto a praça Dr. Jorge), segundo as imagens.

Portanto, a modelagem prevê a existência de riscos moderado tanto no topo do moro (ponto 8) bem como no vale (ponto 9). Apesar do ponto 6 ser considerado de baixo risco (na rodovia), as infraestruturas da COPASA pode estar local considerado de elevado risco, como indica a modelagem, pelo que a distância entre as infraestruturas e a vegetação existente nas proximidades sejam maiores, conforme a Figura 10 (imagem inferior).

4.6. Proteção da bacia hidrográfica do Ribeirão Vermelho contra ventos extremos

A modelagem utilizada nesse estudo prevê locais de ocorrência de risco de desastre como foi mencionado anteriormente, mas também prevê os locais que apresenta proteção devido a disposição do relevo (a sotavento ou barlavento), bem como devido a ocorrência de vegetação considerada área de preservação permanente, conforme a Figura 11 que representa as classes alta, moderada e baixa proteção e, conforme a Figura 12 sobre uso e ocupação do solo da bacia hidrográfica do Ribeirão Vermelho.

Os resultados do índice de proteção contra ventos predominantes (leste) obtido e mapeado com base nos dados de entrada e modelo digital de elevação, indicam que 18.37 km² da bacia encontram-se protegidas, principalmente pela variação do relevo predominante. Todavia, no outro estudo sobre a caracterização da velocidade do vento na região do estudo foi constatado que a direção norte apresenta 7.8% da sua frequência. nesse estudo, observa-se que ventos dessa direção são mais moderados em termos de áreas de risco, com cerca de 52.15 km² com riscos moderados, embora apenas 1.23 km² tem baixo risco. Ventos do noroeste tem cerca de 50.56 km² com risco moderado e 3.41 km² de baixo risco. observa-se que 0.001 km² tem muito risco, o que significa que o relevo também contribui na proteção da bacia hidrográfica, conforme o mapa da Figura 11, representando áreas de menor proteção (mais verde) e de maior proteção ao vento (mais claras).

Com base no estudo, foram identificadas áreas de implantação de quebra-vento. As áreas identificadas apresenta uma altitude vaia de 900 a 1081.9 de altura, de acordo com a Figura 9. As regiões sugeridas para a implantação de quebra vento representam os a região com declividade forte ondulado compreendendo 1.15°, totalizando uma área de 0.64 km².

5. Discussão

Na região do estudo observam-se ventos catabáticos e anabáticos devido as características do relevo predominante. Nesse estudo, a abordagem sobre o índice de barlavento e sotavento foram utilizados para identificar a encosta que apresenta o potencial eólico, impactos do vento na morfologia de encostas e

