

UNIVERSIDADE FEDERAL DO PARANÁ

RAFAEL TOSHIO INOUE

INVESTIGAÇÃO DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA NO PÓS
PROCESSAMENTO DE PREVISÕES DE RAJADA DE VENTO E DETECÇÃO DE EVENTO
SEVERO

CURITIBA PR

2026

RAFAEL TOSHIO INOUE

INVESTIGAÇÃO DE TÉCNICAS DE APRENDIZAGEM DE MÁQUINA NO PÓS
PROCESSAMENTO DE PREVISÕES DE RAJADA DE VENTO E DETECÇÃO DE EVENTO
SEVERO

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Informática no Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, da Universidade Federal do Paraná.

Área de concentração: *Ciência da Computação*.

Orientador: Luiz Eduardo Soares de Oliveira.

CURITIBA PR

2026

AGRADECIMENTOS

Ao meu orientador, Prof. Dr. Luiz Eduardo Soares de Oliveira, pela confiança, paciência e orientação deste trabalho.

Ao Simepar, pela infraestrutura e pela concessão dos dados, fundamentais para a viabilização desta pesquisa.

Aos colegas do Simepar, pelo apoio técnico e pelas discussões que enriqueceram o desenvolvimento deste projeto.

À Ana Carolina Handa, pelo incentivo constante e pelo apoio em todas as etapas desta jornada.

RESUMO

A previsão de rajadas de vento apresenta grandes desafios devido à sua alta variabilidade espaço-temporal e ao seu significativo potencial destrutivo. Este trabalho investigou a aplicação de técnicas de Aprendizagem de Máquina (AM) no pós-processamento de previsões numéricas do tempo, especificamente do modelo Integrated Forecasting System (IFS), com o objetivo de aprimorar a acurácia das previsões no estado do Paraná utilizando-se apenas variáveis de superfície como preditores. Foram avaliadas cinco arquiteturas distintas — Regressão Linear, Long Short-Term Memory (LSTM), Redes Neurais Convolucionais (CNN), Transformer e Support Vector Machine (SVM) — utilizando dados observacionais de estações meteorológicas e previsões por conjunto (ensemble) entre os anos de 2021 e 2024. A metodologia abordou o problema sob a perspectiva da correção da magnitude da rajada via regressão e também a identificação de eventos severos através da detecção de anomalias. Os resultados demonstraram que, embora os modelos de AM tenham sido eficazes na redução dos erros globais e no aumento da correlação em comparação à previsão bruta do IFS, eles tenderam a suavizar a variabilidade dos dados, falhando em capturar a magnitude dos eventos extremos. A detecção de anomalias via SVM apresentou limitações, com altas taxas de falsos positivos. Conclui-se que o uso exclusivo de variáveis de superfície do modelo numérico é insuficiente para a previsão de rajadas severas, indicando a necessidade de incorporar informações sobre a estrutura vertical da atmosfera para superar as limitações físicas na previsão destes extremos.

Palavras-chave: 1 rajada. 2 aprendizagem de máquina. 3 previsão de vento.

ABSTRACT

Wind gust forecasting presents major challenges due to its high spatiotemporal variability and significant destructive potential. This work investigated the application of Machine Learning (ML) techniques in the post-processing of numerical weather predictions, specifically the Integrated Forecasting System (IFS) model, with the objective of improving forecast accuracy in the state of Paraná using only surface variables as predictors. Five distinct architectures were evaluated — Linear Regression, Long Short-Term Memory (LSTM), Convolutional Neural Networks (CNN), Transformer, and Support Vector Machine (SVM) — using observational data from meteorological stations and ensemble forecasts between the years 2021 and 2024. The methodology approached the problem from the perspective of correcting gust magnitude via regression and also identifying severe events through anomaly detection. The results demonstrated that, although the ML models were effective in reducing global errors and increasing correlation compared to the raw IFS forecast, they tended to smooth data variability, failing to capture the magnitude of extreme events. Anomaly detection via SVM presented limitations, with high false positive rates. It is concluded that the exclusive use of surface variables from the numerical model is insufficient for forecasting severe gusts, indicating the need to incorporate information regarding the vertical structure of the atmosphere to overcome physical limitations in predicting these extremes.

Keywords: 1 gust. 2 machine learning. 3 wind forecasting.

Lista de Figuras

2.1	Representação esquemática da solução numérica do modelo. (A) fenômeno meteorológico. (B) A solução espectral utiliza soma de ondas. (C) Solução em ponto de grade discretiza a mesma onda em diversos pontos.	14
2.2	Representação esquemática da solução numérica do modelo.	15
2.3	Escalas típicas de eventos meteorológicos. Adaptado de Ahrens (2013).	16
2.4	Representação da direção de um vento nordeste. O valor da direção indica de onde a massa de ar se origina.	17
2.5	Comparação esquemática entre um neurônio biológico e perceptron.	18
2.6	Arquitetura do modelo Transformer.	20
2.7	Representação esquemática de uma convolução.	21
3.1	Publicações relacionadas ao termo <i>wind forecasting</i> na base da Scopus por área e por ano.	22
4.1	Localização das estações com sensor de vento disponíveis. Os círculos vermelhos indicam as estações selecionadas por terem uma vizinha dentro de 5 km.	26
4.2	Série temporal de rajada de vento a 10 m nas cidades selecionadas. Em roxo são representadas as estações do Sistema de Tecnologia e Monitoramento Ambiental do Paraná (SIMEPAR) e em verde as de outras instituições. As linhas horizontais representam os limites de vento de 11, 15.2 e 19.5 m/s.	27
4.3	Série temporal de rajada de vento a 10 m nas cidades selecionadas filtrando dados em torno de eventos mais intensos. As linhas horizontais representam os limites de vento de 11, 15.2 e 19.5 m/s.	28
4.4	Dias onde há disponibilidade de dados de estação e modelos. Em roxo as estações próprias do simepar e em verde as estações de outras instituições..	30
4.4	Dias onde há disponibilidade de dados de estação e modelos. Em roxo as estações próprias do simepar e em verde as estações de outras instituições..	31
4.5	Arquitetura do modelo Linear.	32
4.6	Arquitetura do modelo LSTM.	32
4.7	Arquitetura do modelo CNN.	33
4.8	Arquitetura do modelo Transformer.	34
4.9	Infográfico representando uma matriz de confusão.	37
5.1	(a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Curitiba. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição .	40
5.2	(a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Guarapuava. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição	40

5.3	(a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Lapa. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição. . .	41
5.4	(a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Londrina. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição	41
5.5	(a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Telêmaco Borba. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição	43
5.6	Comparação direta das previsões e observações para alguns casos da validação. .	44
5.7	Matrizes de Confusão de cada um dos modelos para Curitiba..	44
5.8	Matrizes de Confusão de cada um dos modelos para Guarapuava..	45
5.9	Matrizes de Confusão de cada um dos modelos para Lapa.	45
5.10	Matrizes de Confusão de cada um dos modelos para Londrina.	45
5.11	Matrizes de Confusão de cada um dos modelos para Telêmaco Borba.	45
5.12	Curva ROC e Matriz de Confusão do melhor ponto de operação para Curitiba . .	47
5.13	Curva ROC e Matriz de Confusão do melhor ponto de operação para Guarapuava	47
5.14	Curva ROC e Matriz de Confusão do melhor ponto de operação para Lapa	47
5.15	Curva ROC e Matriz de Confusão do melhor ponto de operação para Londrina. .	48
5.16	Curva ROC e Matriz de Confusão do melhor ponto de operação para Telêmaco Borba	48

Lista de Tabelas

3.1	Trabalhos correlatos em pós-processamento de modelos atmosféricos para a previsão de rajadas de vento.	25
4.1	Comparação entre dados originais e preenchidos por estação	28
4.2	Redução relativa em cada uma das séries após filtragem e quantidade final de dados observados	28
4.3	Configuração dos dados de previsão	29
5.1	Resultados dos modelos por cidade.	42
5.2	Melhor parâmetro de <i>kernel</i> e área sob a curva Característica de Operação do Receptor (Receiver Operating Characteristic) (ROC) por cidade.	46

LISTA DE ACRÔNIMOS

2d	Temperatura média do ponto de orvalho a 2m
2t	Temperatura média a 2m
AM	Aprendizagem de Máquina (Machine Learning)
AUC	Área Sob a Curva ROC
CNN	Redes Neurais Convolucionais (Convolutional Neural Networks)
ECMWF	European Centre for Medium-Range Weather Forecasts
EMOS	Ensemble Model Output Statistics
ERA5	ECMWF Reanalysis v5
fg10	Velocidade da rajada do vento a 10m
FP	Falsos Positivos
GFS	Global Forecasting System
IFS	Integrated Forecasting System
IH	Índice de habilidade
LSTM	Memória de Curto e Longo Prazo (Long short-term memory)
MAE	Mean Absolute Error
MLP	Perceptron Multi Camadas (Multilayer Perceptron)
MOS	Model Output Statistics
NCEP	National Centers for Environmental Prediction
PNT	Previsão Numérica do Tempo
RBF	Função de Base Radial (Radial Basis Function)
RMSE	Root Mean Squared Error
RN	Redes Neurais
RNN	Redes Neurais Recorrentes (Recurrent Neural Networks)
ROC	Característica de Operação do Receptor (Receiver Operating Characteristic)
SIMEPAR	Sistema de Tecnologia e Monitoramento Ambiental do Paraná
SVM	Máquina de Vetores de Suporte (Support Vector Machine)
TFP	Taxa de Falsos Positivos
TVP	Taxa de Verdadeiros Positivos
u10	Componente zonal do vento a 10m
v10	Componente meridional do vento a 10m
VN	Verdadeiros Negativos
WMO	World Meteorological Organization
WRF	Weather Research and Forecasting

Sumário

1	INTRODUÇÃO	10
1.1	O PROBLEMA DA PREVISÃO DE RAJADAS DE VENTO	10
1.2	MOTIVAÇÃO	11
1.3	HIPÓTESES	11
1.4	OBJETIVOS	12
1.5	CONTRIBUIÇÕES	12
1.6	ORGANIZAÇÃO DO DOCUMENTO	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	CONCEITOS METEOROLÓGICOS	13
2.1.1	Previsão numérica do tempo	13
2.1.2	Escalas Meteorológicas	15
2.1.3	Vento nas Estações Meteorológicas	15
2.2	CONCEITOS DE APRENDIZAGEM DE MÁQUINA	17
2.2.1	Redes Neurais Artificiais	18
2.2.2	Redes Neurais Recorrentes (Recurrent Neural Networks)	19
2.2.3	Transformers	19
2.2.4	Redes Neurais Convolucionais (Convolutional Neural Networks)	19
2.2.5	Máquina de Vetores de Suporte (Support Vector Machine)	21
3	ESTADO DA ARTE	22
4	MÉTODO PROPOSTO	26
4.1	ÁREA DE ESTUDO E SELEÇÃO DE ESTAÇÕES	26
4.2	CARACTERÍSTICAS E SELEÇÃO DOS DADOS OBSERVADOS	27
4.3	MODELO METEOROLÓGICO E CONFECÇÃO DO VETOR DE CARACTERÍSTICAS	28
4.4	QUANTIDADE E CARACTERÍSTICAS DOS DADOS	29
4.4.1	Construção dos dados para treinamento	29
4.5	MODELOS DE APRENDIZAGEM DE MÁQUINA	31
4.5.1	Linear	31
4.5.2	Memória de Curto e Longo Prazo (Long short-term memory) (LSTM)	32
4.5.3	Redes Neurais Convolucionais (Convolutional Neural Networks) (CNN)	32
4.5.4	Transformer	33
4.5.5	Máquina de Vetores de Suporte (Support Vector Machine)	33
4.6	DESCRIÇÃO DOS EXPERIMENTOS	35
4.7	MÉTRICAS DE AVALIAÇÃO	35

5	RESULTADOS.	39
5.1	CORREÇÃO DA PREVISÃO NUMÉRICA	39
5.2	DETECÇÃO DE ANOMALIAS	46
5.3	CONSIDERAÇÕES	49
6	CONCLUSÃO	50
	Referências Bibliográficas.	51

1 INTRODUÇÃO

O interesse em rajadas de vento — picos de velocidade em curtos intervalos — deriva principalmente do seu alto potencial destrutivo e dos impactos socioeconômicos associados. Devido à sua alta variabilidade espaço-temporal, a previsão desta variável é ainda mais desafiadora do que a do vento médio. No entanto, à medida que a qualidade das previsões numéricas tem melhorado, sua utilização para antecipar tais eventos severos torna-se cada vez mais crucial, especialmente em regiões propensas a fenômenos intensos como o estado do Paraná. Desta forma, uma previsão mais acurada dessa variável é de primordial importância. As técnicas tradicionais para criar prognósticos de rajadas de vento envolvem parametrizações empíricas e métodos estatísticos. No entanto, nos últimos anos tem crescido o uso de Aprendizagem de Máquina (Machine Learning) (AM) na tentativa de melhorar a acurácia das previsões.

As rajadas de vento podem ser causadas por diversos fenômenos atmosféricos desde a escala sinótica, caracterizados por áreas extensas de baixa pressão e ventos relativamente constantes, até tempestades convectivas locais, que têm um decréscimo rápido da temperatura do ar após a rajada (Surendran et al., 2025). O estado do Paraná está localizado em uma região que também é atingida por fenômenos com potencial destrutivo como complexos convectivos de mesoescala, ciclones extratropicais e convecções profundas e isoladas.

O presente estudo comparou o uso de diversas técnicas de AM (regressão linear, Memória de Curto e Longo Prazo (Long short-term memory) (LSTM), Redes Neurais Convolucionais (Convolutional Neural Networks) (CNN), Transformer e Máquina de Vetores de Suporte (Support Vector Machine) (SVM)) na melhoria das previsões de rajada de vento sob dois aspectos. O primeiro focou na melhoria das métricas de avaliação para toda a série de rajadas, utilizando regressão. O segundo, na previsão por categoria de severidade.

1.1 O PROBLEMA DA PREVISÃO DE RAJADAS DE VENTO

As rajadas de vento exercem uma força em obstáculos que é proporcional ao quadrado da sua velocidade. É uma grandeza particularmente útil para aplicações aéreas, navais e planejamento de estruturas. Dessa forma, saber o valor médio e seus extremos é de suma importância (Bechtold and Bidlot, 2009). O estado do Paraná é uma região propensa a eventos severos associados a rajadas devido aos sistemas meteorológicos presentes.

Rajadas de vento são aumentos abruptos na velocidade do vento, com durações típicas da ordem de segundos. Essa alta variabilidade espaço-temporal costuma ser muito maior do que as equações discretizadas dos modelos de tempo são capazes de resolver.

A solução adotada pela Previsão Numérica do Tempo (PNT) vem na forma de parametrizações, que são equações empíricas que buscam correlações entre os momentos atmosféricos e a variável alvo. Por exemplo, para o modelo Integrated Forecasting System (IFS), a parametrização de vento assume a forma da equação 1.1.

$$U_{gust} = U_{10} + (\text{componente turbulento}) + (0.6D(\max(0, U_{MLA} - U_{MLB}))) \quad (1.1)$$

A equação 1.1 mostra que a rajada calculada pelo modelo (U_{gust}) é função de três componentes. O primeiro termo (U_{10}) é a própria previsão do vento próximo à superfície. O termo seguinte representa as influências de aspecto turbulento, que dependem de outras parametrizações

como, por exemplo, o uso do solo. O último termo, chamado de termo convectivo, pode ou não contribuir na equação dependendo da variável D , que informa se é ou não um caso convectivo. Quando esse termo contribui, ele é função da diferença, ou cisalhamento, do vento em dois níveis, dadas pelas siglas MLA (nível superior de referência do vento) e MLB (nível inferior de referência do vento).

Como consequência, as aproximações por meio de parametrizações das variáveis previstas são fonte inerente de erros das PNT e não levam em conta uma grande quantidade de variáveis. Dessa forma, a correção das saídas dos modelos numéricos utilizando AM pode ser uma solução.

O uso de técnicas de AM para a correção das saídas brutas da PNT são utilizadas desde a década de 90 (Chase et al., 2023). O avanço do uso de energias renováveis, especificamente geração de energia eólica, tem impulsionado os estudos para correções de saída de vento, no entanto, quando se trata de rajadas de vento no médio prazo, poucos são os trabalhos publicados e ainda há lacunas a serem investigadas, especialmente no que tange à aplicação de diferentes arquiteturas de AM e à otimização da previsão de eventos extremos em horizontes de médio prazo.

Esta dissertação contribui nesse contexto ao avaliar se técnicas de AM trazem benefícios à previsão *a priori* dos modelos numéricos, utilizando um conjunto de previsões de um ambiente operacional.

1.2 MOTIVAÇÃO

A assertividade nas previsões de rajada de vento tem impacto em diversas áreas, entre elas cita-se o planejamento estratégico de equipes de manutenção em estruturas, como por exemplo torres de transmissão de energia, plataformas de petróleo e aerogeradores. Os modelos numéricos de previsão do tempo já fazem a previsão de rajadas, porém, por ser uma variável parametrizada, ainda há espaço para aprimoramentos. Além disso, devido à natureza caótica da atmosfera, conjuntos de modelos inicializados por perturbações físicas tendem a gerar previsões muitas vezes conflitantes. Essa incerteza é fonte de confusão no ambiente profissional, onde uma mesma pessoa não é capaz de avaliar todas as nuances de um grande conjunto de prognósticos numéricos.

Modelos de AM são conhecidos por lidar bem com um conjunto grande de dados, dessa forma a junção de técnicas de AM com o ambiente operacional meteorológico se faz necessário. O sucesso na implementação dessas técnicas pode reduzir impactos sobre vidas e propriedades ao fornecer previsões mais acuradas de eventos de vento severo.

1.3 HIPÓTESES

As previsões de rajadas costumam ser oriundas de PNT e os meteorologistas operacionais analisam um conjunto de previsões para tentar estimar as regiões de ocorrência de eventos severos. Ao longo dos anos, uma quantidade maior de previsões e de resolução mais refinada está disponível aos operadores. No entanto, devido ao grande volume de informações, existem restrições quanto ao processamento e armazenamento das mesmas.

