



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO  
CENTRO DE CIÊNCIAS MATEMÁTICAS E DA NATUREZA  
INSTITUTO DE GEOCIÊNCIAS  
DEPARTAMENTO DE METEOROLOGIA

**ANÁLISE E PREVISÃO DE CURTO PRAZO DE *WIND SHEAR* NO AEROPORTO  
SANTOS DUMONT – RIO DE JANEIRO**

**Victor Veiga Souza Leão**

Orientadores: Prof. Gutemberg Borges França

Vinícius Albuquerque de Almeida

Monografia submetida ao corpo docente do Departamento de Meteorologia da Universidade Federal do Rio de Janeiro como parte dos requisitos necessários à obtenção de grau de Bacharel em Meteorologia.

Rio de Janeiro

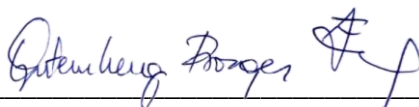
2021

**ANÁLISE E PREVISÃO DE CURTO PRAZO DE WIND SHEAR NO AEROPORTO  
SANTOS DUMONT – RIO DE JANEIRO**

Victor Veiga Souza Leão

Monografia submetida ao corpo docente do Departamento de Meteorologia da Universidade Federal do Rio de Janeiro como parte dos requisitos necessários à obtenção de grau de Bacharel em Meteorologia.

Avaliada por:



---

Prof. Gutemberg Borges França, *PhD.* (Orientador)



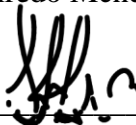
---

Vinícius Albuquerque de Almeida, D Sc. (Coorientador)



---

Prof. Wallace Figueiredo Menezes, D Sc.



---

Francisco Leite de Albuquerque Neto, D Sc.

Rio de Janeiro, RJ

2021

## **AGRADECIMENTOS**

Agradeço à minha família pelo apoio e por sempre buscarem me proporcionar o melhor possível durante a minha jornada, especialmente para a minha mãe Renata, meu padrasto Leonardo e minha companheira e melhor amiga Joyce.

Agradeço a equipe do LMA por ter tido confiança em mim e ter me escolhido para fazer parte do laboratório, ajudando a me desenvolver profissionalmente, e aos professores do departamento pelos ensinamentos ao longo desses anos.

Agradeço aos amigos que fiz graças a meteorologia pelos ótimos momentos, pelas risadas, pela ajuda nas disciplinas e em diversas situações: Marcolino, Beatriz, Jamyle, Renan, Lucas Cesar e Thomas.

Aos grandes amigos que levo do Colégio Pedro II para o resto da vida: Lucas, Braga, Breno, Higor, Eduardo e Walnir.

Por fim, agradeço também a Organização Brasileira para o Desenvolvimento Científico e Tecnológico do Controle do Espaço Aéreo (CTCEA) e ao Departamento de Controle do Espaço Aéreo (DECEA) por me proporcionar a oportunidade de trabalhar com a aviação, minha paixão, na forma de bolsista da Cátedra de Meteorologia Aeronáutica.

## RESUMO

A *Wind Shear* é caracterizada por uma variação na velocidade e/ou direção do vento no espaço. Eventos intensos desse fenômeno podem ser críticos para a atividade aérea, especialmente nas operações de pouso e decolagem, pelo fato de as aeronaves estarem a baixa altura e com baixa velocidade. A *Wind Shear* pode ser classificada, conforme sua intensidade, em leve (variação de 0 a 4 kt a cada 100 ft), moderada (variação de 5 a 8 kt a cada 100 ft), forte (variação de 9 a 12 kt a cada 100 ft) e severa (variação maior do que 12 kt/100 ft). Tendo em vista a importância para a segurança de voo, este estudo teve como objetivo analisar as características e propor um método para a previsão de curto prazo de *Wind Shear*, utilizando aprendizado de máquina, no Aeroporto Santos Dumont, Rio de Janeiro/RJ. Foram utilizados dados do período entre 01/10/2016 e 31/12/2020 oriundos do perfilador vertical de vento *Sonic Detection And Ranging* instalado na área de estudo. Os resultados indicaram que a maioria dos dados foi classificada como leve (99,93%). Ao analisar os eventos de intensidade forte (53 observações), houve maior ocorrência no mês de novembro, em horários noturnos e em alturas abaixo de 100 metros. Além disso, houve associação com ventos de quadrante sul e a passagem de sistemas frontais. Neste estudo, foram desenvolvidos 4 modelos regressivos para realizar previsões de 15, 30, 45 e 60 minutos. Para um mesmo tempo de previsão, os resultados foram semelhantes de forma geral. Entretanto, ao analisar o desempenho nos casos que foram classificados como fortes, houve um aumento nos erros. Por fim, foi possível melhorar o desempenho das previsões ao remover o viés dos modelos.

Palavras-chave: Wind Shear. SODAR. Aeroporto Santos Dumont. Aprendizado de Máquina.

## **ABSTRACT**

Wind Shear is characterized by a variation of speed and/or direction of the wind in space. Intense events of this phenomenon can be critical for air activity, especially during landing and takeoff, because the aircraft is at low height and with low speed. Wind Shear can be classified, according to its intensity, into light (0 to 4 kt per 100 ft), moderate (5 to 8 kt per 100 ft), strong (9 to 12 kt per 100 ft), and severe (greater than 12 kt/100 ft). Due to the importance of this subject for flight safety, this study aimed to analyze the characteristics and propose a method for the short-term forecast of Wind Shear, using machine learning, at Santos Dumont Airport, Rio de Janeiro/RJ. Data from the period between 10/01/2016 and 12/31/2020 from the vertical wind profiler Sonic Detection And Ranging installed in the study area were used. The results indicated that most of the data was classified as light (99.93%). When analyzing the events of strong intensity (53 observations), there was a higher occurrence in November, at night and heights below 100 meters. In addition, there was an association with south quadrant winds and the passage of frontal systems. In this study, 4 regressive models were developed to make predictions of 15, 30, 45, and 60 minutes. For the same forecast time, the results were similar in general. However, when analyzing the performance in cases that were classified as strong, there was an increase in errors. It was possible to improve the performance of the forecasts by removing the bias from the models.

**Keywords:** Wind Shear. SODAR. Santos Dumont Airport. Machine Learning.

## LISTA DE FIGURAS

Figura 2.1 - Tipos de WS: por direção e velocidade. As setas amarelas representam o vetor vento.....	12
Figura 2.2 – Estrutura diurna da CLA .....	15
Figura 2.3 – Influência da estabilidade atmosférica no perfil vertical da intensidade do vento .....	17
Figura 2.4 – Esquema da circulação na Camada Limite Convectiva e na Camada Limite Estável.....	18
Figura 2.5 – Influência do tipo de superfície no perfil vertical da intensidade do vento .....	18
Figura 2.6 – Formação de uma camada limite interna.....	19
Figura 2.7 – Modelo conceitual de uma frente fria evoluindo na América do Sul .....	21
Figura 2.8 – Avanço da Brisa Marítima .....	22
Figura 2.9 – Efeitos do relevo na circulação .....	23
Figura 2.10 – Perfil da subida de uma aeronave ao passar por uma região com jato noturno.....	24
Figura 2.11 – Possíveis efeitos do encontro de um microburst após a decolagem .....	25
Figura 2.12 – Quatro forças que agem sobre uma aeronave.....	25
Figura 2.13 – Linha temporal das medidas preventivas contra WS.....	27
Figura 2.14 – Exemplo de distribuição de anemômetros do LLWAS em um aeroporto .....	28
Figura 2.15 – Tipos de avisos no painel de uma aeronave para atenção (a) e reação (b) à condição de WS.....	29
Figura 2.16 – Sistema integrado de alerta de WS em HKIA .....	30
Figura 2.17 – Exemplo de problemas de classificação e regressão .....	32
Figura 3.1 – Carta de aeródromo (a) e imagem de satélite (b) do SBRJ com a localização do SODAR.....	33
Figura 3.2 – Topografia da cidade do Rio de Janeiro e localização do SBRJ .....	34
Figura 4.1 – Princípio de funcionamento do SODAR .....	36
Figura 4.2 – Exemplo de visualização da intensidade de WS no software APRun .....	38
Figura 4.3 – Queda na disponibilidade de dados de WS com o aumento da altura e intensidade .....	39
Figura 4.4 – Queda na disponibilidade de dados TKE e EDR com o aumento da intensidade da WS .....	39
Figura 4.5 – Processo de transformação das variáveis utilizadas no estudo.....	40
Figura 4.6 – Metodologia do processo de construção dos modelos deste estudo .....	44
Figura 5.1 – Ocorrência de WS por ano e intensidade .....	46
Figura 5.2 - Ocorrência de WS por mês e intensidade .....	47
Figura 5.3 - Ocorrência de WS por hora e intensidade.....	48
Figura 5.4 – Média horária de pousos e decolagens em SBRJ no ano de 2019.....	48
Figura 5.5 – Exemplo de imagem de satélite das condições tempestade (a), cavado (b), frontal (c), pós frontal (d) e não identificado (e).....	51
Figura 5.6 – Rosa dos ventos para as alturas de 30 (a) e 50 (b) metros nos casos de WS forte.....	53
Figura 5.7 – Variação temporal da intensidade da WS no dia 18/11/16.....	53
Figura 5.8 – Imagem do satélite GOES13 no canal infravermelho às 22z do dia 18/11/2016 .....	54
Figura 5.9 – METAR durante o evento .....	55
Figura 5.10 – Perfil Vertical da velocidade (a) e direção (b) do vento às 20h do dia 18/11/2016.....	55
Figura 5.11 –MAE das previsões de 15 (a), 30 (b), 45 (c) e 60 (d) minutos, para a totalidade dos dados e durante condições de WS forte.....	57
Figura 5.12 - Comparação do RMSE dos modelos nas previsões de 15 (a) e 30 (b), 45(c) e 60(d) minutos, para a totalidade dos dados e durante condições de WS forte.....	58
Figura 5.13 – Distribuição de frequência da WSmax no conjunto de dados de teste .....	59
Figura 5.14 – Dispersão entre os valores observados e previstos de WSmax para as previsões de 15 (a), 30 (b), 45 (c) e 60 minutos (d) .....	60
Figura 5.15 – Distribuição dos resíduos das previsões de 15 (a), 30 (b), 45(c) e 60 minutos (d).....	61

## LISTA DE TABELAS

Tabela 2.1 – Critérios para a classificação da intensidade de WS.....	13
Tabela 2.2 – Eventos de WS subdivididos por condição meteorológica.....	20
Tabela 4.1 – Resumo dos tipos de dados utilizados no estudo .....	35
Tabela 4.2 – Informações sobre os conjuntos de treino e teste utilizados pelos modelos .....	42
Tabela 5.1 – Sumário da classificação da intensidade da WS em SBRJ durante o período estudado.....	45
Tabela 5.2 – Ocorrência de WS abaixo de 100m por classe de intensidade .....	49
Tabela 5.3 – Ocorrência de WS forte e severa por faixa de altura detectada abaixo de 100m.....	49
Tabela 5.4 – Resumo das condições meteorológicas associadas aos eventos de WS forte .....	52
Tabela 5.5 – Resultado das previsões dos modelos finais construídos para cada tempo de previsão .....	56
Tabela 5.6 – Variáveis selecionadas por cada modelo para cada tempo de previsão.....	60
Tabela 5.7 – Informações dos resíduos para cada tempo de previsão.....	62
Tabela 5.8 – Comparação entre o observado e previsto nos casos de WS forte no conjunto de dados teste .....	62
Tabela 5.9 – Comparação entre o valor observado e previsto nos casos de WS forte, no conjunto de dados teste, caso fosse feita uma correção do viés.....	63

## LISTA DE ABREVIATURAS E SIGLAS

ASAS	Alta Subtropical do Atlântico Sul
CE	Camada Estável
CI	Camada de Inversão
CLA	Camada Limite Atmosférica
CM	Camada de Mistura
CR	Camada Residual
CS	Camada de Superfície
EDR	Eddy Dissipation Rate
FF	Frente Fria
HKIA	Hong Kong International Airport
LIDAR	Light Detection and Ranging
LLWAS	Low Level Windshear Alert System
MAE	Mean Absolute Error
METAR	Meteorological Aerodrome Report
OACI	Organização da Aviação Civil Internacional
PWS	Predictive Windshear System
RMSE	Root Mean Squared Error
RWS	Reactive Windshear System
SODAR	SONic Detection And Ranging
TDWR	Terminal Doppler Weather Radar
TKE	Turbulent Kinect Energy
WRF	Weather Research and Forecast
WS	Wind Shear



## SUMÁRIO

1. INTRODUÇÃO .....	10
2. REVISÃO BIBLIOGRÁFICA.....	12
2.1. <i>Wind shear</i> .....	12
2.2. Perfil do vento na baixa atmosfera.....	15
2.2.1. Camada Limite Atmosférica (CLA) .....	15
2.2.2. Efeitos da estabilidade atmosférica .....	16
2.2.3. Efeitos da rugosidade da superfície .....	18
2.3. Condições meteorológicas associadas à ocorrência de WS .....	19
2.3.1. Sistema Frontal .....	20
2.3.2. Brisa marítima .....	22
2.3.3. Obstáculos e relevo.....	23
2.3.4. Jato noturno .....	24
2.3.5. <i>Microburst</i> .....	24
2.4. Efeitos da WS no desempenho das aeronaves .....	25
2.5. Sistemas de Detecção de WS .....	26
2.5.1. <i>Low-level wind shear alert system (LLWAS)</i> .....	27
2.5.2. Sistemas de Bordo .....	28
2.5.3. Terminal Doppler Weather Radar (TDWR) .....	29
2.5.4. Sistemas Integrados .....	29
2.6. Previsão de WS .....	30
2.6.1. Modelagem Numérica .....	30
2.6.2. Aprendizado de Máquina.....	31
3. ÁREA DE ESTUDO .....	33
4. DADOS E MÉTODO.....	35
4.1. DADOS.....	35
4.1.1. SODAR.....	36
4.2. METODOLOGIA .....	38
4.2.1. Análise dos dados .....	38
4.2.2. Transformação de variáveis.....	39
4.2.3. Modelos de Regressão .....	40
4.2.4. Seleção de Variáveis.....	42
4.2.5. Avaliação do desempenho dos modelos .....	42
5. RESULTADOS .....	45

5.1.	Ocorrência e Severidade de WS .....	45
5.2.	Variabilidade anual das ocorrências de WS.....	46
5.3.	Variabilidade mensal das ocorrências de WS.....	46
5.4.	Variabilidade horária das ocorrências de WS.....	47
5.5.	Ocorrência de WS por faixa de altura.....	48
5.6.	Condições meteorológicas nos casos de WS forte.....	50
5.6.1.	Evento de WS forte: 18/11/2016 .....	53
5.7.	Modelos de regressão.....	56
5.7.1.	Dispersão entre observado e previsto .....	59
5.7.2.	Análise dos Resíduos.....	61
6.	CONCLUSÕES.....	64
7.	REFERÊNCIAS BIBLIOGRÁFICAS.....	66

## 1. INTRODUÇÃO

Dos acidentes aeronáuticos que tiveram fenômenos meteorológicos como fator contribuinte, o vento é apontado como maior responsável (Gultepe, 2019), principalmente em aviões de menor porte, devido à sua atuação direta na sustentação das aeronaves. Em especial, condições com cisalhamento do vento, conhecidas pelo termo em inglês *Wind Shear* (WS), são as mais perigosas, sobretudo durante as operações de pouso e decolagem, fases do voo em que as aeronaves estão a baixa altura e com baixa velocidade tendo, assim, pouca margem para correção de variações bruscas causadas por eventos inesperados. Além dos riscos para a segurança, tal situação pode ocasionar arremetidas e conseqüente congestionamento do tráfego aéreo.

Em termos de antecedentes, o risco da WS para a aviação foi identificado apenas após um acidente que ocorreu em junho de 1975 próximo do Aeroporto John F. Kennedy, em Nova Iorque. Após esse acidente, verificou-se de maneira mais concreta tanto sua presença quanto sua importância como causa principal ou contribuição em inúmeros acidentes aeronáuticos. A partir disso, foram feitas investigações de alguns acidentes antigos, inicialmente atribuídos a erros dos pilotos, e o que se encontrou foi que, na realidade, a WS estava por trás dos episódios. As investigações tiveram como conclusão que, no período de 1964 a 1983, houve pelo menos 28 acidentes aeronáuticos em âmbito mundial que foram relacionados à WS, resultando na morte de mais de 500 pessoas e 200 feridos (ICAO, 2005).

Após essa descoberta, devido ao maior destaque deste assunto na comunidade aeronáutica, ao perigo que o fenômeno representa, à falta de equipamentos operacionais adequados, à complexidade do assunto, aos diferentes fenômenos meteorológicos que poderiam originá-lo e à dificuldade em sua previsão, a Organização de Aviação Civil Internacional (OACI) o considerou então como um dos maiores problemas que a aviação enfrentava naquela época. Por isso, ao longo dos anos foram estudadas diversas formas de monitoramento e previsão, e houve a criação de treinamentos específicos para que as tripulações se tornassem mais capacitadas a evitar e reagir a presença de WS durante um voo.

Tais iniciativas contribuíram para que, nas últimas décadas, tenha ocorrido uma redução no número de acidentes aeronáuticos que tiveram como fator contribuinte este fenômeno. Porém, devido ao alto risco que ele representa para a aviação, ainda há a necessidade de explorá-lo mais profundamente, especialmente em locais onde não há nenhum estudo prévio. Sendo assim, é necessário que se faça uma análise mais detalhada sobre sua frequência e intensidade

em diversos aeroportos no mundo. Para isso, é recomendado que se invista em equipamentos capazes de observar a WS e que se faça estudos voltados para o desenvolvimento de métodos capazes de prever o fenômeno (ICAO, 2005).

Com o intuito de contribuir para a segurança de voo, o presente trabalho tem como objetivo analisar os eventos de WS no Aeroporto Santos Dumont, Rio de Janeiro - RJ, por meio da análise de dados de perfil vertical de vento para os períodos entre 01/10/2016 e 30/09/2019 e entre 01/01/2020 e 31/12/2020. Com isso, é possível identificar as características associadas aos casos que podem ser significativos para a atividade aérea, classificando-os conforme os critérios de intensidade estabelecidos pela OACI, sendo assim capaz de analisar os meses do ano e horários do dia com maior ocorrência do fenômeno e identificar os sistemas meteorológicos presentes nos casos com intensidade forte. Em seguida, o trabalho propõe um método de previsão de curto prazo do fenômeno, com intervalos de 15, 30, 45 e 60 minutos, utilizando aprendizado de máquina, buscando encontrar o modelo que apresente menor erro para as previsões de WS com intensidade forte.

