



Universidade Federal do Rio de Janeiro - UFRJ

Centro de Ciências Matemáticas e da Natureza

Instituto de Geociências

Departamento de Meteorologia

PREVISÃO DE VISILIDADE E TETO NO AEROPORTO SANTOS DUMONT  
UTILIZANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA

Fabricio Magalhães Cordeiro

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Meteorologia (PPGM) da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do grau de Mestre em Meteorologia.

Orientadores: Gutemberg Borges França, *PhD*.

Francisco Leite de Albuquerque Neto, *DSc*.

Rio de Janeiro

Fevereiro de 2021

PREVISÃO DE VISILIDADE E TETO NO AEROPORTO SANTOS DUMONT  
UTILIZANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA

Fabricio Magalhães Cordeiro

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE  
GEOCIÊNCIAS DE PÓS-GRADUAÇÃO DA UNIVERSIDADE FEDERAL DO RIO  
DE JANEIRO, COMO PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO  
DO GRAU DE MESTRE EM METEOROLOGIA.

Examinada por:

---

Prof. Gutemberg Borges França, Ph.D.

---

Prof. Wallace Figueiredo Menezes, D. Sc.

---

Haroldo Fraga de Campos Velho, Ph.D.

---

Francisco Leite de Albuquerque Neto, D.Sc.

---

Cleber Souza Corrêa, D.Sc.

Rio de Janeiro – RJ

Fevereiro de 2021

## **AGRADECIMENTOS**

Agradeço a Deus por me proporcionar saúde e perseverança para concluir essa etapa da minha vida.

Agradeço ao DECEA pela confiança na minha indicação para representar a Força Aérea nesse acordo junto à UFRJ.

Quero agradecer também ao ICEA e à INFRAERO pela disponibilidade dos dados, que foram essenciais para elaboração dessa pesquisa.

Agradeço aos meus orientadores, Prof. Gutemberg Borges França e Dr. Francisco Leite de Albuquerque Neto, pela paciência, orientações imprescindíveis e incentivos em todos os momentos.

Não poderia deixar de agradecer aos companheiros do Laboratório de Meteorologia Aplicada (LMA), que em algum momento dessa jornada de dois anos e meio contribuíram de alguma forma para a construção desse trabalho.

Por último, agradeço aos meus filhos Caio e Júlia pela compreensão da minha ausência durante esse período, e à minha esposa Raquel pelo carinho e apoio irrestrito em todos os momentos.

## RESUMO

Fenômenos meteorológicos adversos impactam significativamente as operações aéreas, e os procedimentos de pousos e decolagens são as fases dos voos mais sensíveis a essas adversidades. O aeroporto Santos Dumont, localizado na região central da cidade do Rio de Janeiro, possui particularidades que impactam negativamente as operações aéreas, como obstáculos próximos as cabeceiras, pistas com dimensões reduzidas e ausência de sensores de navegação aérea que permitam procedimentos de precisão.

Foi desenvolvido um modelo de previsão de curto prazo para visibilidade (horizontal) e teto, utilizando inteligência artificial, para os limites de 4.500, 3.700, 1.600 metros de visibilidade e 1.000 pés de teto, em acordo com as cartas de aproximação por instrumentos do aeroporto Santos Dumont, para as resoluções temporais de 15, 30, 45 e 60 minutos, visando principalmente auxiliar os voos que ocorrem na ponte aérea Rio/São Paulo, que representam 58% dos movimentos desse aeroporto e duram em média 50 minutos. Foram utilizadas diversas técnicas com modelos classificatórios e regressivos, com dados coletados da estação meteorológica de superfície e do observador meteorológico por um período de 10 anos, e do perfilador de vento (SODAR) por um período de 3 anos.

Para as previsões utilizando redes regressivas, a maioria dos resultados foram satisfatórios, com altos índices de correlação e erros absolutos médios e relativos baixos, exceto a previsão da quantidade de nebulosidade.

Para os modelos classificatórios de visibilidade, as previsões de 15 minutos foram satisfatórias para todos os limites, e os melhores resultados ficaram acima de 88% de desempenho em todas as estatísticas. Na previsão para 30 minutos, o melhor desempenho para o parâmetro de 4.500 metros ficou acima de 82%, porém para 3.700 e 1.600 metros ficou pouco acima de 75% e 72% respectivamente, para 45 e 60 minutos todos as previsões ficaram abaixo do considerado satisfatório para essa pesquisa.

Em relação às previsões classificatórias de teto, os resultados não foram satisfatórios.

## ABSTRACT

Adverse weather phenomena significantly impact air operations, and landing and take-off procedures are the phases of flights most sensitive to these adversities. Santos Dumont Airport, located in the central region of the city of Rio de Janeiro, has particularities that negatively impact air operations, such as obstacles near the runways, runways with reduced dimensions and the absence of air navigation sensors that allow precision procedures.

A short-term forecast model for visibility (horizontal) and ceiling was developed, using artificial intelligence, for the limits of 4.500, 3.700, 1.600 meters of visibility and 1.000 feet of ceiling, in accordance with the airport instrument approach charts. Santos Dumont, for the temporal resolutions of 15, 30, 45 and 60 minutes, aiming mainly to assist the flights that take place on the Rio / São Paulo bridge, which represent 58% of the movements of this airport and last on average 50 minutes. Several techniques were used with classificatory and regressive models, with data collected from the surface weather station and the weather observer for a period of 10 years, and the wind profiler (SODAR) for a period of 3 years.

For the forecasts using regressive networks, most of the results were satisfactory, with high correlation rates and low average and relative absolute errors, except for the forecast of the amount of cloudiness.

For the classification models of visibility, the 15-minute forecasts were satisfactory for all limits, and the best results were above 88% of performance in all statistics. In the forecast for 30 minutes, the best performance for the 4.500 meters parameter was above 82%, but for 3.700 and 1.600 meters it was just above 75% and 72% respectively, for 45 and 60 minutes all forecasts were below what was considered satisfactory for this research.

Regarding the classificatory ceiling predictions, the results were not satisfactory.

## SUMÁRIO

1. INTRODUÇÃO.....	8
1.1 Motivação.....	9
1.2 Objetivo.....	11
1.2.1 Geral.....	11
1.2.2 Específicos.....	11
2. REVISÃO BIBLIOGRÁFICA.....	12
3. FUNDAMENTOS DAS RESTRIÇÕES DE VISIBILIDADE E TETO E APRENDIZADO DE MÁQUINA.....	16
3.1 Visibilidade.....	16
3.2 Restrições à visibilidade.....	17
3.2.1 Névoa Úmida.....	17
3.2.2 Névoa Seca.....	17
3.2.3 Nevoeiro.....	18
3.3 Teto.....	19
3.4 Restrições de teto.....	19
3.5 Aprendizado de máquina.....	20
3.6 Descrição do software WEKA.....	22
3.6.1 Descrição do Auto-WEKA.....	24
4. ÁREA DE ESTUDO E DADOS.....	25
4.1 Área de estudo.....	25
4.2 Dados.....	27
4.2.1 Dados do SODAR.....	29
4.2.2 Dados da Estação Meteorológica de Superfície do Aeroporto Santos Dumont (SBRJ).....	29
4.3 Análise estatística das restrições de visibilidade e teto.....	30
4.3.1 Restrições de visibilidade.....	31
4.3.2 Restrições de teto.....	34
5. MÉTODO.....	36

5.1 Estatísticas de avaliação.....	38
6. RESULTADOS E DISCUSSÃO.....	42
6.1 Aprendizado de máquina.....	42
6.1.1 Nowcasting de visibilidade.....	42
6.2 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 15 minutos.....	43
6.3 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 30 minutos.....	42
6.4 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 45 minutos.....	45
6.5 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 60 minutos.....	46
6.6 Modelos classificatórios de teto para o parâmetro de 1000 pés.....	49
6.7 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros com os dados de 2016 a 2018, com e sem as informações do sodar, utilizando o Auto-WEKA.....	51
6.8 Modelos regressivos com as visibilidades menores ou iguais a 6.000 metros, utilizando o Auto-WEKA.....	53
6.9 Modelos regressivos de visibilidade com os dados de 2016 a 2018, com e sem as informações do sodar, utilizando o Auto-WEKA .....	59
6.10 Modelos regressivos de teto utilizando o Auto-WEKA.....	
6.11 Estudo de caso de evento de baixa visibilidade utilizando modelo regressivo..	61
7. CONCLUSÕES.....	63
8. REFERÊNCIAS.....	66

## 1 INTRODUÇÃO

A aviação, de uma forma geral, é sensível às condições meteorológicas e suas variações podem causar diversos transtornos, como atrasos, desvios em rota e em casos extremos acidentes que podem culminar em perdas de vidas. Os procedimentos de pousos e decolagens podem ser considerados entre as fases mais críticas dos voos, uma vez que as aeronaves durante esses procedimentos estão com velocidade reduzida e um controle mais limitado devido à utilização do trem de pouso, spoilers e flaps. Na Figura 1.1, os fenômenos meteorológicos que impactam a aviação são destacados em suas diferentes fases do voo e nela podemos observar que a visibilidade baixa e o teto baixo, aqui estudados, impactam os procedimentos tanto no aeroporto, quanto nas fases de decolagem, pouso e aproximação. Logo, fica evidente a necessidade de uma previsão com a maior precisão possível, da ocorrência de fenômenos de restrição de visibilidade e teto para o planejamento dos pilotos, das empresas aéreas e dos órgãos que gerenciam o controle de tráfego aéreo.

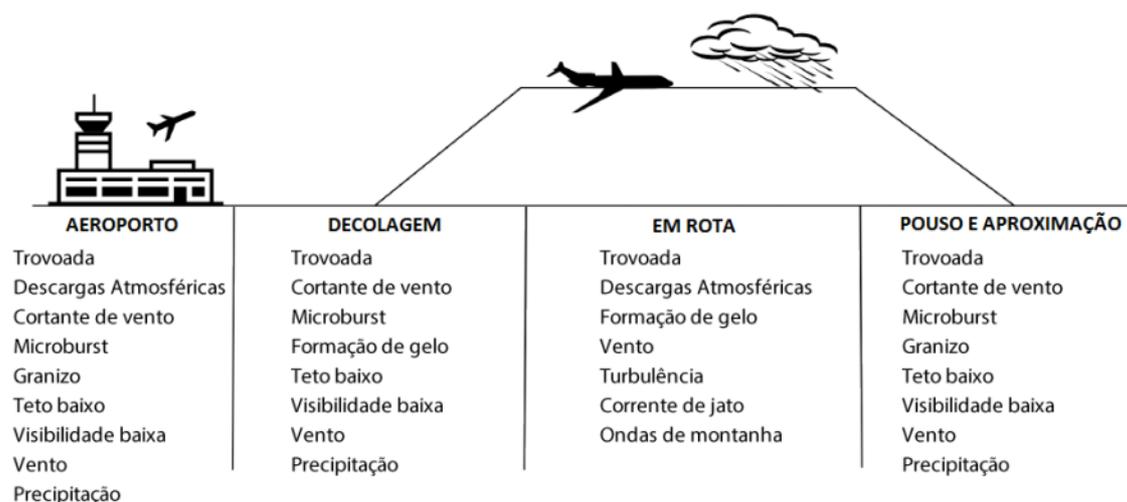


Fig. 1.1: Principais fenômenos meteorológicos que impactam a aviação durante as fases do voo. Fonte: Adaptado de PEJOVIC (2008).

Diante de todo avanço tecnológico ocorrido em diversos setores da sociedade, a aviação não poderia deixar de acompanhar esse processo, e esse avanço pode ser notado pelo aumento da utilização desse meio de transporte e principalmente por condições cada vez mais seguras dos voos proporcionada por todos os profissionais que integram o sistema de controle do espaço aéreo brasileiro, no qual os meteorologistas estão inseridos. A segurança dos voos, otimização de rotas aéreas e a redução dos custos operacionais em cada viagem são os principais requisitos almejados pelas empresas

aéreas, e as informações meteorológicas são de fundamental importância para que esses objetivos sejam alcançados.

Atualmente, as previsões de curto prazo (ou comumente chamada de *Nowcasting*<sup>1</sup>) desenvolvidas pelos órgãos responsáveis pela meteorologia aeronáutica são realizadas de forma subjetiva, em que o previsor utiliza modelos conceituais considerando as informações meteorológicas disponíveis. Em particular, a previsão de curto prazo dos fenômenos meteorológicos que restringem a visibilidade e o teto associada ao surgimento de nevoeiro, névoa úmida, névoa seca e teto baixo, ainda é um desafio. Em particular, segundo BALLARD, GOLDING e SMITH (1991), a previsão da formação, evolução e dissipação do nevoeiro é um dos maiores problemas encontrados pelos previsores do tempo ao redor do mundo.

### **1.1 Motivação**

Atualmente, nos procedimentos de pousos e decolagens em aeroportos brasileiros, as restrições relativas à altura da camada da nebulosidade mais baixa que constitui teto, ou seja, mais da metade da cobertura do céu, não é mais parâmetro para impedir esses tipos de operações nos aeroportos, ficando essa decisão a cargo do piloto, porém, influencia no tipo de procedimento a ser utilizado (AIC 54/18, 2018). No entanto, quando as condições meteorológicas atuantes são degradadas por restrições de visibilidade, dependendo da intensidade da restrição, o aeroporto tem suas operações restringidas ou até mesmo interrompidas durante a duração do fenômeno.

De acordo com os dados do Departamento de Controle do Espaço Aéreo (DECEA, 2018), 63% das causas dos atrasos dos voos entre 2014 e 2016 no Brasil foram motivados por diversos fatores meteorológicos, entre os quais: trovoadas (31%), restrições de visibilidade (27%), precipitações moderadas ou fortes (19%) e restrições devido a teto baixo (15%), conforme Figuras 1.2 e 1.3.

---

<sup>1</sup> *Nowcasting* é definido como a previsão de alguns minutos até 6 horas

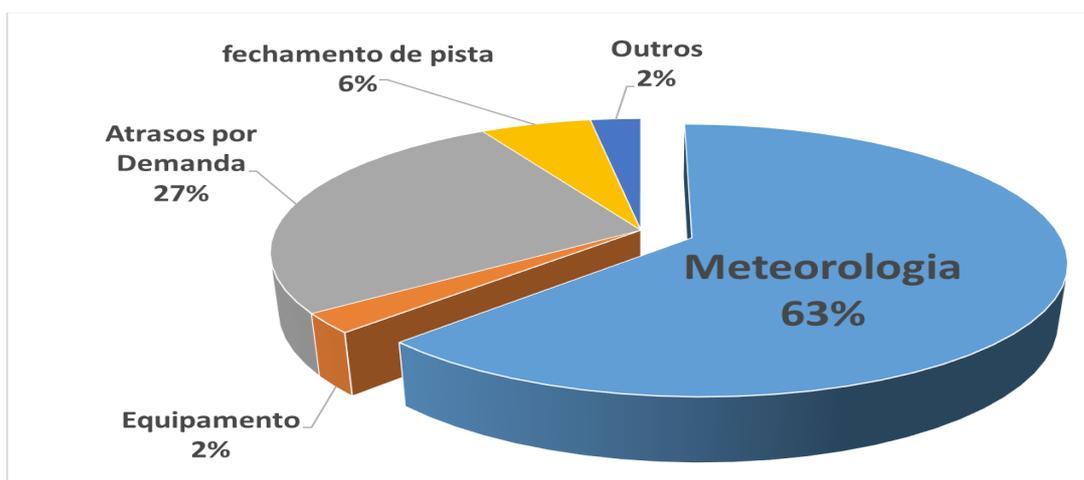


Figura 1.2: Causa dos atrasos dos voos (2014 a 2016)  
Fonte: DECEA (2018)

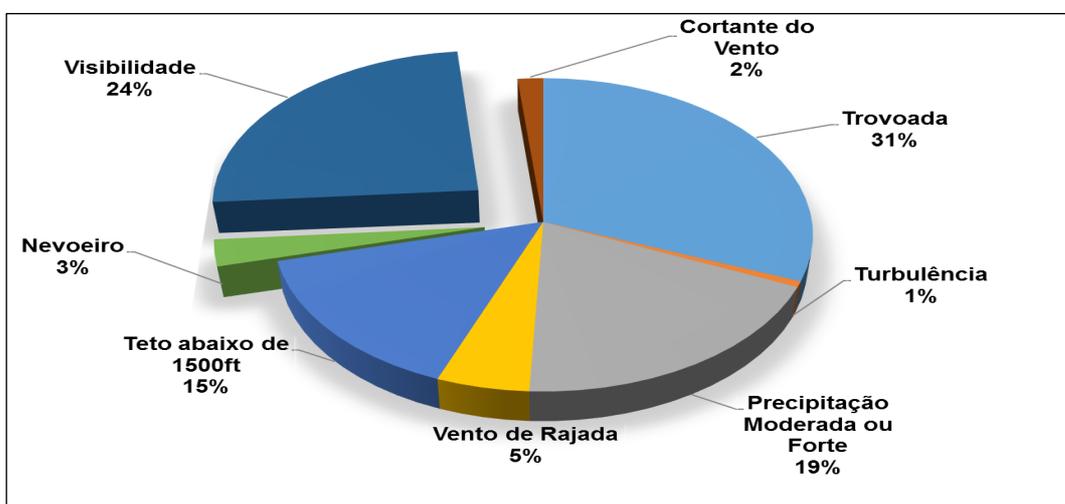


Figura 1.3: Fenômenos Meteorológicos que impactaram a Navegação Aérea entre 2014 e 2016.  
Fonte: DECEA (2018)

O aeroporto Santos Dumont, cujas restrições de teto e visibilidade são aqui estudadas, possui particularidades que impactam negativamente os procedimentos de pousos e decolagens, em função do comprimento reduzido da pista (principal com 1.323 metros e secundária com 1.260 metros), obstáculos próximos às cabeceiras (morro do Pão de Açúcar a 3.700 metros) e a ausência de equipamentos para aproximação de precisão para auxiliar nesses procedimentos. Além disso, é um aeroporto de grande expressão nacional. Conforme o anuário estatístico de 2018 da INFRAERO, este aeroporto foi o segundo com maior fluxo de passageiros e movimento de aeronaves dos aeroportos administrados pela empresa no país, com 9.206.052 passageiros e 100.109 aeronaves nesse período e o terceiro aeroporto do Brasil mais impactado pelas restrições de visibilidade segundo dados do DECEA ilustrados na Figura 1.4.