Entre as hipóteses levantadas tem-se: 1) a suposição de que existem, nas variáveis de superfície das PNT, informações latentes suficientes para prever rajadas de vento forte, essa hipótese deduz-se da equação de parametrização (Eq. 1.1) de rajada de vento, a qual leva em conta a estrutura vertical e turbulência. 2) Métodos de AM são capazes de extrair uma previsão mais assertiva a partir do conjunto de PNT. A segunda hipótese pode ser dividida em dois

desdobramentos: a) primeiro, a correção pode ser feita para todos os tempos de previsão do modelo numérico. b) Segundo, os métodos de AM podem detectar anomalias a partir do mesmo conjunto de dados.

Depreendem-se então das hipóteses as perguntas de pesquisa:

- I Métodos de AM são capazes de corrigir previsões *a priori* dadas por um conjunto de PNT restritas à variáveis de superfície?
- II Esse mesmo conjunto de dados é suficiente para técnicas de AM detectar anomalias, ou seja, o vento forte?

1.4 OBJETIVOS

Partindo da hipótese de que é viável corrigir as previsões de rajadas de vento produzidas por PNTs utilizando técnicas de AM, delinea-se como objetivos dessa investigação:

- Coletar a base de dados e criar um conjunto público de dados;
- Propor uma metodologia de pós-processamento de previsões meteorológicas de rajada de vento utilizando AM, visando aprimorar a acurácia para diferentes intensidades de vento, com foco em eventos fortes, em um horizonte de médio prazo;
- Investigar se é possível prever eventos extremos de rajada utilizando técnicas de AM utilizando variáveis de superfície como preditores.

1.5 CONTRIBUIÇÕES

Considerando o produto final dessa dissertação, este trabalho investigou a capacidade de técnicas de AM de corrigir e identificar eventos severos, das previsões realizadas por 50 membros (simulações individuais geradas a partir de pequenas perturbações nas condições iniciais ou na física do modelo) de um mesmo modelo atmosférico. Os modelos exploraram as relações espaciais e temporais existentes nos fenômenos meteorológicos.

Esse trabalho avança no conhecimento a respeito limitações das características de superfície na utilização de técnicas de AM na melhoria de previsões de rajada, que produzem impactos socioeconômicos relevantes. Especificamente, aponta que para um conjunto de dados sem informações da estrutura vertical da atmosfera, as arquiteturas propostas não são capazes de extrair melhores previsões.

A organização e limpeza dos dados proposta na metodologia deve contribuir em trabalhos futuros, uma vez que procuram manter as relações espaço-temporais das características de entrada. Os dados coletados foram organizados e poderão auxiliar na confecção de novas pesquisas em área correlata.

1.6 ORGANIZAÇÃO DO DOCUMENTO

Este trabalho está dividido em 6 capítulos. No Capítulo 2 são apresentados os fundamentos teóricos utilizados, tanto meteorológicos quanto de AM. No Capítulo 3 são mostrados os trabalhos relevantes na área e como se relacionam com o presente estudo. Em seguida, no Capítulo 4, é descrita a metodologia utilizada. Por fim, nos Capítulos 5 e 6, apresentam-se os resultados e as conclusões.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão apresentados os principais conceitos de meteorologia e de AM essenciais para o pleno entendimento dos experimentos propostos e suas motivações.

2.1 CONCEITOS METEOROLÓGICOS

Nesta seção, é apresentado o funcionamento, a organização e a inicialização dos modelos meteorológicos. Também serão mostradas as escalas meteorológicas e como são medidos os dados de observação.

2.1.1 Previsão numérica do tempo

Modelos numéricos de previsão do tempo são modelos computacionais que resolvem equações físicas que descrevem a atmosfera (Pu and Kalnay, 2018). Eles podem ser interpretados como um sistema de equações para solucionar um problema de condições iniciais e de contorno. Ao conjunto de equações básicas é dado o nome de equações de governo ou primitivas e descrevem a conservação de momento (Eqs. 2.1-2.3), conservação de massa (Eq. 2.5), lei dos gases ideais (Eq. 2.7), conservação de energia (Eq. 2.4) e conservação de massa de água (Eq. 2.6) (Pu and Kalnay, 2018).

$$\frac{\partial u}{\partial t} = -u \frac{\partial u}{\partial x} - v \frac{\partial u}{\partial y} - w \frac{\partial u}{\partial z} + \frac{uv \tan \Phi}{a} - \frac{uw}{a} - \frac{1}{\rho} \frac{\partial p}{\partial x} - 2\Omega(w \cos \Phi - v \sin \Phi) + Fr_x \quad (2.1)$$

$$\frac{\partial v}{\partial t} = -u \frac{\partial v}{\partial x} - v \frac{\partial v}{\partial y} - w \frac{\partial v}{\partial z} + \frac{u^2 \tan \Phi}{a} - \frac{uw}{a} - \frac{1}{\rho} \frac{\partial p}{\partial y} - 2\Omega u \sin \Phi + Fr_y \quad (2.2)$$

$$\frac{\partial w}{\partial t} = -u \frac{\partial w}{\partial x} - v \frac{\partial w}{\partial y} - w \frac{\partial w}{\partial z} + \frac{u^2 + v^2}{a} - \frac{1}{\rho} \frac{\partial p}{\partial z} + 2\Omega u \cos \Phi - g + Fr_z \quad (2.3)$$

$$\frac{\partial T}{\partial t} = -u \frac{\partial T}{\partial x} - v \frac{\partial T}{\partial y} + (\gamma - \gamma_d)w + \frac{1}{c_p} \frac{dH}{dt} \quad (2.4)$$

$$\frac{\partial \rho}{\partial t} = -u \frac{\partial \rho}{\partial x} - v \frac{\partial \rho}{\partial y} - w \frac{\partial \rho}{\partial z} - \rho \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial w}{\partial z} \right) \quad (2.5)$$

$$\frac{\partial q_v}{\partial t} = -u \frac{\partial q_v}{\partial x} - v \frac{\partial q_v}{\partial y} - w \frac{\partial q_v}{\partial z} + Q_v \quad (2.6)$$

$$P = \rho RT \quad (2.7)$$

Nas equações 2.1 a 2.7, u é a componente zonal do vento (positivo para leste), v a componente meridional do vento (positivo para norte) e w a componente vertical do vento (positivo para cima). A pressão é representada por p , a densidade por ρ e a temperatura por T . A variável q_v é a umidade específica, que é uma medida que representa a quantidade de vapor d'água em um volume de ar. A grandeza Ω é a frequência angular de rotação da Terra, Φ é a latitude, a é o raio da Terra, c_p é o calor específico do ar à pressão constante, g é a aceleração da gravidade, H e Q_v representam o ganho ou perda de calor sensível ou latente e de vapor de água,

respectivamente, e Fr representa a fricção em cada uma das coordenadas. A taxa variação de temperatura com a altura, *lapse-rate*, é representado pela letra γ , γ_d é o *lapse-rate* adiabático seco, ou seja a taxa de variação de temperatura com a altura quando não há umidade presente. Mais detalhes sobre a derivação dessas equações podem ser encontrados em Holton and Hakim (2013).

Modelos operacionais costumam utilizar variações das equações apresentadas e com equações adicionais para os diversos tipos de precipitação como água de nuvem, gelo de nuvem etc., além de acoplamentos com outros sistemas. As equações primitivas não possuem solução analítica e portanto precisam ser convertidas utilizando métodos numéricos. Porém, antes dessa conversão, algumas aproximações podem ser feitas para ser mais eficiente do ponto de vista numérico e simplificar processos físicos muito complexos (Wallace and Hobbs, 2006).

A escolha do método numérico para resolver as equações envolve a acurácia do método, requisitos de memória, custo computacional e simplicidade do código. A Figura 2.1 mostra as duas abordagens que são comumente utilizadas nas diferenças espaciais: No quadro (A), um fenômeno meteorológico é representado com uma linha contínua, no entanto soluções numéricas precisam ser discretas. Em (B), a discretização é realizada por meio de um método espectral, onde as equações são aproximadas por uma série de harmônicos (tipicamente funções Fourier–Legendre). Esse tipo de modelo conserva melhor a energia em grande escala e carregam menos ruídos nas derivadas, modelos globais costumam seguir essa abordagem. No painel (C), o mesmo fenômeno é discretizado através de volumes finitos, que é baseado nas séries de Taylor, e tem por vantagem conservar massa, momento e energia. Neste último tipo de modelo a solução das equações é realizada em cada ponto da malha (ou grade). Esse tipo de abordagem é mais utilizada em modelos de escala regional. Para a integração no tempo é utilizado o método das diferenças finitas.

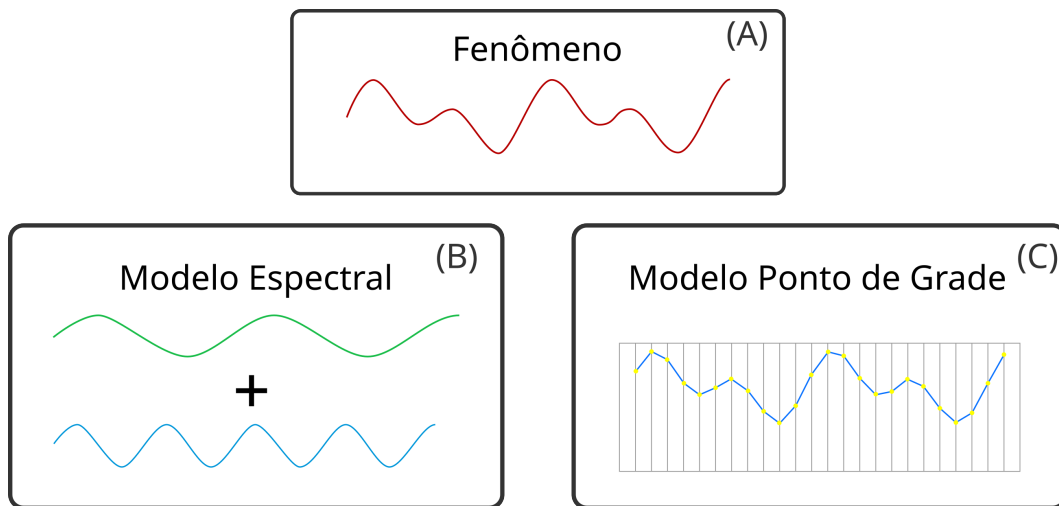


Figura 2.1: Representação esquemática da solução numérica do modelo. (A) fenômeno meteorológico. (B) A solução espectral utiliza soma de ondas. (C) Solução em ponto de grade discretiza a mesma onda em diversos pontos.

A resolução horizontal do modelo atmosférico é definido pelo comprimento de onda mais curto nos modelos espectrais ou pela diferença horizontal na discretização espacial dos modelos de volumes finitos. Essa resolução determina quais tipos de fenômenos um modelo é capaz de resolver. Por exemplo, uma aproximação típica dos modelos meteorológicos é negligenciar efeitos da variação de pressão na densidade (ondas de som). Outros efeitos como turbulência e mudanças de fase também são parametrizados de tal modo que apenas seus efeitos são incorporados.

Os modelos numéricos podem ser classificados quanto à sua área, podendo ser globais ou regionais, esses últimos também chamados de área limitada. A maior diferença entre os dois é a condição de contorno, que no primeiro somente as condições iniciais são necessárias. Nos modelos regionais além das condições iniciais é preciso informar as condições laterais, comumente adquiridas de um modelo global.

As saídas dos modelos, em geral, são pós-processadas para uma grade regular para facilitar o uso em aplicações gerais. Uma organização comum do dado é em matrizes de quatro dimensões: *tempo*, *presso(altura)*, *latitude*, *longitude* (Figura 2.2).




Figura 2.2: Representação esquemática da solução numérica do modelo.

Um dos principais modelos de escala global é o IFS (ECMWF, 2023), mantido pelo European Centre for Medium-Range Weather Forecasts (ECMWF). Sua previsão é fornecida em resolução espacial de 0.1° (aproximadamente 10 km). Outro modelo bastante utilizado por sua qualidade e por ser disponibilizado gratuitamente é o Global Forecasting System (GFS), disponibilizado com resolução de 0.25° , e mantido pelo National Centers for Environmental Prediction (NCEP).

2.1.2 Escalas Meteorológicas

Eventos meteorológicos podem ter durações e impactar áreas muito diversas. Os fenômenos costumam ser classificados quanto à sua escala espaço-temporal. As escalas podem ser divididas nas seguintes categorias: microescala, mesoescala, escala sinótica e global, como pode ser visto na Figura 2.3

A microescala trata de fenômenos de centímetros até poucos quilômetros e curta duração. A mesoescala tem escala da ordem de dezenas a centenas de quilômetros e durações de várias horas. As escalas sinótica e global tratam de fenômenos da ordem de várias centenas a milhares de quilômetros e durações de dias a várias semanas. Fenômenos de escalas menores influenciam as escalas maiores, porém as resoluções horizontais típicas dos modelos utilizados nesse trabalho conseguem resolver apenas fenômenos a partir da mesoescala, portanto fenômenos que não podem ser resolvidos explicitamente ficam a cargo das parametrizações.

2.1.3 Vento nas Estações Meteorológicas

O vento, uma grandeza vetorial, é gerado pela diferença de pressão atmosférica entre regiões: o ar flui das áreas de alta pressão para as áreas de baixa pressão. Essa movimentação visa manter o equilíbrio energético do sistema, sendo afetada pela rugosidade da superfície e pela rotação da Terra (Wallace and Hobbs, 2006; Varejão–Silva, 2006).

Em escala planetária, esses movimentos atmosféricos se manifestam como ciclones, furacões, frentes frias e jatos de médias latitudes. Ao reduzirmos a escala, observamos interações




Figura 2.3: Escalas típicas de eventos meteorológicos. Adaptado de Ahrens (2013)

com a superfície terrestre, incluindo irregularidades e rugosidades que geram movimentos turbulentos.

Além do gradiente de pressão (que impulsiona o ar de áreas de alta para baixa pressão), a força de Coriolis (devido à rotação da Terra, desviando o movimento dos ventos), a força centrípeta (necessária para o movimento curvo do ar) e a fricção (resistência do ar com a superfície) influenciam o comportamento do vento. O balanço termodinâmico dentro dos sistemas convectivos, associado à mudança de fase da água, resulta em fenômenos como tornados, frentes de rajada e microexplosões (Ahrens, 2013).

A velocidade do vento reflete diretamente o gradiente de pressão e é uma medida da intensidade do vento. Quanto à direção do vento, ela indica o deslocamento da massa de ar a partir de sua origem. Por exemplo, um vento nordeste se origina do nordeste e se desloca em direção ao sudoeste. Vale ressaltar que, na notação meteorológica, os ângulos seguem uma convenção específica, diferente da trigonométrica. A Figura 2.4 mostra um vetor de vento representado nessa convenção.

Rajadas de vento são aumentos abruptos na velocidade do vento, com durações típicas da ordem de segundos. Segundo a World Meteorological Organization (WMO), as rajadas de vento são definidas como o máximo valor, ao longo do período da observação, da velocidade média do vento. No monitoramento operacional do SIMEPAR, essa captura é realizada por anemômetros de hélice, que registram medições em alta frequência (geralmente na ordem de segundos, como 1 a 3 segundos), e o valor máximo é reportado a cada hora.

É fundamental destacar a diferença na definição de rajada de vento entre as observações de estações e os modelos numéricos de previsão do tempo. Enquanto as estações meteorológicas, como as do SIMEPAR, medem a rajada diretamente através de sensores de hélice que capturam a variabilidade em escalas de segundos, os modelos numéricos, como o IFS, representam a rajada (variável Velocidade da rajada do vento a 10m (fg10)) como uma parametrização de processos sub-grade, ou seja, fenômenos de pequena escala que não são explicitamente resolvidos pela grade do modelo. Essa diferença metodológica entre a medição direta e a representação parametrizada é




Figura 2.4: Representação da direção de um vento nordeste. O valor da direção indica de onde a massa de ar se origina.

uma fonte intrínseca de incerteza e é um dos desafios centrais no pós-processamento de previsões de rajadas de vento.

2.1.3.1 Classificação das Classes de Vento

Para o contexto deste trabalho e em alinhamento com a experiência operacional do SIMEPAR junto ao setor elétrico, as classes de velocidade do vento são definidas da seguinte forma:

- **Vento Ameno:** Velocidade do vento inferior a 2 m/s. Condições de vento muito baixo, geralmente sem impacto significativo na geração eólica.
- **Vento Fraco:** Velocidade do vento entre 2 m/s e 5 m/s. Condições de vento que permitem alguma geração eólica, mas ainda em níveis reduzidos.
- **Vento Moderado:** Velocidade do vento entre 5 m/s e 10 m/s. Condições ideais para a maioria dos parques eólicos, com geração de energia otimizada.
- **Vento Forte:** Velocidade do vento superior a 10 m/s. Ventos de alta intensidade que podem levar à saturação ou até mesmo ao desligamento de aerogeradores por segurança.

Essas classificações são cruciais para a análise de impacto na geração de energia eólica e para a tomada de decisões operacionais no setor.

2.2 CONCEITOS DE APRENDIZAGEM DE MÁQUINA

Modelos de AM, em oposição aos modelos numéricos, são empíricos, ou seja, usam dados observados em seu treinamento. Um modelo é ajustado otimizando uma função custo, essa otimização pode ser supervisionada (quando conhecemos os rótulos dos valores reais) ou não supervisionada (quando só temos acesso às características). Os modelos podem gerar resultados contínuos (regressão) ou discretos (classificação), sendo que a maioria das arquiteturas conseguem lidar com os dois casos. O presente trabalho contém experimentos em todos esses grupos. Os experimentos de regressão supervisionados tentam melhorar as estimativas de uma

previsão gerada por PNT preexistente. O experimento com SVM, como será explicado na seção 2.2.5, é um exemplo de classificação semi-supervisionada, onde procura detectar eventos anormais.