Este estudo é parte de uma sequência de trabalhos desenvolvidos pelo Laboratório de Meteorologia Aplicada (LMA) da Universidade Federal do Rio de Janeiro (UFRJ) que abordam temas de Meteorologia Aeronáutica, como os trabalhos de Almeida (2009), França *et al.* (2016), França *et al.* (2018) e Almeida *et al.* (2020).

Este trabalho tem seu desenvolvimento organizado em 6 capítulos. No capítulo segundo, será apresentada uma revisão bibliográfica que abordará os principais aspectos teóricos e informações relevantes para o entendimento do trabalho. Em seguida, será apresentada a área de estudo. A descrição dos dados utilizados e os métodos para a caracterização e previsão dos eventos de WS serão discutidos no capítulo 4. No capítulo 5, serão apresentados e discutidos os resultados obtidos. Por fim, as conclusões e recomendações futuras serão apresentadas no capítulo 6.


## 2. REVISÃO BIBLIOGRÁFICA

Neste capítulo, apresenta-se uma revisão sobre os estudos que abordam a característica dos eventos de WS, uma revisão teórica sobre a estrutura da baixa atmosfera, os efeitos do fenômeno nas aeronaves e o que tem sido feito para sua detecção e previsão.

### 2.1. WIND SHEAR

A WS é definida como uma variação na direção e/ou velocidade do vento no espaço. Sua ocorrência foi relacionada a fatores meteorológicos de diferentes escalas espaço-temporais, pois qualquer fenômeno atmosférico ou obstáculo físico que gere uma mudança na velocidade ou direção do vento pode ser considerado como causador de WS (ICAO, 2005). Além disso, como ilustra a Figura 2.1, a WS pode ser caracterizada por uma variação vertical, predominantemente, da intensidade do vento, direção, ou, também, de ambos (Silva, 2016).

Figura 2.1 - Tipos de WS: por direção e velocidade. As setas amarelas representam o vetor vento



Fonte: Silva (2016).

A relevância do fenômeno para a aviação está no efeito que ele causa no desempenho das aeronaves, oferecendo assim risco para a segurança de voo. Apesar da WS poder ser encontrada em diversos níveis da atmosfera, sua ocorrência próxima ao solo é a que apresenta maior risco para a aviação, devido às aeronaves estarem em procedimentos de pouso ou decolagem e, com isso, estarem em alturas e velocidades próximas de valores críticos, tornando-as mais suscetíveis aos riscos que o fenômeno oferece. Por isso, para fins aeronáuticos, a OACI define a ocorrência da WS de baixos níveis como aquela que ocorre entre a superfície a até

aproximadamente 500 metros de altura (ICAO, 2005), e a classifica conforme a sua intensidade, como apresentado pela Tabela 2.1. Neste estudo, foram consideradas as unidades de distância vertical em pés (ft) e velocidade em nós (kt) porque são as normalmente utilizadas em Meteorologia Aeronáutica.

Tabela 2.1 – Critérios para a classificação da intensidade de WS

<b>Intensidade</b>	<b>Variação (kt/100ft)</b>	<b>Variação (m.s<sup>-1</sup>/30m)</b>
Leve	0 a 4	0 a 2,06
Moderada	5 a 8	2,6 a 4,1
Forte	9 a 12	4,6 a 6,2
Severa	≥ 12	≥ 6,6

Fonte: Adaptado de ICAO (2005)

No entanto, ressalta-se que a resposta de uma aeronave ao enfrentar uma condição de WS dependerá de diversos fatores como o seu tipo, a fase do voo e a escala de atuação do fenômeno em relação ao tamanho da mesma. Por isso, uma mesma classe de intensidade definida acima pode afetar cada tipo de aeronave de forma diferente, ou seja, o que pode ser considerado severa para uma pode ser considerada moderada para outra. Além disso, o efeito causado pode ser agravado pelo tempo de exposição à ocorrência do fenômeno. Um exemplo disso é o estudo feito por Woodfield e Woods (1983), no qual foram analisados dados de 9000 voos de 21 aviões do tipo Boeing 747 da companhia inglesa British Airways, entre 1981 e 1982, ao redor de 71 aeroportos no mundo. Foi constatado que alguns voos enfrentaram condições de WS classificadas como severa e, no entanto, os pilotos não reportaram problemas ao pousar.

Devido à importância do fenômeno para a aviação, diversos estudos foram feitos em aeroportos ao redor do mundo nas últimas décadas. Para o Aeroporto Internacional de Hong Kong (HKIA), o trabalho de Shun e Chan (2008) analisou eventos de WS reportados por pilotos e concluiu que 70% foram causados pela interação do escoamento com o terreno complexo da ilha no entorno do aeroporto. Também em HKIA, Chen *et al.* (2020) observaram que o risco de ocorrência de WS era maior quanto maior a velocidade média horária do vento, a maioria dos

casos ocorreu nos meses de março, abril, julho e agosto, e em alturas abaixo de 200 metros. Li *et al.* (2020) analisaram 18 eventos de WS reportados por pilotos no Aeroporto Internacional de Lanzhou - China, e identificaram maior ocorrência nos meses de maio a junho, período de primavera e verão no local, entre 14 e 16h (horário local), em condições sem precipitação e influenciadas por mudanças na direção e intensidade do vento próximo do nível de 700 hPa.

No Brasil, o trabalho de Ribeiro *et al.* (2019) investigou casos de WS a partir de dados obtidos por um SOnic Detection And Range (SODAR) entre 01 de janeiro de 2016 e 09 de junho de 2017 no Aeroporto Internacional de São Paulo, em Guarulhos - SP (SBGR). O estudo identificou que a maioria dos casos mais intensos foi registrada em janeiro e, de forma geral, predominantemente durante o período da madrugada. Além disso, a maioria dos casos severos ocorreu nos primeiros 30 metros de altura. Ainda no cenário nacional, Silva *et. al* (2020) analisaram um evento de WS ocorrido em 04/07/2014 no Aeroporto Internacional de Belém - PA e associaram a ocorrência do fenômeno com a presença de uma tempestade intensa, oriunda de aglomerados de nuvens Cumulonimbus no local.

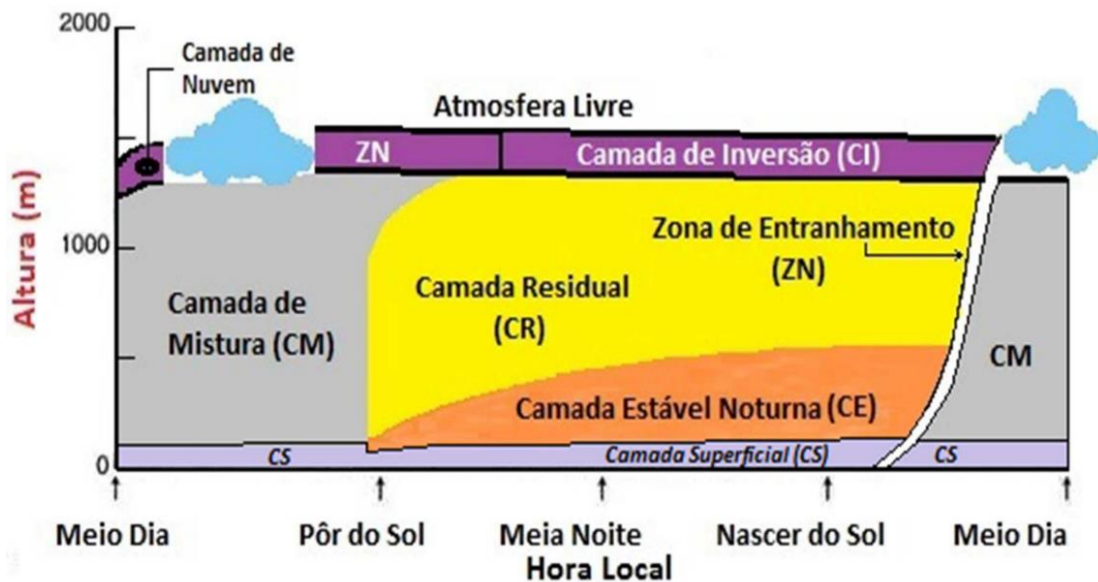
Mesmo sem a influência de fatores específicos que possam causar a WS, o fenômeno está sempre presente na atmosfera devido à natural variação que existe do vento com a altura (ICAO, 2005). Por isso, as seções a seguir introduzirão ao leitor como funciona o perfil do vento na baixa atmosfera, os fatores que o influenciam, as condições meteorológicas associadas à ocorrência de WS, os riscos oferecidos ao desempenho das aeronaves e os esforços feitos nas últimas décadas para desenvolver técnicas de detecção e previsão do fenômeno.

## 2.2. PERFIL DO VENTO NA BAIXA ATMOSFERA

### 2.2.1. Camada Limite Atmosférica (CLA)

Formada a partir da interação entre a superfície terrestre e a porção inferior da atmosfera, encontra-se CLA, camada que possui uma espessura variável entre aproximadamente 100 metros e 3 km por ser dependente das condições atmosféricas, da taxa de aquecimento e resfriamento da superfície, da topografia e do tipo de cobertura do solo, por exemplo (STULL, 1988). A Figura 2.2 ilustra a estrutura e o ciclo diurno da CLA para uma condição idealizada de céu limpo.

Figura 2.2 – Estrutura diurna da CLA



Fonte: Silva (2016)

A parte diurna da CLA sofre influência do aquecimento da superfície terrestre que gera movimentos convectivos e forma a Camada de Mistura (CM), onde a intensidade do vento tende a ser uniforme com a altura. Ao anoitecer, forma-se a Camada Estável (CE) devido ao resfriamento da superfície e à diminuição dos movimentos turbulentos originados durante o dia. Esse processo também origina a Camada Residual (CR), que preserva características da CM formada durante o dia anterior como a concentração de poluentes. No perfil diurno, a região que separa a CLA da Atmosfera livre é chamada de Zona de Entranhamento e, no perfil noturno, esta separação ocorre na Camada de Inversão (CI) (STULL, 1988).



Nos primeiros 5 a 10% (20 - 200m) da espessura da CLA, encontra-se a Camada Superficial (CS). Nesta camada, o escoamento é controlado, predominantemente, pelo atrito do vento com a superfície terrestre, e a direção do vento é aproximadamente constante com a altura (FICHTL; CAMP; FROST, 1977). Para a intensidade do vento, há um aumento que ocorre de forma similar a um perfil logarítmico com a altura, com as mudanças mais drásticas ocorrendo imediatamente acima da superfície (ICAO, 2005). Por isso, uma das formas de se modelar o perfil vertical do vento na CS é utilizando a Lei Logarítmica (Equação 2.1). A equação relaciona a velocidade ( $u$ ) em uma altura ( $z$ ) ao considerar a velocidade de fricção ( $u^*$ ), a constante de von Kármán ( $k$ ) igual a aproximadamente 0.38 e a rugosidade da superfície ( $z_0$ ), como apresentado a seguir:

$$u(z) = \frac{u^*}{k} \ln \frac{z}{z_0} \quad (2.1)$$

Outra forma de se calcular o perfil do vento é por meio da lei de potência (Equação 2.2). Essa lei possui uma maior simplicidade pois relaciona a velocidade do vento em dois níveis da atmosfera, considerando uma altura de referência ( $z_{ref}$ ) por meio apenas de um expoente ( $\alpha$ ), que não é universal, pois dependerá de condições locais como a rugosidade da superfície (Joffre, 1984).

$$u(z) = u(z_{ref}) \left( \frac{z}{z_{ref}} \right)^\alpha \quad (2.2)$$

### 2.2.2. Efeitos da estabilidade atmosférica

Tais leis se adequam bem aos perfis de vento observados na CS, porém não levam em consideração os efeitos causados pelo tipo de estabilidade atmosférica, que é associada à tendência das parcelas de ar se deslocarem verticalmente. Simplificadamente, os tipos de estabilidade atmosférica podem ser compreendidos da seguinte maneira:


**Instável:** Situação na qual a superfície está mais aquecida do que o ar acima, gerando turbulência convectiva, comum tipicamente durante dias ensolarados com céu limpo.

**Estável:** Situação em que a superfície está mais fria do que o ar acima, comum tipicamente durante noites de céu limpo, com turbulência convectiva fraca ou inexistente.

**Neutra:** Há pouco aquecimento ou resfriamento vindo da superfície, sem favorecimento de movimento vertical.

As leis citadas anteriormente assumem a camada com estabilidade neutra e, por isso, os valores calculados por elas serão diferentes da realidade durante condições com outros tipos de estabilidade, como ilustrado pela Figura 2.3. Além disso, nota-se que uma atmosfera estável é caracterizada por um maior aumento da velocidade do vento com a altura e, por isso, apresentará maior intensidade de WS (Sucevic e Djurisc, 2012).


Figura 2.3 – Influência da estabilidade atmosférica no perfil vertical da intensidade do vento



Fonte: Adaptado de Sucevic & Djurisc (2012)

Além disso, devido à natural variação na estrutura diurna da CLA e à influência gerada pela condição de estabilidade atmosférica, que geralmente pode ser associada a situações típicas durante o dia e noite, o perfil do vento em um determinado local apresentará variações ao longo do dia, como ilustrado para uma situação de céu limpo pela Figura 2.4. Assim, durante o dia (Camada Limite Convectiva) haverá uma menor variação do vento com a altura e, durante a noite (Camada Limite Estável), uma maior.

Figura 2.4 – Esquema da circulação na Camada Limite Convectiva e na Camada Limite Estável

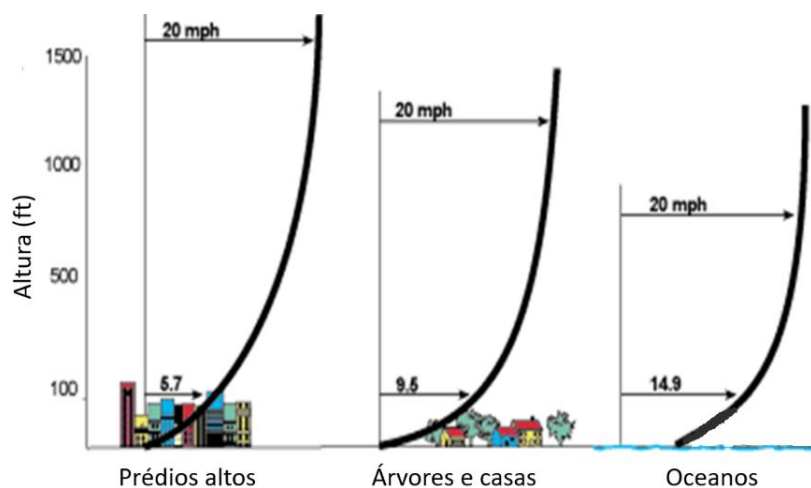


Fonte: Adaptado de Kaimal & Finnigan (1994)

### 2.2.3. Efeitos da rugosidade da superfície

Na CLA, a intensidade do vento será afetada pela rugosidade da superfície terrestre. Quanto maior a rugosidade do terreno, menor será a taxa de aumento da velocidade do vento com a altura. Assim, como ilustrado pela Figura 2.5, as velocidades, em uma mesma altura, em um ambiente urbano, que possui maior rugosidade, serão menores do que em uma área plana ou oceânica, superfícies que possuem menor rugosidade e, por isso, oferecem menor resistência ao escoamento (ENERGY).

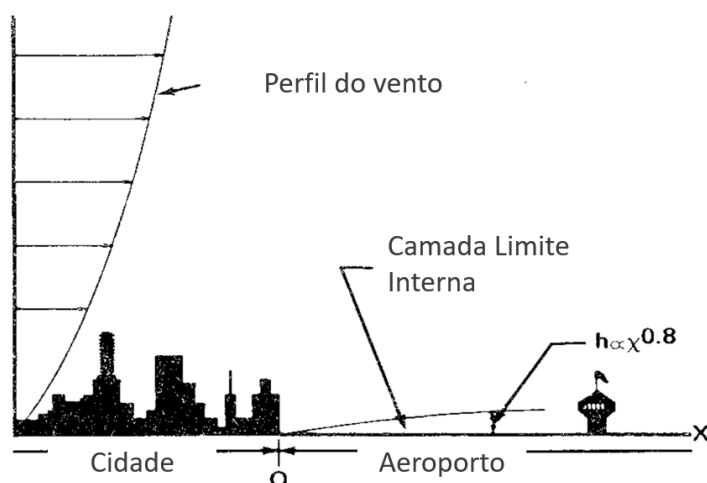
Figura 2.5 – Influência do tipo de superfície no perfil vertical da intensidade do vento



Fonte: Adaptado de ENERGY

Além disso, a maioria dos grandes aeroportos no mundo, onde o terreno é relativamente plano e, por isso, apresenta menores valores de rugosidade, é cercada por grandes cidades. Assim, dependendo da direção predominante do vento, essa influência de regiões com diferentes rugosidades resultará em uma situação de transição no escoamento, e, com isso, haverá a formação de uma camada limite interna que crescerá a uma taxa de  $X^{0.8}$ , onde  $X$  é a distância da região de descontinuidade da rugosidade (Fichtl *et al.*, 1977), como ilustrado na Figura 2.6. Nesse exemplo, o fluxo dentro da camada limite interna será influenciado pela menor rugosidade do aeroporto, permitindo uma maior aceleração com a altura, e, acima dela, o fluxo será influenciado pela rugosidade da área urbana, com menor velocidade, resultando assim em uma região de WS.

Figura 2.6 – Formação de uma camada limite interna



Fonte: Adaptado de Fichtl *et al.* (1977)

Após essa introdução sobre os fatores locais que influenciam o perfil vertical do vento na baixa atmosfera, serão então apresentados os fenômenos atmosféricos que podem alterá-lo, acarretando em maiores intensidades de WS.

### 2.3. CONDIÇÕES METEOROLÓGICAS ASSOCIADAS À OCORRÊNCIA DE WS

Estudos globais identificaram uma grande variedade de fenômenos meteorológicos associados à ocorrência de WS em intensidades que podem ser prejudiciais aos voos. Pode-se citar, por exemplo: tempestades, sistemas frontais, jatos noturnos, brisa marítima. Tais

condições podem estar presentes na maioria dos aeroportos do mundo, enquanto outras podem ser particulares de um determinado local (ICAO, 2005). Além disso, a singularidade das condições que causam o fenômeno também pode resultar da distribuição de edifícios e relevos ao redor do aeroporto, de interfaces terra/água, entre outros (FICHTL; CAMP; FROST, 1977).

A Tabela 2.2 apresenta um resumo dos resultados obtidos pelo Guia do Piloto para *Windshear* (FAA, 1988), estudo que realizou um exame de acidentes aeronáuticos reportados mundialmente entre 1959 e 1983, buscando identificar as condições meteorológicas que originaram a WS.

Tabela 2.2 – Eventos de WS subdivididos por condição meteorológica.