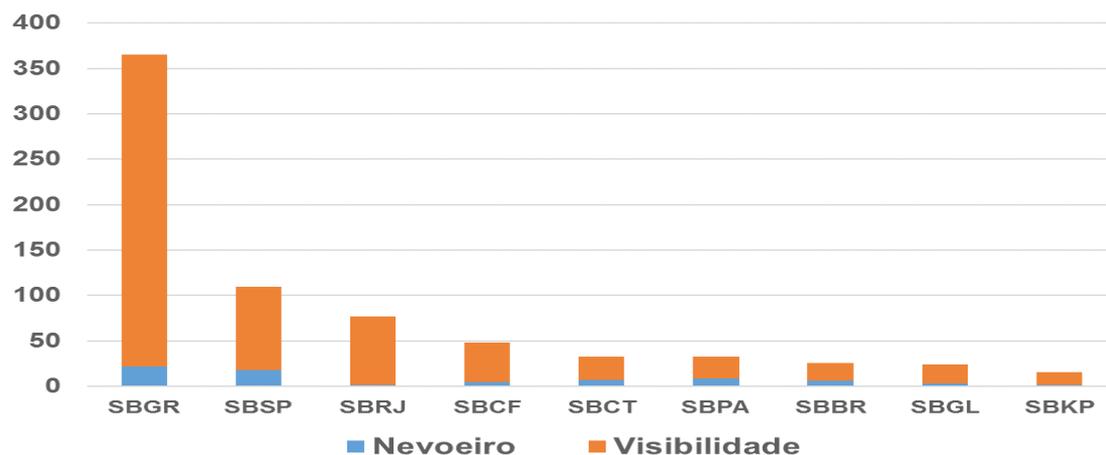


Figura 1.4: Aeroportos com ocorrências de restrições de visibilidade e nevoeiros que causaram atrasos nos voos entre 2014 e 2016. Fonte: DECEA (2018)

## 1.2 Objetivo

### 1.2.1 Geral

Desenvolvimento de um modelo de *nowcasting*, baseado em aprendizado de máquina, do comportamento das condições de visibilidade e teto do Aeroporto Santos Dumont.

### 1.2.2 Específicos

- a) Estudo das condições meteorológicas que implicam em restrições aos pousos e às decolagens no aeroporto Santos Dumont;
- b) Desenvolvimento de um modelo preditivo de visibilidade para os limites de 4.500, 3.700 e 1.600 metros;
- c) Desenvolvimento de um modelo preditivo de teto para o limite de 1.000 pés ou 300 metros.

## 2 REVISÃO BIBLIOGRÁFICA

Diversos trabalhos foram desenvolvidos em outros países e no Brasil utilizando inteligência artificial e técnicas de mineração de dados nessas últimas décadas, visando à previsão de *nowcasting* de vários fenômenos meteorológicos, inclusive restrições de visibilidade. Por exemplo, Pasini, Pelino e Potestà (2001) desenvolveu um modelo baseado em rede neural artificial para previsão de curto prazo de nevoeiro em Milão, Itália. Utilizando a técnica de mínimos quadrados ponderados, ele destacou que o modelo sempre apresentou melhores resultados do que a climatologia e a técnica de persistência. Foram feitas também análises e um esquema de corte, que possibilitou identificar as variáveis físicas mais significativas para uma previsão correta.

Gultepe *et al.* (2009) criou um modelo para caracterizar os diversos tipos de nevoeiro e diagnosticar as características de formação, evolução e dissipação desse fenômeno em ambientes continentais e marinhos. Dentre as diversas conclusões que ele chegou dessa avaliação, podemos destacar que as observações de sensoriamento remoto de um radar meteorológico, perfil de radiômetro e satélites podem ser úteis para observação da cobertura do nevoeiro, e a interação de microfísica, dinâmica (por exemplo, turbulência), processos radiativos e condições da superfície (por exemplo, umidade e temperatura do solo) desempenham um papel importante no ciclo de vida do nevoeiro.

Isaac *et al.* (2014) desenvolveram um projeto de *nowcasting* no Canadá, denominado CAN-Now. Foram utilizados dados de modelos numéricos, relatórios de pilotos, observações de sensores terrestres para medições de precipitação, teto, visibilidade e vento, sensoriamento remoto no local (radar e radiômetro de microondas), e informações de sensoriamento remoto fora do local (satélite e radar) para fornecer previsões detalhadas para até 6 h. O sistema foi desenvolvido e testado nos aeroportos de Toronto e Vancouver, e um gráfico de situação foi desenvolvido para permitir que os usuários tivessem um produto de alto valor que identificasse problemas significativos relacionados ao tempo nos aeroportos. A capacidade de prever variáveis categóricas como teto, visibilidade, bem como taxa e tipo de precipitação foram analisadas, e para a maioria das variáveis, os prognósticos desse sistema superaram as previsões por persistência após as primeiras 2 horas e os modelos de previsão até 6 horas.

Payra e Mohan (2014) utilizaram uma técnica de múltiplos critérios nos dados para o pós-processamento do modelo *Weather Research and Forecasting* (WRF) para melhorar a previsão do nevoeiro na estação de inverno no aeroporto de Nova Délhi, Índia. Essa técnica identificou dias com nevoeiro com sucesso de 94% do tempo, além disso, detectou o início dos eventos com uma precisão de 30 a 90 minutos.

Haefelin *et al.* (2016) elaboraram um estudo de alertas de formação de nevoeiro de radiação usando potência de retroespalhamento atenuada de equipamentos Lidar e Tetômetros. Também utilizaram medições de umidade relativa e medições de visibilidade horizontal para estudar o crescimento dos núcleos higroscópicos de condensação dos nevoeiros. Destacou-se que este processo pode levar de vários minutos a horas, e com base nas leis de crescimento higroscópico, foi derivado um conjunto de parâmetros que pudessem ser usados para fornecer alertas de minutos a horas antes da formação do fenômeno. Foi apresentado um algoritmo que usa a evolução temporal de retroespalhamento atenuado para derivar alertas de formação de nevoeiro. O desempenho do algoritmo foi testado em 45 eventos de nevoeiros independentes em dois locais (Paris, França e Bruxelas, Bélgica). O estudo demonstrou que os alertas do fenômeno ocorrem predominantemente 10 a 50 minutos antes da formação do nevoeiro a uma altitude de 0 a 100 m acima do solo.

Dietz *et al.* (2018) desenvolveram um modelo estatístico com base em árvore de decisão para previsão de curto prazo para os procedimentos de baixa visibilidade a partir de observações de superfície no aeroporto de Viena, Áustria. Ele afirma que o impacto da baixa visibilidade nas atividades de voo em aeroportos aumentará no futuro. Destaca também que embora a taxa anual do número de eventos de baixa visibilidade na Europa Central ter diminuído nos últimos 40 anos o número de atrasos aumentou. O motivo é o aumento do número de voos, que esgotam a utilização da capacidade dos aeroportos. Como o tempo contribui mais para os atrasos nos voos, a importância de previsões precisas de baixa visibilidade aumentará no futuro.

Gultepe *et al.* (2019) realizaram uma revisão do alto impacto da meteorologia na aviação. O estudo resume o conhecimento atual disponível para as operações na aviação e fornece sugestões para melhorias necessárias na medição e previsão de parâmetros relacionados à meteorologia, novos métodos físicos para previsões numéricas do tempo e de novos sistemas integrados. Destacaram que os parâmetros mais importantes para a aviação, relacionados a meteorologia são vento, turbulência, visibilidade, nevoeiro, teto,

quantidade e taxas de chuva, neve e gelo. Salientaram que os parâmetros meteorológicos estão sendo observados com novas plataformas de sensoriamento remoto, como LIDAR, SODAR, radares meteorológicos, satélites geostacionários, instrumentos na superfície e na atmosfera, bem como aeronaves e sensores montados em veículos aéreos não tripulados. A revisão apresentou os recursos disponíveis, questões de meteorologia para a aviação e possibilidade de melhorias relacionadas a medições de parâmetros meteorológicos e previsão do tempo.

No Brasil, pode ser destacado inicialmente Lima (1982) que utilizou um método objetivo para prever a ocorrência e a duração do nevoeiro em Porto Alegre, Rio Grande do Sul. Nesse estudo foram utilizados os dados de estação meteorológica de superfície de 1966 a 1975, para determinação dos preditores e condições sinóticas favoráveis, e em seguida, com os dados de início e duração do fenômeno, foram determinados pelo método dos mínimos quadrados, equações para prever a duração do nevoeiro em cada mês. Após os testes feitos pelos previsores do centro meteorológico, o método apresentou resultados com percentuais de acerto acima de 80%, no entanto uma significativa taxa de falso alarme.

Almeida (2009) desenvolveu um modelo pioneiro de previsão de curtíssimo prazo, baseado em algoritmos de aprendizado de máquina, para prever o teto de nuvens e a visibilidade horizontal no Aeroporto de Guarulhos, São Paulo. Dados de 56 anos da estação meteorológica de superfície foram utilizados e os resultados foram promissores, embora enviesados significativamente.

Cossich *et al.* (2009) fizeram uma análise de casos de nevoeiro na cidade do Rio de Janeiro no período de 2003 a 2007, especificando os meses de maior ocorrência, horários típicos, e duração dos eventos. Utilizaram dados das estações meteorológicas de superfície dos aeroportos do Galeão, Santos Dumont, Afonsos e Santa Cruz. Observaram maior ocorrência de nevoeiros durante o período de inverno, e que os fenômenos tiveram duração de até 6 horas, sendo os eventos menos duradouros (até 1 hora) os mais frequentes.

França, Almeida e Rossete (2016) desenvolveram um modelo de previsão de eventos significativos de instabilidade na área terminal de voo do Rio de Janeiro, Brasil. Foram utilizados dados de doze anos para treinamento, validação e teste das redes neurais e o teste mostrou que o modelo proposto pode detectar o conteúdo físico dentro

do conjunto de dados e seu desempenho é satisfatório para a primeira e a segunda hora para eventos significativos de instabilidade na área de estudo.

Silva (2016) analisou as ocorrências de cisalhamento de vento no aeroporto de Guarulhos, São Paulo, para prevenção de acidentes aeronáuticos. Utilizou dados do SODAR (*Sonic Detection and Ranging*), da estação meteorológica de superfície do aeroporto (METAR), imagens de satélite e radar meteorológico. Destacou que a grande maioria dos eventos de cisalhamento de vento esteve associada à convecção, sistemas pré-frontais ou frontais sobre o aeroporto e que as características das medições do SODAR podem ser utilizadas na prática para previsão desse tipo de fenômeno.

Pereira (2016) empregou redes neurais artificiais na previsão de nevoeiro no aeroporto internacional Afonso Pena, Curitiba. A pesquisa destacou que o aeroporto é o aeródromo brasileiro que mais sofre com estes fenômenos meteorológicos. Foram utilizadas três redes neurais, treinadas independentemente a partir de dados meteorológicos coletados na estação meteorológica de superfície e na estação meteorológica de altitude do aeroporto pelo período de 1997 a 2014. A técnica utilizando climatologia apresentou razão de falso alarme em torno de 96%, a técnica de persistência apresentou índices de desempenho próximos aos apresentados pelas redes neurais, no entanto, a técnica de previsão de nevoeiros utilizando redes neurais alcançou a maior probabilidade de detecção.

França *et al.* (2018) criaram um modelo de *Nowcasting* do perfil do vento em baixos níveis, baseado em rede neural usando dados do perfilador de vento (SODAR) no aeroporto de Guarulhos – São Paulo. O objetivo foi prever os perfis de vento até 45 min nas alturas de 10, 100, 200 e 300 metros, e os resultados revelaram que a assertividade do modelo diminui à medida que a previsão é estendida. Estima-se que isso pode estar correlacionado com o fato de que a rede neural é um modelo estatístico e não físico.

### 3 FUNDAMENTOS DAS RESTRIÇÕES DE VISIBILIDADE E TETO E APRENDIZADO DE MÁQUINA

Segundo Stull (1988), a camada limite atmosférica (CLA) está situada aproximadamente no primeiro quilômetro da atmosfera e pode se estender a poucos quilômetros em determinadas condições de tempo nas regiões tropicais. É a região mais influenciada pela troca de energia (momentum, calor sensível e calor latente) e massa com a superfície terrestre. Movimentos turbulentos com escalas temporais de uma hora ou menos dominam o fluxo nesta região e transportam propriedades da atmosfera, horizontalmente e verticalmente, em seu interior. As principais propriedades dos fluxos são a velocidade dos fluidos, a temperatura e a umidade, que atingem o maior gradiente nos primeiros 100 m, que é denominado camada limite superficial. Os escoamentos turbulentos nesta camada controlam a troca de calor, massa e quantidade de movimento na superfície e, assim, influenciam os padrões de toda a CLA. (KAIMAL e FINNIGAN, 1994). Todos os aspectos mencionados governam as condições associadas às variações locais da visibilidade e do teto.

#### 3.1 Visibilidade

Visibilidade meteorológica é definida como a maior distância em que um objeto escuro pode ser visto e reconhecido quando observado no horizonte durante o dia ou visto e reconhecido durante a noite se a iluminação geral fosse elevada ao nível normal da luz do dia. De acordo com o Guia para Instrumentos Meteorológicos e Métodos de Observação (WMO – para ser coerente com a referência, 2018) em seu capítulo 9, a visibilidade foi definida pela primeira vez para fins meteorológicos como uma quantidade a ser estimada por um observador humano, e as observações feitas dessa forma ainda são amplamente utilizadas.

No entanto, a estimativa da visibilidade é afetada por muitos fatores subjetivos e físicos, e o seu parâmetro essencial que é a transparência da atmosfera pode ser medido objetivamente por equipamentos meteorológicos como o MOR (*Meteorological Optical Range*), que é um Visibilômetro que funciona por intermédio da emissão de ondas eletromagnéticas com ajuste da energia recebida de acordo com os efeitos da atenuação. Nesse contexto, podemos inferir que a estimativa da

visibilidade feita por um observador humano nas EMS (Estações Meteorológicas de Superfície) é obtida de forma subjetiva.

### **3.2 Restrições à visibilidade**

As restrições de visibilidade se originam devido à presença de fenômenos meteorológicos observados na atmosfera, que podem ser classificados como hidrometeoros e litometeoros.