O nome Redes Neurais (RN) vem por analogia ao neurônio biológico. Os neurônios biológicos são células especializadas em diversas atividades diferentes como motoras, sensoras ou intraneurônios (NIH, 2023). As informações excitadoras ou inibidoras chegam através dos dendritos e são agregados no corpo celular, também chamada de soma. A região conhecida como proeminência axônica ou cone de implantação funciona como um filtro que determina o potencial de ação que será transmitido ao axônio, esse potencial consiste em uma onda elétrica do tipo “tudo-ou-nada” (Kotermanski and Cascio, 2023). Os neurônios reais são bem mais complexos do que o descrito acima, mas a morfologia apresentada ajuda a entender o conceito da arquitetura proposta por McCulloch and Pitts (1943) onde entradas são ponderadas por pesos (dendritos) e seu valor agregado (soma) é passado por função de ativação (cone de implantação) que determina a sua saída (Chase et al., 2023), um esquema de neurônio biológico e perceptron é vista na Figura 2.5. Matematicamente ele é descrito pela equação:

$$f(x) = \sigma\left(\sum_{i=1}^n w_i x_i + b\right),$$

sendo x_i as n características de entrada, w_i os pesos correspondentes, σ a função de ativação e b o viés.




Figura 2.5: Comparação esquemática entre um neurônio biológico e perceptron.

2.2.1 Redes Neurais Artificiais

Uma vez que o perceptron seja um neurônio, um conjunto deles interagindo é o equivalente ao cérebro, daí depreende-se o nome de RN artificiais. Essas redes também são conhecidas como Perceptron Multi Camadas (Multilayer Perceptron) (MLP), onde cada camada é composta por nós (neurônios). O uso de RN é popular em meteorologia com trabalhos desde a década de 90 (Chase et al., 2023).

2.2.2 Redes Neurais Recorrentes (Recurrent Neural Networks)

As RNN são uma aplicação de uma RN especializada em dados sequenciais ou séries temporais. Sua arquitetura introduz ciclos com o objetivo de manter informações passadas entre as sequências, ou seja uma memória das informações anteriores. Essa característica de levar em consideração a ordem da sequência é o que torna essa rede diferente das RN profundas tradicionais, onde é assumido que cada entrada seja independente uma da outra.

LSTM (Hochreiter and Schmidhuber, 1997) é um tipo especial de RNN frequentemente usado em aprendizado profundo. Ela surge com o propósito de resolver o problema de desaparecimento do gradiente, para isso introduz uma célula de memória para armazenar as informações por períodos mais longos. Essa característica permite que o LSTM aprenda dependências temporais em prazos mais estendidos.

2.2.3 Transformers

Transformers (Vaswani et al., 2017) é um modelo de sequência para sequência, o que significa que ele transforma uma sequência de entrada (e.g., uma série temporal de dados passados) em uma sequência de saída (e.g., uma previsão de valores futuros). Ele procura resolver o problema de tradução de sentenças muito longas mantendo o contexto, isso é especialmente interessante para previsão meteorológica porque existe uma dependência de um estado futuro com o estado passado. Essa relação de contexto em meteorologia é verdade não somente temporalmente, mas também espacialmente. A inovação desse esquema reside no mecanismo de atenção, que agrega um caminho adicional para cada entrada de forma que cada passo do decodificador pode acessar os valores de entrada diretamente, eliminando recorrências e convoluções. A formulação da atenção é dada pela fórmula 2.8.

$$Atencao(Q, V, K) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2.8)$$

Sendo Q o conjunto das *queries*, K são as chaves e V os valores, cada linha dessas matrizes representa uma entrada do modelo. De forma geral as matrizes Q e K transformam linearmente o *embedding* original (a representação numérica inicial dos dados de entrada), melhorando a representação das entradas do ponto de vista da similaridade. A matriz de valores V usa as similaridades encontradas no passo anterior para encontrar o próximo valor da sequência. A divisão por $\sqrt{d_k}$ vem para escalar o produto escalar pela dimensão da entrada.

Os autores do método consideraram benéfico utilizar um conjunto de Q , K e V , criando um conjunto de representações para cada entrada de forma paralela, sendo esse esquema chamado de *Multi-head attention*. Esse esquema permite que o modelo tenha informações de representações de diferentes subespaços. O uso da auto atenção traz um benefício bastante procurado quando se trata de sistemas físicos, que é a maior facilidade para a interpretação dos resultados.

A arquitetura do modelo (Figura 2.6) consiste em um pré-processamento da entrada por meio do *embedding* e da codificação posicional, essa entrada codificada passa pelo codificador seis vezes. Sendo que o codificador é composto de uma camada de auto atenção e uma camada *feedforward*. O decodificador é semelhante ao codificador, com exceção que existe uma camada extra na entrada para processar os dados do decodificador.

2.2.4 Redes Neurais Convolucionais (Convolutional Neural Networks)

Introduzida por LeCun et al. (1989) para o reconhecimento de dígitos numéricos escritos à mão, como o nome sugere, a técnica utiliza convoluções, que matematicamente é definido

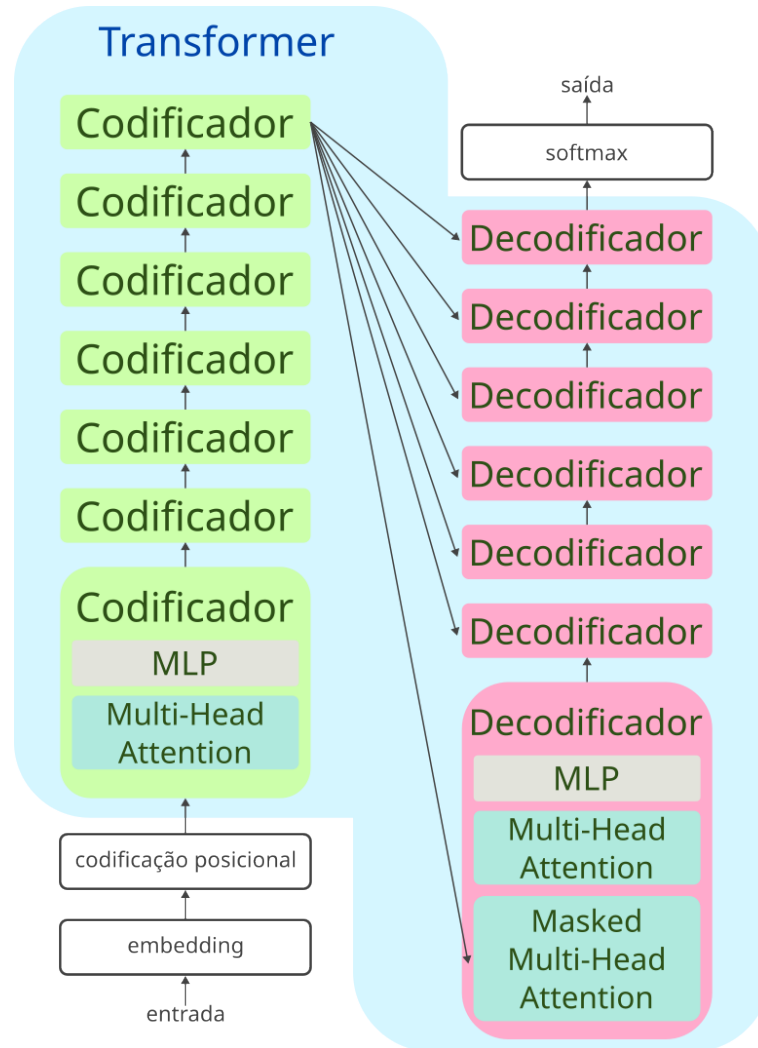


Figura 2.6: Arquitetura do modelo Transformer.

como a soma do produto de duas funções. No caso das CNN a imagem é alterada por um filtro (*kernel*) aplicado a cada ponto de grade como na Figura 2.7. E a formulação matemática de uma convolução em um ponto é dada pela equação 2.9.

$$p_{x,y}\sigma\left(\sum_{j=0}^{j=2k} \sum_{i=0}^{i=2k} w_{i,j} p_{x-k+i,y-k+j} + b\right) \quad (2.9)$$

onde $w_{i,j}$ é o peso na coordenada i, j que é aprendido durante o treinamento, $p_{x,y}$ é o valor do ponto da grade na coordenada (x, y) , k é a metade do tamanho do *kernel* arredondado para inteiro anterior, b é uma constante e indica o viés e σ é função de ativação, por exemplo ReLu.

A função de ativação tem o papel de introduzir a não linearidade, permitindo representações mais complexas (Rasmussen, 2019). Após a função de ativação ser aplicada é adicionado um agrupamento (*pooling*), que tem a função de diminuir o vetor de características enquanto mantém as principais informações. As camadas com aplicação de *kernel* e *pooling* são chamadas de camadas escondidas.

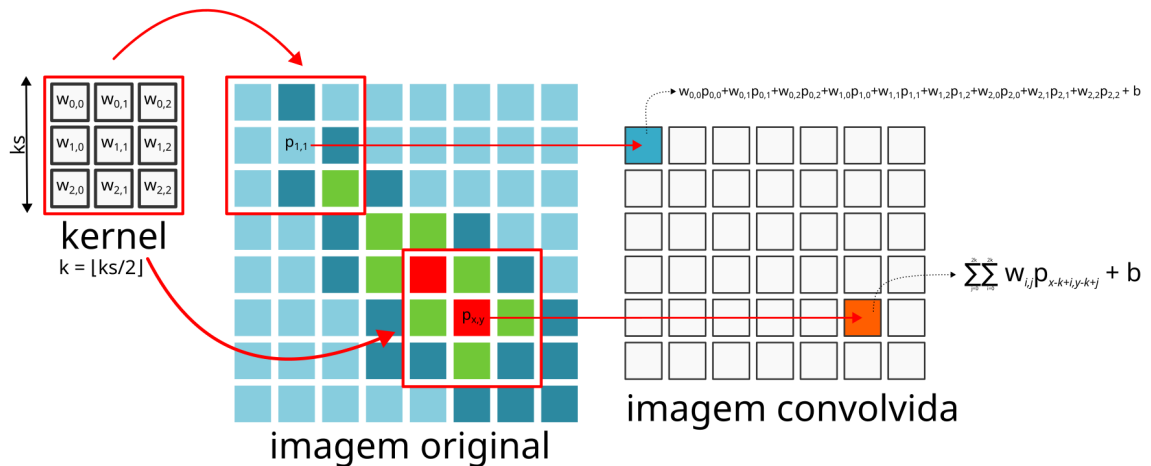


Figura 2.7: Representação esquemática de uma convolução.

Após a extração das características nas camadas escondidas é aplicada uma ou mais camadas completamente conectadas. Essas camadas geralmente são uma rede neural seguida de uma função de ativação.

2.2.5 Máquina de Vetores de Suporte (Support Vector Machine)

Diferente das RN, os modelos SVM são um método que tem por objetivo encontrar um hiperplano que maximize a margem de separação entre classes, sendo essa ideia introduzida por Vladimir Naumovich Vapnik (Vapnik, 2000). AM é comumente utilizado para classificação, mas também existe sua variação para regressão. Neste trabalho é aplicada SVM de classe única, voltada para a detecção de anomalias. Nesta variação a SVM funciona como um modelo semi-supervisionado, pois precisa apenas de exemplos da classe normal. A SVM usa um recurso matemático conhecido como truque do *kernel*, que é o mapeamento dos dados para espaços de maior dimensão sem realizar a transformação explícita. Um dos *kernels* possíveis é o Função de Base Radial (Radial Basis Function) (RBF), sua formulação é apresentada na equação 2.10, onde o parâmetro γ indica a influência de um único vetor de suporte. Valores grandes de γ estão associados a fronteiras mais complexas, enquanto valores baixos tornam as fronteiras de decisão mais suaves.

$$K(x_i, x_j) = \exp(-\gamma|x_i - x_j|^2) \quad (2.10)$$

A implementação do classificador SVM de uma única classe da biblioteca *scikit-learn* recebe um parâmetro adicional chamado ν . Esse parâmetro varia de 0 a 1, e nos permite controlar a fração de anomalias no conjunto de treinamento. Em termos práticos, um valor 0.5 indica que até 50% podem ser tratados como anomalias. Em termos geométricos, um ν pequeno está associado a fronteira mais estreita, enquanto valores grandes indicam fronteiras mais abrangentes.

3 ESTADO DA ARTE

Nos últimos anos o interesse pela previsão de vento está crescendo, principalmente impulsionado pela demanda em energias renováveis (Santhosh et al., 2020), mercado que vem ganhando espaço no Brasil (ANEEL, 2023). A Figura 3.1 mostra que o termo *wind forecasting* corresponde a cada vez mais publicações. Entre as áreas de concentração, a de ciências da computação é uma das mais relevantes no assunto.

Em grande parte, as técnicas de AM ganham força onde os modelos físicos não são capazes de resolver de forma satisfatória. Isso é especialmente verdade na previsão de curto e curtíssimo prazo, onde métodos de extrapolação já tinham melhores resultados que modelos numéricos (Browning, 1980; Yousuf et al., 2019).

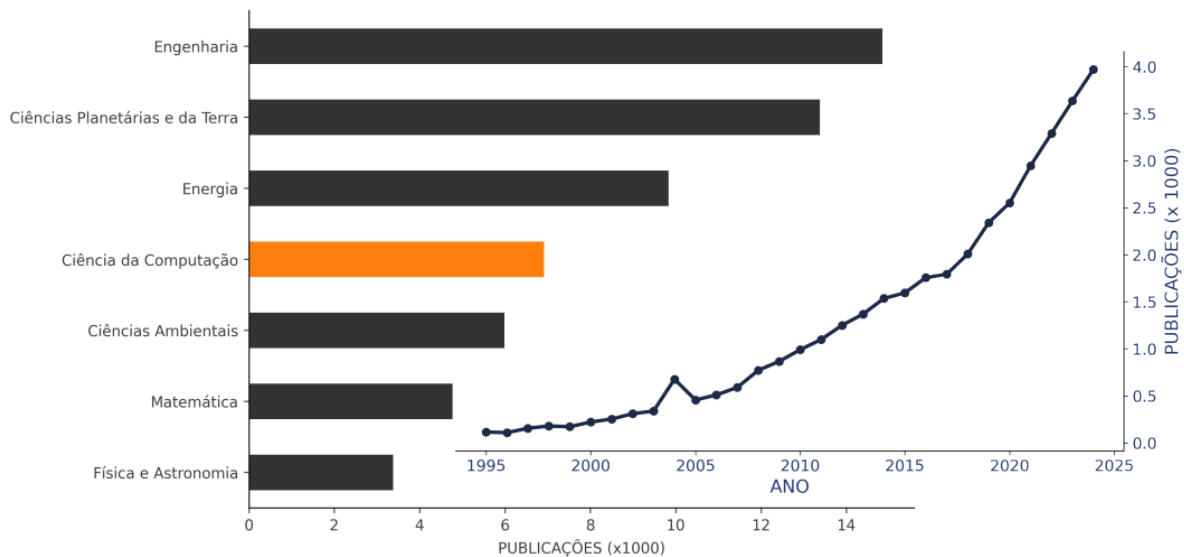


Figura 3.1: Publicações relacionadas ao termo *wind forecasting* na base da Scopus por área e por ano.

Santhosh et al. (2020) descreve as abordagens mais adotadas quando se trata do pós processamento de vento. Primeiro, os trabalhos podem ser divididos quanto ao horizonte de previsão: curtíssimo, curto, médio e longo prazo. O curtíssimo prazo abrange apenas alguns minutos à frente, já o curto prazo chega até 1 dia de previsão. A previsão de médio prazo, região na qual se encontra esse trabalho, abrange o período de 1 dia até 1 mês à frente. O longo prazo trata de previsões de mais de um mês. A segunda divisão dos trabalhos, segundo os autores, é com relação ao método utilizado, podendo ser estatísticos, PNT e AM. Na escala de médio prazo é apontado que a combinação de PNT com métodos de AM possuem melhores resultados.

A revisão de Yousuf et al. (2019) com respeito à previsão de potência gerada, também divide os trabalhos de forma semelhante, porém sua divisão dos prazos temporais de previsão considera como longo prazo as previsões maiores que 1 dia. Apesar dessa pequena diferença de classificação, pode-se entender que a abordagem proposta neste trabalho seja melhor definida como de médio prazo.

Para contextualizar a presente dissertação em relação à literatura existente, o Quadro 3.1 apresenta um comparativo detalhado dos trabalhos de pós-processamento de previsões de vento. Este quadro organiza as principais abordagens, os modelos numéricos e de AM empregados, as variáveis estudadas, o foco em detecção de anomalias ou correção de viés, e as regiões geográficas

dos estudos. Nele, é possível identificar as lacunas e as contribuições específicas desta pesquisa no cenário atual do estado da arte.

O Quadro 3.1 sumariza as abordagens dos trabalhos comparativamente à proposta apresentada.

Entre as técnicas para prever o vento, as de AM também estão sendo mais utilizadas nos estudos mais recentes como em Wu et al. (2022). Em seu trabalho, os autores fazem uma revisão das técnicas mais utilizadas para a previsão de vento para o setor de energia eólica, onde uma melhora de 10% na previsão implica uma melhora de 30% na previsão de produção de energia. Os autores ainda dividem as previsões em duas categorias: determinísticas e probabilísticas, sendo as últimas preferidas devido à melhor descrição da incerteza e aleatoriamente do vento. Os métodos para a previsão de vento foram divididos em cinco categorias: persistência, método físico, métodos estatísticos, AM com estrutura rasa e AM com estrutura profunda. Métodos envolvendo PNT se mostraram mais adequados para previsões com mais de um dia, mas são minoria entre os trabalhos revisados porque os demais concentram-se no curtíssimo prazo. Métodos rasos de AM necessitam engenharia de características extensiva, enquanto RN profundas são capazes de extrair características mais abstratas e ocultas nos dados. Os autores afirmam que RN profundas, assim como RNN e CNN são geralmente usadas para a extração de características. A maior parte dos trabalhos revisados utilizou LSTM e modelos híbridos que combinam diversas técnicas tendem a ter uma melhor performance.

Ao comentar sobre a distinção de eventos fortes e extremos, Surendran et al. (2025) destacam que os fatores que determinam as rajadas extremas são difíceis de identificar, pois diferem substancialmente daqueles que impulsionam as rajadas fortes, e a raridade desses eventos extremos dificulta a obtenção de conclusões generalizáveis. A classificação proposta por Surendran et al. (2025) para vento forte (> 18 m/s) está em concordância com esta dissertação, na qual foi utilizado (> 19 m/s). Eles utilizaram uma floresta aleatória para identificar valores extremos, porém com alta taxa de falsos positivos. A conclusão dos autores para os falsos positivos é que rajadas de vento extremas são determinadas predominantemente por convecções localizadas, as quais as PNT têm desempenho inferior na previsão.