<b>Condição meteorológica</b>	<b>Número de eventos</b>
Tempestades	33
Sistemas frontais	7
Ventos fortes em superfície	2
Inversão térmica	1
Desconhecida	6

Fonte: Adaptado de FAA (1988)

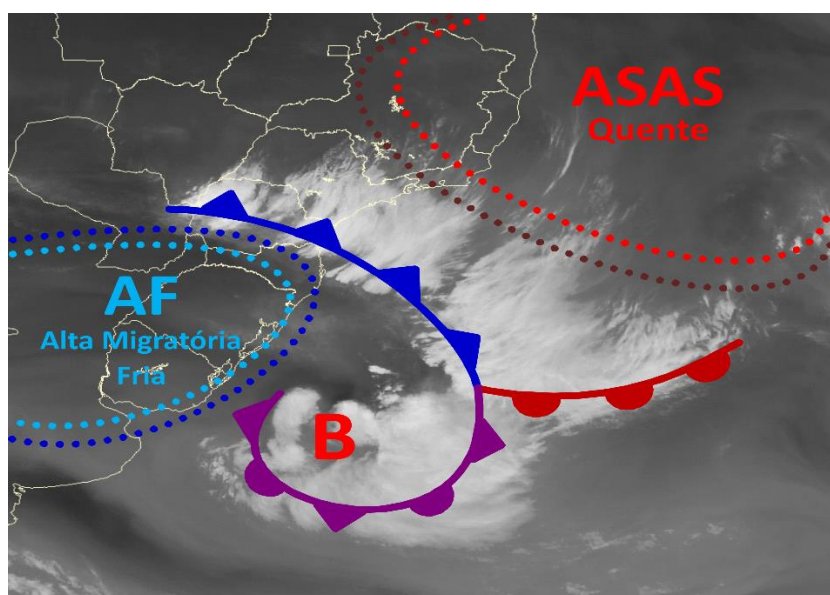
A seguir, é feita uma breve descrição de alguns desses fenômenos meteorológicos, para que eles sejam melhor compreendidos e possa ser entendido como eles podem interferir na intensidade da WS.

### **2.3.1. Sistema Frontal**

Segundo Bjerknes (1919), uma frente é a zona de transição entre duas massas de ar com características físicas distintas e fortes gradientes de temperatura e umidade. Na Frente Fria

(FF), a massa de ar frio (mais densa) se desloca em direção a massa de ar quente (menos densa), forçando o movimento ascendente. Como ilustrado pela Figura 2.7, uma FF típica que evolui sobre a América do Sul tem uma configuração atmosférica constituída da presença da Alta Subtropical do Atlântico Sul (ASAS) em sua dianteira (linha pontilhada vermelha) e um sistema de alta pressão frio, em sua retaguarda (linha pontilhada azul claro). Entre os dois sistemas de alta pressão, encontra-se a FF (linha azul escura com triângulos em sua borda), região de transição entre as massas de ar, e um ciclone extratropical na retaguarda (denotado pela letra B) na região de oclusão do sistema frontal (linha lilás). As FF provocam mudanças significativas no tempo, incluindo chuvas intensas e ventos fortes, e atuam durante todo o ano sobre a América do Sul, geralmente se deslocando de sudoeste para nordeste sobre o continente e Oceano Atlântico adjacente (Andrade, 2005; Oliveira, 1986).

Figura 2.7 – Modelo conceitual de uma frente fria evoluindo na América do Sul



Fonte: Dereczynski & Menezes (2016).


No entanto, nem todas as FF têm como consequência a formação de WS. Na verdade, o risco ocorre normalmente apenas nas frentes com gradientes de vento elevados e superfícies frontais mais inclinadas (ICAO, 2005). Assim como acontece com tantos fenômenos meteorológicos, não há regra absoluta. Mas, o estudo de FAA (2008) listou algumas características que demonstram a possibilidade de ocorrência de WS devido à passagem de uma FF: o gradiente de temperatura horizontal é de 5 °C/90 km ou mais, a FF se move a uma

velocidade de, pelo menos, 30 kt. Por não se tratar de uma regra absoluta, ressalta-se que, para cada aeroporto, é necessário então realizar estudos científicos para que tal critério citado anteriormente seja refinado para a região de interesse.

### 2.3.2. Brisa marítima

As circulações de brisa são fenômenos de mesoescala comuns em muitas áreas costeiras ao redor do mundo. A brisa marítima é uma circulação que se desenvolve a partir do aquecimento diferencial entre o continente e o oceano. A transição entre brisa marítima e brisa terrestre ocorre, geralmente, ao anoitecer, conforme o resfriamento radiativo do continente reduz o gradiente de temperatura até que haja o surgimento da brisa terrestre antes do amanhecer (ICAO, 2005). Geralmente, a WS causada pelas brisas ocorre nas regiões de transição do escoamento (ICAO 2005), como na situação ilustrada pela Figura 2.8.

Figura 2.8 – Avanço da Brisa Marítima



Fonte: Adaptado de ICAO (2005)


O estudo de Lee e Shun (2003) em HKIA identificou condições de WS associada à confluência de ventos no aeroporto devido ao encontro do fluxo predominante de leste com o avanço dos ventos de oeste da brisa marítima. Além disso, Shun e Chan (2008) apontaram a influência da brisa marítima como causadora de 20% dos eventos de WS estudados no local.

### 2.3.3. Obstáculos e relevo

A presença de construções próximas da pista, como prédios e hangares, interage com o escoamento do vento e, com isso, pode causar WS. A formação do fenômeno devido à essa interação dependerá de fatores como a intensidade e direção do vento, do tamanho e proximidade dos obstáculos em relação à pista (ICAO, 2005).

Além disso, um caso de obstrução em superfície que pode afetar as condições de WS são os relevos. Aeródromos próximos de cordilheiras, montanhas ou situados em locais com terreno complexo, podem experimentar situações com maiores intensidades de WS dependendo da interação entre o escoamento do vento e tais obstáculos. De forma geral, essa interação poderá representar riscos para aeródromos situados a sotavento do escoamento predominante (ICAO, 2005), como ilustrado pela Figura 2.9.

Figura 2.9 – Efeitos do relevo na circulação



Fonte: Adaptado de HKO (2010)


Segundo Shun e Chan (2008), 70% dos eventos de WS reportados por pilotos em HKIA foram causados pela interação do escoamento com o terreno complexo da ilha no entorno do aeroporto, especialmente quando associado a ventos de quadrante sul (Chen *et al.* 2020). No Brasil, Cabral e Farias (1991) investigaram 29 ocorrências de WS em SBGR entre 1988-1990 e identificaram uma associação a efeitos de onda de montanha causados pela interação entre ventos pré-frontais de noroeste e a Serra da Cantareira, localizada a norte do aeroporto.



### 2.3.4. Jato noturno

Durante as noites de céu limpo, a superfície terrestre se resfria mais rapidamente do que a atmosfera. Dependendo da intensidade dessa taxa de resfriamento, ocorre uma inversão de temperatura algumas centenas de metros acima do solo. Com isso, o ar ganha velocidade rapidamente com a altura após a região de inversão e há a formação do jato noturno, com eixo encontrado geralmente abaixo de 500 metros e velocidades que podem chegar a 60 kt (ICAO, 2005). Devido à essa rápida aceleração com a altura e interrupção na região de inversão, ao passar por um jato noturno as aeronaves encontrarão WS, como ilustrado na Figura 2.10.

Figura 2.10 – Perfil da subida de uma aeronave ao passar por uma região com jato noturno.




Fonte: Adaptado de AOPA

### 2.3.5. Microburst

O microburst, é uma coluna de ar descendente de pequeno diâmetro e de grande velocidade vertical, a qual, ao aproximar-se do solo, se dispersa radialmente na horizontal, provocando ventos fortes e rajadas em todas as direções. Esse fenômeno é originado por nuvens Cumulonimbus, possui curta duração e é de difícil detecção (ICAO, 2005). De forma geral, ao encontrar um *microburst* durante o voo, inicialmente haverá um aumento da velocidade indicada e, conseqüentemente, um aumento na sustentação. Em seguida, o avião será submetido a efeitos de ventos majoritariamente descendentes e, após isso, de cauda, acarretando uma rápida diminuição da velocidade indicada e sustentação da aeronave (Simão, 2013), situação ilustrada pela Figura 2.11.

Figura 2.11 – Possíveis efeitos do encontro de um *microburst* após a decolagem



Fonte: Simão (2013)

Após um breve entendimento sobre as condições atmosféricas que podem intensificar a WS, torna-se então necessário entender melhor sobre como e por qual motivo esse fenômeno pode ser prejudicial ao desempenho das aeronaves.

#### 2.4. EFEITOS DA WS NO DESEMPENHO DAS AERONAVES

Para entender o efeito que a WS causa no desempenho das aeronaves, é necessário falar sobre alguns princípios básicos de voo. As principais forças que atuam em uma aeronave são ilustradas na Figura 2.12, para uma condição de voo reto e nivelado, na qual podemos listar a Tração, Peso, Sustentação e Arrasto.

Figura 2.12 – Quatro forças que agem sobre uma aeronave



Fonte: AVIADOR (2017)

A força Peso será uma função da massa da aeronave multiplicada pela aceleração da gravidade e a Tração será fornecida diretamente pelos motores. A Sustentação ( $L$ ) e o Arrasto ( $D$ ) são proporcionais à densidade atmosférica ( $\rho$ ), à área da asa ( $S$ ), à velocidade do ar relativa à aeronave ( $V$ ) e aos coeficientes de sustentação ( $C_L$ ) e arrasto ( $C_D$ ) (ICAO, 2005), como mostrado a seguir pelas Equações 2.3 e 2.4:

$$L = \frac{C_L \rho S V^2}{2} \quad (2.3)$$

$$D = \frac{C_D \rho S V^2}{2} \quad (2.4)$$

Pelo fato de a WS ser caracterizada por uma variação no campo de vento, o fenômeno conseqüentemente é capaz de alterar a sustentação. Tal efeito pode ocorrer de forma a aumentar ou diminuir esse valor, situações que, de qualquer forma, irão desestabilizar a aeronave, representando assim alto risco para os voos. O perigo será maior durante os procedimentos de pouso e decolagem devido à proximidade com o solo e baixa velocidade, resultando em uma baixa margem para correção de variações bruscas na atitude de voo.

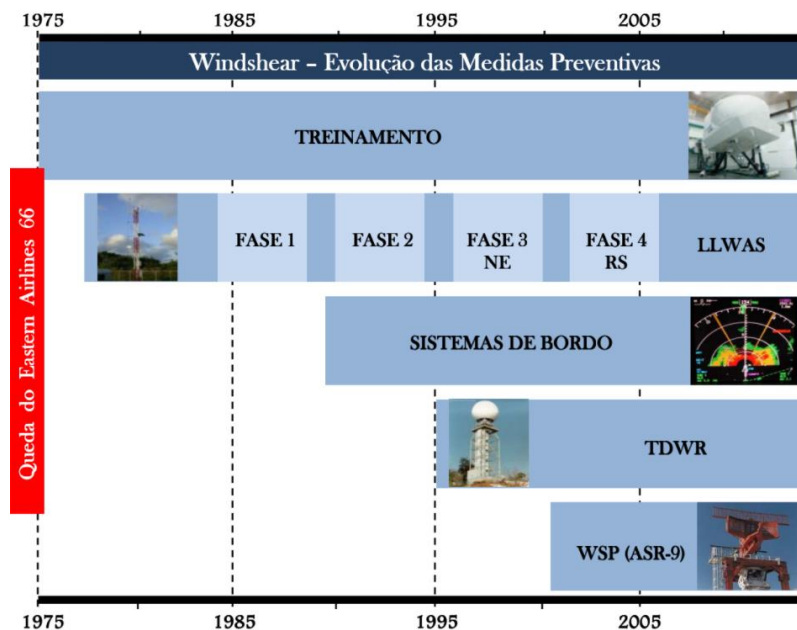
Fica evidente, então, a importância de aeroportos e aeronaves possuírem sistemas de detecção e previsão da ocorrência de WS, o que será descrito na seção a seguir.

## 2.5. SISTEMAS DE DETECÇÃO DE WS

Em 25 de junho de 1975, ao tentar aterrissar no Aeroporto Internacional John F. Kennedy - NY, a aeronave Eastern Airlines 66 sofreu um acidente e, das 124 pessoas a bordo, 107 passageiros e 6 tripulantes morreram. Na época, esse foi o acidente mais mortal na história dos Estados Unidos. Durante a investigação, foi constatado pela primeira vez a presença da WS como fator determinante para um acidente aeronáutico (ICAO, 2005).

A partir desse ocorrido, a comunidade aeronáutica internacional vem apresentando medidas para melhorar a previsão e detecção do fenômeno, principalmente com o avanço dos sistemas de bordo das aeronaves e o aperfeiçoamento no treinamento dos pilotos. A Figura 2.13 ilustra uma linha do tempo com as principais medidas que foram tomadas desde então e, a seguir, será dada uma breve descrição sobre algumas delas.

Figura 2.13 – Linha temporal das medidas preventivas contra WS




Fonte: Simão (2013)

### 2.5.1. Low-level wind shear alert system (LLWAS)

O LLWAS foi desenvolvido durante os anos 1970 e utilizado inicialmente em aproximadamente 100 aeroportos nos Estados Unidos. Originalmente, o sistema foi concebido como uma distribuição de 5 anemômetros em pontos estratégicos no entorno do aeroporto, os quais realizam amostras a cada 10 segundos, e outro instalado em um ponto central, que realiza uma média a cada 2 minutos do vento em superfície. Ambos monitoram, continuamente, a diferença vetorial entre os sensores no entorno da pista com o central, considerado como referência. Com o passar dos anos, foram feitas melhorias no sistema, como o aumento da extensão da área de cobertura para um raio de aproximadamente 5.5 km das pistas e, com isso, o aumento no número de sensores subiu para 32, a exemplo o Aeroporto de Denver, EUA. No entanto, o LLWAS possui limitações como o fato dele apenas detectar diferenças do vento em superfície e na horizontal, causadas geralmente por *microburst* (ICAO, 2005). A Figura 2.14 apresenta uma ilustração do sistema.

Figura 2.14 – Exemplo de distribuição de anemômetros do LLWAS em um aeroporto

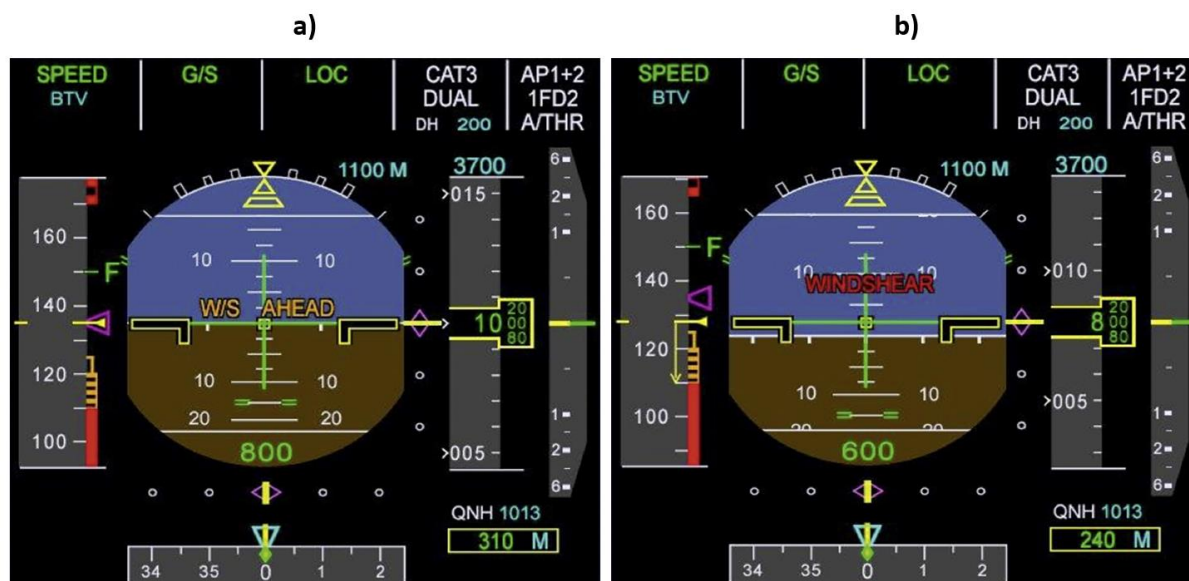


Fonte: WIKIPEDIA

### 2.5.2. Sistemas de Bordo

As modernas aeronaves comerciais possuem dois sistemas de proteção contra WS que operam de forma independente, o *Predictive Windshear warning System* (PWS) e o *Reactive Windshear warning System* (RWS). O PWS funciona utilizando os dados obtidos pelo radar meteorológico de bordo, realizando *scans* a, geralmente, 5 milhas náuticas a frente da trajetória da aeronave, em altitudes que variam dependendo da fase do voo, analisando o movimento da massa de ar a frente, e, com isso, detectando regiões que apresentem condições de WS. A partir disso, o sistema é capaz de emitir um aviso visual e sonoro aos pilotos do tipo “*W/S AHEAD*” com uma antecipação de 1 minuto, como ilustrado pela Figura 2.15a (AIRBUS, 2015). Já o RWS utiliza dados em tempo real de diversos parâmetros do voo, emitindo um alerta visual e sonoro do tipo “*WINDSHEAR*” (Fig 2.15b) ao detectar variações acima de um limite estabelecido. O aviso visual é fornecido visualmente no *Primary flight display*, instrumento de voo cujo objetivo é informar dados cruciais de navegação, como velocidade (escala na esquerda) e altitude (escala na direita). No entanto, ressalta-se que o PWS possui a desvantagem de apenas detectar WS em condições com precipitação, pois o sistema baseia-se na detecção da velocidade de movimentação das partículas de água ou gelo à frente da aeronave (Ribeiro *et al.*, 2017).