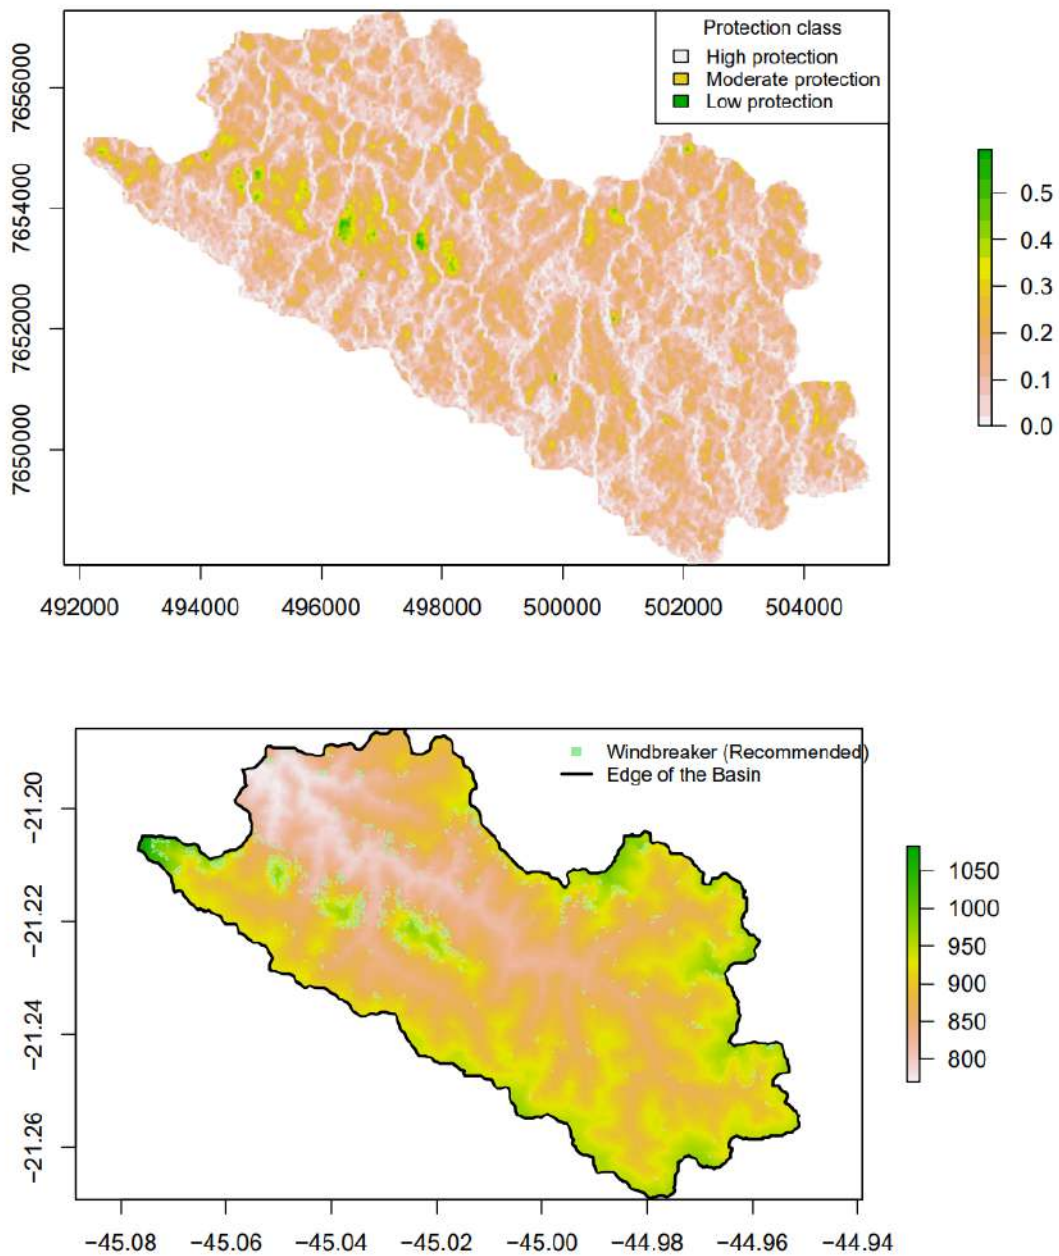


Figure 8: Mapa de cima ilustra áreas de menor proteção (mais verde) e de maior proteção ao vento (mais claras). A imagem de baixo ilustra os locais de plantação de quebra-ventos na bacia hidrográfica do Ribeirão Vermelho, Minas Gerais, Brasil.

distribuição da vegetação visto que o terreno é montanhoso. Além disso, a modelagem do índice de barlavento e sotavento pode contribuir para o planejamento territorial, auxiliando na definição de áreas adequadas para a instalação de parques eólicos e na mitigação dos impactos da erosão eólica. Áreas mais expostas ao vento podem apresentar padrões diferenciados de crescimento e estruturação da vegetação como foi destacado por (Givnish, 2002). Entretanto, os autores afirmam que a modelagem do índice de barlavento e sotavento, aliada ao uso de dados de modelo digital de elevação e sistemas de informação geográfica (SIG), fornece uma ferramenta robusta para a análise da variabilidade espacial do vento em regiões topograficamente complexas como a região do estudo.