Na tentativa de identificar rajada de vento acima de 7.2 m/s na próxima hora, Coburn and Pryor (2022) propuseram modelos de regressão e RN com diversas profundidades. Utilizaram características de casos de vento forte provenientes do ECMWF Reanalysis v5 (ERA5). Os autores indicam que durante a estação fria os modelos são mais assertivos devido à escala sinótica dos eventos, ideia em concordância com Surendran et al. (2025). Modelos mais profundos tenderam ao sobreajuste, mas a inclusão de um termo auto regressivo melhorou os resultados. Mesmo restringindo o treinamento a valores fortes (rajadas de vento entre 17 m/s e 25.7 m/s), ainda subestimaram em 50% a frequência das rajadas.

No nordeste brasileiro, Campos et al. (2022) criaram uma RN cujo objetivo era melhorar a previsão de vento do ensemble do IFS até 46 dias. Os modelos cobriram dois intervalos temporais, o primeiro de 1 a 15 dias e o segundo de 16 a 46 dias. As características foram as variáveis de superfície: componentes zonal e meridional do vento, temperatura, umidade, pressão, latitude, longitude, seno e cosseno do tempo, e o tempo de previsão. Porém, diferentemente desta dissertação, os autores reduziram a dimensionalidade dos dados da previsão por conjuntos utilizando os momentos probabilísticos: média, variância e assimetria das variáveis meteorológicas. Ao longo de todo o intervalo de 1 a 15 dias, o modelo proposto pelos autores apresentaram redução do viés, melhora no RMSE e correlação. A região nordeste, no entanto, não tem registros históricos de ciclones tropicais ou eventos extremos, como bem apontam os autores.

Schulz and Lerch (2022) compararam o pós processamento de uma previsão de conjuntos (método que gera múltiplas simulações do modelo com pequenas variações nas condições iniciais ou parâmetros físicos, visando capturar incertezas e a faixa de possíveis cenários futuros) na Alemanha, visando estimar a distribuição de probabilidade de rajadas de vento. Os autores constataram que os métodos AM se beneficiaram significativamente do uso de variáveis meteorológicas adicionais como preditores, o que não foi alcançado pelos métodos estatísticos. Modelos baseados em árvores de decisão e RN tiveram desempenho melhor que métodos estatísticos tradicionais para todos os limiares de rajada de vento abaixo de 30 m/s.

Para pós processar as saídas do Weather Research and Forecasting (WRF), Xu et al. (2020) usaram um algoritmo de *Gradient Boosting Decision Tree*. O modelo proposto foi capaz de melhorar as previsões do vento médio próximo à superfície nos pontos das torres eólicas para períodos de até 72h, com Root Mean Squared Error (RMSE) entre 1 e 1.5 m/s. Entre as características mais importantes, a previsão próxima à superfície se mostrou a mais relevante, bem como as características temporais. No entanto, os autores alegam que o modelo se beneficiou ao usar um número maior de características. Essa correção do comportamento médio está em concordância com os resultados obtidos nesta dissertação.

Os trabalhos ocorridos no "*2019 Oxford workshop on Machine Learning for Weather and Climate*" são sumarizados por Haupt et al. (2021). Apesar de não ser um trabalho específico a respeito de rajadas de vento, os autores afirmam que os modelos de AM conseguem tratar melhor a não linearidade do que técnicas estatísticas tradicionais como Ensemble Model Output Statistics (EMOS). Em relação a eventos severos e no campo de energias renováveis, os métodos de RN e SVM foram os que chamaram mais a atenção dos autores. As CNN e LSTM especificamente se beneficiaram da relação espacial e temporal dos dados. Para o progresso futuro do uso de AM, os autores sugerem que se busque as seguintes características: confiabilidade, interpretabilidade e usabilidade. Uma nota no sentido ao progresso da área é a habilidade de publicar não apenas resultados positivos, mas também as eventuais falhas e limitações. Essa transparência é crucial, pois evita a duplicação de esforços infrutíferos por outros pesquisadores, acelera a identificação de becos sem saída e promove um entendimento mais completo sobre os limites e desafios das abordagens existentes, permitindo que a comunidade avance de forma mais eficiente.

Tabela 3.1: Trabalhos correlatos em pós-processamento de modelos atmosféricos para a previsão de rajadas de vento.

Referência	Prazo	Modelo Numérico	Modelo de AM	Variável	Deteção de Anomalia	Correção de Viés	Região
Campos et al. (2022)	Médio / Longo	IFS-ens	Perceptron Camadas	Multi	Vento	•	Maranhão / Piauí, BR
Coburn and Pryor (2022)	Curto	ERA5	Regressão Logística, ANN	Rajada	•		Leste EUA
Surendran et al. (2025)	Não se aplica	BARRA-SY	Floresta Aleatória	Rajada	•		South Wales, Austrália
Xu et al. (2020)	Médio	WRF	Gradient Boosting	Vento		•	Jiangsu, China
Proposta	Médio	IFS-ens	Linear, CNN, LSTM, Transformers, SVM	Rajada	•	•	Paraná, BR

4 MÉTODO PROPOSTO

O presente capítulo inicia-se com a apresentação da área de estudo, dos dados utilizados e da construção do vetor de características. Em seguida as arquiteturas dos modelos de AM são elencadas. Por fim, apresenta-se a descrição dos experimentos e métricas de avaliação.

4.1 ÁREA DE ESTUDO E SELEÇÃO DE ESTAÇÕES

A região de estudo é restrita ao estado do Paraná, Brasil. A principal motivação para a escolha da região é a disponibilidade de dados de estações meteorológicas, cujas medidas foram cedidas pelo Sistema de Tecnologia e Monitoramento Ambiental do Paraná (SIMEPAR). Além disso, a região é conhecida pela variedade de eventos severos causadores de ventos intensos, entre eles pode-se citar: frentes frias, complexos convectivos de mesoescala, microexplosões e linhas de estabilidade.

Para limitar a quantidade de estações utilizadas foi definido que seriam escolhidas apenas aquelas que possuíssem uma estação vizinha a menos de 5 km de distância, a fim de validar os dados observados. Na Figura 4.1 são apresentadas a localização das estações disponíveis e das estações selecionadas. Cada um dos municípios a seguir contém duas estações que satisfazem o critério de distância: Curitiba, Guarapuava, Lapa, Londrina e Telêmaco Borba. É importante ressaltar que essa metodologia de seleção resultou na exclusão de estações localizadas em regiões favoráveis a rajadas de vento, como o oeste do estado. Embora a escolha de estações vizinhas tenha sido útil para a validação dos dados observados, reconhece-se que outros critérios de seleção poderiam ser explorados em trabalhos futuros para uma cobertura mais abrangente de fenômenos extremos. Os dados extraídos foram as rajadas de vento máximas observadas a 10 m de altura a cada hora e serviram como rótulo aos dados de treinamento.

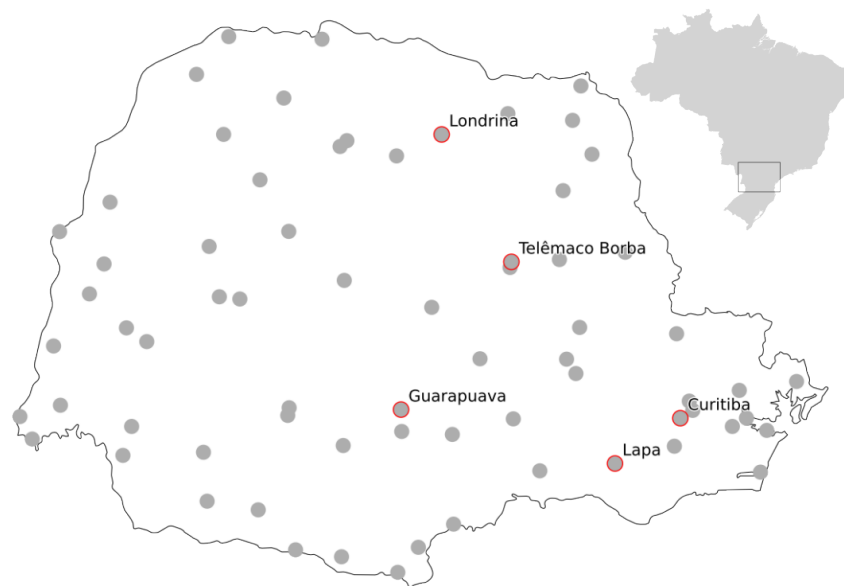


Figura 4.1: Localização das estações com sensor de vento disponíveis. Os círculos vermelhos indicam as estações selecionadas por terem uma vizinha dentro de 5 km.

4.2 CARACTERÍSTICAS E SELEÇÃO DOS DADOS OBSERVADOS

A série de dados extraída corresponde ao período de 01-01-2021 à 01-01-2024. Nesse período foi constatado que as estações próprias do SIMEPAR possuem uma série com menos falhas e, portanto, as mesmas foram escolhidas como referência. Na Figura 4.2 pode-se observar a disponibilidade dos dados do SIMEPAR em comparação com as outras instituições.




Figura 4.2: Série temporal de rajada de vento a 10 m nas cidades selecionadas. Em roxo são representadas as estações do SIMEPAR e em verde as de outras instituições. As linhas horizontais representam os limites de vento de 11, 15.2 e 19.5 m/s.

Ainda na Figura 4.2 vemos que apenas em Curitiba há um período equivalente entre SIMEPAR com outras instituições. Os dados do SIMEPAR foram tomados como referência porque, além de ter maior amostra, existem planos de manutenção e controle de qualidade na programação institucional, realidade que dificilmente as outras instituições conseguem se assemelhar. Antes de fazer a filtragem foram preenchidas falhas de até uma hora em torno de um dado válido com o valor mais próximo, o que significa que na prática lacunas de até 2h foram preenchidas. Esse preenchimento é importante para maximizar o número de vetores de características válidos. Dado que cada vetor de características abrange um período de 48 horas, a presença de até mesmo uma ou duas falhas pontuais inviabilizaria o uso daquele vetor inteiro. Assim, o preenchimento minimiza a perda de amostras valiosas e preserva a continuidade temporal dos dados necessários para o treinamento dos modelos. As quantidades de dados antes e depois do preenchimento para cada estação podem ser conferidos na Tabela 4.1.

Analisando as séries temporais também fica evidente o desbalanceamento dos dados, com poucos dados acima do limiar de 19.5 m/s. Para diminuir a sobreamostragem dos eventos de baixa intensidade, uma metodologia de filtragem foi adotada. Este filtro consiste em identificar os eventos com intensidade maiores que 11 m/s e apenas usar os dados dentro de uma janela de 48h antes até 24h depois desse evento. A Figura 4.3 é semelhante a Figura 4.2, com a diferença de que o filtro supramencionado foi aplicado. Na Tabela 4.2 é apresentada a porcentagem da redução em cada uma das séries.

Tabela 4.1: Comparação entre dados originais e preenchidos por estação

Estação	Simepar		Outro	
	Original	Preenchido	Original	Preenchido
Curitiba	35927	35931	35232	35521
Guarapuava	35936	35950	12377	15878
Lapa	35709	35732	2916	3463
Londrina	35617	35657	19350	21799
Telêmaco Borba	35549	35725	18771	21449




Figura 4.3: Série temporal de rajada de vento a 10 m nas cidades selecionadas filtrando dados em torno de eventos mais intensos. As linhas horizontais representam os limites de vento de 11, 15.2 e 19.5 m/s.

Tabela 4.2: Redução relativa em cada uma das séries após filtragem e quantidade final de dados observados

Cidade	SIMEPAR		Outro	
	Redução	Qtde de dados	Redução	Qtde de dados
Curitiba	72.6%	7184	61.6%	9969
Guarapuava	40.7%	15549	64.2%	2352
Lapa	71.1%	7511	71.0%	1004
Londrina	57.2%	11108	68.3%	3978
Telêmaco Borba	71.8%	7324	98.7%	158

4.3 MODELO METEOROLÓGICO E CONFECÇÃO DO VETOR DE CARACTERÍSTICAS

A previsão por conjuntos do modelo numérico IFS (ECMWF, 2023) foi escolhida como ponto de partida para a extração de características. O IFS é um modelo estado da arte amplamente reconhecido pela sua qualidade. Sua versão em conjuntos conta com 50 membros obtidos por perturbação física das condições iniciais. Dentre as diversas grandezas meteorológicas previstas

as seguintes foram escolhidas como características: fg10, Componente zonal do vento a 10m (u10), Componente meridional do vento a 10m (v10), Temperatura média do ponto de orvalho a 2m (2d) e Temperatura média a 2m (2t).

A principal motivação para a escolha das variáveis citadas foi de ordem prática, ou seja, escolhidas por serem as únicas disponíveis na base de dados do SIMEPAR no momento. No entanto, apesar de ser possível argumentar que outras variáveis em níveis verticais pudessem contribuir com o modelo, o trabalho de Xu et al. (2020) mostrou que a própria variável vento mais próxima à superfície era a mais importante na correção do vento.

O horizonte temporal da previsão foi fixado em 48h à frente. Para cada ponto de previsão nesse horizonte, uma região de 5x5 pontos de grade em torno de cada estação foi considerada para informar as condições espaciais da atmosfera, formando assim uma janela espaço-temporal de características para cada instante de previsão. Estas janelas são extraídas de forma deslizante ao longo de toda a série histórica de dados disponível, gerando múltiplos vetores de características para o treinamento dos modelos. Por fim, os dados foram normalizados pelo método do min-max utilizando valores de cada uma das variáveis no conjunto total.

Na Tabela 4.3 está resumida a quantidade de dados considerados no vetor de características:

Tabela 4.3: Configuração dos dados de previsão

Parâmetro	Valor
Horas de previsão	48
Pontos em X	5
Pontos em Y	5
Membros do conjunto	50
Variáveis previstas	5


4.4 QUANTIDADE E CARACTERÍSTICAS DOS DADOS

O período de tempo de dados de modelo considerado é entre os anos de 2021 a 2024, no entanto, as Figuras 4.4 e suas subfiguras (4.4(a) a 4.4(d)) mostram que há falhas, especialmente entre junho de 2023 e todo o ano de 2024. Estas falhas se devem a múltiplos fatores: (1) o conjunto de dados do modelo IFS já possuía lacunas de origem; (2) a metodologia de filtragem, que removeu dias inteiros de dados fora das janelas de interesse em torno de eventos intensos; e (3) mesmo após o preenchimento de pequenas falhas nas observações, vetores de características incompletos (sem as 48h necessárias) foram eliminados. Na prática, 937 previsões do IFS estavam disponíveis.

4.4.1 Construção dos dados para treinamento

A construção dos dados para treinamento consiste em reunir as características com os rótulos formando tensores que serão enviados aos modelos de AM. Na Figura 4.4 é mostrada a disponibilidade de dados por dia de previsão bem como a contagem de dados disponíveis. Os dias destacados são aqueles que têm tanto dados de modelo quanto pelo menos 12h de dados de estações. Somando-se todos os dados disponíveis de todas as estações existem 2074 vetores para treinamento, onde cada vetor é uma série temporal na forma de $X=(48, 5, 5, 50, 5)$ e os rótulos também são vetores na forma $y=(48)$. Portanto, previsões de 5 variáveis dos 50 membros do


conjunto, em uma área de 5x5 pontos em torno da estação, vão contribuir para uma nova previsão de 48h que tenta simular as observações das estações.




(a) Disponibilidade dados de Curitiba



(b) Disponibilidade dados Guarapuava




(c) Disponibilidade dados de Lapa



(d) Disponibilidade dados Londrina

Figura 4.4: Dias onde há disponibilidade de dados de estação e modelos. Em roxo as estações próprias do simepar e em verde as estações de outras instituições.



(e) Disponibilidade dados de Telêmaco Borba

Figura 4.4: Dias onde há disponibilidade de dados de estação e modelos. Em roxo as estações próprias do simepar e em verde as estações de outras instituições.

4.5 MODELOS DE APRENDIZAGEM DE MÁQUINA

As perguntas desta pesquisa abordam dois problemas. A primeira é se técnicas de AM são capazes de corrigir as previsões subjacentes da PNT, portanto é um problema de regressão. A segunda questão procura detectar anomalias, ou seja, as ocorrências de vento forte. Essa abordagem é uma classificação binária.

Os códigos para a produção dos experimentos foram realizados em Python utilizando as bibliotecas *tensorflow* para os modelos e *scikitlearn* para os cálculos das métricas de avaliação. A seguir são listados nominalmente cada um dos modelos e apresentadas suas arquiteturas. A escolha destas arquiteturas buscou explorar diferentes propriedades dos dados meteorológicos: o modelo Linear serve como base de comparação sobre correção de viés; o LSTM foi selecionado para capturar dependências temporais de longo prazo na série de previsão; as CNNs e o Transformer foram empregados para extrair padrões espaciais complexos e mecanismos de atenção entre os membros do ensemble, respectivamente; e o SVM foi aplicado especificamente pela sua robustez em problemas de detecção de anomalias com classes desbalanceadas.

4.5.1 Linear

O primeiro modelo avaliado (Figura 4.5) foi uma arquitetura minimalista, composta apenas por uma camada densa (Dense) aplicada de forma distribuída no tempo (TimeDistributed). Esse modelo foi escolhido porque, além de sua simplicidade de implementação, se assemelha matematicamente ao Model Output Statistics (MOS), com a diferença que no MOS os pesos variam ao longo do tempo de previsão (Glahn and Lowry, 1972).

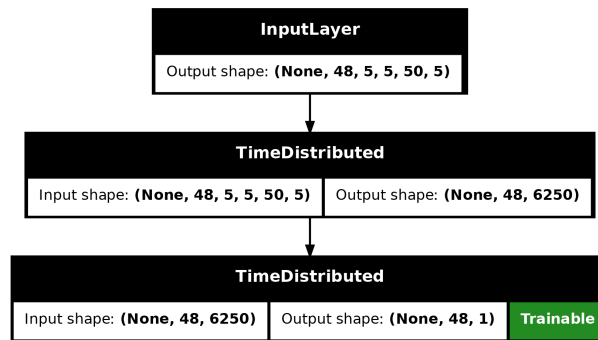


Figura 4.5: Arquitetura do modelo Linear.