Figura 2.15 – Tipos de avisos no painel de uma aeronave para atenção (a) e reação (b) à condição de WS



Fonte: AIRBUS (2015)

### 2.5.3. Terminal Doppler Weather Radar (TDWR)

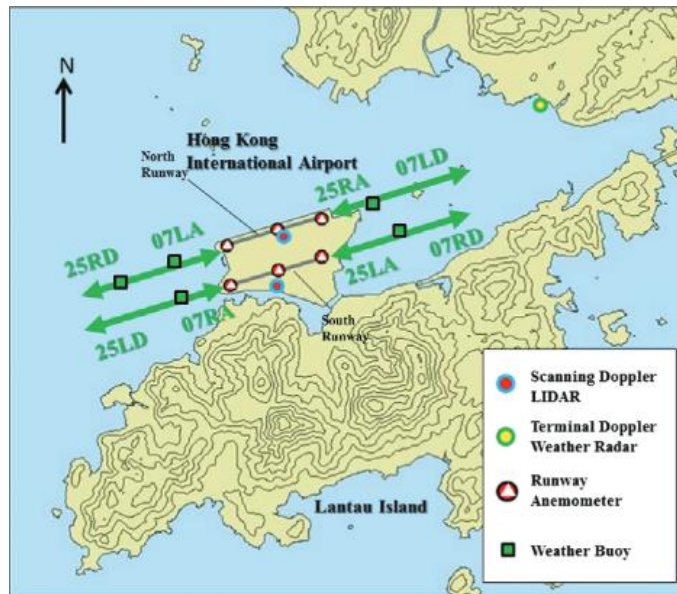
O TDWR é um radar doppler de banda C desenvolvido especialmente para detectar a ocorrência de WS, microbursts e altas taxas de precipitação no entorno dos principais aeroportos dos Estados Unidos que ficam situados em regiões com alta frequência de tempestades. O instrumento funciona avaliando a posição e a intensidade das variações do vento em relação aos segmentos de chegada e saída dos aeroportos, emitindo um alerta caso um limiar seja ultrapassado. O TDWR realiza medições atmosféricas tridimensionais, com precisão e velocidade de detecção melhores em relação aos LLWAS, no entanto, é particularmente suscetível à degradação do sinal recebido em situações com precipitação sobre ele (ICAO 2005).

### 2.5.4. Sistemas Integrados

Alguns aeroportos utilizam sistemas integrados por meio da combinação de diversos tipos de detecção. Um exemplo é o de HKIA, local que, como já citado anteriormente, sofre influência constante da WS. O aeroporto possui um moderno sistema de detecção que conta com um Light Detection And Ranging (LIDAR) que monitora as trajetórias finais de cada uma das cabeceiras do aeroporto, anemômetros espalhados pelas pistas e em boias próximas às cabeceiras, além de um TDWR localizado próximo ao aeroporto. O sistema é ilustrado na Figura 2.16. No entanto, utilizar um sistema tão sofisticado é custoso para se adquirir e manter

e, por isso, na maioria dos aeroportos não são utilizados sistemas que identifiquem a presença e a intensidade da WS (ICAO, 2005).

Figura 2.16 – Sistema integrado de alerta de WS em HKIA



Fonte: Chan (2017)

## 2.6. PREVISÃO DE WS

Neste subtópico, são abordados os avanços e técnicas utilizadas para a previsão de WS nos últimos anos.

### 2.6.1. Modelagem Numérica

Em aeroportos afetados pela presença de WS, mas que não possuem equipamentos operacionais para observar e detectar a sua ocorrência, torna-se difícil construir algum método de previsão do fenômeno. Nesses casos, geralmente, a única alternativa viável é entender melhor os fenômenos meteorológicos que interferem na intensidade da WS no local.

Alguns estudos já foram feitos para tentar prever o fenômeno utilizando diferentes técnicas, com algumas iniciativas envolvendo o uso de modelagem numérica. Wong, Lau e Chan (2013) desenvolveram um modelo com resolução de 200 m baseado no *Advanced Research Weather Research and Forecast* (WRF-ARW) para a área do HKIA que



posteriormente foi utilizado por Hon (2020) para realizar previsões de WS com saídas a cada 1 minuto. Os resultados foram validados utilizando 800 relatos de pilotos obtidos entre 2014 e 2015 e o desempenho foi positivo, obtendo previsões assertivas com uma antecedência de 6 horas.

No Brasil, o estudo de Ribeiro *et al.* (2019) buscou reproduzir as ocorrências de WS em SBGR por meio de 4 experimentos computacionais feitos pelo modelo WRF. Os resultados foram próximos das observações em 2 deles, que se mostraram eficientes para prever a ocorrência do fenômeno com antecipação aproximada de 11 à 13 h. No entanto, ressalta-se que o uso de modelos numéricos exige um custo computacional que nem sempre estará disponível.


### **2.6.2. Aprendizado de Máquina**

Para as previsões, uma alternativa que requer menor custo computacional e apresenta bons resultados é a utilização de aprendizado de máquina. O objetivo desse método é desenvolver algoritmos, técnicas automatizadas, que detectem padrões nos dados. Os modelos desenvolvidos possuem a capacidade de aprender a partir de dados pretéritos e prever em dados futuros. Por isso, nos últimos anos seu uso tem se espalhado e popularizado cada vez mais (Domingos, 2012).

De forma geral, os problemas de aprendizado de máquina podem ser divididos entre classificatórios e regressivos. Os classificatórios são utilizados para obter saídas categóricas como, por exemplo, prever se haverá a ocorrência de um evento de WS forte, tendo, desta forma, uma saída de sim ou não. Já os modelos regressivos são utilizados para prever variáveis contínuas, uma quantidade como, por exemplo, o valor da intensidade da WS. A Figura 2.17 ilustra essa diferença, na qual, para a classificação, pode-se separar os dados em duas categorias, e, em uma regressão, é procurada uma relação entre, por exemplo, 2 variáveis que pode ser obtida por meio do ajuste de uma reta.



Figura 2.17 – Exemplo de problemas de classificação e regressão



Fonte: Adaptado de MEDIUM

Dependendo da localidade e das condições atmosféricas, alguns modelos podem possuir um bom desempenho ao prever variáveis meteorológicas como a velocidade do vento. Porém, estes mesmos modelos podem apresentar pior performance em outras condições devido ao fato de não reconhecerem todos os fatores que afetam a variável, por exemplo, o relevo do terreno, a umidade e temperatura (Brahimi, 2019).

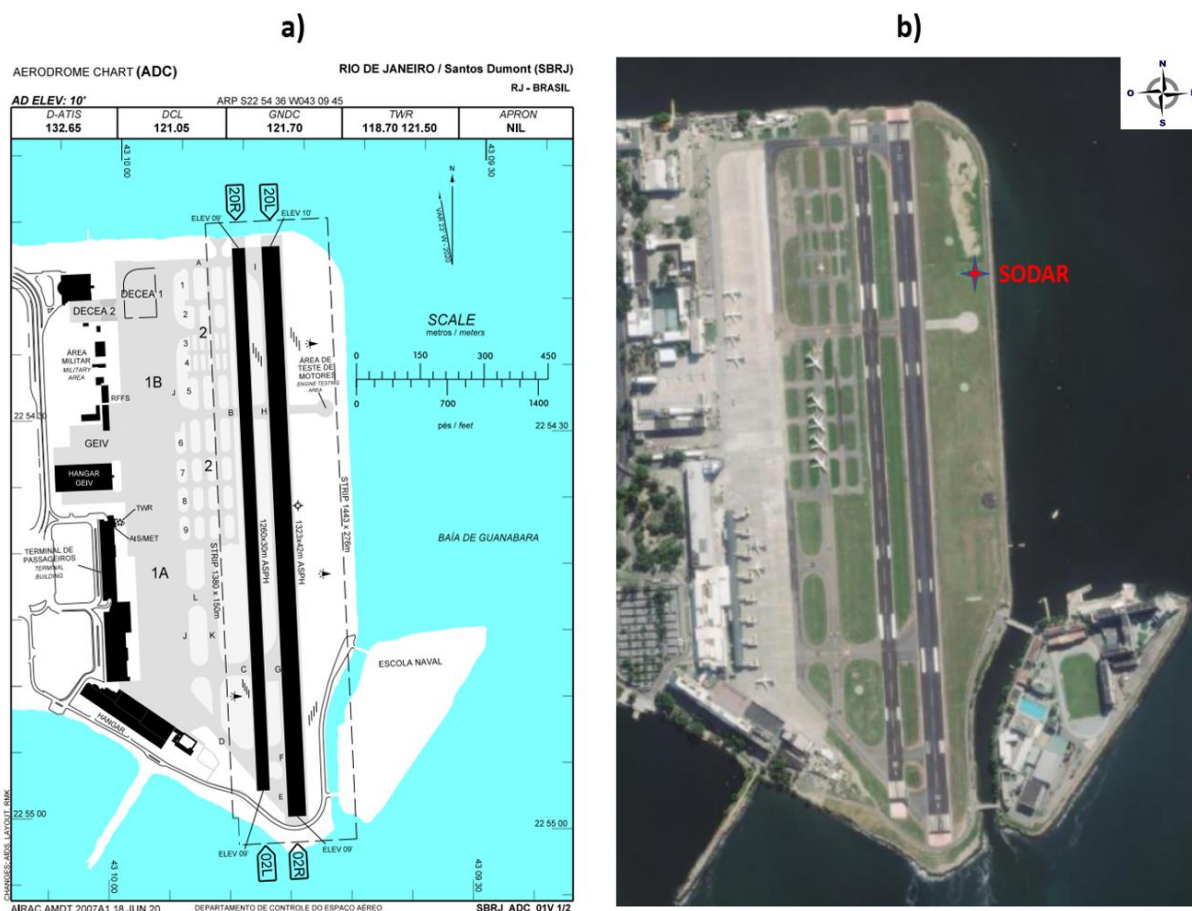
No campo da meteorologia aeronáutica já foram realizados estudos, como o de Almeida (2009), que utilizou Redes Neurais Artificiais para a previsão de visibilidade e teto em SBGR, e os trabalhos de França *et al.* (2016), e Almeida *et al.* (2020) que desenvolveram métodos para a previsão de curto prazo de eventos convectivos na área terminal de voo do Rio de Janeiro. Além disso, França *et al.* (2018) utilizaram dados do SODAR para treinar uma rede neural com o objetivo de prever o perfil de vento em baixos níveis com uma antecedência de até 45 minutos em SBGR.

Com relação à WS, a partir de relatos de pilotos no HKIA, Chen *et al.* (2020) testaram um método de previsão horária do fenômeno utilizando regressão logística com dados de temperatura, velocidade e direção do vento. Devido ao baixo número de dias com a ocorrência de WS no local, o estudo obteve dificuldades e concluiu que eram necessários mais dados para melhorar o desempenho das previsões, especialmente com maior resolução temporal, pela natureza transiente e esporádica do fenômeno.

### 3. ÁREA DE ESTUDO

A área de estudo é o Aeroporto Santos Dumont (designação ICAO: SBRJ), localizado no centro da cidade do Rio de Janeiro – RJ. O local está situado a uma altitude de 3 metros, nas coordenadas 22° 54' 36" S e 043° 09' 45" W (AISWEB, 2021), e possui duas pistas, paralelas entre si, alinhadas em relação ao norte magnético, 02 (orientação magnética de 020°) e 20 (orientação magnética de 200°). A pista 02R/20L possui 1323 m de comprimento e 42 de largura, e a pista 02L/20R possui 1260 m de comprimento e 30 de largura, como ilustrado pela Figura 3.1. Além disso, em 2019 o SBRJ ocupou o 5º lugar no ranking de tráfego de aeronaves nos aeródromos brasileiros (Anuário Estatístico de Tráfego Aéreo – DECEA, 2019) e, entre 1999 e 2013, 146 aeronaves reportaram terem passado por condições com WS nos procedimentos de pouso e decolagem (REDEMET, 2021).

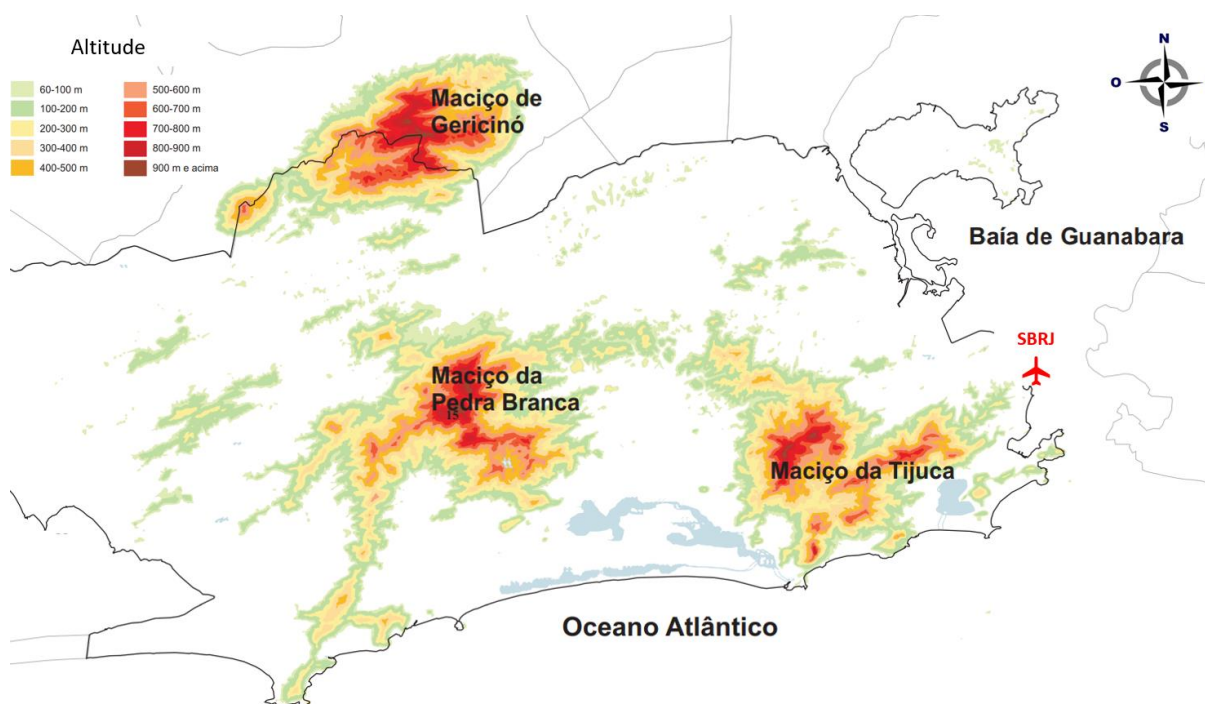
Figura 3.1 – Carta de aeródromo (a) e imagem de satélite (b) do SBRJ com a localização do SODAR



Fonte: AISWEB e Google Earth

O SBRJ encontra-se a beira da Baía de Guanabara e seu entorno conta com a presença de relevos (Figura 3.2), como o Maciço da Tijuca e o Pão de Açúcar, situados a oeste e sul do aeroporto, respectivamente, e a presença da Ponte Rio-Niterói, situada ao norte. A combinação desses obstáculos, em conjunto com o tamanho curto de suas pistas, transforma o aeroporto em um local de aproximação e pouso complicado, com pouca margem para erros.

Figura 3.2 – Topografia da cidade do Rio de Janeiro e localização do SBRJ



Fonte: Adaptado de Ministério do Meio Ambiente (2002)

De acordo com Pimentel *et al.* (2014), o regime de vento na Baía de Guanabara, que circunda o aeroporto, é influenciado pelo escoamento de grande escala com maior frequência por ventos de nordeste associados à ASAS, domínio este que é perturbado durante a passagem de FF, e alterado localmente pelo efeito da circulação das brisas marítima/terrestre. Além disso, os ventos associados à brisa marítima no local são mais intensos na primavera e verão (Oliveira Júnior *et al.*, 2017).

## 4. DADOS E MÉTODO

Neste Capítulo, serão apresentados e descritos os dados utilizados e a metodologia para a análise e previsão dos eventos de WS.

### 4.1. DADOS

Para a realização deste trabalho, foram utilizados dados do perfilador de vento SODAR instalado na área de estudo próximo à cabeceira 20L (Figura 3.1b). O instrumento fornece dados com resolução temporal de 15 minutos e vertical de 10 metros. As informações são obtidas entre as alturas de 30 e 520 metros, e compreendem os períodos entre 01 de outubro de 2016 e 30 de setembro de 2019, e de 01 de janeiro de 2020 a 31 de dezembro de 2020. Para avaliar a condição meteorológica quando houve WS com intensidade classificada como forte, foram utilizados dados complementares como *METeorological Aerodrome Report* (METAR) e *SPECIAL report* (SPECI). O METAR é elaborado de hora em hora, enquanto o SPECI é informado quando há uma alteração acentuada em alguma informação ou um fenômeno significativo observado. Tais informações foram extraídas do sistema OPMET (REDEMET, 2021). Além disso, também foram analisadas imagens de satélite (GOES-13 e GOES-16), obtidas no Centro de Previsão do Tempo e Pesquisas Climáticas (CPTEC), para identificar os sistemas meteorológicos atuantes no momento dos eventos. A Tabela 4.1 apresenta de forma resumida os três tipos de dados e suas respectivas frequências, informações e fontes.


Tabela 4.1 – Resumo dos tipos de dados utilizados no estudo

Dado	Frequência	Informação	Fonte
SODAR	15 min	Perfil vertical do vento	SBRJ
METAR	1 h	Vento em superfície	REDEMET
		Teto	
		Visibilidade	
		Tempo presente	
Satélite (GOES-13 e 16)	30 e 10 min	Nebulosidade dos sistemas	INPE/CPTEC

#### 4.1.1. SODAR

O SODAR é um instrumento de sensoriamento remoto situado na superfície terrestre capaz de estimar o perfil vertical do vento em três eixos (u, v, w), além de calcular parâmetros sobre a turbulência como a taxa de dissipação (EDR) e a energia cinética turbulenta (TKE). Suas estimativas vão desde altura próxima à superfície até várias centenas de metros, e o equipamento é do tipo mono estático, isto é, a mesma antena é utilizada para emissão e recepção de som. O modelo utilizado nesta pesquisa é o MFAS produzido pela empresa alemã Scintec. O SODAR opera sob o princípio de retro espalhamento acústico. Um pulso acústico é enviado para a atmosfera e, à medida que a onda sonora se propaga, uma pequena fração de sua energia é retro espalhada por pequenas variações de densidade causadas pela diferença de temperatura de parcelas do ar próximas entre si, como ilustrado pela Figura 4.1, retornando ao equipamento. A estimativa da altura, intensidade e direção do vento é feita pelo tempo de retorno e variação de frequência do eco recebido.

Figura 4.1 – Princípio de funcionamento do SODAR



Fonte: Adaptado de Scintec (2017)

Como exemplos de estudos com a aplicação do instrumento, Vogt e Thomas (1995) testaram a precisão e a confiabilidade de diferentes SODARs por meio da comparação com sensores *in situ* em uma torre meteorológica de 200 m de altura. O trabalho teve como conclusão que a confiabilidade e precisão do vetor de vento, medida por um SODAR, é, geralmente, satisfatória. Gerz *et al.* (2008) utilizaram dados do SODAR para diagnóstico e previsão de curto prazo de nevoeiro e WS no aeroporto de Frankfurt. Chan (2014) observou a eficiência do uso

de dois mini-SODARs para detecção de WS em HKIA, Silva *et al.* (2016) construíram um modelo conceitual de mudança do perfil de vento em SBGR.