Segundo Hesp et al. (2015), os ventos oblíquos tendem a ser desviados para uma crista mais normal à medida que o fluxo se aproxima e cruza a encosta íngreme ou crista, num fenômeno conhecido como deflexão do fluxo do vento. Os autores destacam que a deflexão do fluxo próximo à superfície ocorre em resposta a diferenças de pressão a favor do vento. Todavia, é útil considerar por que a deflexão do fluxo ocorre quando o vento se aproxima de uma crista ou montanha frontal de um ângulo oblíquo. Como também, diferenças de altura, velocidade do vento e ângulo de ataque do vento impactam na deflexão do vento (Liu et al., 2024a). Assim, é esclarecida a deflexão do vento na região do estudo e os potenciais riscos observados no topo da montanha próximo ou superior a 1081.9 m. Para além dos parâmetros do terreno definidos localmente como a elevação, aspeito, declive, foram utilizadas características morfométricas da bacia relacionadas com o processo de fluxo do vento. Estas incluem a distância horizontal da crista na direção do vento (Leste), correspondentes a 300 m, uma medida de proteção topográfica contra o vento topográfico e a radiação solar, de acordo com (Plattner et al., 2004).

Qian et al. (2009) afirmam que as velocidades verticais ascendentes também aumentaram com o aumento do ângulo de inclinação e da velocidade do vento de fluxo livre. Os pesquisadores afirmam que sobre o barlavento de uma duna transversal por exemplo, a velocidade do vento aumenta da ponta da duna até sua crista como resultado da convergência do fluxo de ar, resultando em aumento do estresse de cisalhamento sobre a superfície aerodinâmica da duna. No lado de sotavento da duna, o fluxo de ar se separa na crista da duna devido à mudança morfológica dramática; como resultado, uma célula de separação e uma região de esteira se formam no lado de sotavento, e os fluxos se reconectam a uma certa distância a favor do vento. A semelhança do que ocorre, estes fatos podem ser vir de base e sustentar a razão da maior exposição ao vento no topo da montanha a 1081.9 m por exemplo, conforme a as Figuras 10 e 12.

Segundo Ngo and Letchford (2009), Tan and Fang (2018), terrenos complexos têm um impacto pronunciado na velocidade do vento próximo à superfície, pressão e estrutura de turbulência. Consequentemente, os campos de vento nessas áreas exibem uma diferença significativa daqueles sobre regiões planas. Tan and Fang (2018) afirmam que há um grande aumento na velocidade do vento sobre colinas e penhascos, o que é importante ao modelar riscos de vento. Este fato pode ser a grande razão do risco observado no topo do morro pertencente a bacia hidrográfica em estudo.

Para Ngo and Letchford (2009) a diferença de aceleração entre duas condições de rugosidade da superfície torna-se maior para cristas mais íngremes (declive a favor do vento de 30%). Ainda sobre os efeitos da declividade topográfica, os autores demonstra que as características topográficas com uma inclinação tão baixa quanto 4.1% podem ter efeitos de aceleração significativos perto da crista. E, os pesquisadores também afirmam que a aceleração na crista aumenta com a inclinação até uma inclinação de $\sim 30\%$ e parece constante acima disso para uma inclinação de 100%. Portanto, estudos de Ngo and Letchford (2009) indicam que a aceleração máxima sempre aumenta com o aumento da inclinação a favor do vento e, para características muito íngremes, o local de aceleração máxima acima da topografia pode ser movido.

A dinâmica dos ventos sobre superfícies heterogenicamente variável é um fator essencial para a compreensão de processos ambientais como erosão, dispersão de poluentes, distribuição da vegetação e potencial eólico. O índice de barlavento é uma métrica derivada de modelos digitais de elevação que permite avaliar a influência da topografia na variação da direção e velocidade do vento. Este índice quantifica a relação entre a orientação das encostas e a direção predominante do vento, identificando áreas de aceleração e desaceleração do fluxo de ar.