4.5.2 Memória de Curto e Longo Prazo (Long short-term memory) (LSTM)

O segundo modelo explorou a capacidade das redes recorrentes de capturar dependências temporais (Figura 4.6) através do uso de uma camada LSTM. Essa característica tentou superar a limitação do modelo linear, que ignora as relações temporais existentes nos fenômenos físicos representados nas previsões. A arquitetura manteve o uso de camadas TimeDistributed no pré-processamento para transformar os mapas espaciais em vetores sequenciais, preservando a estrutura temporal necessária para a leitura da LSTM. Após testes empíricos preliminares, fixou-se a camada oculta em 128 unidades, configuração que demonstrou desempenho superior à de 64 unidades na captura da variabilidade dos dados, sem incorrer no custo proibitivo de redes mais profundas.

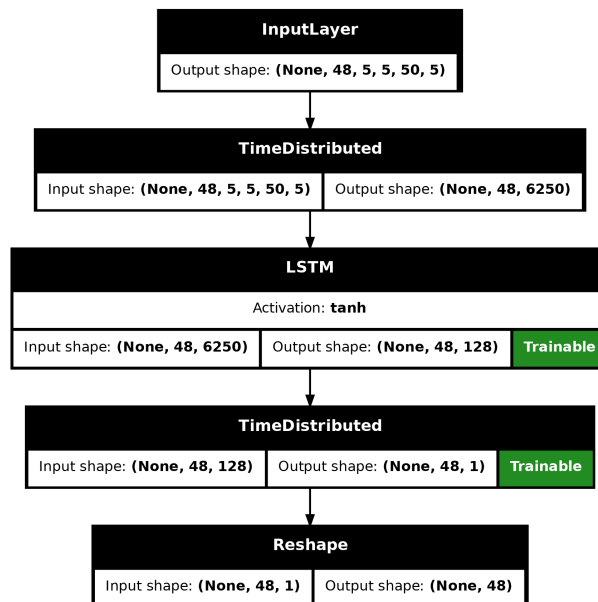


Figura 4.6: Arquitetura do modelo LSTM.

4.5.3 Redes Neurais Convolucionais (Convolutional Neural Networks) (CNN)

A terceira arquitetura (Figura 4.7) empregou convoluções tridimensionais para processar as dimensões espaciais e os membros do ensemble como um volume unificado. O objetivo foi aprender a extrair estatísticas de incerteza diretamente dos dados: as operações de convolução e *MaxPooling* resumem a dispersão dos membros automaticamente, dispensando o cálculo prévio

de média ou desvio padrão. Essa preservação da estrutura probabilística mostrou-se relevante para a previsão de eventos extremos, onde a simples média do ensemble tende a suprimir informações críticas.

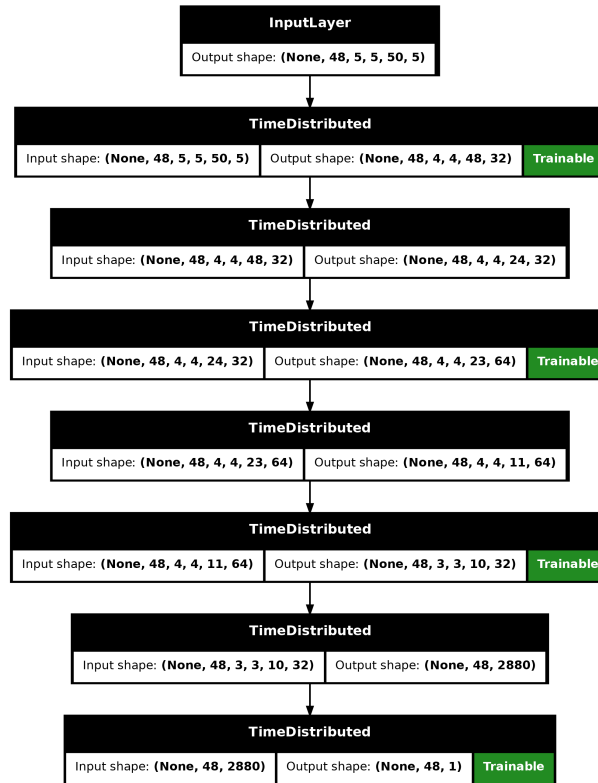


Figura 4.7: Arquitetura do modelo CNN.

4.5.4 Transformer

O quarto modelo avaliado (Figura 4.8) baseou-se na arquitetura Transformer, escolhida por sua capacidade de processar dependências temporais globais através de mecanismos de atenção. Essa abordagem mitiga o problema do desaparecimento de gradiente e a perda de contexto em sequências longas, limitações comuns em redes recorrentes.

A camada de Positional Embedding é responsável por armazenar a ordem da sequência, essa camada também foi utilizada para diminuir a dimensionalidade dos dados de entrada e consequentemente a quantidade de parâmetros treináveis.

O núcleo do modelo é composto por 2 blocos sequenciais (*TransformerBlock*). Cada bloco foi configurado com 4 cabeças de atenção (*multi-head attention*) e uma rede *feed-forward* interna de dimensão 256, totalizando uma profundidade que equilibra a capacidade de modelagem com os recursos computacionais disponíveis. A camada final densa (Dense) projeta o resultado de volta para um único valor de correção para cada um dos 48 passos de tempo.

4.5.5 Máquina de Vetores de Suporte (Support Vector Machine)

A variação do SVM para classificação de uma única classe foi utilizada para a detecção de anomalias. Os dados para treinamento foram apenas os amenos, ou seja, apenas os ventos abaixo de 11 m/s. Para o cálculo das métricas de acerto foi utilizado um conjunto balanceado entre a classe amena e ventos acima da classe moderada (15.2 m/s).

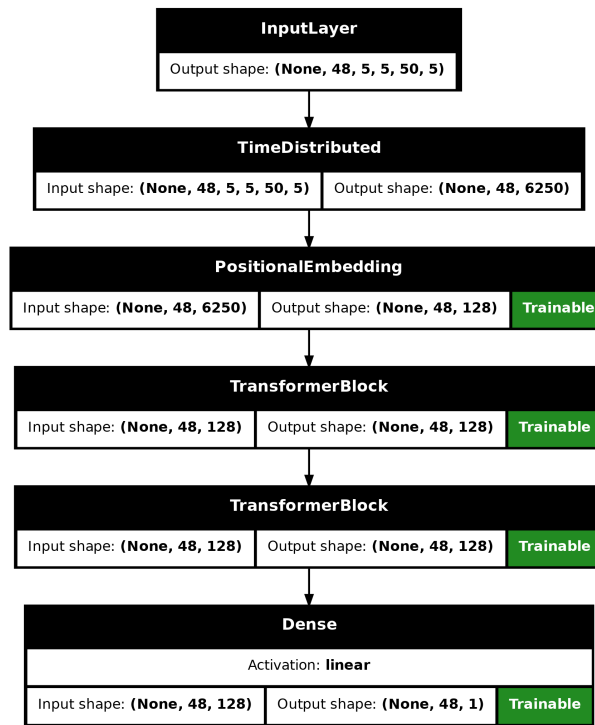


Figura 4.8: Arquitetura do modelo Transformer.

A implementação do SVM é a da biblioteca *scikitlearn* para classificar uma única classe. Essa implementação usa o *kernel* RBF, ambos descritos na seção 2.2.5. Os parâmetros do *kernel* foram buscados por meio de uma busca cruzada, esta busca está descrita na seção 5.2.

4.6 DESCRIÇÃO DOS EXPERIMENTOS

Para garantir a robustez dos resultados, cada modelo foi treinado e avaliado 10 vezes, utilizando diferentes divisões dos dados de treinamento e validação cruzada para cada uma das cidades. Em cada rodada, o conjunto de treinamento foi modificado de forma aleatória para simular diferentes cenários de generalização, sendo que a semente utilizada foi o próprio número do experimento, isso permite que um mesmo número de experimento trabalhe os mesmos arquivos independente da cidade. Essa abordagem permite uma análise mais robusta da performance dos modelos, mitigando o impacto de divisões específicas dos dados.

4.7 MÉTRICAS DE AVALIAÇÃO

O modelo foi avaliado segundo duas perspectivas diferentes. A primeira, do ponto de vista da regressão, procura determinar a capacidade dos modelos de AM corrigirem o modelo meteorológico de forma global.

Sendo x as características e y os rótulos, pode-se citar e formular as seguintes métricas de desempenho:

Mean Absolute Error (MAE)

O erro médio absoluto é uma das métricas mais utilizadas em problemas de regressão. A métrica dá uma visão global do erro, sem sobrevalorizar valores extremos, tal como outras métricas como o RMSE. Sua desvantagem se apresenta em situações de quantidade grande de valores baixos que podem mascarar erros relevantes.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (4.1)$$

Root Mean Squared Error (RMSE)

Assim como descrito no item anterior, o RMSE é também uma medida global do erro. Sua diferença em relação à métrica anterior consiste na penalização de erros maiores de previsão. É uma medida de performance adequada quando a análise de eventos extremos são relevantes. Este método possui uma limitação ao ser usado para comparar regiões climatologicamente diferentes ou com escalas temporais distintas.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (4.2)$$

Coefficiente de Determinação R2

O R2 é uma medida da capacidade das previsões explicarem as observações. Os valores de R2 serão 1 quando o modelo for perfeito. O seu cálculo leva em conta a soma dos quadrados das distâncias entre observações e previsões. Para transformar em fração os resultados são normalizados pela variância total, ou seja, a soma da diferença quadrática entre a observação e sua média. A fórmula de R2 é apresentada em 4.3. Vale notar que, diferentemente do que citam em algumas fontes, R2 não é em si uma potência quadrática e portanto pode assumir valores negativos quando a soma dos quadrados dos resíduos for maior que a variância total. Em termos práticos um valor negativo indica que o modelo foi pior do que apenas prever o valor médio.

$$R2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4.3)$$

Correlação de Pearson ρ

Esta métrica determina o grau de correlação entre duas variáveis, observação e previsão. É uma das métricas mais utilizadas para determinar se um modelo é capaz de representar o comportamento de um fenômeno.

$$\rho = \frac{\text{cov}(x, y)}{\sigma_x \sigma_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.4)$$

sendo σ o desvio padrão.

Índice de habilidade (IH)

O IH tem por objetivo comparar duas previsões, a referência utilizada foram as previsões originais da PNT. Nessa métrica, quanto mais próximo de 1, melhor é o modelo em relação à referência. Em nosso trabalho foi adotada a mediana dos membros do IFS como referência.

$$IH = 1 - \frac{MAE}{MAE_{ref}} \quad (4.5)$$

Matriz de Confusão

A matriz de confusão é uma ferramenta que permite avaliar, de forma visual e quantitativa, o desempenho do modelo na classificação de eventos em diferentes categorias. Neste estudo, foram definidas quatro classes de intensidade de rajadas de vento. A primeira corresponde ao vento ameno (0–11 m/s), faixa em que os impactos operacionais são geralmente desprezíveis. A segunda classe, denominada fraca, abrange o intervalo de 11–15.2 m/s. A terceira corresponde à categoria moderada (15.2–19 m/s). Por fim, a classe de rajada de vento forte inclui valores maiores ou iguais a 19 m/s.

A definição dessas faixas foi baseada na experiência operacional do Simepar no atendimento ao setor elétrico, considerando limiares relevantes para impactos na infraestrutura.

Além da classificação em múltiplas categorias, as matrizes de confusão também foram empregadas para avaliar a capacidade do modelo SVM em identificar eventos severos, tratados como um problema binário.

As matrizes quantificam os acertos e erros do modelo sob quatro perspectivas, fundamentais para entender o viés de predição:

- Verdadeiros Positivos (VP): O modelo previu corretamente uma rajada acima de um determinado limiar de interesse e o valor observado na estação confirmou a ocorrência do evento.
- Verdadeiros Negativos (VN): O modelo previu corretamente que a rajada seria amena (abaixo do limiar) e a observação foi condizente com a ausência de evento.
- Falsos Positivos (FP): Também chamados de alarmes falsos, ocorrem quando o modelo indica a presença de um evento que não foi verificado na observação real.

- Falsos Negativos (FN): Representam as omissões, casos em que o evento ocorreu na estação, mas o modelo falhou em identificá-lo.

No contexto multiclasse deste trabalho, os acertos referem-se à diagonal principal da matriz, enquanto na abordagem binária do modelo SVM, o evento positivo é definido pela ultrapassagem do limiar específico de 15,2 m/s.

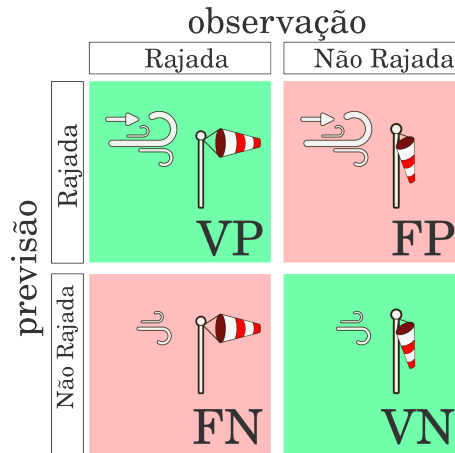


Figura 4.9: Infográfico representando uma matriz de confusão.

Precisão, Recall e F1-Score

Para avaliar o desempenho do modelo SVM, foram utilizadas métricas específicas voltadas à análise de eventos positivos, a saber, precisão, *recall* e F1-score.

A precisão quantifica a proporção de previsões positivas que de fato correspondem a eventos observados, representando o grau de confiabilidade do modelo ao indicar a ocorrência de um evento:

$$\text{precisão} = \frac{VP}{VP + FP} \quad (4.6)$$

O *recall*, também denominado taxa de detecção ou sensibilidade, mede a capacidade do modelo em identificar corretamente os eventos que realmente ocorreram, sendo definido como a razão entre os verdadeiros positivos e o total de eventos observados:

$$\text{recall} = \frac{VP}{VP + FN} \quad (4.7)$$

O F1-score corresponde à média harmônica entre precisão e *recall*, fornecendo uma medida equilibrada entre a capacidade de detectar eventos e a confiabilidade das previsões positivas:

$$F_1 = \frac{2 \cdot \text{precisão} \cdot \text{recall}}{\text{precisão} + \text{recall}} \quad (4.8)$$

Em problemas desbalanceados, como é comum em aplicações meteorológicas envolvendo eventos severos, o F1-score tende a ser mais informativo do que a acurácia, pois penaliza simultaneamente omissões e alarmes falsos.

Curva Característica de Operação do Receptor (Receiver Operating Characteristic) (ROC)

A curva ROC é uma ferramenta gráfica utilizada para avaliar o desempenho de modelos de classificação binária sob diferentes limiares de decisão. No eixo das ordenadas é representada a Taxa de Verdadeiros Positivos (TVP) (definida como *recall* na Equação 4.7), enquanto no eixo das abscissas é representada a Taxa de Falsos Positivos (TFP) (Equação 4.9), que corresponde à taxa de alarmes falsos. Dessa forma, a curva permite analisar o compromisso entre a capacidade de detectar eventos positivos (sensibilidade) e a probabilidade de classificar incorretamente um evento negativo como positivo (alarme falso).

$$TFP = \frac{FalsosPositivos(FP)}{FP + VerdadeirosNegativos(VN)} \quad (4.9)$$

Uma das estratégias para definir o ponto ótimo de operação na curva é o índice de Youden (J), apresentado na Equação 4.10. Esse índice busca maximizar a diferença entre a taxa de acertos em eventos positivos e a taxa de erros em eventos negativos:

$$J = TVP - TFP \quad (4.10)$$

Onde a relação entre a TFP e a especificidade do modelo é dada por:

$$\text{Especificidade} = \frac{VN}{VN + FP} = 1 - TFP \quad (4.11)$$

A partir da curva ROC obtém-se ainda a Área Sob a Curva ROC (AUC). Essa métrica quantifica a capacidade discriminatória do modelo, isto é, sua habilidade em distinguir corretamente eventos positivos de negativos. Em termos práticos, valores de AUC superiores a 0,5 indicam desempenho melhor do que o acaso, enquanto o valor máximo igual a 1 representa um classificador perfeito.

5 RESULTADOS

A apresentação dos resultados está dividida em duas partes. A primeira procura responder se os modelos são capazes de melhorar a PNT. A segunda seção avalia se é possível identificar eventos severos por meio da detecção de anomalias.

5.1 CORREÇÃO DA PREVISÃO NUMÉRICA

Antes de avaliar os modelos de AM, é necessário estabelecer uma linha de base com as previsões brutas do conjunto IFS. Para isso, foram calculadas quatro métricas descritivas do conjunto para servirem como referência: a mediana ("IFS median"), a média ("IFS mean"), o percentil 90 ("IFS pct90") e o valor máximo ("IFS pct100"). Essas referências representam, respectivamente, a tendência central, a média, um cenário de vento forte e o extremo superior das previsões do conjunto. A comparação com essas métricas permite quantificar o valor agregado pelas técnicas de pós-processamento.

As dispersões apresentadas nas Figuras 5.1 a 5.5 comparam as previsões originais geradas pela PNT e as corrigidas por AM. Para a confecção dos gráficos foram utilizados todos os resultados dos 10 experimentos de cada modelo, porém filtrados para que todos os modelos tivessem dados válidos, garantindo uma comparação justa entre eles. De modo geral a PNT (em vermelho) apresenta uma superestimativa nos ventos fracos e uma subestimativa na rajada de vento mais intensa. As correções por AM tiveram a tendência de corrigir melhor a rajada menos intensa, porém agravaram a subestimativa dos ventos mais fortes.

Para aprofundar o entendimento dos erros dos modelos foram feitas comparações diretas entre as observações e previsões. Na Figura 5.6 são apresentados exemplos de resultados da previsão para todas as cidades. Percebe-se que os modelos de AM conseguem melhorar a previsão quando a variação é lenta ou de forma persistente, mas falham, assim como as previsões originais, nos casos de variações abruptas como observado nas cidades de Curitiba e Londrina.