No entanto, é importante ressaltar que o equipamento possui algumas restrições para o uso. Por ser um instrumento acústico, a umidade e a temperatura na área de atuação, assim como o som do ambiente (ruídos), interferem diretamente no seu alcance vertical. Portanto, a antena deve ser protegida por um invólucro acústico a fim de diminuir a interferência externa. Além disso, o trabalho de Ribeiro *et al.* (2019) indicou que os dados obtidos do SODAR em SBGR, quando comparados com a quantidade de relatos de WS pelos pilotos, revelaram pouca coincidência na prática (31,3%).

A partir do perfil de vento estimado pelo SODAR, a intensidade da WS em uma altura qualquer ( $z$ ) é calculada pelo instrumento por meio de uma relação entre a diferença da componente zonal ( $u$ ) e meridional ( $v$ ) do vento em uma altura acima ( $z_a$ ) e abaixo ( $z_b$ ), conforme apresentado pelas Equações 4.1 e 4.2:

$$WS_u(z) = \frac{u_a - u_b}{z_a - z_b} \quad (4.1)$$


$$WS_v(z) = \frac{v_a - v_b}{z_a - z_b} \quad (4.2)$$

As equações anteriores nos revelam a variação de cada componente do vento horizontal em determinada altura. Com isso, a intensidade total da WS em uma altura qualquer ( $z$ ) é calculada por (Equação 4.3):

$$WS(z) = \sqrt{ws(u)^2 + ws(v)^2} \quad (4.3)$$

Os dados obtidos podem, então, ser analisados utilizando o software *APRun*, ferramenta que possui opções para a visualização das variáveis, como ilustrado pela Figura 4.2, e exportação dos dados em formatos que permitem a análise dos mesmos em outros ambientes.

Figura 4.2 – Exemplo de visualização da intensidade de WS no software *APrun*




## 4.2. METODOLOGIA

### 4.2.1. Análise dos dados


Conforme citado anteriormente, as condições atmosféricas influenciam de forma significativa na atenuação da onda sonora emitida pelo SODAR, causando assim uma variação natural da cobertura de dados disponíveis. Esse fato tornou-se evidente durante uma análise inicial dos dados obtidos pelo instrumento, na qual foi constatada uma menor disponibilidade conforme o aumento da altura, como ilustrado pela Figura 4.3. Nota-se que, considerando os dados obtidos até 100 metros, há uma disponibilidade de 95,7% que decai para 10,9% em alturas entre 400 e 520 m. Essa disponibilidade torna-se menor ainda sob condições de WS com intensidade classificada como forte (barra vermelha). Por isso, para não ser penalizado com a exclusão de muitas linhas com dados faltosos, durante o processo de construção dos modelos preditivos foram considerados apenas os dados obtidos até 100 metros.

Figura 4.3 – Queda na disponibilidade de dados de WS com o aumento da altura e intensidade



Além disso, também foi constatada uma baixa disponibilidade de dados TKE e EDR em condições com WS com intensidade acima de leve, especialmente em observações com classificação forte (barra laranja). Nessas situações, a disponibilidade dessas variáveis caiu para valores abaixo de 50% (Figura 4.4). Por isso, as informações de TKE e EDR também não foram utilizadas no processo de construção dos modelos preditivos de WS.

Figura 4.4 – Queda na disponibilidade de dados TKE e EDR com o aumento da intensidade da WS



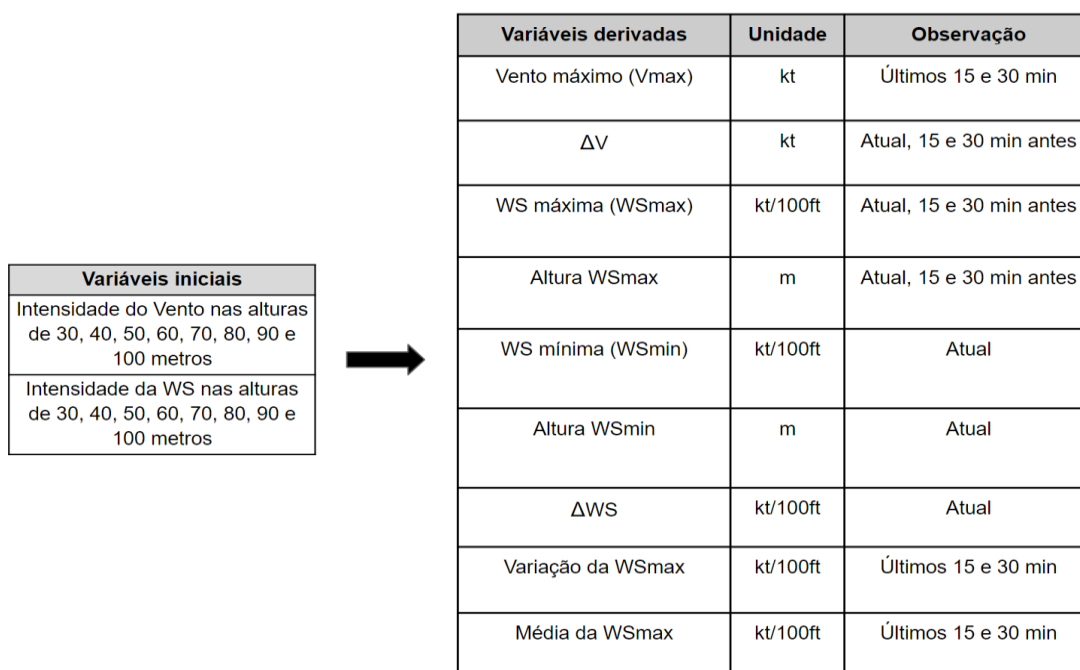
#### 4.2.2. Transformação de variáveis

De início, para utilizar como entrada no modelo preditivo, estavam disponíveis os valores de WS e intensidade do vento para as faixas de altura obtidas pelo SODAR, entre 30 e



100 metros. Com isso, selecionou-se o valor da WS máxima (WSmax) encontrada nessa faixa para ser o alvo das previsões deste estudo. Assim, os modelos desenvolvidos tentaram prever a WSmax da camada entre 30 e 100 metros, independente de em qual altura ela ocorra, para os próximos 15, 30, 45 e 60 minutos. Além disso, com o intuito de reduzir o número de variáveis e obter outras informações complementares, também foram derivados outros parâmetros, processo ilustrado na Figura 4.5. Os valores  $\Delta V$  e  $\Delta WS$  são, respectivamente, a diferença entre a intensidades máxima e mínima do vento e WS para o horário considerado. Destaca-se também que, para algumas variáveis, são consideradas apenas o valor da observação atual, e, para outras, considera-se também seus valores nos últimos 15 e 30 minutos. Com isso, estiveram disponíveis no total 18 variáveis para a construção dos modelos preditivos.

Figura 4.5 – Processo de transformação das variáveis utilizadas no estudo



### 4.2.3. Modelos de Regressão

Para a previsão da WS, foram construídos, e posteriormente comparados, 4 modelos de aprendizado de máquina a fim de se encontrar aquele com o menor erro nas previsões, especialmente nos casos classificados como fortes. Devido ao fato de o fenômeno ser contínuo na atmosfera e o interesse ser em prever a sua intensidade, foram utilizados modelos regressivos.

A seguir, é feita uma breve descrição sobre os modelos de regressão utilizados:

- 1) Linear Regression: O algoritmo encontra uma relação linear entre as variáveis dependente (alvo) e independentes (entrada) por meio do ajuste de uma reta nos dados que visa minimizar a soma dos quadrados das diferenças entre o valor previsto e observado.
- 2) Decision Tree: Método que realiza decisões aprendidas pelo algoritmo por meio dos dados de treinamento, dividindo-os em categorias e em uma hierarquia. Assim, a partir de um valor de entrada, o dado segue essa hierarquia de decisões até atingir um resultado final.
- 3) Random Forest: Constituído por uma agregação de múltiplas árvores de decisão. Para fornecer uma previsão, o algoritmo utiliza o resultado combinado de várias árvores, agrupando assim o resultado obtido por elas para adquirir uma saída final com menor erro e mais estável do que se utilizasse apenas uma árvore.
- 4) eXtreme Gradient Boosting (XGBoost): Utiliza um conjunto de modelos árvores individuais, adicionando novas durante o processo de treinamento para reduzir o erro obtido pelas previsões feitas inicialmente. O XGBoost utiliza uma função de perda e um termo de regularização, para evitar um *overfitting*, e avalia a diferença entre os valores observados e previstos durante seu treinamento para melhorar a qualidade da sua previsão até que não consiga mais.

Todo o processo de preparação dos dados, construção e avaliação dos modelos foi feito utilizando a linguagem de programação Python e a biblioteca de aprendizado de máquina scikit-learn (Pedregosa *et al.*, 2011), a qual inclui diversos algoritmos de classificação e regressão, como os utilizados nesse estudo.

No aprendizado de máquina, os modelos são construídos utilizando um conjunto de dados chamado de treino. Posteriormente, para avaliarmos o desempenho após a construção, é necessário utilizar outro conjunto de dados, denominado de teste, que não foi aplicado previamente no modelo durante sua construção. A Tabela 4.2 apresenta mais informações sobre estes conjuntos, os quais, para o treinamento, utilizou-se os dados do período entre 01 de

outubro de 2016 e 30 de setembro de 2019 e, para o teste, entre 01 de janeiro de 2020 a 31 de dezembro de 2020.

Tabela 4.2 – Informações sobre os conjuntos de treino e teste utilizados pelos modelos

<b>Conjunto</b>	<b>Período</b>	<b>Nº de linhas</b>
Treino	01/10/2016 a 30/09/2019	92.368
Teste	01/01/2020 a 31/12/2020	29.290

#### **4.2.4. Seleção de Variáveis**

Devido ao alto número de informações disponíveis, nem todas serão úteis para o processo de construção do modelo preditivo. Por isso, torna-se necessário a utilização de algum método de seleção de variáveis. Esse processo identifica o número mínimo de variáveis do conjunto de dados que acarretam um modelo com menor erro. Além disso, é possível reduzir a complexidade dos algoritmos construídos (Kumar, 2019). Para isso, foi utilizada uma função de seleção de variáveis que constrói um *ranking* baseado nas correlações entre as variáveis de entrada e o alvo da previsão. Assim, o modelo é treinado seguindo esse ranking, adicionando uma variável por vez, até que todas tenham sido utilizadas. Com isso, avalia-se então, por meio dos dados de teste, quais variáveis e qual o número ótimo que construirá o modelo com o menor erro.

#### **4.2.5. Avaliação do desempenho dos modelos**

Como mencionado anteriormente, após o treino foi utilizado o conjunto de dados de teste para avaliar o desempenho dos modelos. Este processo foi feito considerando a raiz do erro médio quadrático (RMSE), o erro médio absoluto (MAE) e o coeficiente de determinação ( $R^2$ ). Para o RMSE e MAE, são buscados valores próximos de zero, e suas unidades são as mesmas da variável avaliada. Considerando  $V^{obs}$  como o valor observado e  $V^{prev}$  como o valor previsto, a RMSE (Equação 4.4) é dado por (WILKS, 2006):

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (V_i^{obs} - V_i^{prev})^2} \quad (4.4)$$

O MAE (Equação 4.5) mede a magnitude média da diferença absoluta entre os valores previstos e observados (WILKS, 2006):

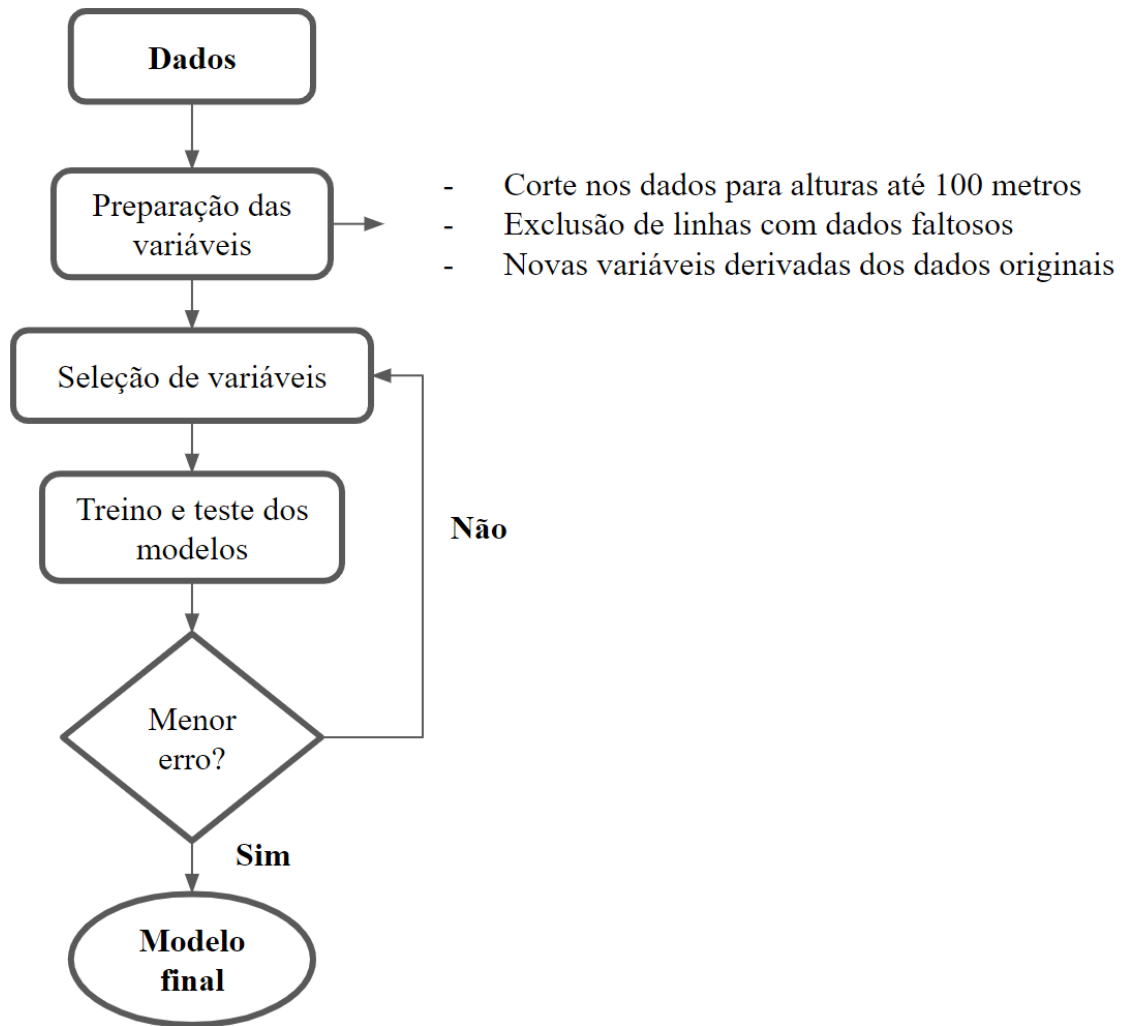
$$MAE = \frac{1}{N} \sum_{i=1}^N |V_i^{obs} - V_i^{prev}| \quad (4.5)$$

O  $R^2$  (Equação 4.6) varia de 0 a 1 e fornece a informação do quão bem ajustado está o modelo em relação aos dados observados e o quanto da variância é explicada por ele. Por exemplo, um valor de  $R^2 = 1$  indicará que as previsões feitas pela regressão se ajustam perfeitamente aos dados observados. Considerando  $V^{med}$  como o valor médio da variável (WILKS, 2006):

$$R^2 = 1 - \frac{\sum_{i=1}^N (V_i^{obs} - V_i^{prev})^2}{\sum_{i=1}^N (V_i^{obs} - V^{med})^2} \quad (4.6)$$

Após os cálculos das métricas acima, foram comparados os resultados dos modelos para escolher aquele que obteve menor erro durante as condições de WS forte. Após essa escolha, também foram analisados os resíduos das previsões, isto é, a diferença entre os valores observados e previstos. A metodologia completa desse estudo é ilustrada pela Figura 4.6.

Figura 4.6 – Metodologia do processo de construção dos modelos deste estudo



## 5. RESULTADOS

Neste Capítulo, serão apresentados os resultados obtidos pelo estudo a fim de se conhecer e discutir as características que envolveram os eventos de WS, os sistemas atmosféricos relacionados e as previsões realizadas pelos modelos desenvolvidos.

### 5.1. OCORRÊNCIA E SEVERIDADE DE WS

A Tabela 5.1 descreve a quantidade total dos valores de intensidade de WS contabilizadas a partir dos dados estimados pelo SODAR. Ao todo, foram obtidas 3.074.981 estimativas, considerando todas as alturas disponíveis para cada observação realizada durante o período do estudo. Nota-se um predomínio da classe leve (99,93%), resultado similar ao obtido por Ribeiro *et al.* (2017) que classificaram 98,69% dos dados obtidos em SBGR, entre 01 de janeiro e 31 de maio de 2016, com essa mesma intensidade, a qual normalmente não é relatada por pilotos. Por isso, nas seções seguintes, as condições associadas à essa intensidade não serão analisadas, dando foco apenas para os registros moderados, fortes e severos, classes essas que, em conjunto, representaram 0,07% dos dados registrados e ocorreram em 19 diferentes dias durante o período estudado.


Tabela 5.1 – Sumário da classificação da intensidade da WS em SBRJ durante o período estudado.

<b>Intensidade</b>	<b>Nº de dados</b>	<b>Porcentagem</b>
Leve	3.072.801	99,93%
Moderada	2.126	0,07%
Forte	53	
Severa	1	
Total	3.074.981	100%

## 5.2. VARIABILIDADE ANUAL DAS OCORRÊNCIAS DE WS

A Figura 5.1 apresenta a variabilidade anual dos casos de WS moderada (azul), forte (vermelho) e severa (amarelo) durante os anos analisados. As barras das classes forte e severa correspondem ao eixo da direita, pois foi aplicado um fator de escala com o intuito de facilitar a visualização desses registros, já que eles ocorrem em menor quantidade. É possível observar uma maior variabilidade na ocorrência dos casos moderados em relação aos classificados como fortes, os quais foram observados aproximadamente 10 vezes por ano, exceto em 2018, que obteve apenas 1 registro. Destaca-se ainda que, em 2016, os dados compreendem apenas o período entre 01 de outubro e 31 de dezembro e, em 2019, os dados são até o dia 30 de setembro. Além disso, nota-se que o único registro de intensidade classificada como severa ocorreu em 2020.