Segundo o Vocabulário Meteorológico Internacional (1992), os hidrometeoros e litometeoros reduzem a visibilidade onde estejam ocorrendo e são definidos como:

1. Hidrometeoros são constituídos por um aglomerado de partículas de água, na fase líquida ou sólida, em queda livre ou em suspensão na atmosfera, ou levantada da superfície terrestre pelo vento, ou depositadas sobre objetos, no solo ou na atmosfera livre. Os hidrometeoros mais comuns são: Chuva, Chuvisco, Orvalho, Garoa, Neve, Grãos de Neve, Pelotas de Gelo, Cristais de Gelo, Granizo, Nevoeiro, Névoa, Neve, Tornado ou Tromba d'água;
2. Litometeoros ou Aerossóis são causados pela suspensão de partículas no ar, geralmente sólidas, de natureza não aquosa. Os litometeoros mais comuns são: Névoa Seca, Fumaça, Poeira ou Areia, Turbilhão de Poeira ou de Areia, Cinza Vulcânica.

Dentre todos os fenômenos destacados, a névoa úmida, névoa seca e o nevoeiro são os restritores de visibilidade mais recorrentes nos aeroportos, e de acordo com as condições atmosféricas locais presentes podem ser intensificados ou enfraquecidos, sendo assim, são os fenômenos destacados nesse trabalho.

#### **3.2.1 Névoa úmida**

Gotículas de água em suspensão ou partículas higroscópicas úmidas que reduzem a visibilidade horizontal predominante de, no mínimo 1.000 metros, até o limite de 5.000 metros inclusive, e com umidade relativa de 80% ou mais (ICA 105-15, 2019).

#### **3.2.2 Névoa seca**

Suspensão no ar de partículas secas tão pequenas que, à vista do observador Meteorologista são invisíveis, mas suficientemente numerosas para ocasionar ao ar uma aparência opaca, com uma redução da visibilidade horizontal predominante de

5000 metros ou menos. Neste caso, a umidade relativa é menor que 80% (ICA 105-15, 2019).

### 3.2.3 *Nevoeiro*

O nevoeiro é um hidrometeoro que ocorre próximo à superfície terrestre. Segundo Oliveira, Vianello e Ferreira (2001) “Nevoeiro é uma formação de grande quantidade de gotículas de água (excepcionalmente, cristais de gelo), e massa de ar estável, sobre a superfície, provocando redução de visibilidade”. Para fins aeronáuticos, esta restrição deve ser inferior a 1000 metros (ICA 105-15, 2019).

Em seu processo físico, o nevoeiro se forma quando uma porção de ar alcança a saturação, e o vapor d’água nela contida condensa-se. Segundo VAREJÃO-SILVA (2006) existem diferentes tipos de nevoeiros, classificados de acordo com seu processo de formação, que são os nevoeiros de radiação, de advecção e orográfico.

Os nevoeiros de radiação são assim chamados, pois sua gênese é devida ao resfriamento do solo através da liberação do calor da radiação solar e atmosférica acumulados durante o dia. A massa de ar mais próxima ao solo passa a se resfriar, isobaricamente, através da troca de energia com o solo, por condução. No entanto, a quantidade de vapor d’água existente no início do processo continua a mesma, mas à medida que a porção de ar esfria, esta se aproxima da saturação. Se a porção de ar for suficientemente úmida, ou o resfriamento for suficiente para que a temperatura alcance o ponto de orvalho, ocorrerá a condensação e, por conseguinte, o nevoeiro. O nevoeiro de radiação se forma em noites sem nuvens, ou com uma camada de nuvens que não gere efeito estufa, de modo a impedir o rápido resfriamento do solo. Portanto, para a formação do nevoeiro de radiação é necessária umidade relativa elevada, grande resfriamento da superfície, e ventos fracos que gerem alguma turbulência de modo que a camada resfriada seja ampliada.

O nevoeiro de advecção, o mais comum na área de estudo, é formado a partir de uma massa de ar quente e úmida que escoia sobre uma superfície mais fria. A massa de ar passa a resfriar-se progressivamente, e quando atinge o ponto de orvalho, forma o nevoeiro. Neste caso, é necessária uma grande diferença de temperatura entre a massa de ar e a superfície, e que a massa esteja se deslocando em baixa velocidade, de modo que possa resfriar-se no processo de troca de calor com a superfície.

O nevoeiro orográfico ocorre quando uma porção de ar úmido se eleva ao longo de uma encosta. Esta porção passa a resfriar-se adiabaticamente (supondo que o

movimento ascendente da porção de ar é suficientemente rápido para que não haja troca de calor com o ambiente). Se o aclave for suficientemente longo e inclinado, a partir da altura em que o ar atingir o ponto de saturação, até o topo da elevação, haverá a formação de nevoeiro.

### **3.3 Teto**

O teto é definido para a aviação como a cobertura de nuvens no céu composta por mais de quatro oitavos do total da abóbada celeste, e as nebulosidades de significado operacional são definidas como aquelas com altura da base abaixo de 1.500 metros (5.000 pés), nuvens CB ou TCU, em qualquer altura, ou nuvens com altura da base abaixo da altitude mínima de setor mais elevada, destes valores o maior. Altitude mínima de setor é definida como a menor altitude que pode ser utilizada, em condições de emergência, provendo-se uma separação mínima de 300 metros (1.000 pés) acima de todos os obstáculos localizados dentro um setor circular de 46km (25 NM) de raio centrado no auxílio rádio à navegação do aeródromo (ICA 105-16, 2017).

Conforme destacado anteriormente, o teto não é mais um requisito operacional referenciado nas cartas de aproximação de pouso ou decolagem para impedir esses procedimentos, pois a decisão de proceder para essas operações agora fica a cargo do piloto quando essas restrições estão presentes, no entanto, esse tipo de fenômeno ainda impacta significativamente as operações nos aeródromos. Segundo a AIC Nº 54/18 (2018), até junho de 2017, os mínimos operacionais de aeródromo para pouso no Brasil eram estabelecidos em termos de visibilidade ou limites de RVR (Alcance Visual da Pista), conforme o caso, e teto. Contudo, uma revisão dos critérios de determinação de tais mínimos concluiu pela conveniência de eliminação do requisito de teto para estas operações.

### **3.4 Restrições de teto**

As restrições de teto impactam as operações nos aeródromos, porém, esse impacto varia de acordo com os equipamentos de auxílios à navegação disponíveis. Aeroportos que possuam procedimentos de pousos por instrumentos, baseados em auxílios à navegação que possuam indicação eletrônica de trajetória de planeio, como o *Instrument Landing System* (ILS) tem esses impactos minimizados, o que não é o caso do Aeroporto Santos Dumont.

### 3.5 Aprendizado de máquina

É a área dentro da inteligência artificial definida como a capacidade de aprender sem que haja uma programação de computador explícita, ou seja, não há um conjunto de linhas de códigos, de comando para a realização de uma tarefa específica. Aprendizado de máquina se refere a uma vasta gama de algoritmos e metodologias que permitem que modelos adquiram conhecimento a partir do ambiente, ou seja, a partir de dados que representam a caracterização do processo a ser classificado. Baseado nesse conhecimento, o modelo produz classificação de padrão ou predição. Essa aquisição de conhecimento ocorre a partir do treinamento do algoritmo do modelo, pois com a alimentação de grande quantidade de dados históricos ele se ajusta e melhora o seu aprendizado (Witten *et al*, 2017).

Segundo Liu e Mason (2016) o aprendizado de máquina se divide em dois tipos principais, a aprendizagem supervisionada e a aprendizagem não supervisionada:

- Na aprendizagem supervisionada existe um conjunto prévio de dados inseridos na máquina e as sugestões que serão dadas ao usuário devem ser parecidas com os dados registrados. As informações são usadas para prever um resultado esperado pelo usuário ou para fazer a classificação de elementos usados;
- Na não supervisionada não existe um resultado específico esperado. Dessa forma, não é possível prever os resultados do cruzamento das informações. Nesse tipo de aprendizagem os dados são agrupados e os resultados mudam de acordo com as variáveis.

Por conta da vasta gama de algoritmos e metodologias, existem diversas técnicas de aprendizado de máquina. As que serão utilizadas nesse trabalho são as redes neurais artificiais e as árvores de decisão.

Segundo ALMEIDA (2009), o termo “Redes Neurais Artificiais” advém do fato de que estas tecnologias buscam representar matematicamente as estruturas cerebrais biológicas. Da mesma maneira que os seres humanos buscam nos eventos passados os auxílios necessários para a resolução de novos problemas, as redes neurais procuram padrões, em conjunto de dados, que auxiliem em classificações e previsões. E define-se como modelos matemáticos capazes de armazenar e dar conhecimento extraído, por exemplo, do meio ambiente e de torná-lo disponível por meio de generalizações, são constituídos de unidades simples de processamentos (os neurônios artificiais) distribuídas paralelamente, e seu conhecimento é adquirido por

meio de um processo de aprendizagem que é armazenado através de parâmetros ponderados (pesos ou coeficientes).

As redes neurais encontram aplicações em áreas da ciência tão diversas como modelagem numérica, análise de séries temporais, reconhecimento de padrões e processamento de sinais. A razão dessa diversidade de aplicações está na habilidade de aprender a partir do seu ambiente, ou seja, dos dados de entrada (Haykin, 2002).

Algumas propriedades características das redes neurais serão descritas aqui:

- Aprendizagem – a habilidade de extrair padrões dos dados;
- Não linearidade – capacidade de resolver problemas que não sejam linearmente separáveis;
- Adaptabilidade – a capacidade inata de adaptar seus pesos às modificações do ambiente (padrões de dados);
- Robustez – Possui tolerância às falhas; e
- Generalização – fornece resposta satisfatória diante de informações novas.

Outra técnica de aprendizado de máquina utilizada nesse trabalho é a árvore de decisão, que é uma técnica estatística de treinamento supervisionado para a classificação e previsão de dados. Um algoritmo de árvore de decisão geralmente começa com um único nó, que se divide em possíveis resultados, conforme ilustrado na Figura 3.9. Cada um desses resultados leva a nós adicionais, que se ramificam em outras possibilidades, assim, cria-se uma forma de árvore. As árvores de decisão estão entre os mais populares algoritmos de inferência.

As árvores de decisão possuem uma compreensão intuitiva do modelo, diferente das redes neurais por exemplo, que são mais difíceis de interpretar, além disso, elas podem identificar os atributos mais importantes de um conjunto de dados e excluir os irrelevantes. Essa capacidade de ser seletiva aumenta sua legibilidade humana e pode proporcionar uma melhor compreensão sobre o que é mais significativo em um conjunto de dados (Gagne II, 2009 apud Hermsdorff, 2018)

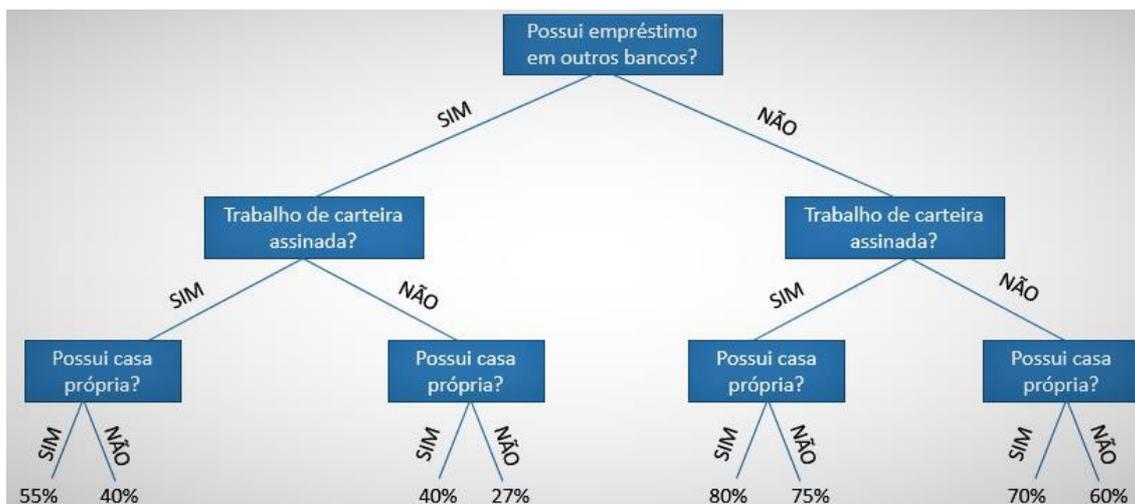


Figura 3.9: Exemplo de árvore de decisão para fornecer empréstimos bancários.  
 Fonte: <https://estatsite.com/2016/06/11/1970/>. Acesso em 04/12/2019 às 23:30

### 3.6 Descrição do software WEKA

Para a utilização das técnicas de aprendizado de máquina, redes neurais artificiais e árvores de decisão, foi utilizado nesse trabalho o *software* livre WEKA (*Waikato Environment for Knowledge Analysis*), versão 3.8.4, desenvolvido pela Universidade de *Waikato*, Nova Zelândia.

O WEKA é uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados. O software foi escrito na linguagem Java e contém ferramentas para preparação de dados, classificação, regressão, agrupamento, mineração de regras de associação e visualização de dados.

A implementação de algoritmos contidos nesse software possui baixo custo computacional, e sua utilização é viável tanto em pesquisa como em um ambiente operacional.

O WEKA possui 56 algoritmos classificatórios disponíveis que foram preliminarmente testados e os desempenhos analisados e, assim, os cinco melhores algoritmos foram selecionados para realizar as previsões de teto e visibilidade. Na Tabela 3.1 são descritas as características dos algoritmos selecionados.

Tabela 3.1: Algoritmos do *software* WEKA com o resumo de suas descrições.

Algoritmos	Descrição	Referência
Bayes Net	<ul style="list-style-type: none"> <li>• Aprendizado baseado na construção de uma rede bayseana, usando vários algoritmos de pesquisa e medidas de qualidade;</li> <li>• Fornece estruturas de dados, estruturas de rede e distribuições de probabilidade condicional;</li> <li>• Capacidade de classificação binária, valores de classes ausentes e classe nominal;</li> <li>• As probabilidades das classes são calculadas desprezando a dependência de valores que um atributo pode assumir.</li> </ul>	Witten <i>et al.</i> (2017)
Multilayer Perceptron	<ul style="list-style-type: none"> <li>• Classificador que usa retropropagação para classificar instâncias;</li> <li>• RNA de aprendizado supervisionado, na qual o sinal de entrada se propaga para frente por meio da rede, camada por camada;</li> <li>• A rede pode ser construída manualmente ou configurada, cujos parâmetros podem ser monitorados e modificados durante o tempo de treinamento;</li> <li>• Conjunto de unidades que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída;</li> <li>• Números aleatórios são usados para definir os pesos iniciais das conexões entre os nós e para embaralhar os dados de treinamento.</li> </ul>	Witten <i>et al.</i> (2017)
Random Forest	<ul style="list-style-type: none"> <li>• Combinação de preditores de árvores de decisão, de modo que cada árvore depende dos valores de um vetor aleatório amostrado de forma independente e com a mesma distribuição para todas as árvores da floresta;</li> <li>• Aumento da precisão da classificação devido ao crescimento do conjunto de árvores e ao final tem-se a votação da classe mais popular;</li> <li>• Estimativas internas monitoram erros, força, e correlação, bem como medem a importância das variáveis;</li> <li>• Menores taxas de erros são significativamente possíveis, quando os conjuntos de dados são maiores.</li> </ul>	Breiman (2001)
REPTree	<ul style="list-style-type: none"> <li>• Árvore de decisão rápida, que utiliza a lógica da árvore de decisão e regressão e cria várias árvores em diferentes iterações;</li> <li>• Seleciona a melhor de todas as árvores geradas através do erro quadrático médio;</li> <li>• Classifica valores para atributos numéricos apenas uma única vez.</li> </ul>	Witten <i>et al.</i> (2017)
Hoeffding Tree	<ul style="list-style-type: none"> <li>• Algoritmo de indução de árvore de decisão capaz de aprender com grandes fluxos de dados, assumindo que os exemplos de geração de distribuição não mudam com o tempo;</li> <li>• Explora o fato de que uma amostra pequena pode ser suficiente para escolher um atributo de divisão ideal;</li> <li>• Quantifica o número de observações necessárias para estimar algumas estatísticas dentro de uma</li> </ul>	Witten <i>et al.</i> (2017)

	precisão prescrita	
--	--------------------	--

### 3.6.1 Descrição do Auto-WEKA

Conforme destacado anteriormente, foram utilizados todos os algoritmos do WEKA, testados individualmente e, na sequência, selecionados os que obtiveram melhores resultados, porém, devido à vasta gama de opções de combinações possíveis entre os algoritmos disponíveis, seus hiperparâmetros e as variáveis do conjunto de dados, torna-se inviável testar todas as opções para se obter a melhor abordagem. No entanto, a ferramenta Auto-WEKA, que está integrada ao *Software* WEKA, desenvolvida pelo Departamento de Ciência da Computação da Universidade de *British Columbia*, Canadá, utiliza um método de otimização bayesiana de última geração, que possui a capacidade de pesquisar automaticamente através do conjunto dos algoritmos de aprendizagem do WEKA e suas respectivas configurações de hiperparâmetros, a melhor configuração disponível, culminando na maximização do desempenho. O Auto-WEKA soluciona esse problema tratando o WEKA como uma única estrutura de aprendizado de máquina e, através da otimização bayesiana, busca encontrar a maior correlação para um determinado conjunto de dados, e conseqüentemente as melhores configurações de desempenho. Um ponto crucial do Auto-WEKA está na facilidade em utilizar essa ferramenta, pois fornece uma interface que não requer um conhecimento aprofundado sobre os algoritmos de aprendizagem disponíveis ou seus hiperparâmetros, solicitando ao usuário que forneça, além do conjunto de dados a ser processado, apenas um limite de memória disponível e o tempo desejado para o processamento.