Para uma análise objetiva, foram calculadas as métricas de avaliação para cada um dos experimentos. Os resultados apresentados na Tabela 5.1 são uma média entre todos os 10 experimentos. Todos os modelos foram capazes de diminuir o erro médio, o absoluto e o quadrático. Os modelos de AM também conseguiram correlações melhores, exceto para o modelo linear. Isso também é verdade para o coeficiente de determinação. Cabe salientar que o modelo de PNT teve R^2 negativo para as cidades de Lapa e Telêmaco Borba. Um valor de R^2 negativo indica que o modelo numérico teve um desempenho pior do que um modelo ingênuo que simplesmente previsse o valor médio das rajadas de vento para todas as situações, ressaltando a grande dificuldade do IFS em capturar a variabilidade local nestas duas cidades. Por fim, os modelos de AM conseguiram melhores IH, exceto para Londrina, onde o modelo Linear teve resultados piores. Modelos mais complexos como Transformer, de forma geral, apresentaram resultados semelhantes ao CNN e LSTM.

Os resultados da Tabela 5.1 e os gráficos de dispersão (Figuras 5.1 a 5.5), dão indício de que os modelos AM tendem a corrigir o comportamento médio e não foram capazes, mesmo diminuindo a quantidade de amostras na classe amena, de capturar informações sobre eventos severos. As matrizes de confusão presentes nas Figuras 5.7 a 5.11 asseguram esse fato. Os modelos de AM tenderam a ajustar-se à classe dominante.

A principal métrica ao comparar os modelos é o RMSE, uma vez que tem uma penalidade maior que as demais métricas para os erros maiores. Entre os modelos propostos, o modelo

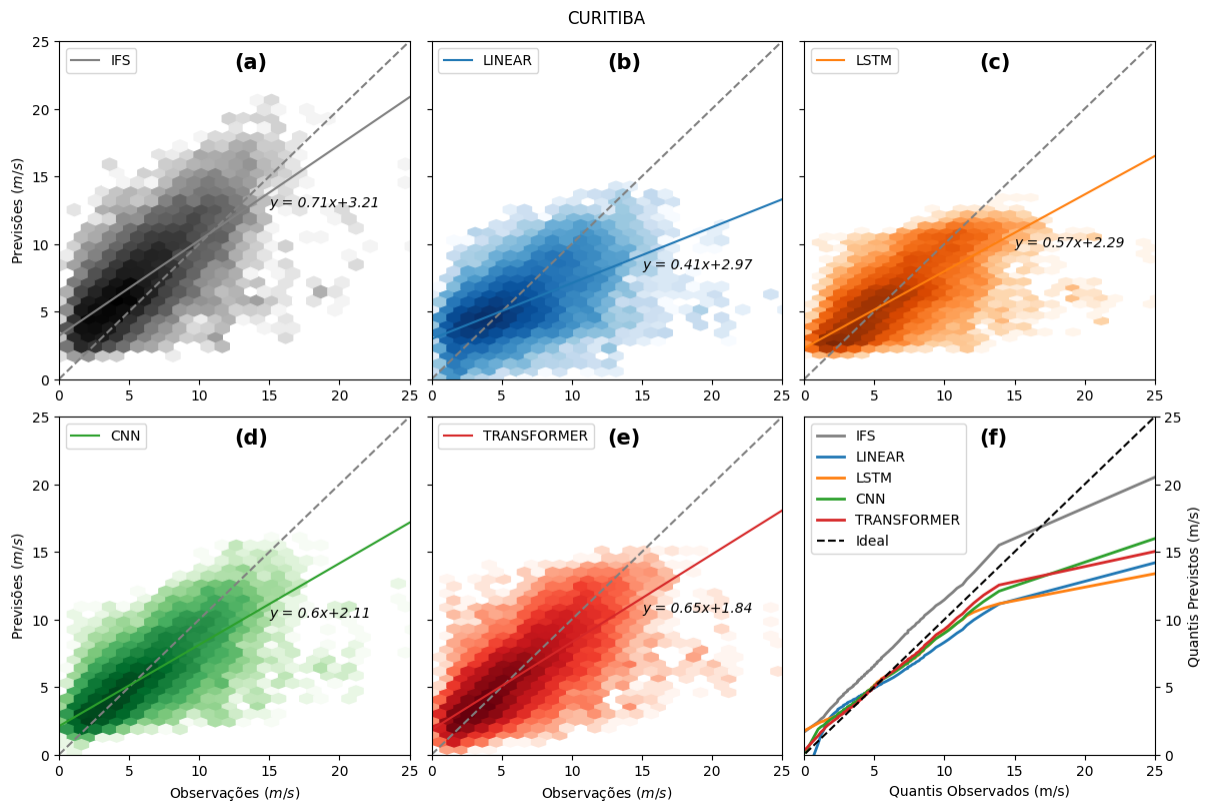


Figura 5.1: (a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Curitiba. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição

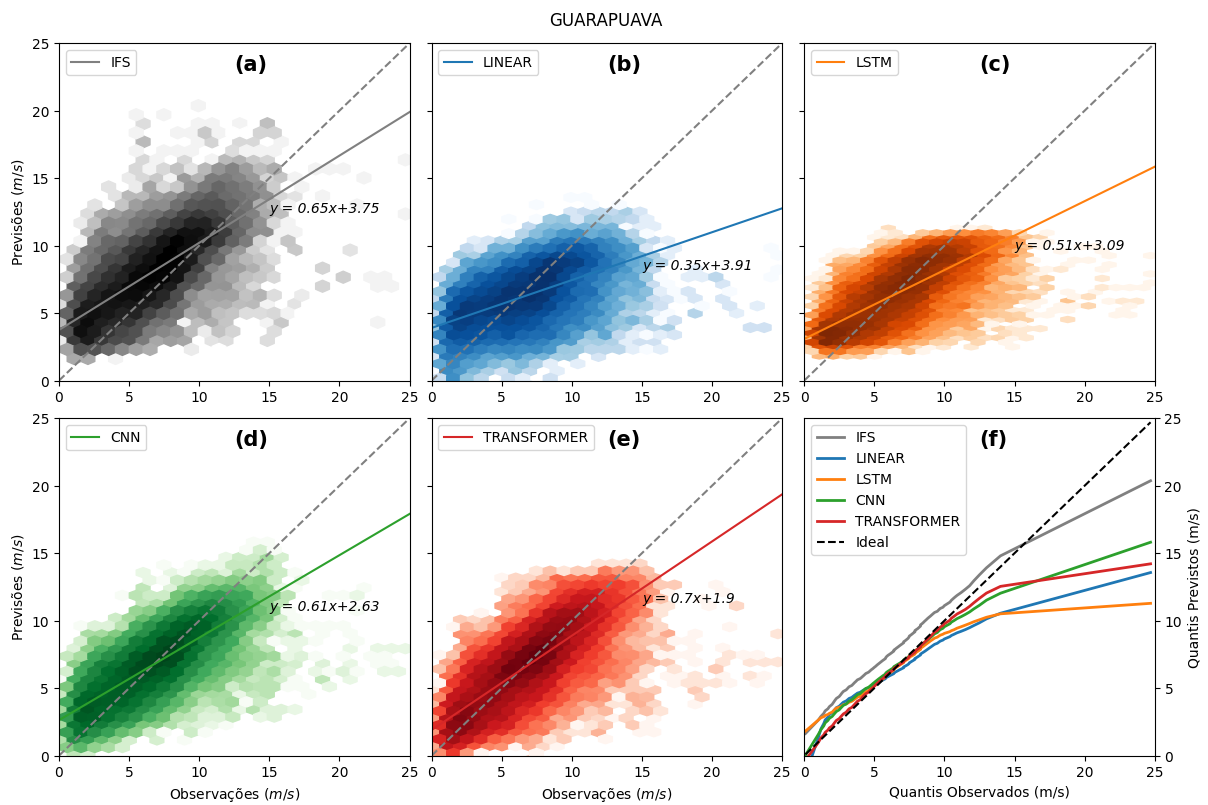


Figura 5.2: (a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Guarapuava. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição

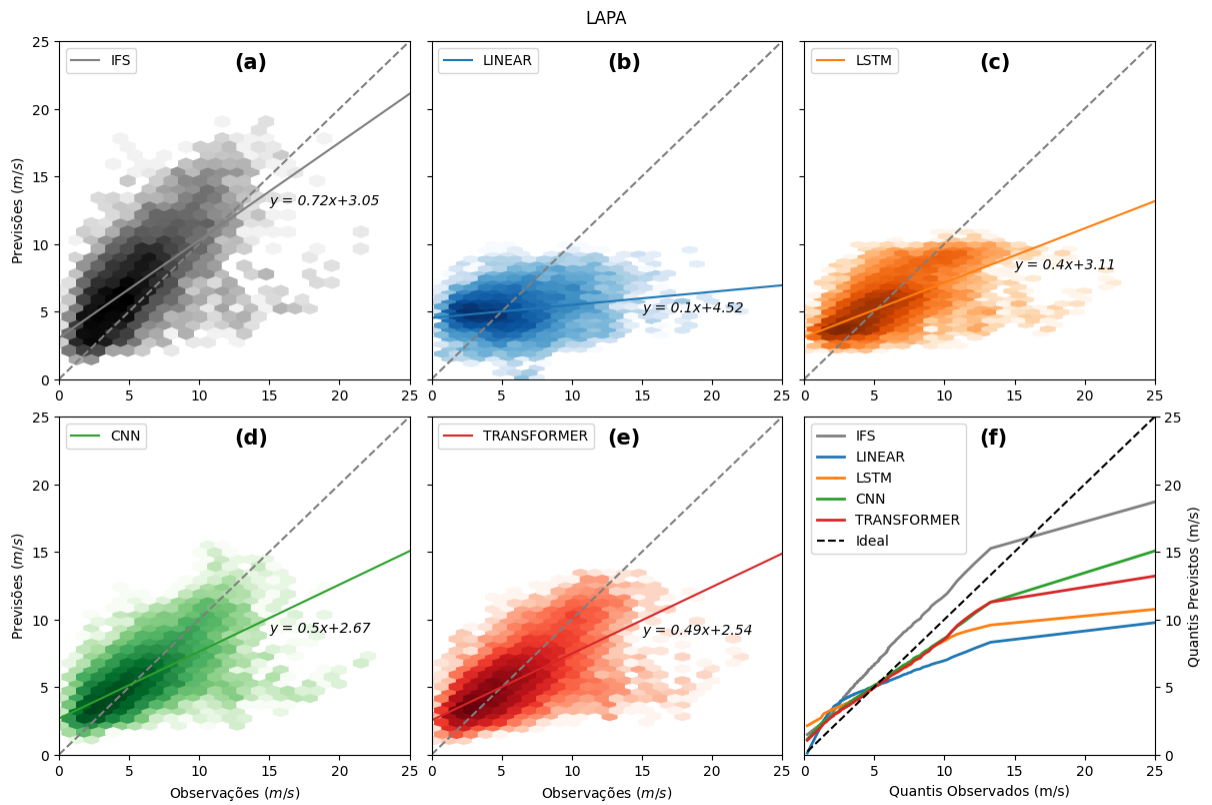


Figura 5.3: (a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Lapa. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição

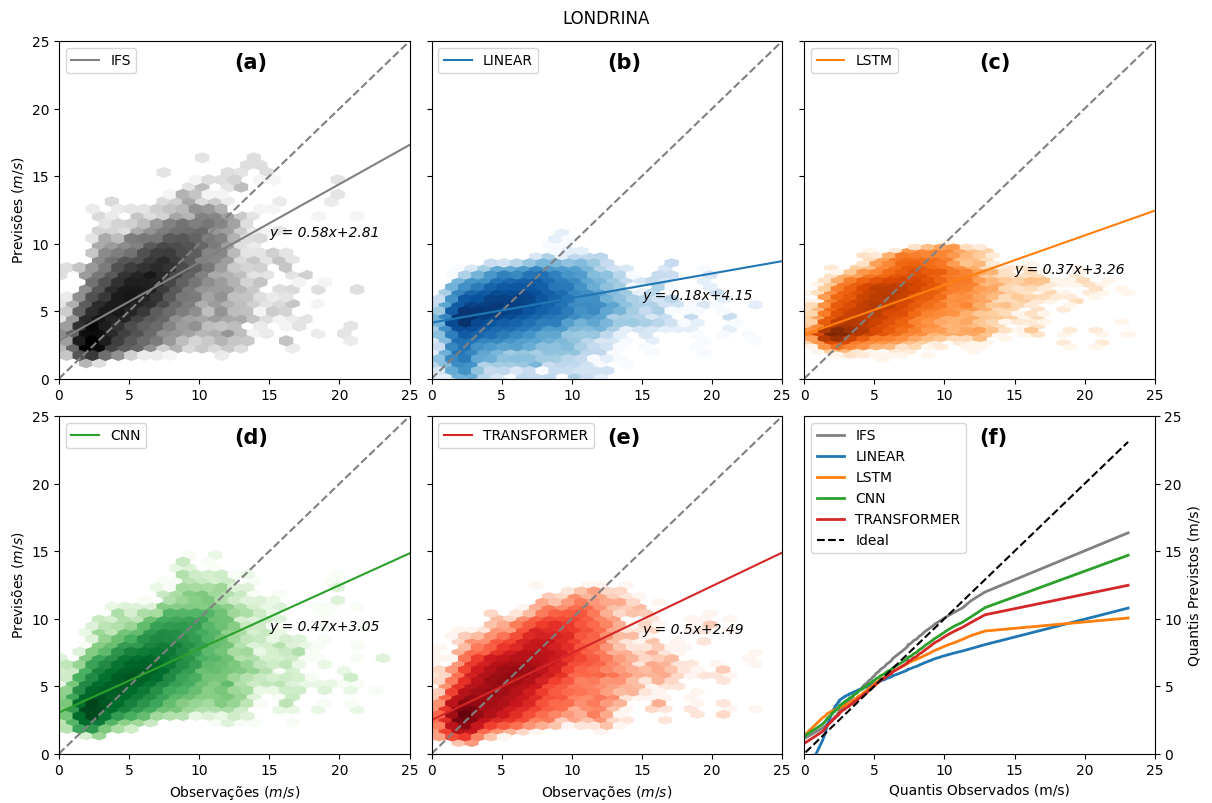


Figura 5.4: (a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Londrina. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição

Tabela 5.1: Resultados dos modelos por cidade

cidade	model	ME	MAE	RMSE	ρ	R2	IH
CURITIBA	IFS median	1.59 ± 0.28	2.19 ± 0.18	2.75 ± 0.21	0.71 ± 0.05	0.14 ± 0.06	0.00 ± 0.00
	IFS mean	1.63 ± 0.28	2.21 ± 0.19	2.77 ± 0.21	0.71 ± 0.05	0.13 ± 0.06	-0.01 ± 0.00
	IFS pct90	2.99 ± 0.27	3.23 ± 0.23	3.82 ± 0.27	0.70 ± 0.05	-0.66 ± 0.15	-0.47 ± 0.02
	IFS pct100	4.28 ± 0.31	4.41 ± 0.28	5.03 ± 0.33	0.68 ± 0.05	-1.88 ± 0.28	-1.01 ± 0.06
	Linear	-0.27 ± 0.47	1.82 ± 0.10	2.43 ± 0.16	0.61 ± 0.06	0.32 ± 0.10	0.17 ± 0.06
	LSTM	-0.09 ± 0.25	1.42 ± 0.08	1.96 ± 0.10	0.76 ± 0.04	0.56 ± 0.05	0.35 ± 0.05
	CNN	-0.09 ± 0.28	1.39 ± 0.06	1.91 ± 0.06	0.77 ± 0.04	0.58 ± 0.06	0.36 ± 0.04
	Transformer	-0.10 ± 0.22	1.42 ± 0.05	1.97 ± 0.05	0.76 ± 0.04	0.56 ± 0.05	0.35 ± 0.04
GUARAPUAVA	IFS median	1.44 ± 0.24	2.10 ± 0.11	2.68 ± 0.12	0.71 ± 0.02	0.25 ± 0.05	0.00 ± 0.00
	IFS mean	1.48 ± 0.24	2.11 ± 0.12	2.69 ± 0.13	0.71 ± 0.02	0.24 ± 0.05	-0.01 ± 0.00
	IFS pct90	2.77 ± 0.24	3.03 ± 0.19	3.65 ± 0.18	0.69 ± 0.02	-0.40 ± 0.11	-0.44 ± 0.02
	IFS pct100	4.01 ± 0.26	4.14 ± 0.23	4.79 ± 0.23	0.64 ± 0.03	-1.41 ± 0.18	-0.97 ± 0.05
	Linear	-0.32 ± 0.33	2.07 ± 0.08	2.68 ± 0.10	0.54 ± 0.03	0.25 ± 0.04	0.01 ± 0.05
	LSTM	-0.12 ± 0.24	1.59 ± 0.05	2.10 ± 0.08	0.74 ± 0.02	0.53 ± 0.03	0.24 ± 0.04
	CNN	0.08 ± 0.47	1.51 ± 0.07	2.01 ± 0.08	0.77 ± 0.02	0.58 ± 0.03	0.28 ± 0.05
	Transformer	-0.07 ± 0.25	1.47 ± 0.04	2.00 ± 0.06	0.78 ± 0.02	0.58 ± 0.03	0.29 ± 0.05
LAPA	IFS median	1.62 ± 0.36	2.18 ± 0.21	2.77 ± 0.21	0.67 ± 0.07	-0.04 ± 0.11	0.00 ± 0.00
	IFS mean	1.66 ± 0.35	2.20 ± 0.22	2.77 ± 0.22	0.68 ± 0.06	-0.04 ± 0.11	-0.01 ± 0.00
	IFS pct90	3.07 ± 0.32	3.30 ± 0.28	3.90 ± 0.27	0.66 ± 0.07	-1.07 ± 0.19	-0.52 ± 0.02
	IFS pct100	4.43 ± 0.32	4.55 ± 0.30	5.21 ± 0.29	0.63 ± 0.07	-2.69 ± 0.31	-1.09 ± 0.07
	Linear	-0.20 ± 0.42	2.15 ± 0.15	2.75 ± 0.16	0.22 ± 0.08	-0.02 ± 0.08	0.01 ± 0.07
	LSTM	-0.01 ± 0.27	1.48 ± 0.10	2.04 ± 0.06	0.67 ± 0.06	0.43 ± 0.07	0.32 ± 0.04
	CNN	0.04 ± 0.30	1.40 ± 0.07	1.98 ± 0.07	0.69 ± 0.06	0.46 ± 0.08	0.36 ± 0.04
	Transformer	-0.10 ± 0.40	1.42 ± 0.05	1.99 ± 0.07	0.69 ± 0.07	0.45 ± 0.10	0.34 ± 0.07
LONDRINA	IFS median	0.58 ± 0.26	1.71 ± 0.13	2.31 ± 0.12	0.63 ± 0.03	0.27 ± 0.09	0.00 ± 0.00
	IFS mean	0.66 ± 0.26	1.72 ± 0.13	2.30 ± 0.12	0.64 ± 0.03	0.28 ± 0.09	-0.00 ± 0.00
	IFS pct90	2.05 ± 0.29	2.52 ± 0.22	3.06 ± 0.22	0.65 ± 0.03	-0.28 ± 0.23	-0.47 ± 0.05
	IFS pct100	3.56 ± 0.29	3.78 ± 0.26	4.34 ± 0.27	0.62 ± 0.03	-1.57 ± 0.40	-1.21 ± 0.07
	Linear	-0.19 ± 0.66	1.97 ± 0.20	2.60 ± 0.29	0.40 ± 0.08	0.08 ± 0.18	-0.16 ± 0.17
	LSTM	-0.09 ± 0.43	1.56 ± 0.10	2.17 ± 0.12	0.63 ± 0.02	0.37 ± 0.04	0.08 ± 0.09
	CNN	0.25 ± 0.49	1.54 ± 0.14	2.10 ± 0.09	0.67 ± 0.02	0.40 ± 0.07	0.10 ± 0.05
	Transformer	-0.18 ± 0.27	1.45 ± 0.08	2.07 ± 0.09	0.67 ± 0.02	0.42 ± 0.03	0.15 ± 0.08
TELÊMACO BORBA	IFS median	1.86 ± 0.30	2.50 ± 0.17	3.07 ± 0.15	0.57 ± 0.07	-0.26 ± 0.19	0.00 ± 0.00
	IFS mean	1.91 ± 0.30	2.53 ± 0.17	3.09 ± 0.15	0.57 ± 0.07	-0.27 ± 0.19	-0.01 ± 0.00
	IFS pct90	3.25 ± 0.30	3.57 ± 0.22	4.10 ± 0.22	0.59 ± 0.07	-1.25 ± 0.34	-0.43 ± 0.02
	IFS pct100	4.61 ± 0.31	4.79 ± 0.27	5.34 ± 0.30	0.57 ± 0.06	-2.81 ± 0.55	-0.92 ± 0.06
	Linear	-0.25 ± 0.42	1.89 ± 0.14	2.57 ± 0.11	0.41 ± 0.05	0.12 ± 0.06	0.24 ± 0.09
	LSTM	-0.12 ± 0.26	1.57 ± 0.06	2.20 ± 0.12	0.61 ± 0.07	0.35 ± 0.08	0.37 ± 0.04
	CNN	-0.04 ± 0.22	1.46 ± 0.08	2.10 ± 0.12	0.65 ± 0.06	0.41 ± 0.08	0.41 ± 0.05
	Transformer	-0.05 ± 0.42	1.53 ± 0.09	2.17 ± 0.16	0.63 ± 0.07	0.37 ± 0.10	0.38 ± 0.06