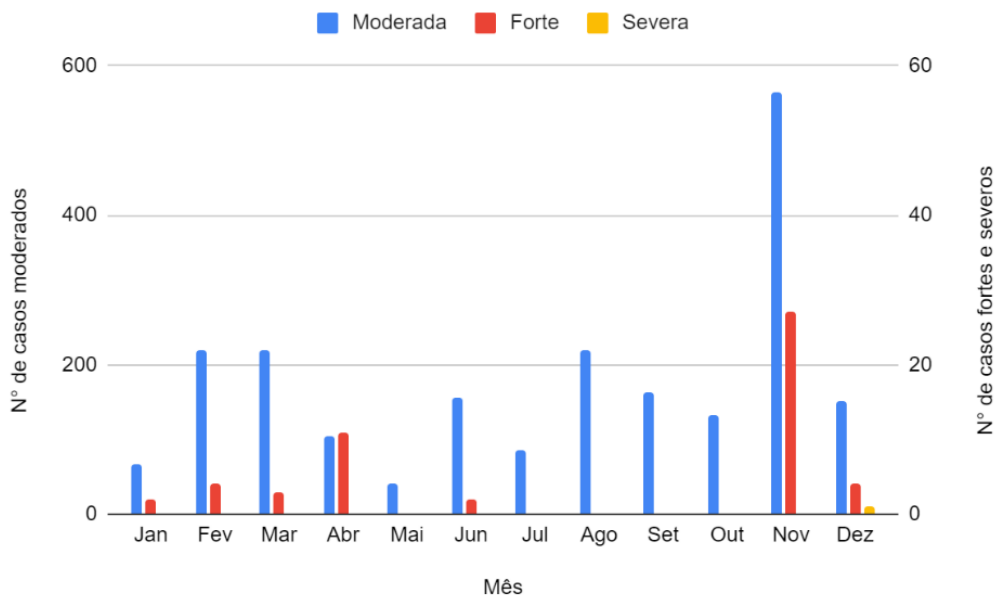
Figura 5.1 – Ocorrência de WS por ano e intensidade



## 5.3. VARIABILIDADE MENSAL DAS OCORRÊNCIAS DE WS

A variabilidade mensal dos casos de WS é apresentada na Figura 5.2. Evidencia-se uma maior ocorrência em novembro, tanto para a classe moderada quanto para a forte. Além disso, nota-se que, de forma geral, os eventos classificados como forte foram mais comuns entre novembro e abril, meses entre o final da primavera e início do outono. Observa-se ainda que o único registro de intensidade classificada como severa ocorreu em dezembro.

Figura 5.2 - Ocorrência de WS por mês e intensidade



#### 5.4. VARIABILIDADE HORÁRIA DAS OCORRÊNCIAS DE WS

Em relação à variabilidade horária (Figura 5.3), é possível notar uma variação ao longo do dia, com menor quantidade de registros entre 01 e 04h e entre 11 e 16h (horário local). Houve maior ocorrência de casos fortes entre 16 e 23h, com pico às 19h, horário que ocorreu o único caso de WS classificada como severa. Além disso, destacam-se duas faixas com maior ocorrência de eventos moderados, uma entre os horários de 5 a 10h e outra de 17 a 01h. Nesses horários, a estrutura da CLA está em transição entre seu perfil diurno e noturno, alterando assim o perfil vertical do vento. Ademais, esses horários coincidem com os de maior número de pousos e decolagens em SBRJ (Figura 5.4), aumentando o risco oferecido para as operações de pouso e decolagem no local.



Figura 5.3 - Ocorrência de WS por hora e intensidade

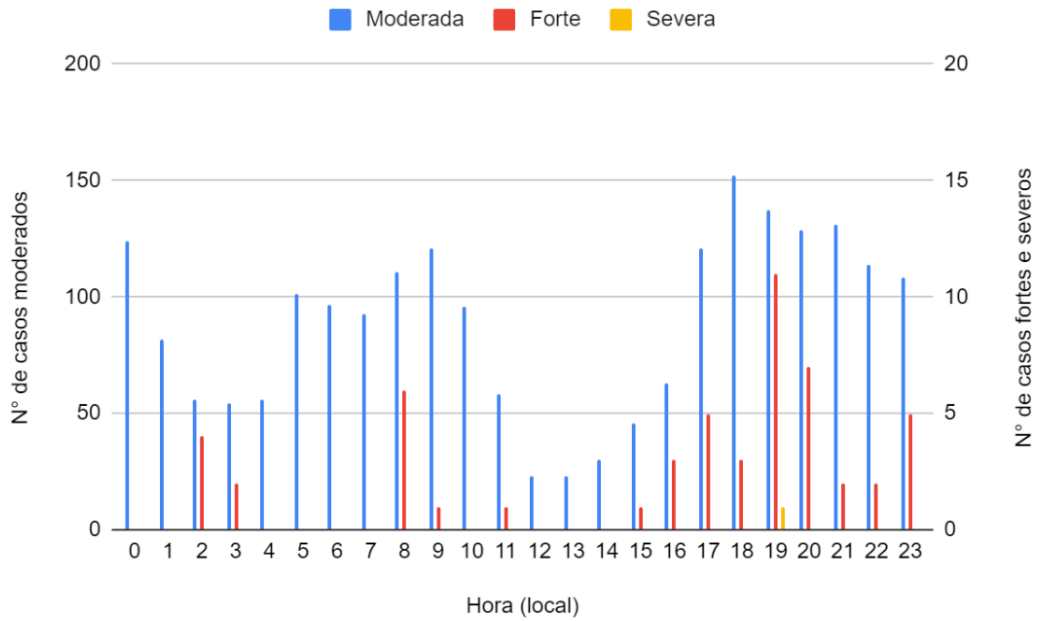



Figura 5.4 – Média horária de pousos e decolagens em SBRJ no ano de 2019



Fonte: Adaptado de DECEA (2019)

### 5.5. OCORRÊNCIA DE WS POR FAIXA DE ALTURA

As ocorrências de WS também foram analisadas conforme a sua faixa de altura. Como apresentado pela Tabela 5.2, pode-se observar que a maioria dos casos moderados ocorreu em

alturas abaixo de 100m (93,70%), e que todas as intensidades classificadas como fortes ou severas foram registradas abaixo de 100m.

Tabela 5.2 – Ocorrência de WS abaixo de 100m por classe de intensidade

<b>Intensidade da WS</b>	<b>Porcentagem</b>
	Altura (Z) ≤ 100m
<b>Moderada</b>	93,70 %
<b>Forte</b>	100 %
<b>Severa</b>	100 %

Devido à essa predominância de ocorrência de WS forte e severa abaixo dos primeiros 100m, também foram analisadas as ocorrências em faixas de altura inferiores, como apresentado pela Tabela 5.3. Nota-se então que a maioria dos casos fortes, e o único registro classificado como severo, ocorreu em 30m, resultado similar com o obtido por Ribeiro *et al.* (2019) para SBGR. Além disso, não houve registro de WS forte em alturas acima de 70m. Ou seja, os casos com maior intensidade ocorreram em maior proximidade com a superfície, situação que representa criticidade para as operações de pouso e decolagem, conforme justificado anteriormente pelo trabalho.

Tabela 5.3 – Ocorrência de WS forte e severa por faixa de altura detectada abaixo de 100m

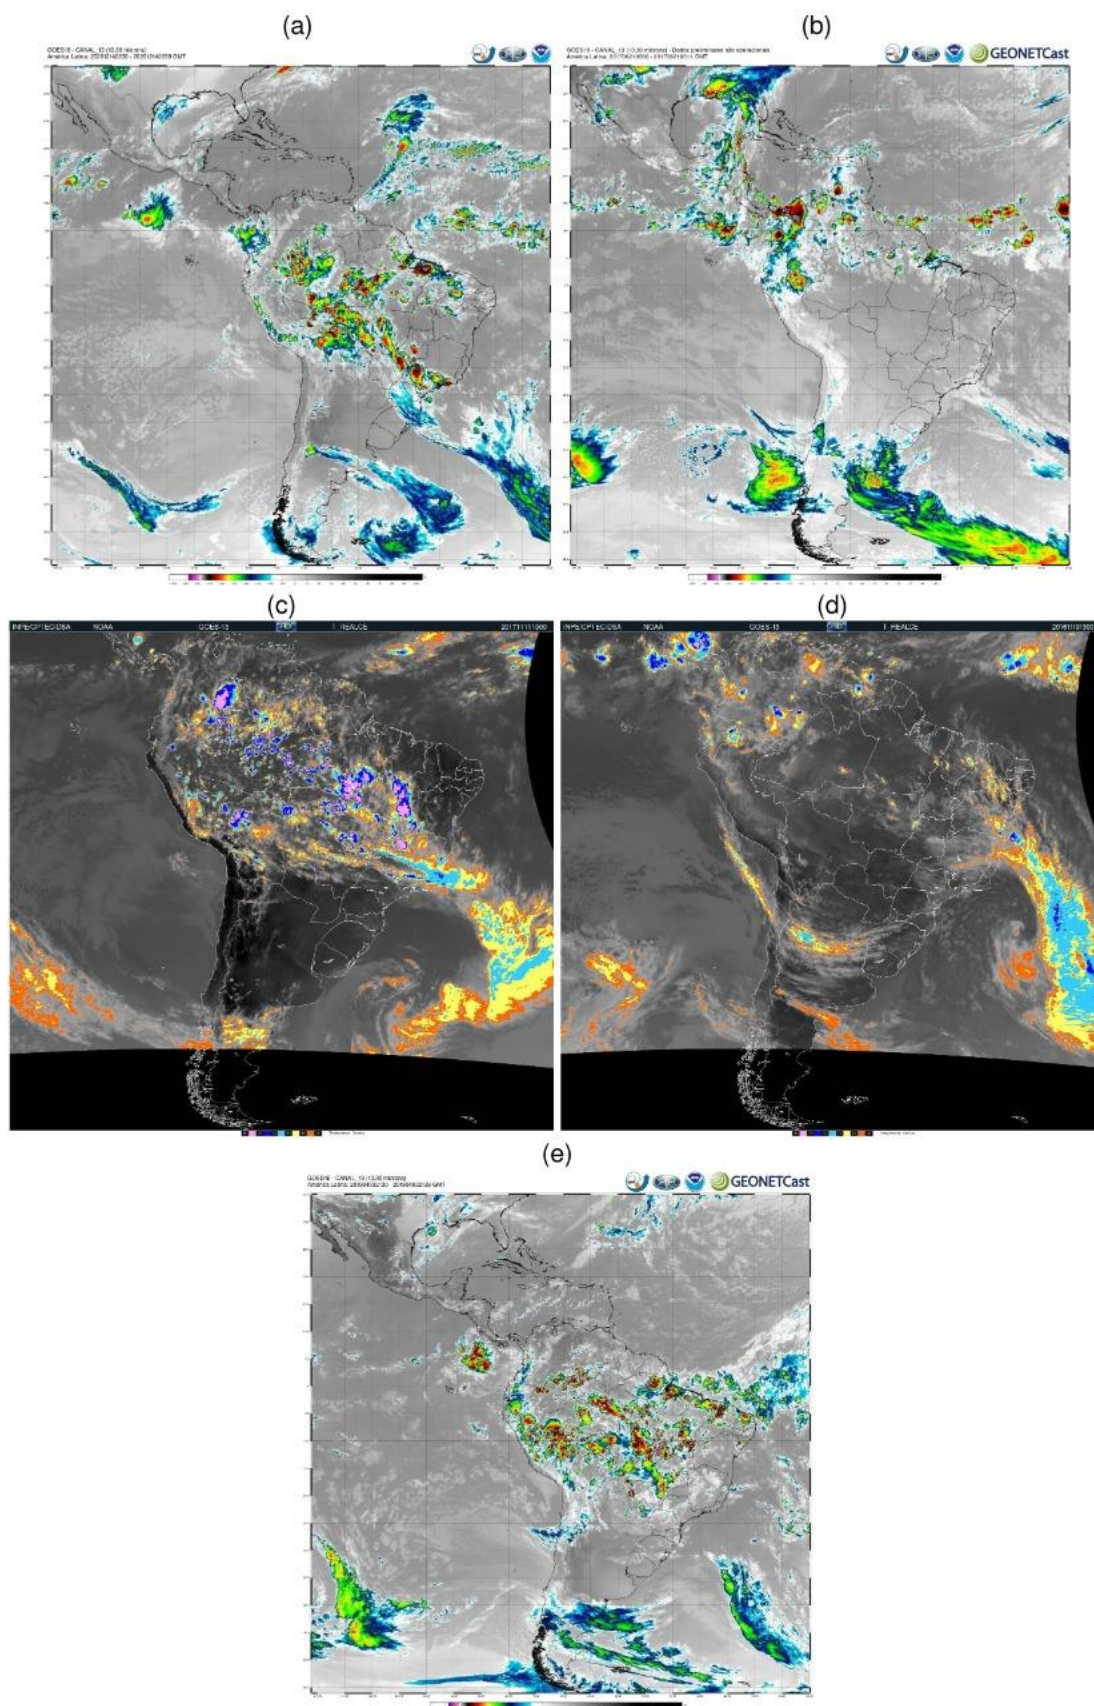
<b>Intensidade da WS</b>	<b>Altura</b>				
	<b>30m</b>	<b>40m</b>	<b>50m</b>	<b>60m</b>	<b>70m</b>
<b>Forte</b>	68,5 %	20,4%	7,4%	1,8%	1,8%
<b>Severa</b>	100 %	-	-	-	-

## 5.6. CONDIÇÕES METEOROLÓGICAS NOS CASOS DE WS FORTE

Para identificar quais fenômenos atmosféricos estiveram associados à ocorrência de WS forte, foram avaliadas as cartas sinóticas e imagens de satélite dos 19 dias em que essa intensidade ocorreu durante o período deste estudo, incluindo o caso severo. Como ilustrado pela Figura 5.5, os sistemas atuantes foram classificados em:

- Tempestade (Figura 5.5a): presença de nebulosidade convectiva próxima da área de estudo, não causada pela atuação de um sistema frontal no estado;
- Cavado (Figura 5.5b): presença de nebulosidade não convectiva e não causada por diferença de massas de ar;
- Frontal (Figura 5.5c): sistema frontal atuando no estado;
- Pós frontal (Figura 5.5d): após a passagem de um sistema frontal pelo estado;
- Não identificado (Figura 5.5e): dias em que não houve atuação de algum sistema frontal, sem presença de nebulosidade estratiforme ou convecção isolada próxima à área de estudo.

Figura 5.5 – Exemplo de imagem de satélite das condições tempestade (a), cavado (b), frontal (c), pós frontal (d) e não identificado (e)



Fonte: CPTEC

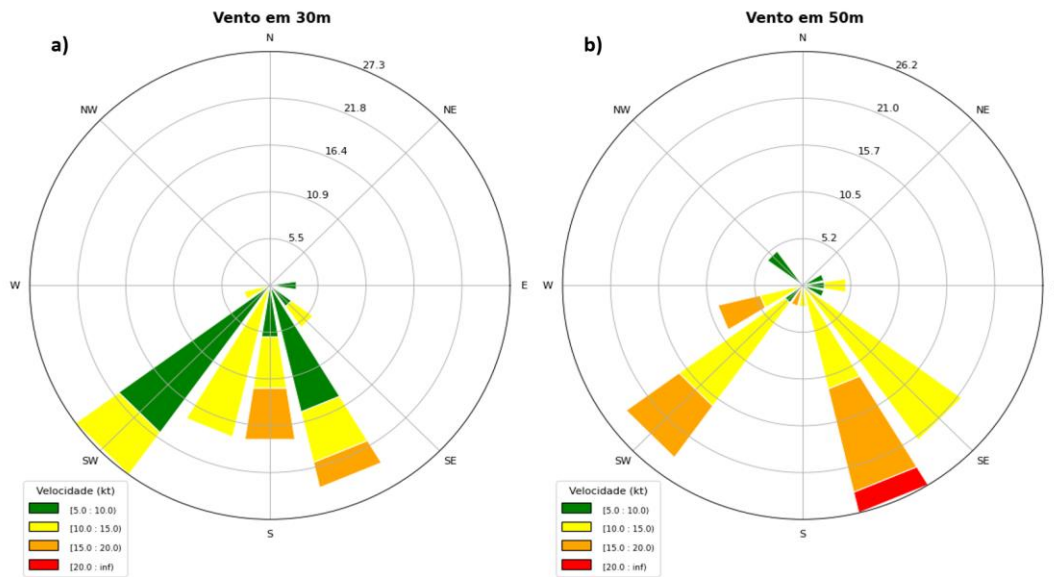
A Tabela 5.4 apresenta então um resumo das condições meteorológicas identificadas e nota-se que, dos casos analisados, houve uma evidente associação com a passagem de sistemas frontais, representando 8 dos 19 dias avaliados ao agrupar os dias frontais e pós frontais.

Tabela 5.4 – Resumo das condições meteorológicas associadas aos eventos de WS forte

<b>Condição meteorológica</b>	<b>Nº de dias</b>
Tempestade	2
Cavado	3
Frontal	4
Pós frontal	4
Não identificado	6

Além disso, os eventos classificados como fortes foram associados a ventos de quadrante sul, fato evidenciado pela Figura 5.6 que apresenta uma rosa dos ventos, para as alturas de 30 e 50 metros, utilizando dados dos horários em que a intensidade da WS foi classificada como forte. Destaca-se um predomínio de ventos sudoeste, associados aos eventos frontais, e de sul-sudeste, associados à circulação de brisa marítima no local, escoamento predominante nos casos com origem classificada como não identificada.


Figura 5.6 – Rosa dos ventos para as alturas de 30 (a) e 50 (b) metros nos casos de WS forte



### 5.6.1. Evento de WS forte: 18/11/2016


Para ilustrar os fatores envolvidos na ocorrência de WS forte, foi escolhido um caso que ocorreu no dia 18/11/2016. A Figura 5.7 apresenta a variação da intensidade da WSmax ao longo do evento, com as linhas pontilhadas indicando os limiares de intensidade moderada e forte. Destaca-se então que os valores foram pelo menos moderados entre 18 e 23h (local), e fortes entre 19h e 20:45, sendo assim, um evento de duração considerável.

Figura 5.7 – Variação temporal da intensidade da WS no dia 18/11/16



Esse caso foi associado à passagem de um Sistema Frontal e a Figura 5.8 apresenta a imagem do satélite GOES-13, no canal infravermelho, no horário das 22Z (20h local). Nota-se a presença de um sistema frontal atuando no estado, com uma convergência noroeste-sudeste ao norte e um ciclone no Oceano Atlântico.

Figura 5.8 – Imagem do satélite GOES13 no canal infravermelho às 22z do dia 18/11/2016



Fonte: CPTEC

Ao consultar o METAR entre 20Z do dia 18/11/2016 e 01Z do dia 19/11/2016 (Figura 5.9), horários que compreendem o período apresentado anteriormente pela Figura 5.7, é possível observar a diminuição da visibilidade horizontal para 5000m e chuva fraca a partir das 21Z. Com relação aos ventos em superfície, a direção predominante era próxima de sudoeste, com velocidades variando entre 7 e 15 kt e rajadas entre 22 e 25 kt.