O mapa do índice de barlavento fornece uma representação espacial da interação entre a topografia e os padrões de vento, possibilitando diversas aplicações em estudos ambientais. As regiões com valores positivos do índice indicam encostas voltadas para o fluxo de vento predominante, sugerindo maior exposição ao escoamento de ar e potencial de erosão. Entretanto, os valores negativos representam áreas protegidas do vento, favorecendo a deposição de sedimentos e maior retenção de umidade no solo.

O valor positivo do mapa da Figura 7, significa que a encosta está voltada no sentido oposto à direção do vento (leste), ou seja, a área (à sotavento) está protegida do vento predominantemente. Nessas regiões, ocorre uma redução da velocidade do vento, resultando na formação de zonas de calmaria e efeitos como estagnação do ar; são áreas propícias ao acúmulo de umidade, sedimentos e poluentes, favorecendo a deposição de partículas suspensas. Nesses locais podem ocorrer resfriamento noturno mais intenso devido à menor circulação de ar, aumentando a estabilidade térmica local.

Sotavento é um índice importante para compreender a variação espacial do vento, especialmente em regiões de relevo acentuado, como bacias hidrográficas e áreas montanhosas. Refere-se às zonas localizadas nas costas opostas à direção predominante do vento, onde a intensidade do vento tende a ser significativamente reduzida devido ao bloqueio ou desvio causado por elevações do relevo. Foi calculado com base no modelo digital de elevação, é obtido através da comparação entre a direção do vento e o aspecto da encosta, que é a orientação da superfície do terreno.

O índice negativo, indica que a encosta está exposta ao vento predominantemente (leste). Nessas regiões, o vento tende a acelerar, gerando aumento na velocidade do fluxo de ar e favorecendo a turbulência. Regiões de sotavento negativos são mais propensas à erosão eólica, especialmente em terrenos com pouca cobertura vegetal, aumenta a evapotranspiração, o que pode impactar os níveis de disponibilidade hídrica do solo.

Portanto, áreas com alto índice negativo podem ser projetadas para a geração de energia eólica, pois indicam fluxo de ar (vento) são mais constantes e intensos.

6. Conclusão

A metodologia aplicada, com recurso ao modelo digital de elevação permitiu caracterizar a morfometria da região do estudo e apresentar a variação espacial do vento e sua relação com os índices de exposição e proteção ao vento na bacia hidrográfica, contribuindo para o entendimento de processos ambientais causados pela variação espacial do vento, análises de riscos de desastres, identificação de locais para implantação de quebra-ventos, planejamento sustentável do uso do solo e instalação de parques eólicos.

7. Declarações

8. Interesses concorrentes

Os autores declaram que não têm interesses financeiros concorrentes ou relações pessoais que possam parecer influenciar o trabalho relatado neste documento.

9. Financiamento

O primeiro autor recebeu uma bolsa científica da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

10. Disponibilidade de dados e materiais

Os conjuntos de dados gerados durante e/ou analisados durante o presente estudo estão disponíveis junto do autor correspondente, mediante pedido.

References

- Abatzoglou, J.T., Hatchett, B.J., Fox-Hughes, P., Gershunov, A., Nauslar, N.J., 2021. Global climatology of synoptically-forced downslope winds. *International Journal of Climatology* 41, 31–50.
- Alvares, C.A., Stape, J.L., Sentelhas, P.C., Gonçalves, J.d.M., Sparovek, G., et al., 2013. Köppen's climate classification map for brazil. *Meteorologische zeitschrift* 22, 711–728.
- Böhner, J., AntoniĆ, O., 2009. Land-surface parameters specific to topo-climatology. *Developments in soil science* 33, 195–226.
- Carlsaw, D., Ropkins, K., 2014. Package 'openair' .
- Dragulescu, A.A., Dragulescu, M.A.A., Provide, R., 2020. Package 'xlsx'. Cell 9.
- Fernández-López, J., Schliep, K., Arjona, Y., 2022. 2 rwind-package. Package 'rWind' , 2.
- Givnish, T.J., 2002. Adaptive significance of evergreen vs. deciduous leaves: solving the triple paradox. *Silva fennica* 36, 703–743.
- Grange, S.K., 2014. Averaging wind speeds and directions. no. October , 12.