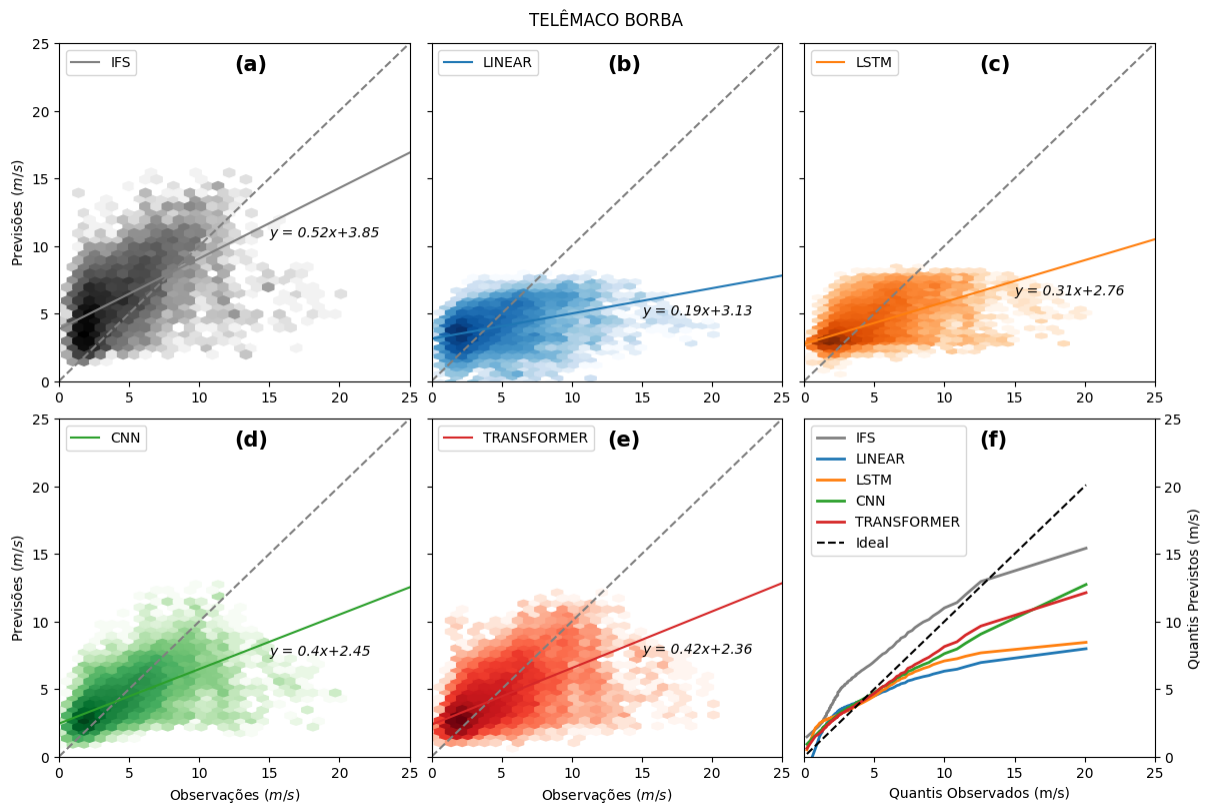


Figura 5.5: (a-e) Gráficos de densidade comparando rajada de vento observada e prevista em Telêmaco Borba. (f) Gráfico quantil-quantil (Q-Q) para análise da cauda de distribuição

Linear apresentou valores de RMSE consistentemente superiores aos demais. Nessa mesma métrica, a LSTM foi a segunda pior em quatro das cinco cidades, não sendo a melhor nenhuma vez. O modelo CNN apresentou resultados melhores de RMSE, R^2 e ρ para as cidades de Curitiba, Lapa e Telêmaco Borba. Em Guarapuava e Londrina, foi o Transformer quem obteve melhores resultados. A coerência entre os melhores modelos no RMSE e os maiores valores de IH em todas as cidades reforça a consistência dos vencedores. Contudo, nota-se que mesmo os melhores modelos tendem a subestimar eventos extremos, sugerindo que a limitação principal não reside na arquitetura da rede, mas na ausência de variáveis explicativas nos dados de entrada, como o perfil vertical de temperatura e vento, os quais poderiam ser capazes de antecipar tais fenômenos.

A combinação de modelos é uma estratégia comum, no entanto, como foi constatado, nenhum dos modelos foi efetivo na detecção de eventos severos e por essa razão a combinação dos modelos também não teria essa característica.

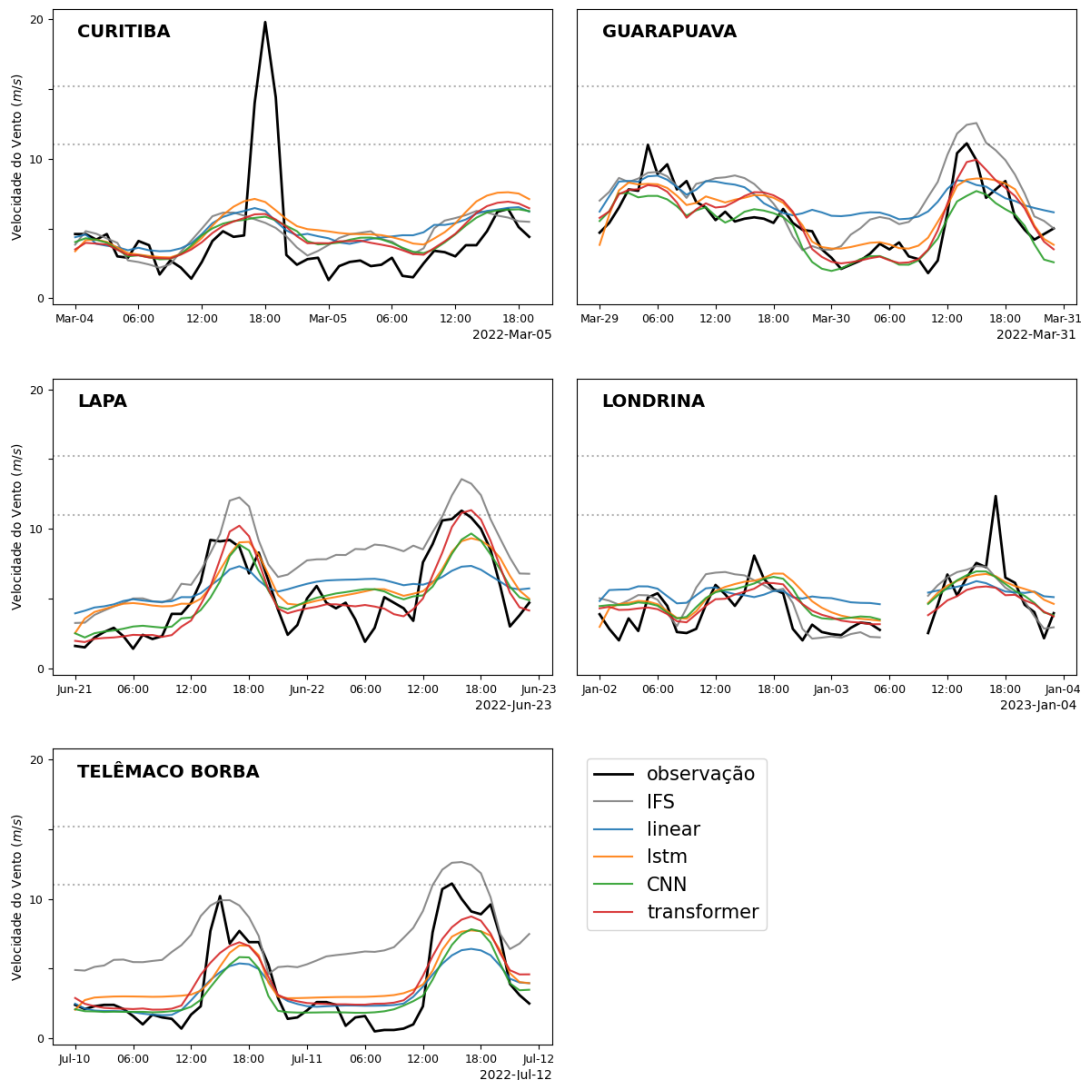


Figura 5.6: Comparação direta das previsões e observações para alguns casos da validação.

	LINEAR				LSTM				CNN				TRANSFORMER			
ameno	5188 (99%)	77 (1%)	0 (0%)	0 (0%)	5279 (100%)	21 (0%)	0 (0%)	0 (0%)	5253 (99%)	47 (1%)	0 (0%)	0 (0%)	5005 (94%)	295 (6%)	0 (0%)	0 (0%)
fraco	290 (85%)	53 (15%)	0 (0%)	0 (0%)	288 (84%)	55 (16%)	0 (0%)	0 (0%)	266 (78%)	77 (22%)	0 (0%)	0 (0%)	182 (53%)	161 (47%)	0 (0%)	0 (0%)
moderado	7 (70%)	3 (30%)	0 (0%)	0 (0%)	8 (80%)	2 (20%)	0 (0%)	0 (0%)	8 (80%)	2 (20%)	0 (0%)	0 (0%)	7 (70%)	3 (30%)	0 (0%)	0 (0%)
forte	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)
	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte

Figura 5.7: Matrizes de Confusão de cada um dos modelos para Curitiba.

	LINEAR				LSTM				CNN				TRANSFORMER			
ameno	5468 (99%)	42 (1%)	0 (0%)	0 (0%)	5542 (100%)	0 (0%)	0 (0%)	0 (0%)	5442 (98%)	87 (2%)	0 (0%)	0 (0%)	5430 (98%)	88 (2%)	0 (0%)	0 (0%)
fraco	396 (92%)	36 (8%)	0 (0%)	0 (0%)	432 (100%)	0 (0%)	0 (0%)	0 (0%)	327 (76%)	105 (24%)	0 (0%)	0 (0%)	316 (73%)	116 (27%)	0 (0%)	0 (0%)
moderado	12 (100%)	0 (0%)	0 (0%)	0 (0%)	12 (100%)	0 (0%)	0 (0%)	0 (0%)	12 (100%)	0 (0%)	0 (0%)	0 (0%)	12 (100%)	0 (0%)	0 (0%)	0 (0%)
forte	2 (100%)	0 (0%)	0 (0%)	0 (0%)	2 (100%)	0 (0%)	0 (0%)	0 (0%)	2 (100%)	0 (0%)	0 (0%)	0 (0%)	2 (100%)	0 (0%)	0 (0%)	0 (0%)
	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte

Figura 5.8: Matrizes de Confusão de cada um dos modelos para Guarapuava.

	LINEAR				LSTM				CNN				TRANSFORMER			
ameno	2645 (100%)	0 (0%)	0 (0%)	0 (0%)	2645 (100%)	0 (0%)	0 (0%)	0 (0%)	2630 (99%)	15 (1%)	0 (0%)	0 (0%)	2639 (100%)	6 (0%)	0 (0%)	0 (0%)
fraco	96 (100%)	0 (0%)	0 (0%)	0 (0%)	96 (100%)	0 (0%)	0 (0%)	0 (0%)	85 (89%)	11 (11%)	0 (0%)	0 (0%)	81 (84%)	15 (16%)	0 (0%)	0 (0%)
moderado	12 (100%)	0 (0%)	0 (0%)	0 (0%)	12 (100%)	0 (0%)	0 (0%)	0 (0%)	10 (83%)	2 (17%)	0 (0%)	0 (0%)	10 (83%)	2 (17%)	0 (0%)	0 (0%)
forte	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)
	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte

Figura 5.9: Matrizes de Confusão de cada um dos modelos para Lapa.

	LINEAR				LSTM				CNN				TRANSFORMER			
ameno	4526 (100%)	0 (0%)	0 (0%)	0 (0%)	4528 (100%)	0 (0%)	0 (0%)	0 (0%)	4526 (100%)	2 (0%)	0 (0%)	0 (0%)	4525 (100%)	3 (0%)	0 (0%)	0 (0%)
fraco	141 (100%)	0 (0%)	0 (0%)	0 (0%)	141 (100%)	0 (0%)	0 (0%)	0 (0%)	141 (100%)	0 (0%)	0 (0%)	0 (0%)	134 (95%)	7 (5%)	0 (0%)	0 (0%)
moderado	26 (100%)	0 (0%)	0 (0%)	0 (0%)	26 (100%)	0 (0%)	0 (0%)	0 (0%)	26 (100%)	0 (0%)	0 (0%)	0 (0%)	26 (100%)	0 (0%)	0 (0%)	0 (0%)
forte	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)	4 (100%)	0 (0%)	0 (0%)	0 (0%)
	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte

Figura 5.10: Matrizes de Confusão de cada um dos modelos para Londrina.

	LINEAR				LSTM				CNN				TRANSFORMER			
ameno	2386 (100%)	0 (0%)	0 (0%)	0 (0%)	2386 (100%)	0 (0%)	0 (0%)	0 (0%)	2386 (100%)	0 (0%)	0 (0%)	0 (0%)	2386 (100%)	0 (0%)	0 (0%)	0 (0%)
fraco	60 (100%)	0 (0%)	0 (0%)	0 (0%)	60 (100%)	0 (0%)	0 (0%)	0 (0%)	60 (100%)	0 (0%)	0 (0%)	0 (0%)	60 (100%)	0 (0%)	0 (0%)	0 (0%)
moderado	14 (100%)	0 (0%)	0 (0%)	0 (0%)	14 (100%)	0 (0%)	0 (0%)	0 (0%)	14 (100%)	0 (0%)	0 (0%)	0 (0%)	14 (100%)	0 (0%)	0 (0%)	0 (0%)
forte	2 (100%)	0 (0%)	0 (0%)	0 (0%)	2 (100%)	0 (0%)	0 (0%)	0 (0%)	2 (100%)	0 (0%)	0 (0%)	0 (0%)	2 (100%)	0 (0%)	0 (0%)	0 (0%)
	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte	ameno	fraco	moderado	forte

Figura 5.11: Matrizes de Confusão de cada um dos modelos para Telêmaco Borba.

5.2 DETECÇÃO DE ANOMALIAS

Na seção anterior foi visto que os modelos de AM, quando modelados para regressão, tendem a corrigir o comportamento médio e foram incapazes de prever as classes moderada e forte. Diante dessa incapacidade dos modelos de regressão em corrigir a subestimativa dos eventos extremos, a estratégia de detecção de anomalias foi empregada como uma alternativa de capturar esses erros sistemáticos do modelo numérico. A hipótese testada aqui é se, ao simplificar o problema para uma classificação binária, seria possível identificar o sinal de vento forte na previsão original. A forma escolhida para essa classificação foi a procura de anomalias na PNT, uma vez que os eventos mais intensos podem ser considerados raros no conjunto de dados utilizado. Com essa finalidade, foi proposto o modelo SVM. Para a análise desse modelo foi considerado como raro todo evento acima de 15 m/s. Os treinamentos contam com apenas elementos da classe normal e a previsão é uma classe binária indicando se o evento será severo ou não.