## 4 ÁREA DE ESTUDO E DADOS

### 4.1 Área de estudo

É área da circunvizinhança do aeroporto Santos Dumont representada nas Figuras 4.1 a 4.4, localizada na região central da cidade do Rio de Janeiro, que possui no seu entorno diversos obstáculos que dificultam e restringem as operações de pouso e decolagem.



Figura 4.1: Aeroporto Santos Dumont com a Ponte Rio-Niterói ao fundo.

Fonte: <https://oglobo.globo.com/aeroporto-santos-dumont>. Acesso em 03/08/2018 às 08:30.

Especificamente no Santos Dumont, que possui as adversidades comentadas anteriormente, o DECEA, órgão do Comando da Aeronáutica responsável pelo controle do espaço aéreo brasileiro, normatiza os procedimentos em três cartas de aproximação por instrumentos para pousos nas pistas com orientações magnéticas em  $200^{\circ}$  e  $20^{\circ}$ , denominadas respectivamente por 20 e 02 conforme Tabela 4.1 e Figura 4.2, que descrevem os limites mínimos de visibilidade e teto requeridos de acordo com cada procedimento em metros para a visibilidade e pés para o teto:

1. RNAV/GNSS – Sistema de navegação aérea baseada por satélite;
2. NDB – Sistema de ajuda rádio a navegação ou Farol não direcional; e
3. RNAV/RNP – Sistema de performance de navegação requerida.

Tabela 4.1: Limites operacionais de cada procedimento nas pistas do Santos Dumont.

PROCEDIMENT	RWY20	RWY02
<b>O</b>		
<b>RNAV/GNSS</b>	4.500 Metros / 1.000 Pés	5.000 Metros / 1.000 Pés
<b>NDB</b>	3.700 Metros / 1.200 Pés	4.800 Metros / 1.500 Pés
<b>RNAV/RNP</b>	1.600 Metros / 300 Pés	1.600 Metros / 300 Pés



Figura 4.2: Pistas do aeroporto Santos Dumont, com os morros Pão de Açúcar, Cara de Cão e da Urca ao fundo.

Fonte: <https://brasilturis.com.br/infraero-santos-dumont-rj/>. Acesso em 03/08/2018 às 08:40.

Dependendo das condições meteorológicas presentes, as restrições de visibilidade e teto se tornam ainda mais impactantes para as operações nesse aeroporto, pois obstáculos como a ponte Rio-Niterói próximo a pista 20 e o morro Pão de Açúcar a 3697 metros de distância da pista 02, com uma altitude de 407 metros, podem ficar parcial ou totalmente obscurecidos, causando mudanças de procedimentos ou até mesmo impedimento de pousos e decolagens.

É importante salientar que dentre os três procedimentos de pouso por instrumentos existentes no aeroporto Santos Dumont, o que possibilita uma operação em condições meteorológicas mais restritas, é o RNAV/RNP, com parâmetros de visibilidade e teto de 1.600 metros e 300 pés respectivamente. Porém, esse procedimento requer treinamento de toda tripulação, bem como a aeronave também precisa estar habilitada para realizá-lo, pois é requerido autorização especial para aeronave e tripulação, e esses requisitos não são atendidos por todas as equipes das empresas aéreas.



Figura 4.3: Aeroporto Santos Dumont com o morro Pão de Açúcar ao fundo.

Fonte: [https://pleno.news/brasil/santos-dumont-aps-reformas](https://pleno.news/brasil/santos-dumont-apos-reformas). Acesso em 03/08/2018 às 08:50

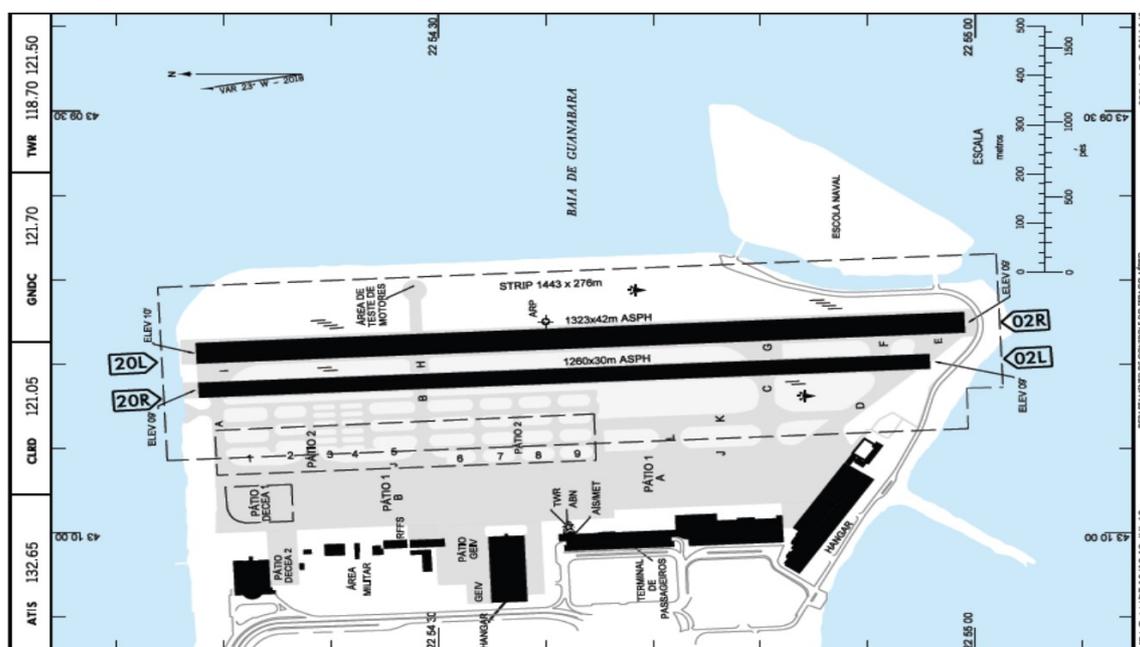


Figura 4.4: Carta de Aeródromo representando a Área de estudo.

Fonte: DECEA (2018)

## 4.2 Dados

Serão utilizados três tipos de dados nesse trabalho:

- Dados do SODAR;
- Dados da estação meteorológica de superfície do aeroporto Santos Dumont (SBRJ); e
- Dados do observador meteorológico.

Os dados que serão utilizados para este estudo estão contidos na tabela 4.2, assim como sua fonte, frequência, informação, período e local. Na figura 4.5 são destacadas as localizações do SODAR e da EMS no aeroporto Santos Dumont.

Tabela 4.2: Fontes dos dados e variáveis coletas e derivadas (entrada) usadas para o treinamento dos algoritmos de máquinas.

Fonte	Frequência (minutos)	Variáveis coletadas (entrada)		Período	Resultados
		Primárias	Derivadas		
SODAR	15	<i>Backscatter</i> <i>(normalizado)</i> BACK (h;t) (30, 40, 50, 60 e 70 metros; 15, 30, 45 e 60 minutos)	DIR (°), V (kt), *EDR (h;t) ( $m^2/s^3$ ) e *TKE (h;t) ( $m^2/s^2$ ) (30, 40, 50, 60 e 70 metros; 15, 30, 45, e 60 minutos)	2016 a 2018	Limites operacionais de VSB (4.500, 3.700, 1.600 metros) ou Teto (1.000 pés)
		Mês, dia, ano, hora, Tar (°C) UR (%), Td (°C) V02, D02, V10, D10 QNH (hPa)	-----		
Observador	60	-----	Teto (pés), VSB (metros), Cobertura de nuvens (total=TCLDLO e nuvens baixa=BCLDLO)	2009 a 2018	

\*TKE e EDR representam respectivamente a energia cinética turbulenta e taxa de dissipação de energia.



Figura 4.5: Localizações do SODAR e da EMS.  
 Fonte: Adaptado do [www.google.com.br/maps](http://www.google.com.br/maps).

#### 4.2.1 *Dados do SODAR*

Foram selecionados os dados do SODAR desde a sua instalação, no Aeroporto Santos Dumont (lat.: 22°54'25,5"S; long.: 043°09'42,3"W), ocorrida em 2016, até dezembro de 2018, pois essa sequência fica compatível com a disponibilidade dos dados da EMS, com uma resolução temporal de 15 minutos. Os parâmetros do equipamento utilizados foram a TKE, EDR e o retroespalhamento.

#### 4.2.2 *Dados da estação meteorológica de superfície do aeroporto Santos Dumont (SBRJ)*

O aeroporto Santos Dumont é administrado pela INFRAERO, e dentre toda estrutura para viabilizar as operações de pousos e decolagens, esse aeroporto é composto de uma estação meteorológica classe 2. Inicialmente, o objetivo era utilizar os dados dessa empresa com uma alta resolução temporal de um minuto, o que não foi possível, pois essa estação não possui sensores como o visibilômetro, logo a informação de visibilidade com essa frequência não está disponível. A alternativa foi utilizar os dados de visibilidade do Instituto de Controle do Espaço Aéreo (ICEA), obtidas das informações meteorológicas regulares de aeródromo (METAR – *METEorological Aerodrome Report*) com uma frequência horária.

Os dados meteorológicos utilizados descrevem condições de superfície compreendidas no período de 01/01/2009 00h 00min a 31/12/2018 23h 59min e foram coletados na Estação Meteorológica de Superfície (EMS) do Rio de Janeiro, localizada no Aeroporto Santos Dumont (lat.: 22°54'37"S; long.: 043°09'47"W).

No âmbito da Meteorologia Aeronáutica, as observações meteorológicas à superfície podem ser classificadas como Regulares, Especiais e Locais. As observações regulares são realizadas nas horas cheias, as especiais sempre que houver mudanças significativas nas condições meteorológicas e as observações locais quando ocorre algum incidente ou acidente aeronáutico no aeródromo que comporta a Estação Meteorológica de Superfície (ICA 105-16, 2017).

Os dados foram organizados em uma tabela Excel, e contém as seguintes variáveis:

Ano, mês, dia, hora (HH), minuto (MM), vento instantâneo (WNDI) em graus e nós, direção do vento instantânea (DINST) em graus (°), velocidade instantânea (VINST) em nós (kt), vento médio dos últimos 02 minutos (WND02), direção média dos últimos 02 minutos (DIR02), velocidade média dos últimos 02 minutos (V02), vento médio dos últimos 10 minutos (WND10), direção média dos últimos 10 minutos (DIR10), velocidade média dos últimos 10 minutos (V02), visibilidade em metros (VSB), visibilidade predominante ( $VSB_{pred}$ ), quantidade da nebulosidade mais baixa representada em oitavos da abóbada celeste (TCLDLO), base da nebulosidade mais baixa (BCLDLO) em pés (ft), temperatura do ar (TEMP) em graus celsius (°C), temperatura do ponto de orvalho (DEWPT), umidade relativa (UR) e pressão ao nível da estação (QNH) em hectopascal (hpa), EDR em metros quadrados por segundo ao cubo ( $m^2/s^3$ ) nas alturas de 30 (EDR30), 40 (EDR40), 50 (EDR50), 60 (EDR60) e 70 metros (EDR70), TKE em metros quadrados por segundo ao quadrado ( $m^2/s^2$ ) nas alturas de 30 (TKE30), 40 (TKE 40), 50 (TKE 50), 60 (TKE 60) e 70 metros (TKE 70) e o *backscatter* também nas alturas de 30 (BACK30), 40 (BACK40), 50 (BACK50), 60 (BACK60) e 70 metros (BACK 70).

#### **4.3 Análise estatística das restrições de visibilidade e teto**

Considerando os dados descritos na Tabela 4.2, as restrições de visibilidade e tetos são analisadas nas duas seções seguintes.

### 4.3.1 Restrições de visibilidade

Assume-se o limite de 4.500 metros de visibilidade por ser a menor visibilidade em relação aos maiores limites de restrições nas cartas de aproximação por instrumentos em procedimentos RNAV/GNSS (Sistema de navegação aérea baseada por satélite) e NDB (Sistema de ajuda rádio a navegação ou Farol não direcional) que são 4.500, 4.800 e 5.000 metros, dependendo da pista em uso. Nas figuras 4.6 e 4.7 são respectivamente apresentadas as quantidades dos eventos mensais e horários cuja visibilidade é inferior a 4.500 metros. Observa-se que estas restrições ocorrem distribuídas durante todos os meses, com ocorrências maiores nos meses de julho e as menores nos meses de fevereiro, sendo 50% das ocorrências no período das 5 às 11 horas local, com um máximo às 8 horas.

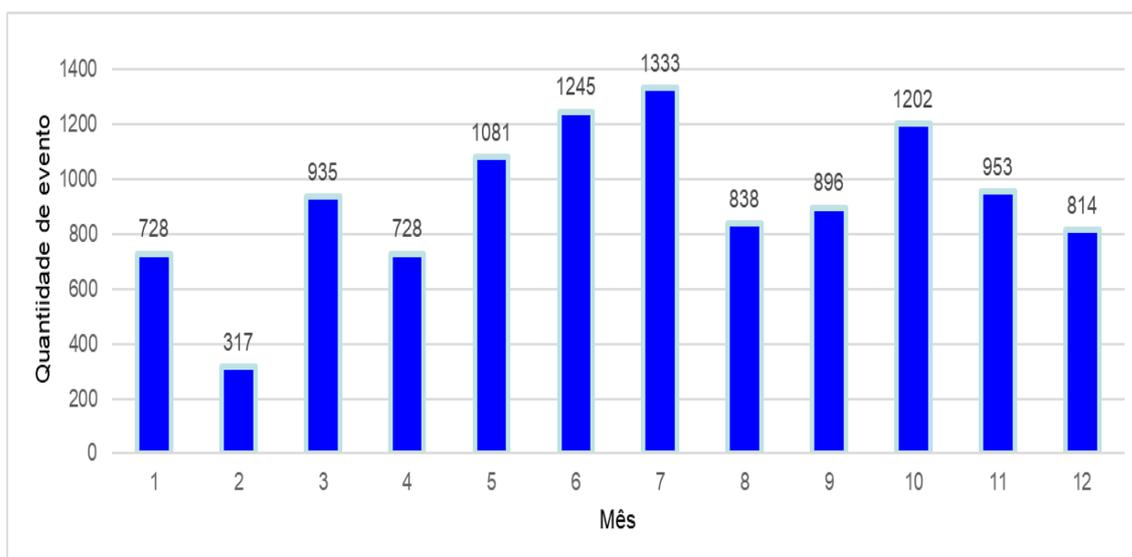


Figura 4.6: Distribuição mensal dos eventos de visibilidade inferior ao limite de 4.500 metros no período de 2009 a 2018.

Fonte: O autor.