- Hesp, P.A., Smyth, T.A., Nielsen, P., Walker, I.J., Bauer, B.O., Davidson-Arnott, R., 2015. Flow deflection over a foredune. *Geomorphology* 230, 64–74. doi:10.1016/j.geomorph.2014.11.005.
- Hijmans, R.J., Bivand, R., Forner, K., Ooms, J., Pebesma, E., Sumner, M.D., 2022. Package ‘terra’. Maintainer: Vienna, Austria .
- Hijmans, R.J., Van Etten, J., Mattiuzzi, M., Sumner, M., Greenberg, J., Lamigueiro, O., Bevan, A., Racine, E., Shortridge, A., 2013. Raster package in r. Version. <https://MirroRs.Sjtu.Edu.Cn/Cran/Web/PackaGes/Raster/Raster.Pdf> .
- Jiang, L., Ma, H., Wang, S., Chen, B., 2023. Wind-induced fragility of a group of three gable-roof buildings with different roof slope and building spacing. *Engineering Structures* 292, 116532.
- Liu, Y., Guo, Y., Wang, B., Li, Q., Gao, Q., Wan, Y., 2024a. Research on influencing factors and wind deflection warning of transmission lines based on meteorological prediction. *Energies* 17, 2612. doi:doi.org/10.3390/en17112612.
- Liu, Y.S., Yigitcanlar, T., Guaralda, M., Degirmenci, K., Liu, A., 2024b. Spatial modelling of urban wind characteristics: review of contributions to sustainable urban development. *Buildings* 14, 737.
- Magesh, N., Jitheshlal, K., Chandrasekar, N., Jini, K., 2013. Geographical information system-based morphometric analysis of bharathapuzha river basin, kerala, india. *Applied Water Science* 3, 467–477.
- Magesh, N.S., Chandrasekar, N., Soundranayagam, J.P., 2011. Morphometric evaluation of papanasam and manimuthar watersheds, parts of western ghats, tirunelveli district, tamil nadu, india: a gis approach. *Environmental Earth Sciences* 64, 373–381.
- Ngo, T.T., Letchford, C.W., 2009. Experimental study of topographic effects on gust wind speed. *Journal of wind engineering and industrial aerodynamics* 97, 426–438.
- Paraschaki, L., Eriksson, L., 2019. Beräkningsmodell för vindistribuerad snöackumulation i överumans avrinningsområde.
- Pareta, K., Pareta, U., 2011. Quantitative morphometric analysis of a watershed of yamuna basin, india using aster (dem) data and gis. *International journal of Geomatics and Geosciences* 2, 248.
- Peckham, S.E., Wicker, L.J., 2000. The influence of topography and lower-tropospheric winds on dryline morphology. *Monthly weather review* 128, 2165–2189.
- Plattner, C., Braun, L., Brenning, A., 2004. Spatial variability of snow accumulation on vernagtferner, austrian alps, in winter 2003/2004. *Zeitschrift für Gletscherkunde und Glazialgeologie* 39, 43–57.
- Purves, R., Barton, J., Mackaness, W., Sugden, D., 1998. The development of a rule-based spatial model of wind transport and deposition of snow. *Annals of Glaciology* 26, 197–202.
- Qian, G., Dong, Z., Luo, W., Wang, H., 2009. Variations of horizontal and vertical velocities over two-dimensional transverse dunes: A wind tunnel simulation of the effect of windward slope. *Journal of arid environments* 73, 1109–1116.
- Rai, P.K., Mishra, V.N., Mohan, K., 2017. A study of morphometric evaluation of the son basin, india using geospatial approach. *Remote Sensing Applications: Society and Environment* 7, 9–20.
- Rueda, F.J., Schladow, S.G., Monismith, S.G., Stacey, M.T., 2005. On the effects of topography on wind and the generation of currents in a large multi-basin lake. *Hydrobiologia* 532, 139–151.
- Ryan, B.C., 1977. A mathematical model for diagnosis and prediction of surface winds in mountainous terrain. *Journal of Applied Meteorology and Climatology* 16, 571–584.
- Schillaci, C., Braun, A., Kropáček, J., 2015. 2.4. 2. terrain analysis and landform recognition. *Geomorphol. Tech* 2, 1–18.
- Schubert, A.N., Pai, A.D., Sarnighausen, V.C.R., Rodrigues, S.A., 2022. Direção e velocidade do vento em botucatu-sp. *Tekhne e Logos* 13, 50–64. doi:https://orcid.org/0000-0002-4111-2127.
- Şen, Z., 2001. Areal assessment of wind speed and topography with applications in turkey. *Renewable energy* 24, 113–129.
- Tan, C., Fang, W., 2018. Mapping the wind hazard of global tropical cyclones with parametric wind field models by considering the effects of local factors. *International Journal of Disaster Risk Science* 9, 86–99.
- Wickham, H., Chang, W., Wickham, M.H., 2016. Package ‘ggplot2’. Create elegant data visualisations using the grammar of