Os resultados do SVM são altamente dependentes dos parâmetros do *kernel* RBF. Para encontrar os melhores parâmetros ν e γ um *grid search* foi montado, os valores de ν testados foram [0.05, 0.1, 0.2], e os valores de γ foram [0.01, 0.05, 0.1, 0.5, 1.0]. O critério para a escolha do melhor par foi a maximização da AUC.

A Tabela 5.2 apresenta os parâmetros encontrados, a AUC e o F1-Score para cada uma das cidades.

Cidade	ν	γ	AUC
Curitiba	1.0	0.05	0.69
Lapa	0.5	0.05	0.68
Guarapuava	0.1	0.2	0.78
Londrina	1.0	0.2	0.83
Telêmaco Borba	0.5	0.05	0.75

Tabela 5.2: Melhor parâmetro de *kernel* e área sob a curva ROC por cidade.

Em seguida foi estimado o melhor ponto de operação ao encontrar a distância ao hiperplano de separação. A determinação do melhor ponto de operação foi feita utilizando-se do índice de Youden. Nas Figuras 5.12 à 5.16 são mostradas as curvas ROC para cada uma das cidades. Nessas figuras, o ponto em vermelho indica o melhor ponto de operação e à direita da curva ROC é possível ver a matriz de confusão para esse ponto. O SVM obteve valores baixos de F1-Score para a classificação de eventos fortes, com uma alta taxa de falsos positivos.

Os resultados combinados dos parâmetros ν e γ indicam que a fronteira encontrada é larga e complexa. Os baixos valores de F1-Score e a alta taxa de falsos positivos indicam que, mesmo simplificando o problema para detecção, a AM não foi capaz de corrigir a falha do modelo numérico em antecipar eventos severos. Isso reforça a conclusão de que o erro na previsão de extremos não é apenas uma questão de método, mas de ausência de informação preditiva, como a estrutura vertical, nas variáveis de entrada.





Figura 5.12: Curva ROC e Matriz de Confusão do melhor ponto de operação para Curitiba

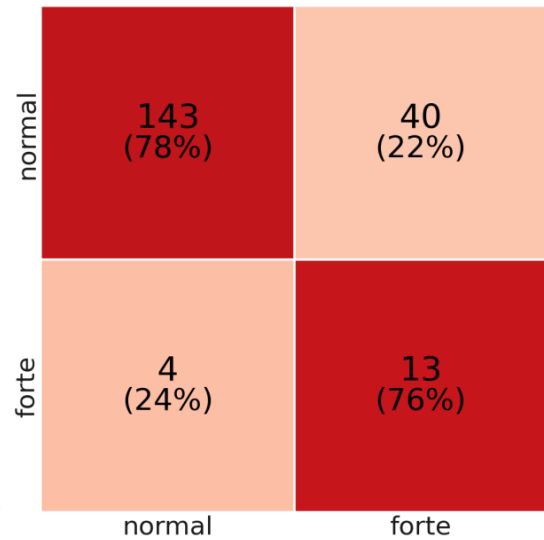
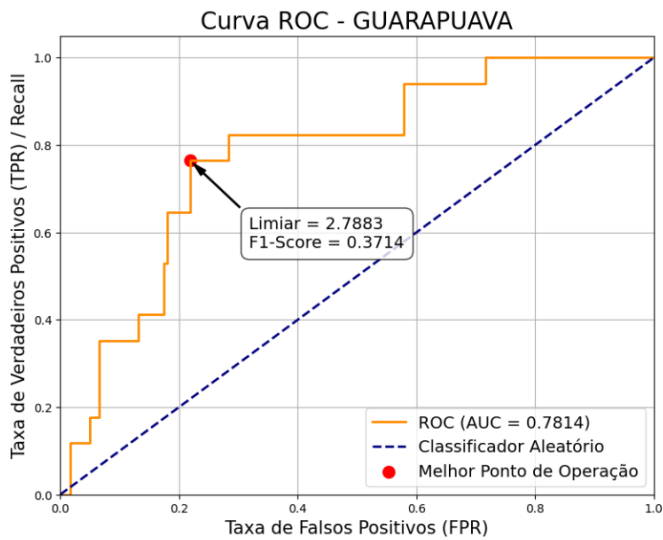


Figura 5.13: Curva ROC e Matriz de Confusão do melhor ponto de operação para Guarapuava





Figura 5.14: Curva ROC e Matriz de Confusão do melhor ponto de operação para Lapa

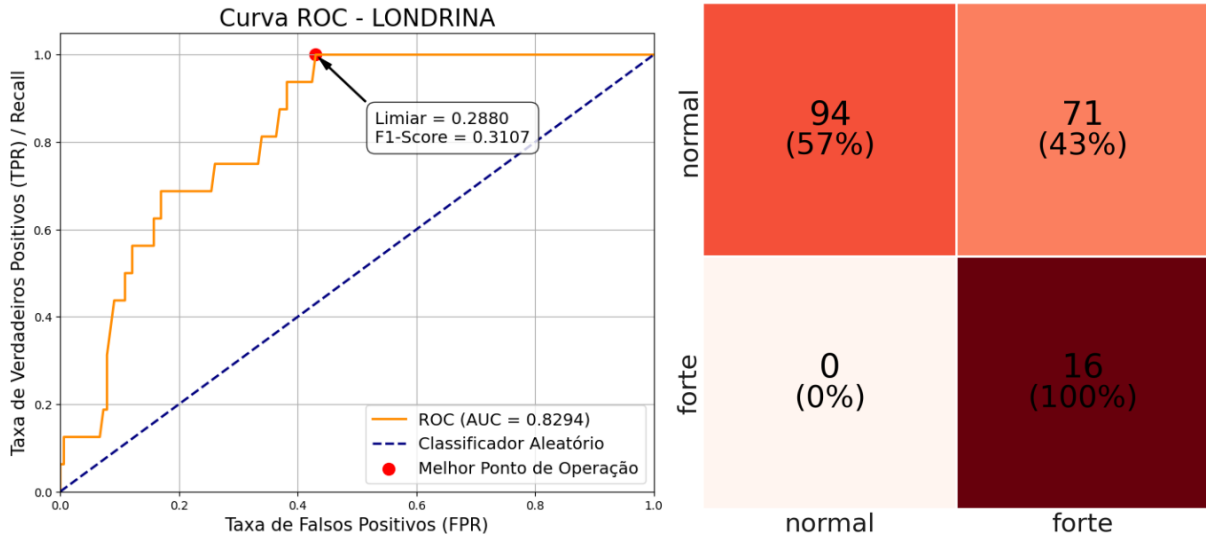


Figura 5.15: Curva ROC e Matriz de Confusão do melhor ponto de operação para Londrina

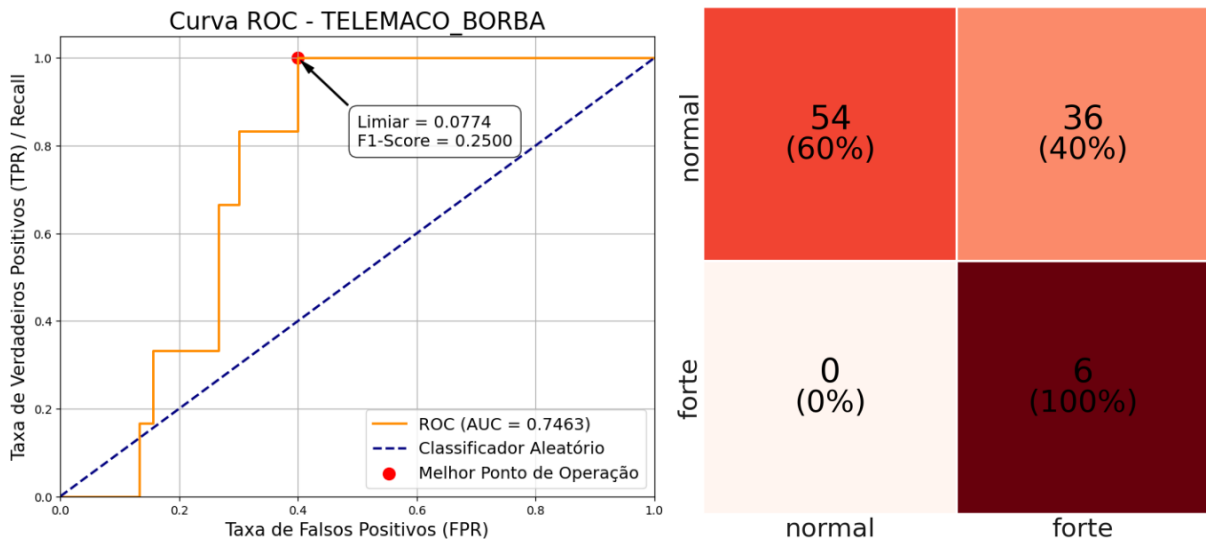


Figura 5.16: Curva ROC e Matriz de Confusão do melhor ponto de operação para Telêmaco Borba

5.3 CONSIDERAÇÕES

A análise dos resultados obtidos, tanto na etapa de correção via regressão quanto na tentativa de detecção de anomalias, indicou uma dificuldade persistente dos modelos propostos em capturar os eventos mais severos de rajada de vento. Diante desse cenário, cabe justificar a premissa adotada nesta pesquisa de que as variáveis de superfície conteriam informações latentes suficientes para a previsão desses extremos.

Tal hipótese baseou-se na física do fenômeno, uma vez que a rajada de vento observada a 10 metros é frequentemente resultante do transporte de momento linear de camadas superiores para a superfície. Esse transporte é impulsionado por mecanismos de mistura turbulenta ou correntes descendentes convectivas. A própria parametrização do modelo IFS, apresentada na equação 1.1, define a rajada como função do vento médio e de componentes que consideram o cisalhamento em níveis superiores.

Sendo assim, era cientificamente plausível supor que as arquiteturas de AM propostas, notadamente as CNNs e Transformers que exploram relações espaciais e temporais complexas, seriam capazes de realizar o mapeamento inverso. O objetivo era inferir a instabilidade vertical e a dinâmica da atmosfera livre a partir das assinaturas remanescentes nas variáveis de superfície. A realização completa dos experimentos permitiu testar os limites dessa inferência. Os resultados demonstraram que, apesar do acoplamento físico existente entre os níveis verticais, o sinal contido apenas nos dados de superfície do modelo global não se mostrou suficiente para reconstruir a severidade dos eventos extremos com a precisão necessária, tornando falsa a premissa desse estudo.

Por fim, quanto à seleção dos modelos, observou-se que o RMSE se mostrou a métrica mais adequada para a comparação, dada a sua sensibilidade a erros maiores, característicos dos eventos severos. Embora a literatura sugira que a combinação de diferentes arquiteturas possa reduzir a variância do erro, optou-se por não combiná-los, uma vez que individualmente não captaram os eventos severos. Nesse contexto, modelos como CNN e Transformer apresentaram desempenhos superiores em cidades específicas, mas compartilharam da mesma limitação física imposta pelos dados de entrada.

6 CONCLUSÃO

Este trabalho investigou a capacidade de técnicas de AM em duas frentes. A primeira procurou corrigir as previsões *a priori* de rajada de vento da previsão por conjuntos do modelo IFS. A segunda teve como objetivo detectar anomalias associadas a eventos severos. O estudo foi conduzido em um ambiente operacional, partindo da premissa inicial de que as variáveis de superfície do modelo numérico conteriam informações suficientes para essa tarefa.

Como subproduto metodológico, uma base de dados de quatro anos foi curada e normalizada, preservando as relações espaço-temporais do ensemble, a qual será disponibilizada para fomentar pesquisas futuras.

Os resultados apontaram que os modelos de AM propostos, com exceção da abordagem linear, foram eficazes em extrair padrões da PNT, resultando em uma melhora consistente nas métricas globais de erro (RMSE e MAE) em relação à PNT original. Contudo, esses resultados devem ser interpretados com parcimônia. A análise detalhada por classes de impacto revelou que a correção imposta pelos modelos tendeu a suavizar a variabilidade, ajustando-se ao comportamento médio e errando sistematicamente nos eventos de maior severidade. Essa “suavização” se manifestou na subestimação de rajadas de vento intensas, que foram frequentemente previstas em classes de velocidade inferiores às observadas, conforme evidenciado nos gráficos de dispersão (Figuras 5.1 a 5.5) e, de forma mais explícita, nas matrizes de confusão (Figuras 5.7 a 5.11), onde os modelos de AM demonstram uma forte tendência a ajustar-se à classe dominante de ventos amenos ou fracos.

Respondendo diretamente às perguntas de pesquisa da introdução, conclui-se que: (I) os métodos de AM são capazes de corrigir o viés médio das previsões de rajada de vento do IFS utilizando apenas variáveis de superfície, mas falham em prever os eventos de maior impacto; e (II) este mesmo conjunto de dados de superfície é insuficiente para a detecção de anomalias de vento forte. A investigação demonstrou que as características utilizadas não possuem a informação latente necessária para discriminar a gênese de rajadas intensas. Desta forma, a principal conclusão deste estudo é que a assertividade na previsão de extremos depende fundamentalmente da incorporação de variáveis que descrevam a estrutura vertical da atmosfera, uma limitação física que não pôde ser superada apenas pela complexidade das arquiteturas de AM testadas.

Referências Bibliográficas

- Ahrens, C. (2013). *Meteorology Today: An Introduction to Weather, Climate, and the Environment*. International edition. Brooks/Cole.
- ANEEL (2023). Usinas eólicas dominam expansão da oferta de energia elétrica em julho. <https://www.gov.br/aneel/pt-br/assuntos/noticias/2023/usinas-eolicas-dominam-expansao-da-oferta-de-energia-eletrica-em-julho>. Acesso em: 2023-11-01.
- Bechtold, P. and Bidlot, J.-R. (2009). Parametrization of convective gusts. *ECMWF Newsletter*, 119(Spring 2009):15–18.
- Browning, K. A. (1980). Review lecture: Local weather forecasting. *Proceedings of the Royal Society of London. Series A, Mathematical and Physical Sciences*, 371(1745):179–211.
- Campos, R. M., Palmeira, R. M. J., Pereira, H. P. P., and Azevedo, L. C. (2022). Mid-to-long range wind forecast in brazil using numerical modeling and neural networks. *Wind*, 2(22):221–245.
- Chase, R. J., Harrison, D. R., Lackmann, G. M., and McGovern, A. (2023). A machine learning tutorial for operational meteorology. Part II: Neural networks and deep learning. *Weather and Forecasting*, 38(8):1271–1293.
- Coburn, J. and Pryor, S. C. (2022). Do machine learning approaches offer skill improvement for short-term forecasting of wind gust occurrence and magnitude? *Weather and Forecasting*, 37(5):525–543.
- ECMWF (2023). *IFS Documentation CY48R1 - Part I: Observations*. Number 1. ECMWF.
- Glahn, H. R. and Lowry, D. A. (1972). The use of model output statistics (MOS) in objective weather forecasting. *Journal of Applied Meteorology*, 11(8):1203–1211.
- Haupt, S. E., Chapman, W., Adams, S. V., Kirkwood, C., Hosking, J. S., Robinson, N. H., Lerch, S., and Subramanian, A. C. (2021). Towards implementing artificial intelligence post-processing in weather and climate: proposed actions from the Oxford 2019 workshop. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379(20200091):20200091.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Holton, J. R. and Hakim, G. J. (2013). *An Introduction to Dynamic Meteorology*. Elsevier.
- Kotermanski, S. E. and Cascio, M. (2023). Neuronal action potentials and ion channel allostery. In Bradshaw, R. A., Hart, G. W., and Stahl, P. D., editors, *Encyclopedia of Cell Biology (Second Edition)*, pages 316–325. Academic Press, Oxford, second edition edition.
- LeCun, Y., Bengio, Y., Bottou, L., Haffner, P., Simard, P., and Wechsler, D. (1989). Handwritten digit recognition with a back-propagation network. In *Advances in Neural Information Processing Systems*, volume 2, pages 396–404.

- McCulloch, W. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5(4):115–133.
- NIH (2023). Brain basics: The life and death of a neuron. <https://www.ninds.nih.gov/health-information/public-education/brain-basics/brain-basics-life-and-death-neuron>. Acesso em: 2023-11-10.
- Pu, Z. and Kalnay, E. (2018). *Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation*. Springer, Berlin, Heidelberg.
- Rasmussen, J. (2019). Using activation functions in neural networks.
- Santhosh, M., Venkaiah, C., and Vinod Kumar, D. M. (2020). Current advances and approaches in wind speed and wind power forecasting for improved renewable energy integration: A review. *Engineering Reports*, 2(6):e12178.
- Schulz, B. and Lerch, S. (2022). Machine learning methods for postprocessing ensemble forecasts of wind gusts: A systematic comparison. *Monthly Weather Review*, 150(1):235–257.
- Surendran, G., Sherwood, S., Evans, J., Rafei, M. E., Dowdy, A., Ji, F., and Brown, A. (2025). Distinguishing environmental controls on strong vs. extreme wind gusts. *Weather and Climate Extremes*, 49:100788.
- Vapnik, V. N. (2000). *The Nature of Statistical Learning Theory*. Springer New York.
- Varejão–Silva, M. A. (2006). *Meteorologia e Climatologia*. INMET.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems*, pages 5998–6008.
- Wallace, J. M. and Hobbs, P. V. (2006). *Atmospheric Science: An Introductory Survey*. Elsevier.
- Wu, Z., Luo, G., Yang, Z., Guo, Y., Li, K., and Xue, Y. (2022). A comprehensive review on deep learning approaches in wind forecasting applications. *CAAI Transactions on Intelligence Technology*, 7(2):129–143.
- Xu, W., Ning, L., and Luo, Y. (2020). Wind speed forecast based on post-processing of numerical weather predictions using a gradient boosting decision tree algorithm. *Atmosphere*, 11(77):738.
- Yousuf, M. U., Al-Bahadly, I., and Avci, E. (2019). Current perspective on the accuracy of deterministic wind speed and power forecasting. *IEEE Access*, 7:159547–159564.