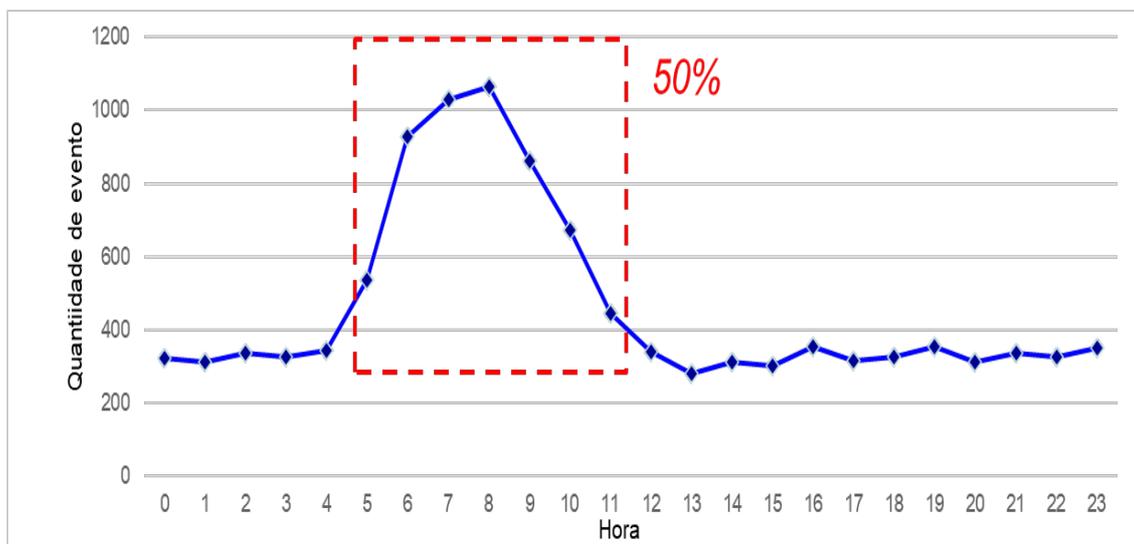


Figura 4.7: Distribuição horária dos eventos de visibilidade inferior ao limite de 4.500 metros no período de 2009 a 2018.

Fonte: O autor

O limite de 3.700 metros de visibilidade pode ser considerado o mais importante, uma vez que com a visibilidade abaixo desse valor, somente é permitido os procedimentos RNAV/RNP (Sistema de performance de navegação requerida), que requer autorização especial para a aeronave e para a tripulação. Nas figuras 4.8 e 4.9, são respectivamente apresentadas as quantidades mensais e horárias dos eventos cuja visibilidade é inferior a 3.700 metros. As restrições são mais frequentes entre maio e julho, com 40% dos eventos, e 54% destes ocorrendo no período das 5 às 11 horas local, com um máximo às 7 horas.

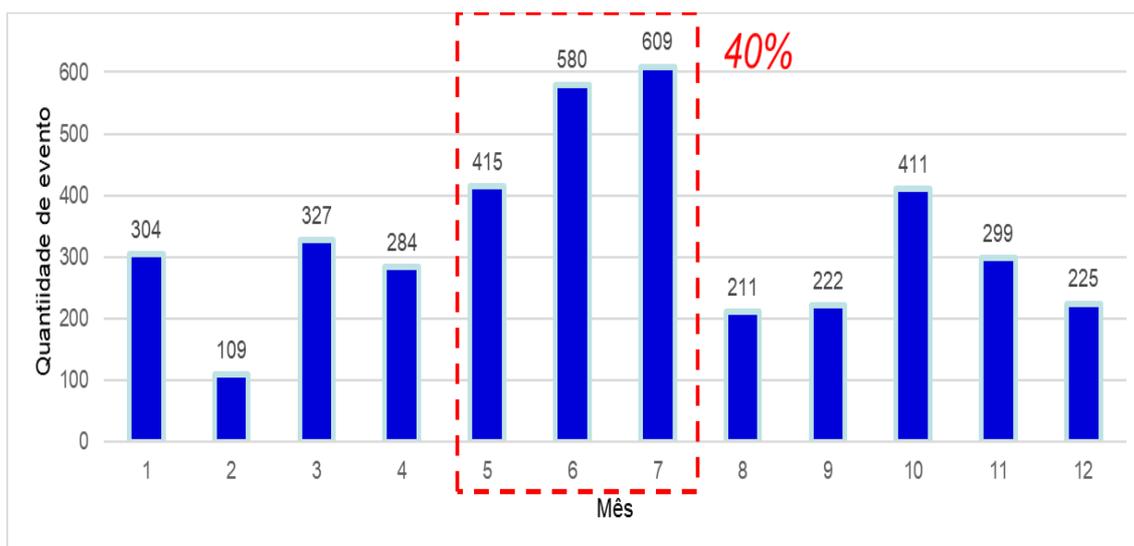


Figura 4.8: Distribuição mensal dos eventos de visibilidade inferior ao limite de 3.700 metros no período de 2009 a 2018.

Fonte: O autor.

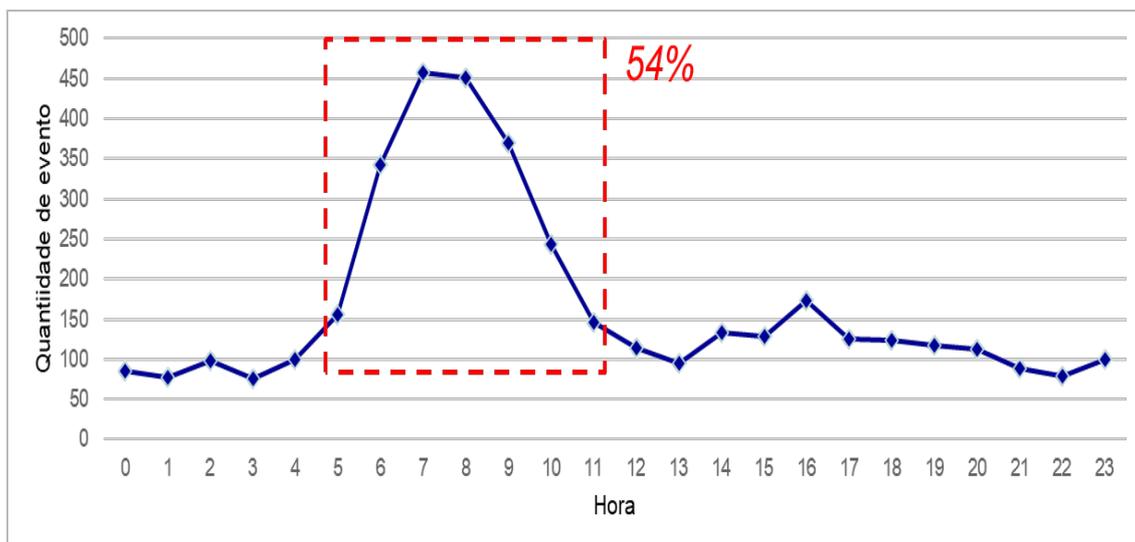


Figura 4.9: Distribuição horária dos eventos de visibilidade inferior ao limite de 3.700 metros no período de 2009 a 2018.

Fonte: O autor.

O parâmetro de 1.600 metros é bastante restritivo, pois abaixo desse valor não há procedimento de pouso no Santos Dumont, e os procedimentos de pouso e decolagem com a visibilidade acima disso e abaixo de 3.700 metros, seguem as orientações conforme carta de aproximação por instrumentos RNAV/RNP, onde a aeronave e a tripulação precisam estar habilitadas para realizar esse tipo de procedimento. Similarmente aos limites de visibilidade anteriores, as Figuras 4.10 e 4.11 apresentam respectivamente as quantidades dos eventos mensais e horários cuja visibilidade é inferior a 1.600 metros e nota-se que 63% dos eventos se concentram entre maio e agosto, com 67% destes ocorrendo no período das 5 às 10 horas local, com um máximo às 8 horas.

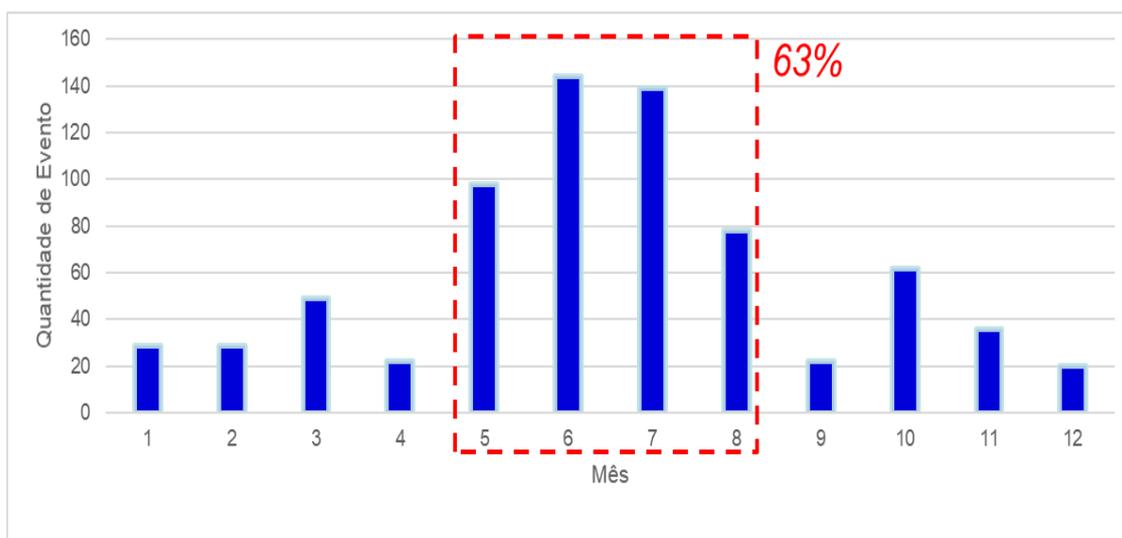


Figura 4.10: Distribuição mensal dos eventos de visibilidade inferior ao limite de 1.600 metros no período de 2009 a 2018.

Fonte: O autor.

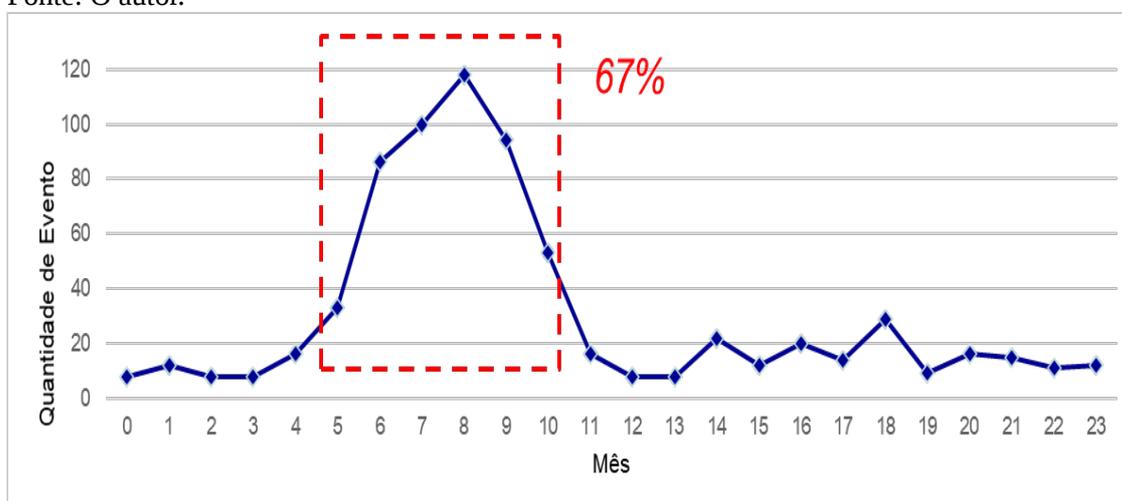


Figura 4.11: Distribuição horária dos eventos de visibilidade inferior ao limite de 1.600 metros no período de 2009 a 2018.

Fonte: O autor.

### 4.3.2 Restrições de teto

Assume-se o limite de 1.000 pés de teto por ser o limite intermediário e o mais impactante, pois abaixo desse valor e não inferior a 300 pés, o procedimento utilizado é o RNAV/RNP, e conforme já destacado é o procedimento mais restritivo existente no aeroporto. Nas figuras 4.12 e 4.13, pode-se observar que essas restrições ocorrem com uma frequência de 44% dos casos entre os meses de maio e agosto, e 67% dos casos entre 5 e 10 horas local, com um máximo às 9 horas.

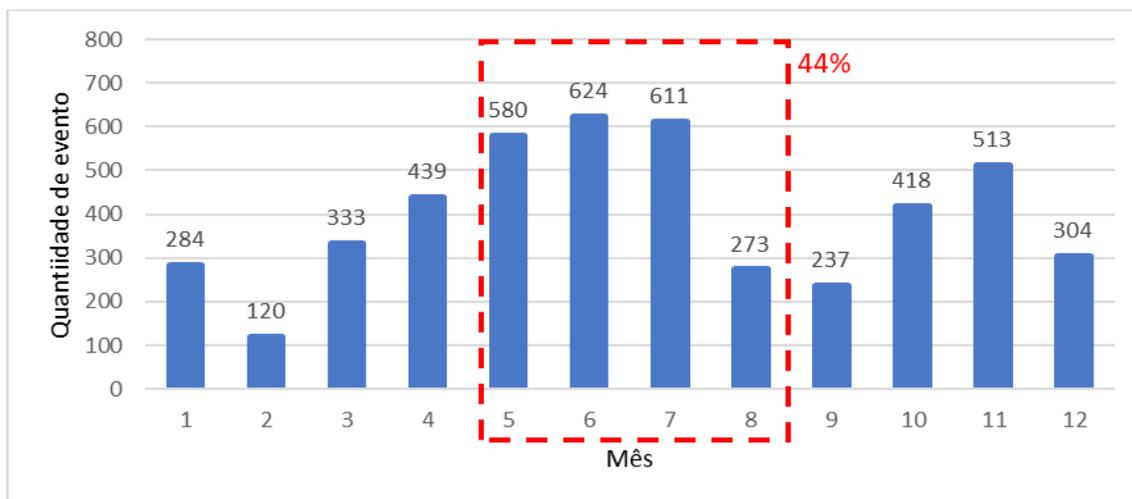


Figura 4.12: Distribuição mensal dos eventos de teto inferior ao limite de 1.000 pés no período de 2009 a 2016.

Fonte: O autor.

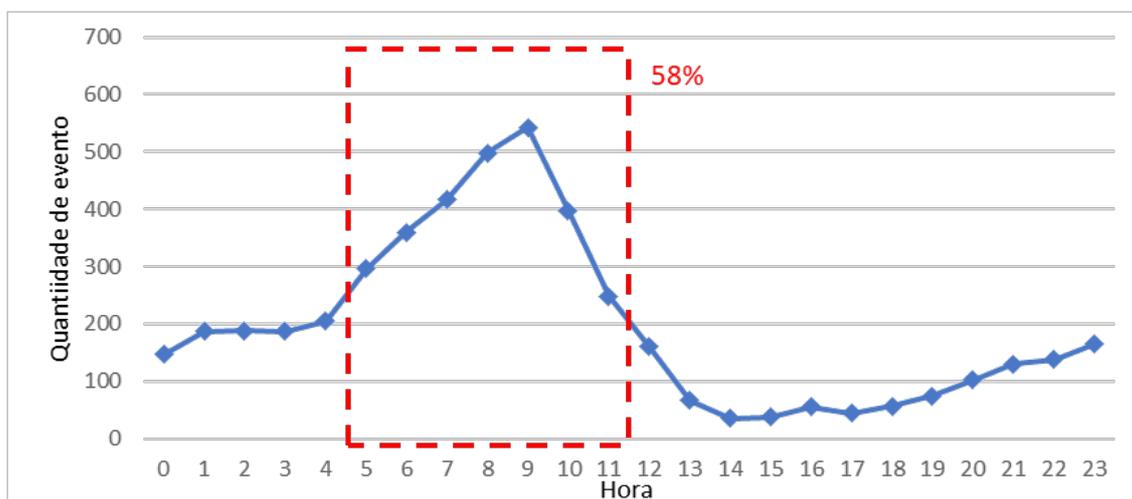


Figura 4.13: Distribuição horária dos eventos de teto inferior ao limite de 1.000 pés no período de 2009 a 2016.

Fonte: O autor.