- graphics. Version 2, 1–189.
- Winstral, A., Elder, K., Davis, R.E., 2002. Spatial snow modeling of wind-redistributed snow using terrain-based parameters. *Journal of hydrometeorology* 3, 524–538.
- Zhou, Q., Liu, X., 2004. Analysis of errors of derived slope and aspect related to dem data properties. *Computers & Geosciences* 30, 369–378.

2 CONCLUSÃO

A velocidade do vento na região de estudo caracteriza-se por uma tendência de redução ao longo dos anos. Junho, 1.54 ms^{-1} é o mês que caracteriza-se por menor média do vento para a série histórica 2010-2024 bem como para médias previstas (1.04 ms^{-1}) de Janeiro a Dezembro de 2025. De Agosto a Novembro a velocidade é mais alta, reduzindo na época chuvosa, sendo mais instáveis nessa época, provocando desastres como ocorreu nos meses de Setembro de 2023, Janeiro e Fevereiro de 2024 na região urbana da bacia hidrográfica, confirmando a presença de locais com muito alto risco de ocorrência de desastres. Ao longo da época seca, a velocidade do vento é mais estável, favorecendo o aproveitamento eólico.

A direção do vento predominante na região é o sentido leste. De Abril a Novembro os sentidos predominantes são leste e sudeste e de Dezembro a Março predominam ventos de leste e nordeste o que pode ser benéfico para o aproveitamento eólico na época seca devido a estabilidade da velocidade. Ventos do nordeste expõe cerca de 13.68 km^2 ao alto e muito alto risco de ocorrência de desastres.

A caracterização da variação espacial do vento torna-se importante para o estudo sobre o potencial eólico e riscos de ocorrência de desastres, planejamento e colocação de quebra-vento, instalação de propriedades agrícolas e agroindustriais..

Todavia, com base análise da tendência do vento e das médias previstas, ficou claro que na região ocorre a redução da velocidade do vento dependendo das mudanças climáticas, principalmente o aumento global das temperaturas e baixa umidade relativa do ar. Mas, destaca-se que a instabilidade observada, causados pelos fenômenos físicos da terra, Zona de Convergência do Atlântico Sul favorecem a ocorrência de instabilidades do vento, podendo causar danos desastrosos na região da bacia hidrográfica sugerindo-se o reforço a vigilância e implantação de medidas de proteção preventivamente.