Figura 5.9 – METAR durante o evento

Data/Hora	Mensagem
18/11/2016 20:00	METAR SBRJ 182000Z 23012KT 9999 BKN015 OVC040 23/16 Q1011=
18/11/2016 21:00	METAR SBRJ 182100Z 24008KT 5000 -RA HZ BKN015 BKN040 22/16 Q1011=
18/11/2016 21:00	<b>SPECI SBRJ 182115Z 23009G22KT 5000 -RA HZ BKN015 BKN040 22/17 Q1011=</b>
18/11/2016 22:00	METAR SBRJ 182200Z 24012G23KT 5000 HZ BKN015 BKN040 22/15 Q1012=
18/11/2016 23:00	METAR SBRJ 182300Z 22007KT 5000 -RA BR BKN015 OVC030 20/17 Q1013=
19/11/2016 00:00	METAR SBRJ 190000Z 23012G25KT 6000 RA BKN020 OVC030 22/16 Q1013=
19/11/2016 00:00	<b>SPECI SBRJ 190040Z 23015G25KT 8000 -RA BKN015 OVC030 20/18 Q1013=</b>
19/11/2016 01:00	METAR SBRJ 190100Z 23015G27KT 9999 BKN015 OVC030 20/18 Q1014=

Fonte: REDEMET

Como apresentado pela Figura 5.7, às 20h houve um pico na intensidade da WS de 10,84 kt/100. Por isso, foram utilizados os dados de direção e velocidade do vento desse horário para ilustrar o perfil vertical no momento. No perfil de velocidade (Figura 5.10a), há uma rápida intensificação entre 30 e 50 metros, como notado pela inclinação da reta. No perfil de direção (Figura 5.10b), há uma variação de aproximadamente 10° na direção do vento entre 30 e 50 metros. Tais fatores, em conjunto, resultaram na WS forte registrada.

Figura 5.10 – Perfil Vertical da velocidade (a) e direção (b) do vento às 20h do dia 18/11/2016





## 5.7. MODELOS DE REGRESSÃO

A Tabela 5.5 apresenta os resultados obtidos pelos 4 modelos regressivos utilizados nesse trabalho. Evidencia-se que, considerando um mesmo tempo de previsão, o desempenho dos algoritmos é similar, com a maior variação entre eles ocorrendo em relação à quantidade de variáveis de entrada escolhidas, resultando em modelos de complexidades distintas. Para as previsões de 15 minutos, os valores de  $R^2$  variaram entre 0,8 e 0,82, com o Decision Tree apresentando o menor valor. Para os erros calculados, os valores de MAE e RMSE ficaram em torno de 0,28 (kt/100ft) e 0,44 (kt/100ft), respectivamente. Com relação ao número de variáveis de entrada selecionadas, a quantidade variou de 1 (Random Forest) até 7 (Linear Regression). Para as previsões de 30 minutos, há uma diminuição do  $R^2$  para aproximadamente 0,62, com o Decision Tree novamente apresentando o menor valor, e um aumento aproximado do MAE e RMSE para 0,42 e 0,62, respectivamente. Além disso, o número de variáveis escolhidas variou entre 1 (XGBoost) e 16 (Linear Regression). Nas previsões de 45 minutos, novamente há uma diminuição dos valores de  $R^2$ , com valores variando entre 0,43 (Random Forest) e 0,52 (XGBoost). Para esse horizonte de previsão, houve um aumento no MAE e RMSE para valores próximos de 0,52 (kt/100ft) e 0,73 (kt/100ft), respectivamente, e a quantidade de variáveis escolhidas ficou entre 4 (Decision Tree) e 16 (Linear Regression). Já para as previsões de 60 minutos, a tendência de diminuição nos valores de  $R^2$  se mantém e também há um aumento nos erros. Ou seja, conforme maior o tempo de previsão, maior o erro, resultando em previsões com menor qualidade.

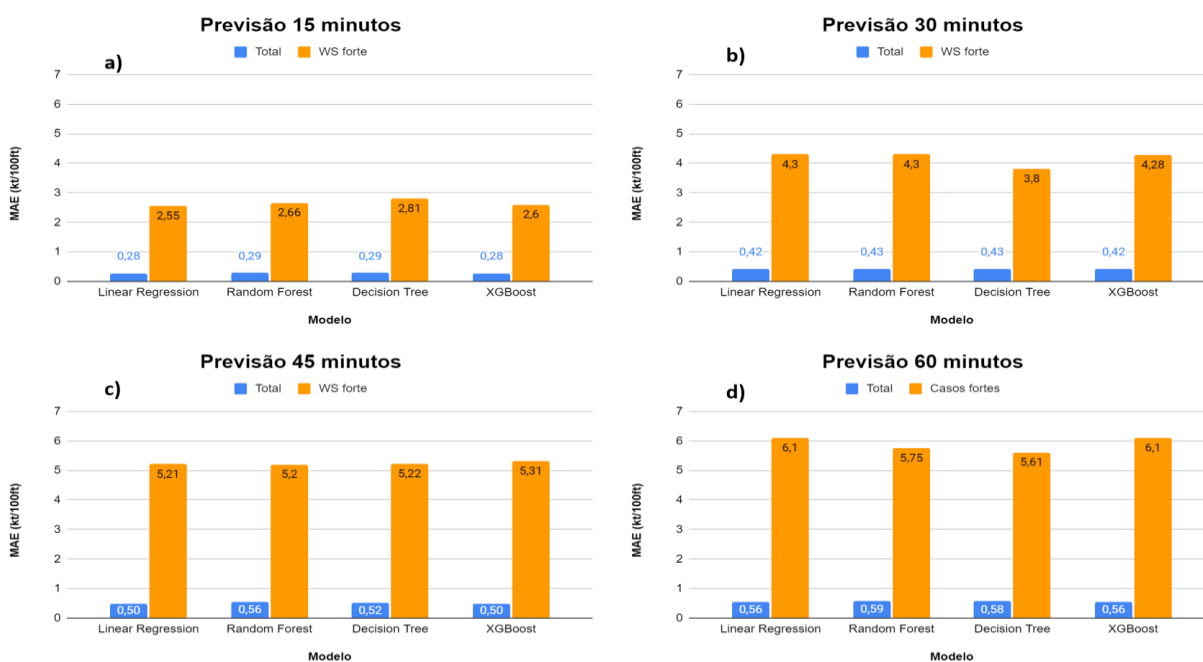
Tabela 5.5 – Resultado das previsões dos modelos finais construídos para cada tempo de previsão

<b>Modelo</b>	<b>Tempo de previsão</b>	<b><math>R^2</math></b>	<b>MAE (kt/100ft)</b>	<b>RMSE (kt/100ft)</b>	<b>Nº de variáveis</b>
<b>Linear Regression</b>	15min	0,82	0,28	0,44	7
	30min	0,65	0,42	0,61	16
	45min	0,51	0,5	0,73	16
	60min	0,4	0,56	0,8	16
<b>Decision Tree</b>	15min	0,8	0,29	0,44	13
	30min	0,62	0,43	0,64	5
	45min	0,47	0,52	0,76	4
	60min	0,33	0,58	0,85	17

<b>Random Forest</b>	15min	0,82	0,29	0,44	1
	30min	0,63	0,43	0,63	9
	45min	0,43	0,56	0,78	6
	60min	0,34	0,59	0,84	2
<b>XGBoost</b>	15min	0,82	0,28	0,43	4
	30min	0,64	0,42	0,62	1
	45min	0,52	0,5	0,72	14
	60min	0,41	0,56	0,8	11

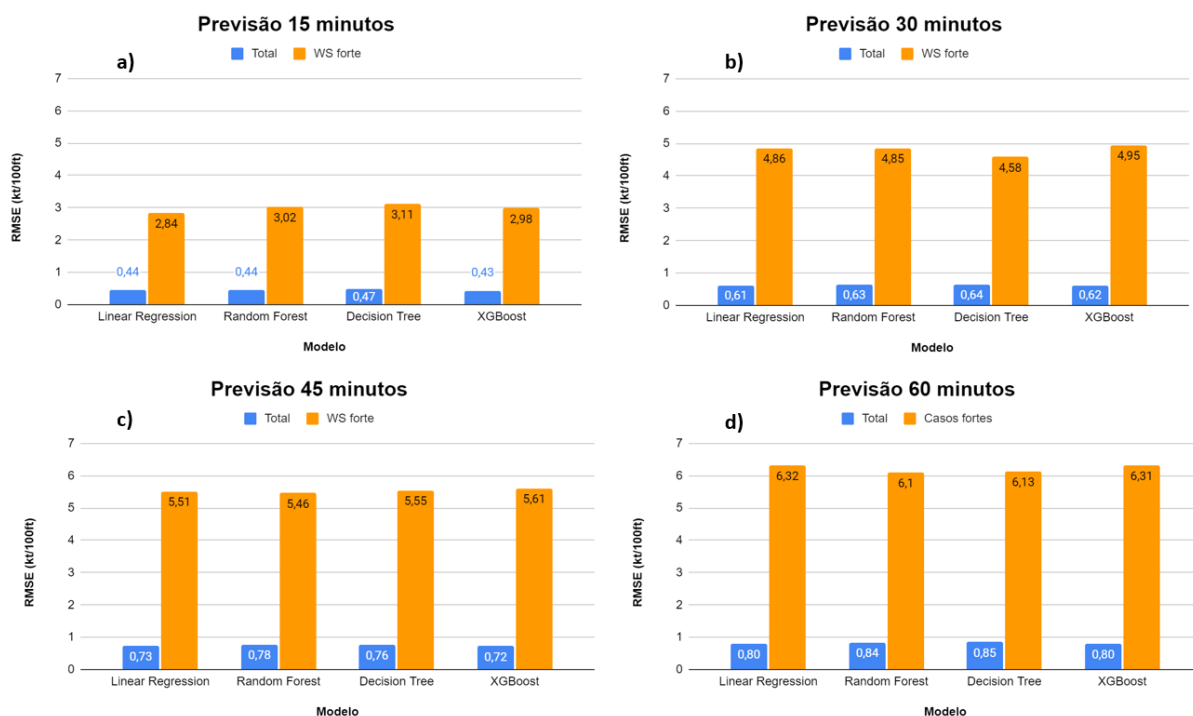
No entanto, para proporcionar uma melhor segurança de voo, o interesse maior é obter um modelo que tenha bom desempenho nas condições com WS forte. Por isso, também foram calculados os erros nesses casos para que o melhor resultado fosse escolhido. Nota-se então que, nessas condições, o MAE (Figura 5.11) e a RMSE (Figura 5.12) aumentam significativamente e há uma maior variação desses valores entre os modelos. Para o MAE nas previsões de 15 minutos, o menor valor é obtido pelo Linear Regression (Figura 5.11a) com 2,55 (kt/100ft) e, nas previsões de 30 minutos, pelo Decision Tree (Figura 5.11b), com 3,8 (kt/100ft). Já para as previsões de 45 e 60 minutos, os menores valores são obtidos pelo Random Forest (Figura 5.11c) e Decision Tree (Figura 5.11d), respectivamente.

Figura 5.11 –MAE das previsões de 15 (a), 30 (b), 45 (c) e 60 (d) minutos, para a totalidade dos dados e durante condições de WS forte



Em relação ao RMSE, o modelo Linear Regression também apresentou o menor valor nas previsões de 15 minutos (Figura 5.12a), com 2,84 (kt/100ft), e, para as previsões de 30 minutos, novamente o Decision Tree apresentou o menor valor (Figura 5.12b), com 4,58 (kt/100ft). Para as previsões de 45 (Figura 5.12c) e 60 minutos (Figura 5.12d), o modelo Random Forest apresentou os menores valores, com 5,46 (kt/100ft) e 6,1 (kt/100ft), respectivamente. Nota-se também que para 60 minutos a RMSE foi bem próxima entre o Random Forest e o Decision Tree, com a diferença ocorrendo na segunda casa decimal. Mas, o MAE nesse tempo de previsão foi menor para o Decision Tree. Desta forma, para as previsões de 15, 30, 45 e 60 minutos, considerou-se, respectivamente, o Linear Regression, Decision Tree, Random Forest e Decision Tree como os melhores modelos construídos, devido ao menor erro nas condições de WS forte. Por isso, nas seções seguintes, esses serão os modelos utilizados nas análises.


Figura 5.12 - Comparação do RMSE dos modelos nas previsões de 15 (a) e 30 (b), 45(c) e 60(d) minutos, para a totalidade dos dados e durante condições de WS forte



Essa queda de desempenho nas previsões em condições de WS forte pode ser explicada, em parte, pela baixa frequência desses eventos, conforme apresentado anteriormente pela Tabela 5.1. De forma complementar, a Figura 5.13 apresenta a distribuição de frequência dos valores de WSmax para o conjunto de dados de teste. Ressalta-se ainda que, das

aproximadamente 92 mil observações do conjunto de treino, apenas 33 eram de valores classificados como fortes. Já no conjunto teste, das aproximadamente 29 mil linhas, apenas 10 possuíam essa intensidade. Com isso, durante o processo de construção e treinamento dos modelos houve poucos exemplos para que os algoritmos fossem capazes de aprender corretamente as relações entre as variáveis de entrada disponíveis e o alvo da previsão e, assim, ser capaz de realizar melhores previsões para essas situações.

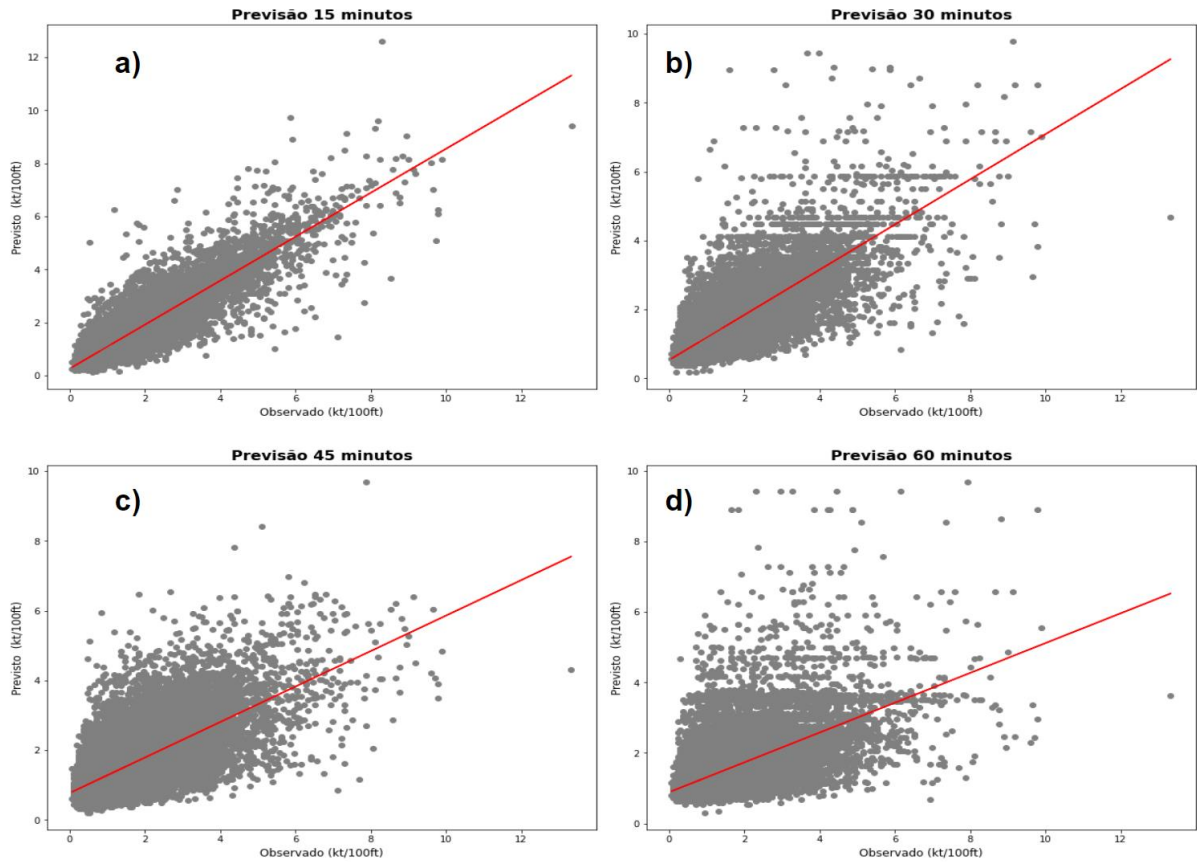
Figura 5.13 – Distribuição de frequência da WSmax no conjunto de dados de teste



### 5.7.1. Dispersão entre observado e previsto

A Figura 5.13 apresenta a dispersão entre os valores observados e previstos, para cada tempo de previsão, para observar a relação entre ambos. Para 15 minutos (Figura 5.14a), pode-se notar uma tendência positiva entre os dados, com padrão de inclinação da reta de melhor ajuste próximo a 45°, o que indica que os valores possuem uma boa correlação. Nota-se também uma maior dispersão para valores observados acima de, aproximadamente, 5 (kt/100ft). Esse padrão se deteriora ao aumentar o tempo de previsão, onde nota-se uma diminuição na inclinação das retas e uma maior dispersão dos pontos.

Figura 5.14 – Dispersão entre os valores observados e previstos de WSmax para as previsões de 15 (a), 30 (b), 45 (c) e 60 minutos (d)



Além disso, a Tabela 5.6 apresenta, para cada tempo de previsão, quais foram as variáveis finais utilizadas por cada modelo. Nota-se uma dependência de informações como a intensidade da WSmax atual e a média desse valor nos últimos 15 e 30 minutos, em todos os tempos de previsão.

Tabela 5.6 – Variáveis selecionadas por cada modelo para cada tempo de previsão

<b>Modelo</b>	<b>Tempo de Previsão</b>	<b>Variáveis Selecionadas</b>
Linear Regression	15min	WSmax, $\Delta$ WS, $\Delta$ V, WSmax média 15min antes, WSmax média 30min antes, WSmax 15min antes, WSmax 30min antes
Decision Tree	30min	WSmax, $\Delta$ WS, WSmax média 15min antes, WSmax média 30min antes, WSmax 15min antes

Random Forest	45min	WSmax, $\Delta$ WS, WSmax média 15min antes, WSmax média 30min antes, WSmax 15min antes, WSmax 30min antes
Decision Tree	60min	Todas exceto Altura da WSmax nos últimos 30 minutos

### 5.7.2. Análise dos Resíduos

De forma complementar aos erros analisados, também pode-se avaliar os resíduos das previsões. A partir da Figura 5.15, a qual apresenta a distribuição de frequência dos resíduos obtidos nos dados de teste, é possível observar que a maioria dos valores está centrada próxima de zero, o que é um bom indicativo, para todos os tempos de previsão. Além disso, a Tabela 5.7 apresenta os valores da média, desvio padrão, máximo e mínimo dos resíduos obtidos.