Através do estudo dos dados, conclui-se que os fenômenos de restrição de visibilidade e teto possuem uma correlação, pois em 28% dos eventos de restrições de teto abaixo de 1.000 pés, também havia restrições de visibilidade abaixo de 4.500 metros, e em 69% dos casos de restrições de teto também abaixo de 1.000 pés, a visibilidade se restringiu abaixo ou igual a 10.000 metros.

Em resumo, pode-se inferir que a maioria dos eventos de restrições de visibilidade e teto ocorrem entre os meses de maio a agosto no período da manhã, ou seja, a maioria das ocorrências coincide com o período de inverno na região de estudo, o que caracteriza que os eventos são predominantemente de condições atmosféricas estáveis, características intrínsecas à essa estação do ano.

A maioria das restrições de visibilidade e teto ocorrendo no período da manhã no Santos Dumont, impacta ainda mais por se tratar de um dos períodos de maior movimento no aeroporto, pois coincide com os horários de maior fluxo de aeronaves devido à ponte aérea Rio/São Paulo, que ocorre entre 7 e 9 horas no período da manhã e entre 17 e 19 horas no período da noite, segundo dados do anuário estatístico do CGNA de 2019.

## 5 MÉTODO

Na Figura 5.1 são apresentados de forma esquemática os passos metodológicos deste estudo que serão detalhados a seguir:

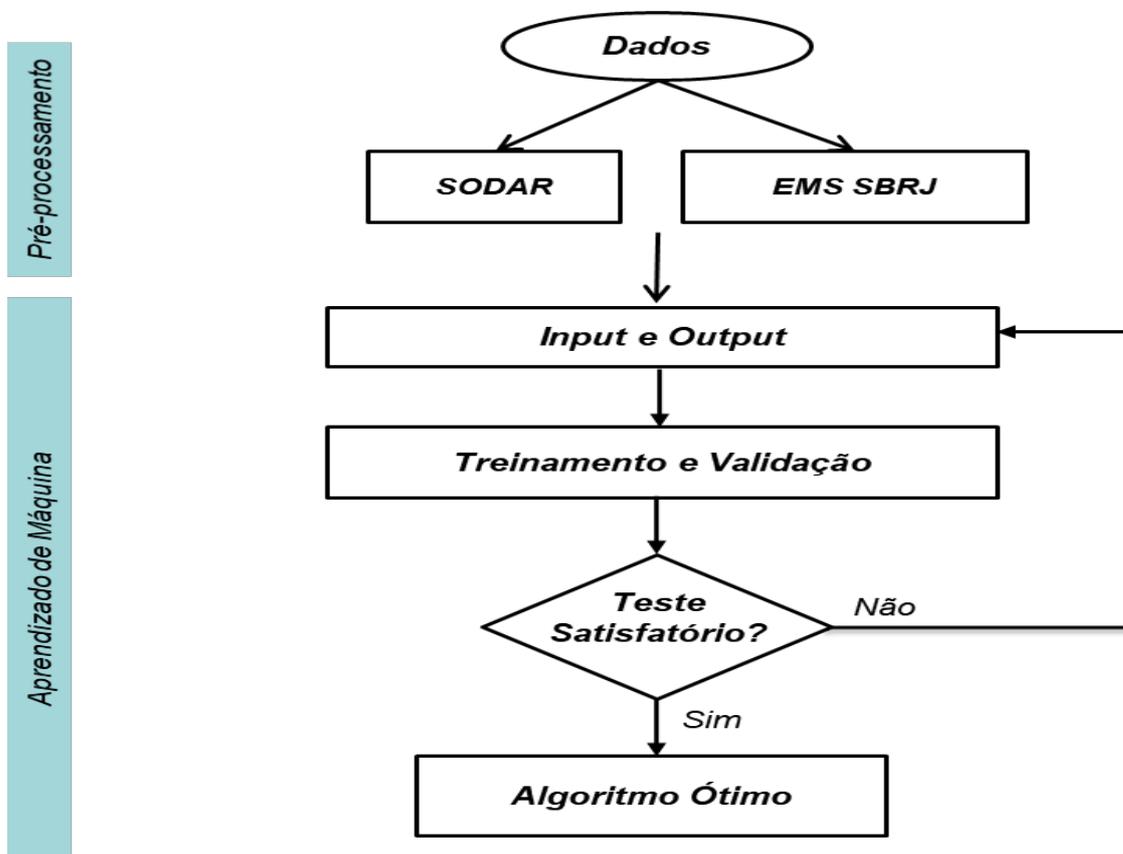


Figura 5.1: Passos Metodológicos.  
Fonte: O autor.

Considerando que os dados observacionais registram o comportamento termodinâmico da atmosfera associado às variações da visibilidade e do teto, no aeroporto Santos Dumont, o propósito é tentar identificar e prever os limites operacionais do referido aeródromo baseado nos dados coletados. Desta forma, o problema aqui é classificar padrões termodinâmicos que precedem as restrições operacionais de teto e de visibilidade e, para isso, os seguintes passos são necessários:

- I. Organiza-se de forma cronológica as séries de dados (isto é, SODAR, EMS e OBSERVADOR) e remove-se os dados espúrios;
- II. Analisa-se o histórico das ocorrências dos eventos de visibilidade e teto restritivos às operações de pouso e decolagens;

- III. Define-se os períodos de previsão com 15, 30, 45 e 60 minutos para os limites operacionais para visibilidade inferior a 4.500, 3.700, 1.600 metros e teto de 1.000 pés;
- IV. Analisa-se a correlação cruzada das variáveis meteorológicas coletadas e derivadas e define-se os dados de entrada (*input*) a serem utilizados pelos algoritmos de aprendizado de máquina. O *output* é a classe (da visibilidade ou do teto) a ser prevista para cada período de previsão (conforme passo III), que é SIM se a visibilidade ou o teto tem valor inferior a um dado limite operacional; caso contrário é NÃO;
- V. Considerando os períodos de previsão e limites operacionais no passo III, constrói-se respectivamente doze e quatro conjuntos de dados (isto é, conectando *input* e *output*) para treinamento e teste dos algoritmos preditivos da visibilidade e do teto, aqui definidos como dados originais;
- VI. Divide-se aleatoriamente os conjuntos de dados de visibilidade em 60% para treinamento e 40% para teste e 80% para treinamento e 20% para teste na avaliação do teto. O conjunto para as avaliações de visibilidade é composto de dez anos de dados (2009 a 2018), e para as avaliações de teto é composto de 8 anos de dados (2009 a 2016);
- VII. Testa-se preliminarmente todos os algoritmos classificatórios de aprendizagem de máquina disponíveis no pacote WEKA utilizando o conjunto de dados definidos no passo V, e seleciona-se aqueles com os melhores desempenhos (conforme Tabela 3.1);
- VIII. Realiza-se experimentos com os algoritmos selecionados no passo VII, variando artificialmente o conjunto de dados de treinamento em cinco configurações, com a proporção da saída de registro com SIM e NÃO, a saber: (1) dados originais, (2) em 55% de "SIM" e 45% de "NÃO", (3) 60% de "SIM" e 40% de "NÃO", e (4) 65% de "SIM" e 35% de "NÃO", para os períodos de previsão e limites operacionais no passo II;
- IX. Testa-se os algoritmos treinados no passo VII para todas as configurações de conjuntos de dados de teste definido em VI e obtém-se o algoritmo ótimo;

- X. Realiza-se experimentos para previsão da visibilidade e do teto, classificatório e regressivo (onde o *output* é valor da visibilidade ou do teto), utilizando a opção Auto-WEKA, que analisa automaticamente o problema e treina algoritmos classificatórios ou regressivos. Este divide o conjunto de dados originais em 70% para treinamento e 30% para teste. Os algoritmos são treinados e o desempenho é avaliado através da validação cruzada, a qual consiste em dividir o total de dados definidos em subconjuntos mutuamente exclusivos do mesmo tamanho, e a partir daí um subconjunto é usado para validação e o k-1 restante é usado para treinamento. Este processo é realizado k vezes alternando o subconjunto de validação até que todos os subconjuntos sejam usados tanto para treinamento quanto validação. Os algoritmos são então avaliados iterativamente com o conjunto de dados de teste, até que o ótimo seja obtido (Kotthoff *et al*, 2016).

### 5.1 Estatísticas de avaliação

Os algoritmos classificatórios utilizados têm suas previsões avaliadas em comparação com as observações utilizando uma tabela de contingência bidimensional, definida na Tabela 5.1.

Tabela 5.1 – Tabela de contingência 2x2.

		Observado		
		evento	não-evento	
previsto	evento	a	b	a+b
	não-evento	c	d	c+d
		a+c	b+d	n=a+b+c+d

Fonte: Wilks (2006).

Onde a é o número de acertos do evento; b é o número de eventos previstos, mas que não foram observados; c é o número de eventos que foram observados e não foram previstos; d é o número de acertos do não-evento; (a+c) é o total de eventos observados; (b+d) é o total de não-eventos observados; (a+b) é o total de eventos previstos; (c+d) é o total de não-eventos previstos; e n é o tamanho do conjunto ou amostra. Esta permite determinar cinco estatísticas categóricas, a saber:

- 1) *POD* – Probabilidade de Detecção ou Previsão Correta do Evento (ou verdadeiro-positivo); fornece a taxa de previsão correta do evento desejado. É descrito na equação 5.1.

$$POD = \frac{a}{a+c} \quad (5.1)$$

- 2) *FAR* – Probabilidade de Falsa Detecção ou alarme falso (ou falso-positivo). Corresponde à razão do número de alarme falso dividido pelo total de não eventos observados, como na equação 5.2.

$$FAR = \frac{b}{b+d} \quad (5.2)$$

Para que todas as estatísticas tenham o valor ideal a unidade, a diferença de 1-*FAR* com a probabilidade de detecção do não evento, é utilizada para medir a precisão do prognóstico da não ocorrência.

- 3) *F-MEASURE* – Representa a média harmônica da precisão e da sensibilidade, representado pela equação 5.3.

$$F - MEASURE = \frac{2 \times \text{sensibilidade} \times \text{precisão}}{\text{sensibilidade} + \text{precisão}} = \frac{2 \times \text{Sensibilidade} \times \text{Precisão}}{\text{Sensibilidade} + \text{Precisão}} \quad (5.3)$$

onde  $\text{Sensibilidade} = \frac{\text{N}^\circ \text{ de eventos recuperados que são relevantes}}{\text{Total de N}^\circ \text{ de eventos que são relevantes}}$ ,  
 $\text{Precisão} = \frac{\text{N}^\circ \text{ de eventos recuperados que são relevantes}}{\text{Total de N}^\circ \text{ de eventos que são recuperados}}$ ,

TP é o verdadeiro positivo; FP é o falso positivo; e FN é o falso negativo.

- 4) *VIÉS (BIAS)* – Erro sistemático que denota a tendência dos resultados se afastarem do valor verdadeiro, o valor ideal dessa estatística é igual a 1.
- 5) *KAPPA* – Estatística usada para medir a concordância entre as categorizações previstas e observadas de um conjunto de dados. Landis e Koch (1977) classificaram os diferentes níveis de concordância (ou reprodutibilidade) conforme mostra tabela abaixo:

Tabela 5.2 – Tabela do coeficiente KAPPA.

INTERVALO	NÍVEL DE CONCORDÂNCIA
< 0	Não existe Concordância
0 - 0,20	Concordância Mínima
0,21 - 0,40	Concordância Razoável
0,41 - 0,60	Concordância Moderada
0,61 - 0,80	Concordância Substancial
0,81 - 1,0	Concordância Perfeita

Coeficiente de correlação – Mede a correlação entre duas variáveis estatísticas, varia de 1 para resultados totalmente correlacionados, a 0 quando não há correlação. Pode ser representado segundo a equação 5.4.

$$\frac{S_{PA}}{\sqrt{S_P S_A}} \quad (5.4)$$

onde:

$$S_{PA} = \frac{\sum (P_i - \bar{P})(a_i - \bar{a})}{n-1} ; \quad S_P = \frac{\sum (P_i - \bar{P})^2}{n-1} ;$$

$$S_A = \frac{\sum (a_i - \bar{a})^2}{n-1}$$

Erro médio absoluto – Representado pela equação 5.5.

$$\frac{|p_1 - a_1| + \dots + |P_n - a_n|}{n} \quad (5.5)$$

Erro absoluto relativo – Representado pela equação 5.6.

$$\frac{|p_1 - a_1| + \dots + |P_n - a_n|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|} \quad (5.6)$$

Erro médio quadrático – Representado pela equação 5.7.

$$\frac{(p_1 - a_1)^2 + \dots + (P_n - a_n)^2}{n} \quad (5.7)$$

Erro quadrático relativo – Representado pela equação 5.8.

$$\frac{(p_1 - a_1)^2 + \dots + (P_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2} \quad (5.8)$$

- $p$  são os valores previstos das instâncias de teste;
- $a$  são os valores reais das instâncias de teste;
- $\bar{a}$  é a média dos valores das instâncias de teste; e
- $n$  é o número de instâncias.

Destaca-se que de acordo com as avaliações estatísticas mencionadas, foram considerados como resultados satisfatórios e possíveis de serem utilizadas em órgãos operacionais de meteorologia aeronáutica, os que alcançaram desempenhos iguais ou maiores a 80% nas avaliações classificatórias dos modelos de previsão de visibilidade e teto.

Para as avaliações regressivas dos modelos, foram adotados o coeficiente de correlação e o erro absoluto relativo como as estatísticas de referência, com valores considerados satisfatórios sendo iguais ou maiores a 80% e iguais ou menores a 20% respectivamente.

## 6 RESULTADOS E DISCUSSÃO

Considerando os passos do método definido, a seguir são apresentadas as discussões relativas aos processos de aprendizado dos algoritmos, treinamento e testes deles para previsão de visibilidade e do teto no aeroporto estudado neste trabalho.

### 6.1 Aprendizado de Máquina

#### 6.1.1 *Nowcasting de visibilidade*

Em geral, a tarefa de treinar algoritmos de inteligência computacional demanda tempo, como ficou evidenciado nos vários passos descritos no item 5. O êxito não somente depende do algoritmo e hiperparâmetros selecionados, mas também da escolha das variáveis que caracterizam o estado da atmosfera local que precede a ocorrência das restrições dos limites operacionais de visibilidade e teto estabelecidos e que são respectivamente descritos no passo III do método. Na tabela 4.2, nas colunas 3 e 4 são apresentadas as variáveis meteorológicas coletadas ou primárias (coluna 3) e derivadas (coluna 4) pelas três fontes de dados utilizadas, totalizando 34 variáveis (coletada e derivada) ou possíveis preditores. Assim, considerando o passo IV do método, se analisou a correlação cruzada das variáveis, eliminando aquelas redundantes. Os resultados indicaram o uso de dezenove variáveis preditoras, no treinamento dos algoritmos de nowcasting de visibilidade e teto, a saber: MÊS, DIA, HH, IR02, V02, DIR10, V10, TCLDLO, BCLDLO, Tar, Td, UR, QNH, VIS<sub>pred</sub>, VSB-15, VSB-30, VSB-45, VSB-60, VSB-120.

Segundo os passos do método, 4 (quatro) períodos de previsão, ou seja 15, 30, 45 e 60 minutos, 3 (três) limites operacionais de visibilidade (VSB inferior a 4.500, 3.700, 1.600 metros) e 1 (um) de teto (inferior a 1.000 pés) foram estabelecidos no passo III; 5 (cinco) algoritmos classificatórios foram selecionados no passo VII; e 4 (quatro) configurações de conjunto de treinamento foram idealizados no passo VIII. Isto possibilitou a execução de 240 experimentos de treinamento para os cinco algoritmos e os resultados são abaixo discutidos.