REFERÊNCIAS

- ABD-ELAAL, E.-S.; MILLS, J. E.; MA, X. Numerical simulation of downburst wind flow over real topography. **Journal of Wind Engineering and Industrial Aerodynamics**, Elsevier, v. 172, p. 85–95, 2018.
- BÖHNER, J.; ANTONIĆ, O. Land-surface parameters specific to topo-climatology. **Developments in soil science**, Elsevier, v. 33, p. 195–226, 2009.
- CURRY, C. L.; KAMP, D. van der; MONAHAN, A. H. Statistical downscaling of historical monthly mean winds over a coastal region of complex terrain. i. predicting wind speed. **Climate dynamics**, Springer, v. 38, p. 1281–1299, 2012.
- FILHO, W. L. F. C. et al. The wind regime over the brazilian southeast: Spatial and temporal characterization using multivariate analysis. **International Journal of Climatology**, Wiley Online Library, v. 42, n. 3, p. 1767–1788, 2022.
- GODZIEK, J.; PAWLIK, Ł. Indicators of wind-driven forest disturbances–pit–mound topography, its automatic detection and significance. **Catena**, Elsevier, v. 221, p. 106757, 2023.
- HE, B.-J. Urban morphology, urban ventilation and urban heat island mitigation: A methodological framework. In: **Climate Change and Environmental Sustainability**. [S.l.]: Springer, 2022. p. 131–136.
- LIU, Y.-S.; YIGITCANLAR, T.; GUARALDA, M.; DEGIRMENCI, K.; LIU, A. Spatial modelling of urban wind characteristics: Review of contributions to sustainable urban development. **Buildings**, MDPI, v. 14, n. 3, p. 737, 2024.
- LIU, Z.; SHIE, C.-L.; LI, A.; MEYER, D. Nasa global satellite and model data products and services for tropical meteorology and climatology. **Remote Sensing**, MDPI, v. 12, n. 17, p. 2821, 2020.
- LUIZ-SILVA, W.; OSCAR-JÚNIOR, A. C.; CAVALCANTI, I. F. A.; TREISTMAN, F. An overview of precipitation climatology in brazil: space-time variability of frequency and intensity associated with atmospheric systems. **Hydrological Sciences Journal**, Taylor & Francis, v. 66, n. 2, p. 289–308, 2021.
- OJO, A. R.; SADIKU, N. A. Slenderness coefficient and growth characteristics of africa giant bamboo: *Bambusa vulgaris schrad. ex jc wendl.* **Advances in Bamboo Science**, Elsevier, v. 2, p. 100017, 2023.
- PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. Agrometeorologia: fundamentos e aplicações práticas. 2002.
- PIMENTA, F. M. et al. Characterization of wind resources of the east coast of maranhão, brazil. **Energies**, MDPI, v. 16, n. 14, p. 5555, 2023.
- PITZ, I.; NEVES, L.; PITZ, J.; ELI, K.; OLIVEIRA, E. Caracterização da velocidade e direção predominante dos ventos para a localidade de rio do sul-sc. **ENCICLOPEDIA BIOSFERA**, v. 9, n. 16, 2013.
- SOUZA, C. J. de; LIBERATO, A. M. Análise da velocidade e direção do vento em vilhena, rondônia. **Revista de Administração e Negócios da Amazônia**, v. 11, n. 3, p. 344–361, 2019.

WATSON, S. Quantifying the variability of wind energy. **Wiley Interdisciplinary Reviews: Energy and Environment**, Wiley Online Library, v. 3, n. 4, p. 330–342, 2014.

YOUNG, I.; VINOTH, J.; ZIEGER, S.; BABANIN, A. V. Investigation of trends in extreme value wave height and wind speed. **Journal of Geophysical Research: Oceans**, Wiley Online Library, v. 117, n. C11, 2012.