Figura 5.15 – Distribuição dos resíduos das previsões de 15 (a), 30 (b), 45(c) e 60 minutos (d)




Tabela 5.7 – Informações dos resíduos para cada tempo de previsão

<b>Tempo de Previsão</b>	<b>Média (kt/100ft)</b>	<b>Desvio (kt/100ft)</b>	<b>Máximo (kt/100ft)</b>	<b>Mínimo (kt/100ft)</b>
<b>15min</b>	0,005	0,4	5,64	- 5,07
<b>30min</b>	0,01	0,64	8,66	-7,35
<b>45min</b>	0,004	0,78	9,01	-5,12
<b>60min</b>	0,02	0,85	9,71	-7,23

Da mesma forma que foi feito com o MAE e RMSE, também foram analisados os resíduos das previsões nos horários nos quais o valor da WS foi classificado como forte (Tabela 5.8). Nesses casos, para as previsões de 15, 30, 45 e 60 minutos, a média dos resíduos aumentou para, 2,55 (kt/100ft), 3,63 (kt/100ft), 5,41 (kt/100ft) e 5,60 (kt/100ft), respectivamente. Ou seja, nota-se novamente a queda no desempenho das previsões durante tal situação e um padrão de subestimação das previsões para todos os tempos considerados.

Tabela 5.8 – Comparação entre o observado e previsto nos casos de WS forte no conjunto de dados teste

<b>Data</b>	<b>Observado (kt/100ft)</b>	<b>Previsão 15 min (kt/100ft)</b>	<b>Previsão 30 min (kt/100ft)</b>	<b>Previsão 45 min (kt/100ft)</b>	<b>Previsão 60 min (kt/100ft)</b>
<b>14/01/2020 21:45</b>	<b>9,60</b>	8,03	7,15	4,22	2,30
<b>14/01/2020 22:15</b>	<b>9,89</b>	8,14	7,02	4,85	5,54
<b>21/02/2020 16:30</b>	<b>9,66</b>	7,01	2,94	6,05	3,36
<b>03/03/2020 08:15</b>	<b>9,01</b>	8,15	5,88	5,26	4,87
<b>03/03/2020 08:45</b>	<b>9,12</b>	7,78	9,79	6,40	6,57
<b>04/03/2020 17:15</b>	<b>9,18</b>	7,60	8,53	4,50	2,46
<b>25/11/2020 02:00</b>	<b>9,78</b>	6,25	8,53	3,50	8,89

<b>14/12/2020 19:30</b>	<b>9,72</b>	5,08	4,49	4,07	2,44
<b>14/12/2020 19:45</b>	<b>13,33</b>	9,40	4,67	4,32	3,62
<b>15/12/2020 17:30</b>	<b>9,78</b>	6,10	3,82	3,90	2,96

Por fim, um exemplo de iniciativa que pode ser feita para reduzir o erro dos modelos é corrigir o viés das previsões ao adicionar (devido a subestimação) o erro médio (média dos resíduos) às previsões realizadas (Tabela 5.9). Desta forma, o erro remanescente das previsões seria devido à variância (a mudança de desempenho do modelo em diferentes conjuntos de dados) e um erro inerente dos modelos.

Tabela 5.9 – Comparação entre o valor observado e previsto nos casos de WS forte, no conjunto de dados teste, caso fosse feita uma correção do viés

<b>Data</b>	<b>Observado (kt/100ft)</b>	<b>Previsão 15 min (kt/100ft)</b>	<b>Previsão 30 min (kt/100ft)</b>	<b>Previsão 45 min (kt/100ft)</b>	<b>Previsão 60 min (kt/100ft)</b>
<b>14/01/2020 21:45</b>	<b>9,60</b>	10,58	10,78	9,42	7,91
<b>14/01/2020 22:15</b>	<b>9,89</b>	10,69	10,65	10,05	11,15
<b>21/02/2020 16:30</b>	<b>9,66</b>	9,56	6,57	11,25	8,97
<b>03/03/2020 08:15</b>	<b>9,01</b>	10,7	9,51	10,46	10,48
<b>03/03/2020 08:45</b>	<b>9,12</b>	10,33	13,42	11,6	12,18
<b>04/03/2020 17:15</b>	<b>9,18</b>	10,15	12,16	9,7	8,07
<b>25/11/2020 02:00</b>	<b>9,78</b>	8,8	12,16	8,7	14,5
<b>14/12/2020 19:30</b>	<b>9,72</b>	7,63	8,12	9,27	8,05
<b>14/12/2020 19:45</b>	<b>13,33</b>	11,95	8,3	9,52	9,23
<b>15/12/2020 17:30</b>	<b>9,78</b>	8,65	7,45	9,1	8,57



## 6. CONCLUSÕES

Este trabalho foi o primeiro a apresentar um estudo sobre a ocorrência e previsão de *Wind Shear* no Aeroporto Santos Dumont e preenche uma lacuna de pesquisas voltadas ao tema em aeroportos brasileiros. Foi possível observar que, na área de estudo, o fenômeno, geralmente, apresenta intensidade classificada como leve, a qual normalmente não é sentida e relatada pelos pilotos e, portanto, não foi analisada em detalhe.

Em relação à variabilidade mensal, houve uma alta quantidade de casos registrados no mês de novembro e, de forma geral, nos meses de primavera e verão. Para a ocorrência horária, foi possível notar uma maior frequência entre o final da tarde e início da noite, especialmente às 19h para a classe forte. Além disso, ao analisar a altura de ocorrência, observou-se que todos os casos fortes, e o evento severo, ocorreram abaixo de 100 metros, geralmente na faixa entre 30 e 70 metros, com predominância em 30 metros.

Do ponto de vista das condições meteorológicas associadas à ocorrência dos casos de classificados como forte, notou-se uma maior associação com a presença de sistemas frontais atuando no estado e também com condições pós frontais. De forma geral, a maioria dos eventos com essa intensidade esteve associada a ventos de quadrante sul, principalmente entre sudeste e sudoeste.

Foram construídos modelos de regressão para previsões de *Wind Shear* em intervalos de 15, 30, 45 e 60 minutos. Para um mesmo tempo de previsão, os modelos obtiveram desempenho similar ao considerar a totalidade dos dados, com erros próximos de zero que aumentaram ao aumentar o tempo de previsão. Porém, considerando apenas as observações com intensidade classificada como forte, os erros foram maiores e as previsões subestimaram os valores observados. Ressalta-se que, em termos operacionais, um alerta com 15 minutos de antecedência, tempo de previsão que obteve o menor erro, é o suficiente para que uma tripulação entre em procedimento de espera até que as condições melhorem para, então, poderem prosseguir com o pouso. No entanto, após a remoção do viés dos modelos, foi obtido um bom desempenho para as previsões com antecedência de até 60 minutos. Assim, os produtos desenvolvidos podem ser utilizados operacionalmente.

Como trabalhos futuros para entender melhor a gênese do fenômeno em SBRJ, deve-se estudar as características dos sistemas frontais associados à ocorrência de eventos classificados como fortes e, também, avaliar a influência dos relevos situados nos setores sudoeste e oeste do aeroporto. Além disso, seria importante analisar dados de relatos dos pilotos para observar se

há correlação com os critérios de intensidade estabelecidos pela Organização de Aviação Civil Internacional, ou se outras condições devem ser levadas em consideração para o estudo do fenômeno. Em termos de previsão, é necessário avaliar o uso de outras variáveis como temperatura, pressão, visibilidade e umidade relativa, para identificar se há uma melhoria nas previsões realizadas. Em conjunto, também podem ser testados outros tipos de aprendizado de máquina, como o uso de redes neurais.

Apesar dos casos fortes e severos serem pouco frequentes, é vital para a segurança de voo que se estude-os, para que se tenha um melhor conhecimento das condições associadas à sua ocorrência. Por isso, torna-se fundamental a continuidade do monitoramento da *Wind Shear* para que, posteriormente, seja possível realizar estudos que investiguem um período maior de tempo, a fim de encontrar novas informações sobre as características da ocorrência do fenômeno no Aeroporto Santos Dumont. Desta forma, também será possível fornecer mais dados aos algoritmos, com o intuito de melhorar o treinamento dos modelos e, conseqüentemente, suas previsões.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- AIRBUS. Wind shear: an invisible enemy to pilots? Safety first, v. 19, n. January, p. 1–13, 2015. Disponível em: <[https://safetyfirst.airbus.com/app/themes/mh\\_newsdesk/pdf.php?p=15543](https://safetyfirst.airbus.com/app/themes/mh_newsdesk/pdf.php?p=15543)>.
- Almeida, M. V. 2009. Aplicação De Técnicas De Redes Neurais Artificiais Na Previsão De Curtíssimo Prazo Da Visibilidade E Teto Para O Aeroporto De Guarulhos – SP.” Tese de Doutorado, COPPE/UFRJ, Universidade Federal do Rio de Janeiro, Brasil.
- Andrade, K.M. 2005, ‘Climatologia e comportamento dos sistemas frontais sobre a América do Sul’, Instituto Nacional de Pesquisas Espaciais (INPE).
- AOPA. WEATHER: THE LOWDOWN ON JET STREAMS. Disponível em: <<https://www.aopa.org/news-and-media/all-news/2018/september/flight-training-magazine/weather-jet-stream>>.
- AVIADOR, G. DO. Forças que atuam em um avião. Disponível em: <<https://guiadoaviador.wordpress.com/2017/03/29/forcas-que-atuam-em-um-avi/>>.
- Bjerknes, J. 1919, ‘ON THE STRUCTURE OF MOVING CYCLONES’, *Monthly Weather Review*, vol. 47, no. 2, pp. 95–9, viewed 2 June 2019, <<http://journals.ametsoc.org/doi/abs/10.1175/1520-0493%281919%2947%3C95%3AOTSOMC%3E2.0.CO%3B2>>
- BRAHIMI, Tayeb. Using artificial intelligence to predict wind speed for energy application in saudi arabia. *Energies*, v. 12, n. 24, p. 4669, 2019.
- Chan, P. W. (2014). Performance and Aviation Applications of Minisodars at Hong Kong International Airport. *Meteorological Applications*. 21, pp. 62-73
- Chan, P.W. (2017), Severe wind shear at Hong Kong International Airport: climatology and case studies. *Met. Apps*, 24: 397-403. <https://doi.org/10.1002/met.1637>

- DECEA, Departamento de Controle do Espaço Aéreo. Anuário Estatístico de Tráfego Aéreo 2019. 2019.
- Dereczynski, C.P. & Menezes, W.F. 2016, *Meteorologia Da Bacia De Campos, Meteorologia e Oceanografia*, Elsevier Editora Ltda
- Domingos, Pedro. (2012). A Few Useful Things to Know About Machine Learning. *Commun. ACM*. 55. 78–87.
- ENERGY, R. **Wind Speed Data**. Disponível em: <<http://rlsenergy.com/products/wind-power/wind-speed-data/>>.
- FEDERAL AVIATION ADMINISTRATION. Pilot Windshear Guide (1988). FAA, Advisory Circular No. 00-54.
- FICHTL, George H.; CAMP, Dennis W.; FROST, Walter. Sources of low-level wind shear around airports. *Journal of Aircraft*, v. 14, n. 1, p. 5–14, 1977.
- FLAT, Scintec; SODARS, Array. Theory Manual. (2017). v1.03
- França, G.B., Almeida, M. V., Bonnet, S. M. & Albuquerque Neto, F. L. (2018) Nowcasting model of low wind profile based on neural network using SODAR data at Guarulhos Airport, Brazil, *International Journal of Remote Sensing*, 39:8, 2506-2517, DOI: 10.1080/01431161.2018.1425562
- França, G. B., M. V. Almeida, and A. C. Rossete. 2016. “An Automated Nowcasting Model of Significant Instability Events in the Flight Terminal Area of Rio De Janeiro, Brazil.” *Atmospheric Measurement Techniques* 9: 2335–2344. doi:10.5194/amt-9-2335-2016.
- Gerz, T.; Holzäpfel, F.; Gerling, W.; Scharnweber, A.; Frech, M.; Kober, K.; Dengler, K. & Rahm, S. (2009). The Wake Vortex Prediction and Monitoring System WSVBS Part II: Performance and ATC Integration at Frankfurt Airport. *Air Traffic Control Quart.* 17(4), pp. 323-346.
- GULTEPE, Ismail et al. A review of high impact weather for aviation meteorology. *Pure and applied geophysics*, v. 176, n. 5, p. 1869-1921, 2019.

HKO, IFALPA, GAPAN. 2010. Windshear and Turbulence in Hong Kong - information for pilots, 3rd edn. 40,

Hon, K.-K. Predicting Low-Level Wind Shear Using 200-m-Resolution NWP at the Hong Kong International Airport. *J. Appl. Meteorol. Clim.* 2020, 59, 193–206.

ICAO. Manual on Low-level Wind Shear. *Doc 9817 AN/449*, p. 213, 2005. Disponível em: <<https://www.skybrary.aero/bookshelf/books/2194.pdf>>.

Joffre, S.M. 1984: Power laws and the empirical representation of velocity and directional shear, *Journal of Applied Meteorology*, Vol. 23, Issue 8.

KAIMAL, Jagadish Chandran; FINNIGAN, John J. Atmospheric boundary layer flows: their structure and measurement. Oxford university press, 1994.

Li, L., Shao, A., Zhang, K. *et al.* Low-Level Wind Shear Characteristics and Lidar-Based Alerting at Lanzhou Zhongchuan International Airport, China. *J Meteorol Res* 34, 633–645 (2020). <https://doi.org/10.1007/s13351-020-9134-6>

MEDIUM. MACHINE LEARNING FOR BEGINNERS. Disponível em: <<https://medium.com/@sonish.sivarajkumar/machine-learning-for-beginners-96ab7061dcd>>.

MMA – MINISTÉRIO DO MEIO AMBIENTE. Relatório Ambiental Urbano Integrado. Disponível em: <<http://www.mma.gov.br/port/sqa/urbana/>>. Acesso em: 15 mar. 2007.

Oliveira, L.L., Vianello, R.L. & Ferreira, N.J. 2001, *Meteorologia Fundamental*, Edifapes, Erechim, RS. Vianello, R.L. & Alves, A.R. 1991, *Meteorologia básica e aplicações*, Universidade Federal de Viçosa, Viçosa, Minas Gerais.

Oliveira-Júnior, Jose & Terassi, Paulo & Gois, Givanildo. (2017). Estudo da circulação dos ventos na Baía de Guanabara/RJ, entre 2003 e 2013. *Revista Brasileira de climatologia*. 21. 59-80.

PIMENTEL, Luiz Cláudio Gomes et al. Caracterização do regime de vento em superfície na Região Metropolitana do Rio de Janeiro. **Eng. Sanit. Ambient.** Rio de Janeiro, v. 19, n. 2, p. 121-132, June 2014. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S1413-41522014000200121&lng=en&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-41522014000200121&lng=en&nrm=iso)>

Ribeiro, DP, Fisch, GF, Junior, JBVL, Sokabe, EDJR. (2017) Estudo da Ocorrência de Cisalhamento do Vento no Aeroporto Internacional de São Paulo. *Revista Conexão Sipaer*, Vol. 8, No. 2, pp. 54-65.

Ribeiro, D. P., Leal Junior, J. B. V., Fisch, G., Ramos, D. N. D. S., & Reuter, E. D. D. J. (2020). Cisalhamento do Vento no Aeroporto Internacional de São Paulo: Aspectos Observacionais e de Modelagem. *Revista Brasileira de Meteorologia*, v.35, n.2, 301-315.

Scikit-learn: Machine Learning in Python, Pedregosa *et al.*, *JMLR* 12, pp. 2825-2830, 2011.

Shun, C.M. and Chan, P.W. (2008) Applications of an infrared Doppler lidar in detection of wind shear. *Journal of Atmospheric and Oceanic Technology*, 25(5), 637–655.

SILVA, H.A.J.S. Análise das ocorrências de cisalhamento de vento no aeroporto de Guarulhos (SP) para a prevenção de acidentes aeronáuticos. Dissertação de Mestrado. Universidade de São Paulo (USP), São Paulo, SP, 2016.

SILVA, L. P. da, JESUS, N. de V. G., GOMES, D. J. C., et al. "ANÁLISE DAS CONDIÇÕES ATMOSFÉRICAS NA OCORRÊNCIA DE WINDSHEAR NO AEROPORTO INTERNACIONAL DE BELÉM: UM ESTUDO DE CASO (XX CBMET - 2018)", *Brazilian Journal of Development*, v. 7, n. 1, p. 8712–8721, 2021. DOI: 10.34117/bjdv7n1-590. Disponível em: <https://www.brazilianjournals.com/index.php/BRJD/article/view/23601/18969>.

SIMÃO, Alexander Coelho. Tesouras de Vento e a Segurança de Voo. Revista Conexão SIPAER, v. 4, n. 2, p. 149-189, 2013.

Stull, R.B., 1994. An introduction to boundary layer meteorology. [S.l: s.n.], 1988. v. 8.

Sucevic, Nikola & Djuriscic, Zeljko. (2012). INFLUENCE OF ATMOSPHERIC STABILITY VARIATION ON UNCERTAINTIES OF WIND FARM PRODUCTION ESTIMATION.

Vinícius Albuquerque de Almeida, Gutemberg Borges França & Haroldo Fraga de Campos Velho (2020). Short-range forecasting system for meteorological convective events in Rio de Janeiro using remote sensing of atmospheric discharges, International Journal of Remote Sensing, 41:11, 4372-4388, DOI: [10.1080/01431161.2020.1717669](https://doi.org/10.1080/01431161.2020.1717669)

Vogt, S., and P. Thomas. "SODAR—A useful remote sounder to measure wind and turbulence." Journal of wind engineering and industrial aerodynamics 54 (1995): 163-172.

Wai-Kin Wong, Cheong-Shing Lau, Pak-Wai Chan, "Aviation Model: A Fine-Scale Numerical Weather Prediction System for Aviation Applications at the Hong Kong International Airport", Advances in Meteorology, vol. 2013, Article ID 532475, 11 pages, 2013. <https://doi.org/10.1155/2013/532475>

WIKIPEDIA. Low-level windshear alert system. Disponível em: [https://en.wikipedia.org/wiki/Low-level\\_windshear\\_alert\\_system](https://en.wikipedia.org/wiki/Low-level_windshear_alert_system).

WILKS, D. S. Statistical methods in the atmospheric sciences. San Diego, CA: Academic Press (International Geophysics Series 91), 2006.

WOODFIELD, Alan A.; WOODS, John F. Worldwide experience of wind shear during 1981-1982. ROYAL AIRCRAFT ESTABLISHMENT BEDFORD, 1983.