## 6.2 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 15 minutos

Na tabela 6.1, que demonstra as performances classificatórias dos cinco melhores algoritmos de previsão, para 4.500, 3.700 e 1.600 metros e 15 minutos de resolução temporal, com os dados originais e com os pesos modificados. Após o treinamento e o teste, a maioria dos algoritmos tiveram desempenhos acima do limite considerado satisfatório, com POD, 1-FAR, F-MEASURE e viés acima de 80%, tanto do evento quanto do não evento. O Auto-WEKA possui a capacidade de pesquisar automaticamente através do conjunto dos algoritmos de aprendizagem do WEKA, a melhor configuração disponível para a previsão do evento desejado, e foi utilizado com o intuito de melhorar os resultados das previsões classificatórias para tentativas que não obtiveram resultados satisfatórios. Destaca-se que os melhores desempenhos foram obtidos pela árvore de decisão *Random Forest*, conforme ilustrado na tabela 6.1, para 4.500 metros com o Auto-Weka, e para 3.700 e 1.600 metros com os pesos dos eventos modificados para 60% e 65% respectivamente. Destaca-se que a previsão para 4.500 metros foi a que obteve melhor desempenho com todas as métricas acima de 90%, e que para 3.700 e 1.600 metros os resultados também foram acima do limite satisfatório, porém com um pequeno decréscimo, principalmente na POD (V), que está relacionado com a diminuição da quantidade de eventos à medida que a restrição de visibilidade aumenta.

Tabela 6.1 – Algoritmos com os melhores resultados para previsão de 15 Min e 4.500, 3.700 e 1.600 metros.

Previsão de 15 minutos para VIS <4.500 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE (V)	VIÉS (V)	POD(F)	1-FAR (F)	F-MEASURE (F)	VIÉS (F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,825	0,965	0,719	0,77272723	0,965	0,825	0,99	0,990891	0,7092	PESO 68%
Multilayer Perceptron	0,883	0,998	0,905	1,049167734	0,998	0,883	0,997	1,001451	0,9016	DADOS ORIGINAIS
Random Forest	0,909	0,997	0,908	0,999268293	0,997	0,909	0,997	0,999977	0,9055	PESO 50%
Hoeffding Tree	0,909	0,997	0,908	0,999512076	0,997	0,909	0,997	0,999985	0,9057	DADOS ORIGINAIS
REPTree	0,889	0,998	0,903	1,030951183	0,998	0,889	0,997	1,00093	0,9	DADOS ORIGINAIS
Random Forest	0,911	0,997	0,911	0,999856549	0,997	0,911	0,997	0,999995	0,9076	AUTOWEKA
Previsão de 15 minutos para VIS <3.700 metros										
Algoritmo	POD(V)	1-FAR (V)	F-MEASURE (V)	VIÉS (V)	POD(F)	1-FAR (F)	F-MEASURE (F)	VIÉS (F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,893	0,966	0,367	0,258952703	0,966	0,893	0,982	0,967467	0,3559	DADOS ORIGINAIS
Multilayer Perceptron	0,838	0,999	0,877	1,098137536	0,999	0,838	0,999	1,001016	0,8761	DADOS ORIGINAIS
Random Forest	0,882	0,999	0,885	1,007889546	0,999	0,882	0,999	1,000089	0,8841	PESO 60%
Hoeffding Tree	0,817	0,999	0,864	1,120614035	0,999	0,817	0,999	1,001224	0,8624	DADOS ORIGINAIS
REPTree	0,849	0,999	0,885	1,086463501	0,999	0,849	0,999	1,000905	0,8833	DADOS ORIGINAIS
Random Forest	0,871	0,998	0,875	1,007780508	0,998	0,871	0,998	1,000098	0,873	AUTOWEKA
Previsão de 15 minutos para VIS <1.600 metros										
Algoritmo	POD(V)	1-FAR (V)	F-MEASURE (V)	VIÉS (V)	POD(F)	1-FAR (F)	F-MEASURE (F)	VIÉS (F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,88	0,994	0,427	0,32	0,994	0,88	0,997	0,993874	0,4242	DADOS ORIGINAIS
Multilayer Perceptron	0,681	1	0,78	1,337883959	1	0,681	0,999	1,000728	0,779	DADOS ORIGINAIS
Random Forest	0,883	1	0,883	1,023498695	1	0,883	1	1,000066	0,8926	PESO 68%
Hoeffding Tree	0,556	1	0,667	1,496183206	1	0,556	0,999	1,000956	0,6659	DADOS ORIGINAIS
REPTree	0,888	1	0,888	1	1	0,888	1	1	0,8874	DADOS ORIGINAIS
Random Forest	0,86	1	0,86	1	1	0,86	1	1	0,8599	AUTOWEKA

### 6.3 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 30 minutos

Destacando as previsões para 30 minutos, foi observado na Tabela 6.2, que o desempenho da inteligência artificial diminui com o passar do tempo e com a diminuição dos eventos de restrição de visibilidade. O algoritmo *Random Forest* obteve o melhor desempenho no conjunto das estatísticas avaliadas para os três limites de visibilidade. O melhor desempenho foi alcançado na previsão de 4.500 metros com o Auto-Weka, na qual todas as estatísticas foram satisfatórias, contudo, destaca-se a queda de desempenho na probabilidade de detecção do evento em comparação à melhor previsão de 15 minutos, que passou de 91.1% para 82.2% na previsão de 30 minutos, o que representa uma perda de 8.9%. Destaca-se também que para os limites de 3.700 e 1.600 metros, os desempenhos dos melhores algoritmos ficaram abaixo do limite satisfatório nas estatísticas POD (V), F-MEASURE (V), 1 – FAR (F) e KAPPA.

Tabela 6.2 – Algoritmos com os melhores resultados para previsão de 30 Min e 4.500, 3.700 e 1.600 metros.

Previsão de 30 minutos para VIS <4.500 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,835	0,951	0,491	0,416031698	0,951	0,835	0,973	0,956548	0,468	DADOS ORIGINAIS
Multilayer Perceptron	0,748	0,996	0,8	1,150280899	0,996	0,748	0,994	1,004044	0,7945	DADOS ORIGINAIS
Random Forest	0,815	0,994	0,814	0,996835443	0,994	0,815	0,994	0,999902	0,8081	PESO 60%
Hoeffding Tree	0,767	0,994	0,785	1,05	0,994	0,767	0,994	1,001474	0,779	DADOS ORIGINAIS
REP Tree	0,741	0,995	0,783	1,12088037	0,995	0,741	0,994	1,008326	0,7766	DADOS ORIGINAIS
Random Forest	0,822	0,994	0,822	0,999819266	0,994	0,822	0,994	0,999994	0,8158	AUTOWEKA
Previsão de 30 minutos para VIS <3.700 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,836	0,956	0,295	0,2137575	0,956	0,836	0,977	0,958212	0,2812	DADOS ORIGINAIS
Multilayer Perceptron	0,606	0,999	0,704	1,38517179	0,999	0,606	0,997	1,008159	0,7015	DADOS ORIGINAIS
Random Forest	0,75	0,998	0,767	1,04648067	0,998	0,75	0,997	1,000504	0,7644	PESO 65%
Hoeffding Tree	0,667	0,994	0,605	0,829004329	0,994	0,667	0,995	0,997657	0,5998	DADOS ORIGINAIS
REP Tree	0,644	0,998	0,721	1,273482959	0,998	0,644	0,997	1,00244	0,7182	DADOS ORIGINAIS
Random Forest	0,756	0,997	0,756	1,001254076	0,997	0,756	0,997	1,000015	0,7535	AUTOWEKA
Previsão de 30 minutos para VIS <1.600 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,811	0,99	0,316	0,241826033	0,99	0,811	0,995	0,990962	0,3128	DADOS ORIGINAIS
Multilayer Perceptron	0,406	1	0,555	2,165745856	1	0,406	0,999	1,001552	0,5542	DADOS ORIGINAIS
Random Forest	0,727	0,999	0,764	1,107344633	0,999	0,727	0,999	1,000279	0,7634	PESO 60%
Hoeffding Tree	0,173	0,999	0,015	0,04688899	0,999	0,173	0,967	0,941142	0,01	PESO 60%
REP Tree	0,656	0,343	0,761	1,395159011	1	1	0,999	1,000802	0,7609	DADOS ORIGINAIS
Random Forest	0,751	0,999	0,756	1,012517385	0,999	0,751	0,999	1,000027	0,7555	AUTOWEKA

#### 6.4 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 45 minutos

Analisando os resultados das previsões para 45 minutos destacados na Tabela 6.3, os desempenhos dos algoritmos ficaram abaixo do limite satisfatório de 80% em algumas estatísticas. Os melhores resultados foram obtidos pelo algoritmo *Random Forest* com o Auto-Weka em todos os limites, no entanto, as estatísticas POD (V), F-Measure (V) e 1 – FAR (F) foram insatisfatórias, ficando pouco acima de 73% para 4.500 metros, 63% para 3.700 metros e no pior desempenho que foi para a previsão de 1.600 metros, o resultado foi de 60% para o POD (V) e 1 – FAR (F), e 73.3% para o F-Measure (V), além de um Viés (V) de 1.568, indicando que a previsão do evento está sendo superestimada em 56.8%. Portanto, o modelo para 45 minutos com as configurações aqui detalhadas, não é recomendável para ser utilizado isoladamente, no entanto, a utilização em conjunto com outros modelos, como os regressivos, pode auxiliar nas tomadas de decisões no setor operacional.

Tabela 6.3 – Algoritmos com os melhores resultados para previsão de 45 Min e 4.500, 3.700 e 1.600 metros.

Previsão de 45 minutos para VIS <4.500 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE (V)	VIÉS (V)	POD(F)	1-FAR (F)	F-MEASURE (F)	VIÉS (F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	<b>0,798</b>	<b>0,942</b>	<b>0,435</b>	<b>0,374462636</b>	<b>0,942</b>	<b>0,798</b>	<b>0,967</b>	<b>0,948301</b>	<b>0,4087</b>	<b>DADOS ORIGINAIS</b>
Multilayer Perceptron	<b>0,633</b>	<b>0,995</b>	<b>0,703</b>	<b>1,248170732</b>	<b>0,995</b>	<b>0,633</b>	<b>0,992</b>	<b>1,006153</b>	<b>0,6949</b>	<b>DADOS ORIGINAIS</b>
Random Forest	<b>0,721</b>	<b>0,992</b>	<b>0,725</b>	<b>1,012363996</b>	<b>0,992</b>	<b>0,721</b>	<b>0,992</b>	<b>1,000378</b>	<b>0,7168</b>	<b>PESO 60%</b>
Hoeffding Tree	<b>0,718</b>	<b>0,99</b>	<b>0,708</b>	<b>0,973834443</b>	<b>0,99</b>	<b>0,718</b>	<b>0,991</b>	<b>0,999168</b>	<b>0,6992</b>	<b>DADOS ORIGINAIS</b>
REPTree	<b>0,607</b>	<b>0,991</b>	<b>0,645</b>	<b>1,133444075</b>	<b>0,991</b>	<b>0,607</b>	<b>0,99</b>	<b>1,003644</b>	<b>0,6347</b>	<b>DADOS ORIGINAIS</b>
Random Forest	<b>0,736</b>	<b>0,991</b>	<b>0,738</b>	<b>1,00390235</b>	<b>0,991</b>	<b>0,736</b>	<b>0,991</b>	<b>1,000134</b>	<b>0,7285</b>	<b>AUTOWEKA</b>
Previsão de 45 minutos para VIS <3.700 metros										
Algoritmo	POD(V)	1-FAR (V)	F-MEASURE (V)	VIÉS (V)	POD(F)	1-FAR (F)	F-MEASURE (F)	VIÉS (F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	<b>0,792</b>	<b>0,945</b>	<b>0,257</b>	<b>0,19360392</b>	<b>0,95</b>	<b>0,792</b>	<b>0,973</b>	<b>0,952725</b>	<b>0,2426</b>	<b>DADOS ORIGINAIS</b>
Multilayer Perceptron	<b>0,465</b>	<b>0,999</b>	<b>0,589</b>	<b>1,729943503</b>	<b>0,999</b>	<b>0,465</b>	<b>0,996</b>	<b>1,004791</b>	<b>0,586</b>	<b>DADOS ORIGINAIS</b>
Random Forest	<b>0,602</b>	<b>0,997</b>	<b>0,644</b>	<b>1,15112782</b>	<b>0,997</b>	<b>0,602</b>	<b>0,996</b>	<b>1,001491</b>	<b>0,6401</b>	<b>PESO 60%</b>
Hoeffding Tree	<b>0,601</b>	<b>0,997</b>	<b>0,635</b>	<b>1,12161172</b>	<b>0,997</b>	<b>0,601</b>	<b>0,996</b>	<b>1,001231</b>	<b>0,6315</b>	<b>DADOS ORIGINAIS</b>
REPTree	<b>0,506</b>	<b>0,997</b>	<b>0,572</b>	<b>1,299660441</b>	<b>0,997</b>	<b>0,506</b>	<b>0,996</b>	<b>1,002618</b>	<b>0,5679</b>	<b>DADOS ORIGINAIS</b>
Random Forest	<b>0,639</b>	<b>0,996</b>	<b>0,642</b>	<b>1,009104704</b>	<b>0,996</b>	<b>0,639</b>	<b>0,996</b>	<b>1,00011</b>	<b>0,6734</b>	<b>AUTOWEKA</b>
Previsão de 45 minutos para VIS <1.600 metros										
Algoritmo	POD(V)	1-FAR (V)	F-MEASURE (V)	VIÉS (V)	POD(F)	1-FAR (F)	F-MEASURE (F)	VIÉS (F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	<b>0,75</b>	<b>0,987</b>	<b>0,243</b>	<b>0,193675899</b>	<b>0,987</b>	<b>0,75</b>	<b>0,993</b>	<b>0,987999</b>	<b>0,2397</b>	<b>DADOS ORIGINAIS</b>
Multilayer Perceptron	<b>0,23</b>	<b>1</b>	<b>0,352</b>	<b>3,294117647</b>	<b>1</b>	<b>0,23</b>	<b>0,999</b>	<b>1,002008</b>	<b>0,3514</b>	<b>DADOS ORIGINAIS</b>
Random Forest	<b>0,518</b>	<b>0,999</b>	<b>0,597</b>	<b>1,361111111</b>	<b>0,999</b>	<b>0,518</b>	<b>0,999</b>	<b>1,000765</b>	<b>0,5961</b>	<b>PESO 60%</b>
Hoeffding Tree	<b>0,541</b>	<b>0,999</b>	<b>0,606</b>	<b>1,272727273</b>	<b>0,999</b>	<b>0,541</b>	<b>0,999</b>	<b>1,000618</b>	<b>0,6047</b>	<b>DADOS ORIGINAIS</b>
REPTree	<b>0,469</b>	<b>1</b>	<b>0,583</b>	<b>1,640167364</b>	<b>1</b>	<b>0,469</b>	<b>0,999</b>	<b>1,001125</b>	<b>0,5823</b>	<b>DADOS ORIGINAIS</b>
Random Forest	<b>0,6</b>	<b>1</b>	<b>0,733</b>	<b>1,568965517</b>	<b>1</b>	<b>0,6</b>	<b>1</b>	<b>1,000795</b>	<b>0,7328</b>	<b>AUTOWEKA</b>

## 6.5 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros para 60 minutos

Quando a resolução temporal foi estendida para 1 hora, os resultados das previsões tiveram uma queda ainda maior. As estatísticas cujos desempenhos ficaram abaixo do limite satisfatório, foram o POD (V), F-Measure (V) e 1 – FAR (F), semelhante à resolução temporal de 45 minutos, com o melhor resultado para a previsão de 4.500 metros, com o POD (V) de 64.8%, F-Measure (V) de 69.6% e 1 – FAR (F) de 64.8%. Para as previsões de 3.700 e 1.600 metros os resultados caíram ainda mais, ratificando a perda de desempenho na previsão com o aumento da resolução temporal e das restrições de visibilidade. Evidenciando o limite desta tecnologia, com os tipos de dados utilizados, para a resolução temporal de 60 minutos.

Tabela 6.4 – Algoritmos com os melhores resultados para previsão de 60 Min e 4.500, 3.700 e 1.600 metros.

Previsão de 60 minutos para VIS <4.500 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,768	0,995	0,397	0,34864105	0,995	0,768	0,963	0,942209	0,2914	DADOS ORIGINAIS
Multilayer Perceptron	0,487	0,994	0,575	1,444405224	0,994	0,487	0,989	1,009517	0,3229	DADOS ORIGINAIS
Random Forest	0,632	0,989	0,638	1,018163722	0,989	0,632	0,989	1,000552	0,6268	PESO 68%
Hoeffding Tree	0,531	0,984	0,519	0,95540509	0,984	0,531	0,985	0,998556	0,3588	DADOS ORIGINAIS
REPTree	0,804	0,92	0,367	0,29589992	0,92	0,804	0,955	0,926395	0,3362	PESO 68%
Random Forest	0,648	0,993	0,696	1,162514454	0,993	0,648	0,99	1,004808	0,6866	AUTOWEKA
Previsão de 60 minutos para VIS <3.700 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,759	0,945	0,231	0,17953532	0,945	0,759	0,971	0,94815	0,2161	DADOS ORIGINAIS
Multilayer Perceptron	0,342	0,998	0,456	2,005242464	0,998	0,342	0,995	1,005688	0,4521	DADOS ORIGINAIS
Random Forest	0,431	0,997	0,498	1,369740376	0,997	0,431	0,995	1,003063	0,4931	PESO 68%
Hoeffding Tree	0,315	0,995	0,368	1,401098901	0,995	0,315	0,994	1,003248	0,3617	DADOS ORIGINAIS
REPTree	0,336	0,996	0,398	1,448863636	0,996	0,336	0,994	1,003515	0,392	DADOS ORIGINAIS
Random Forest	0,242	0,998	0,354	2,718473074	0,998	0,242	0,995	1,007672	0,35	AUTOWEKA
Previsão de 60 minutos para VIS <1.600 metros										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,716	0,983	0,189	0,152258567	0,983	0,716	0,991	0,983991	0,1852	DADOS ORIGINAIS
Multilayer Perceptron	0,176	1	0,282	3,949494949	1	0,176	0,999	1,002147	0,2808	DADOS ORIGINAIS
Random Forest	0,353	0,999	0,452	1,785388128	0,999	0,353	0,999	1,001265	0,4513	PESO 68%
Hoeffding Tree	0,481	0,999	0,535	1,253205128	0,999	0,481	0,999	1,000581	0,5337	DADOS ORIGINAIS
REPTree	0,312	0,999	0,401	1,793577982	0,999	0,312	0,999	1,001272	0,3994	DADOS ORIGINAIS
Random Forest	0,476	1	0,613	1,812967581	1	0,476	0,999	1,000982	0,6129	AUTOWEKA

Foi destacado nos gráficos 6.1 e 6.2 os melhores resultados para as previsões de 15, 30, 45 e 60 minutos, para os limites de 4.500, 3.700 e 1.600 metros, representados pelas estatísticas POD (V), POD (F), 1 – FAR (V) e 1 – FAR (F). Destaca-se que todas as previsões de 15 minutos tiveram resultados satisfatórios, com as estatísticas ficando próximas a 90%, tanto nas avaliações do evento quanto nas do não evento. Para as previsões de 30 minutos, os resultados para o limite de 4.500 metros foram satisfatórios, com POD (V), 1 – FAR (V), POD (F) e 1 – FAR (F) de 82.2%, 99.4%, 82.2% e 99.4% respectivamente, porém, nas previsões de 3.700 e 1.600 metros os resultados ficaram abaixo de 80%. Conforme destacado anteriormente, as previsões de 45 e 60 minutos obtiveram resultados insatisfatórios, principalmente nas estatísticas POD (V) e no 1 – FAR (F).

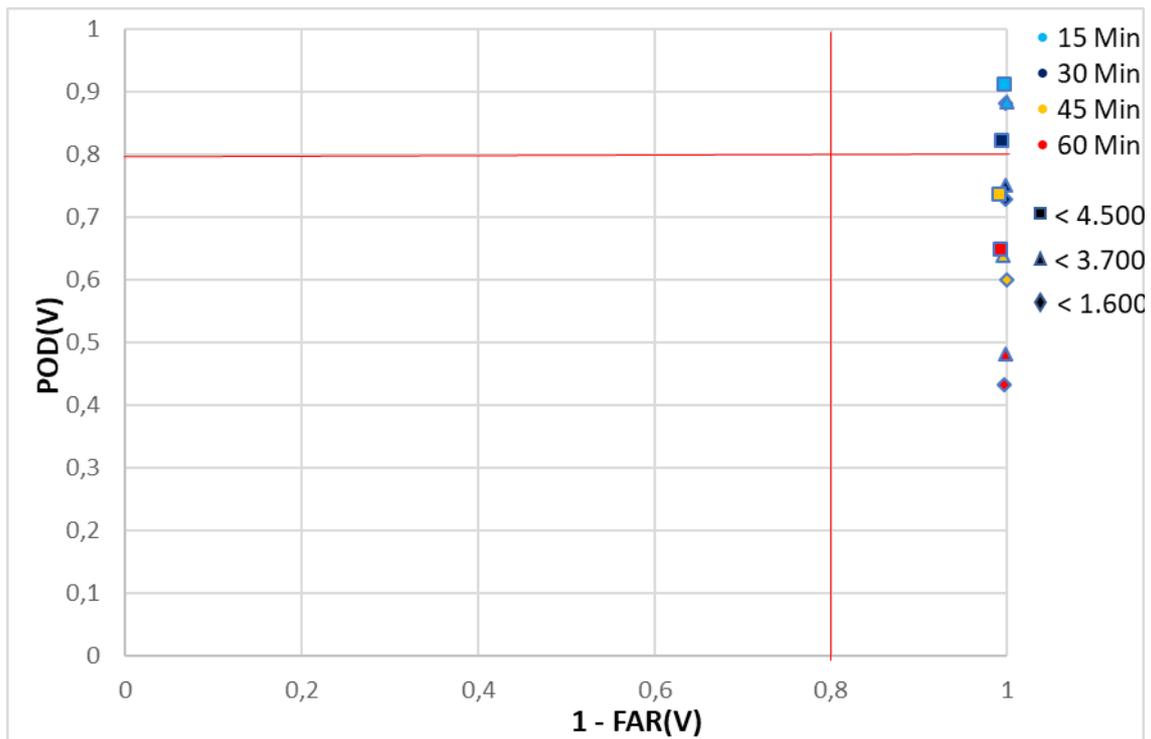


Gráfico 6.1: POD (V) x 1-FAR (V) com as melhores previsões para 15, 30, 45 e 60 minutos.  
Fonte: O autor.

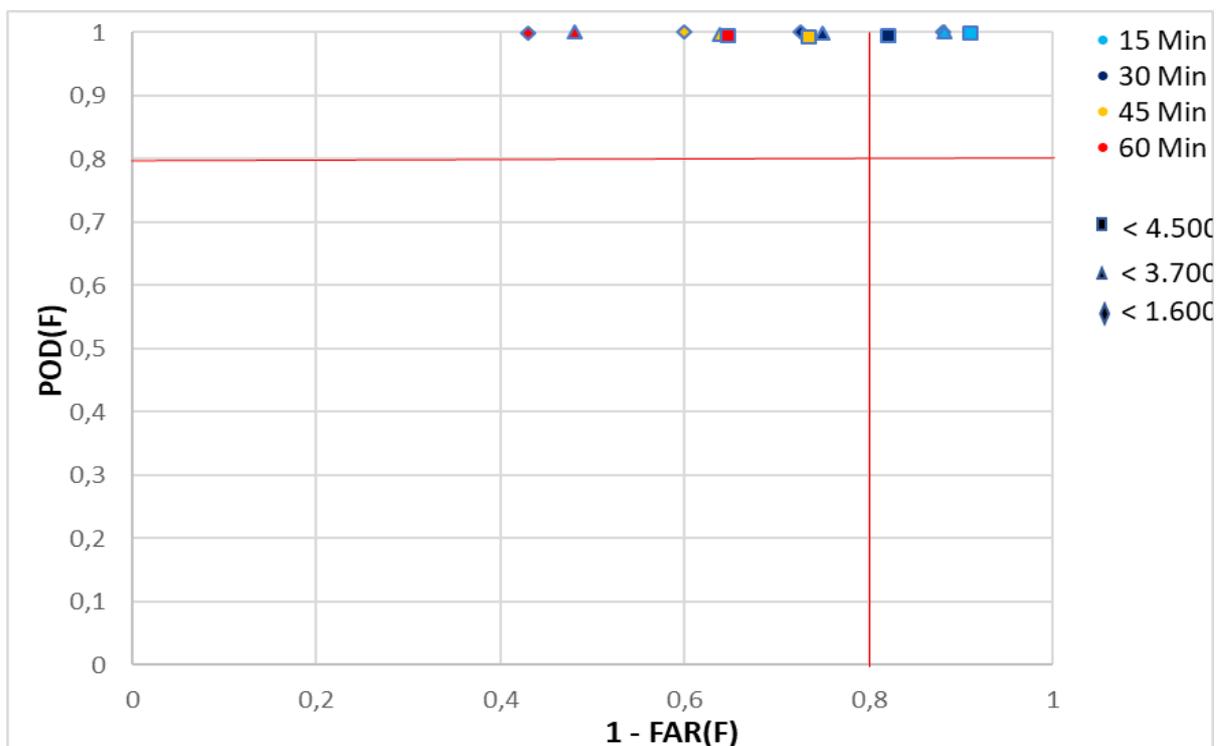


Gráfico 6.2: POD (F) x 1-FAR (F) com as melhores previsões para 15, 30, 45 e 60 minutos.  
Fonte: O autor.

## 6.6 Modelos classificatórios de teto para o parâmetro de 1000 pés

Na tabela 6.5 e nos gráficos 6.3 e 6.4, foram destacados os desempenhos dos modelos classificatórios para previsão de teto, cujo parâmetro restritivo estipulado nessa pesquisa foi de 1.000 pés de altura em relação à base da camada da nebulosidade que contenha mais de quatro oitavos do total da abóbada celeste, ou seja, que constitua teto para fins aeronáuticos. Foram feitos experimentos para todas as resoluções temporais de 15, 30, 45 e 60 minutos, porém, ficou evidente através da avaliação dos resultados, que os desempenhos dos algoritmos não foram satisfatórios já a partir do primeiro limite temporal, que é o de 15 minutos. O baixo desempenho das redes classificatórias para a previsão do teto, se devem principalmente à pouca ocorrência do evento, e ao fato de que a partir de 2016 até 2018, não houve mais registros de nebulosidade pelo tetômetro, em virtude da inoperância do equipamento, que é o responsável pela detecção da quantidade e base das nuvens. O melhor resultado desses experimentos foi obtido pelo algoritmo *Random Forest*, com o  $1 - \text{FAR}$  (V),  $\text{POD}$  (F) e  $F - \text{Measure}$  (F) sendo os destaques com valores de 99.1% de desempenho para as três medidas, e sem contar que tanto a Viés (V), quanto a Viés (F) obtiveram valores próximos a 1, que é o ideal. Porém, as estatísticas do  $\text{POD}$  (V),  $F - \text{Measure}$  (V) e  $1 - \text{FAR}$  (F) não obtiveram desempenhos satisfatórios, com valores de 69.1%, 68% e 69.1% respectivamente. Sendo assim, os modelos classificatórios de teto com os desempenhos destacados, não são indicados para utilização operacional.

Tabela 6.5 – Algoritmos com os melhores resultados para previsão de 15, 30, 45 e 60 Min e 1.000 pés.

Previsão de 15 minutos para TETO <1.000 pés										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,79	0,873	0,248	0,186551866	0,873	0,79	0,929	0,878806	0,2126	DADOS ORIGINAIS
Multilayer Perceptron	0,668	0,991	0,671	1,00942873	0,991	0,668	0,991	1,00026	0,6616	DADOS ORIGINAIS
Random Forest	0,691	0,991	0,68	0,968085106	0,991	0,691	0,991	0,999084	0,671	PESO 65%
Hoeffding Tree	0,863	0,901	0,317	0,22549669	0,901	0,863	0,946	0,904539	0,2859	PESO 50%
REP Tree	0,589	0,995	0,661	1,276297335	0,995	0,589	0,992	1,006017	0,6522	DADOS ORIGINAIS
Previsão de 30 minutos para TETO <1.000 pés										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,75	0,852	0,212	0,164859666	0,852	0,75	0,917	0,859305	0,1741	DADOS ORIGINAIS
Multilayer Perceptron	0,413	0,992	0,486	1,426332288	0,992	0,413	0,988	1,008308	0,4741	DADOS ORIGINAIS
Random Forest	0,437	0,991	0,496	1,315028902	0,991	0,437	0,988	1,006658	0,4842	PESO 65%
Hoeffding Tree	0,777	0,889	0,27	0,209846651	0,889	0,777	0,938	0,895345	0,2353	PESO 50%
REP Tree	0,823	0,898	0,299	0,222059541	0,898	0,823	0,944	0,90263	0,2667	PESO 50%
Previsão de 45 minutos para TETO <1.000 pés										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,728	0,84	0,194	0,153976311	0,84	0,728	0,909	0,847286	0,1547	DADOS ORIGINAIS
Multilayer Perceptron	0,801	0,783	0,167	0,116204827	0,783	0,801	0,876	0,788614	0,1243	PESO 50%
Random Forest	0,326	0,993	0,415	1,758454106	0,993	0,326	0,987	1,011988	0,4037	PESO 65%
Hoeffding Tree	0,647	0,814	0,155	0,136044252	0,814	0,647	0,882	0,823493	0,1126	PESO 60%
REP Tree	0,814	0,811	0,189	0,131464895	0,811	0,814	0,893	0,816377	0,1485	PESO 60%
Random Forest	0,46	0,999	0,598	1,853620852	0,999	0,46	0,996	1,006652	0,5937	AUTOWEKA
Previsão de 60 minutos para TETO <1.000 pés										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
Bayes Net	0,706	0,834	0,184	0,149535782	0,834	0,706	0,905	0,841926	0,1434	DADOS ORIGINAIS
Multilayer Perceptron	0,79	0,726	0,136	0,099916095	0,726	0,79	0,838	0,73185	0,0907	PESO 50%
Random Forest	0,273	0,994	0,37	2,113821138	0,994	0,273	0,987	1,014645	0,3589	PESO 65%
Hoeffding Tree	0,715	0,819	0,174	0,138085647	0,819	0,715	0,896	0,826441	0,1323	PESO 60%
REP Tree	0,765	0,836	0,199	0,14974494	0,836	0,765	0,907	0,842186	0,1598	PESO 50%
Random Forest	0,683	0,999	0,794	1,388449135	0,999	0,683	0,997	1,004041	0,7919	AUTOWEKA

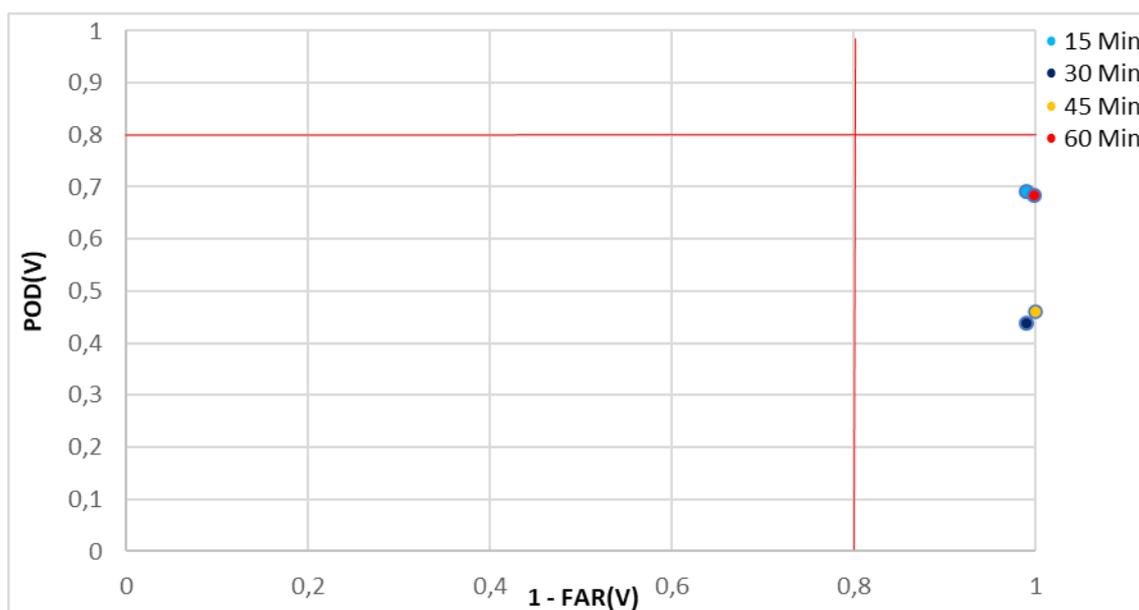


Gráfico 6.3: POD (V) x 1-FAR (V) com as melhores previsões para 15, 30, 45 e 60 minutos. Fonte: O autor.

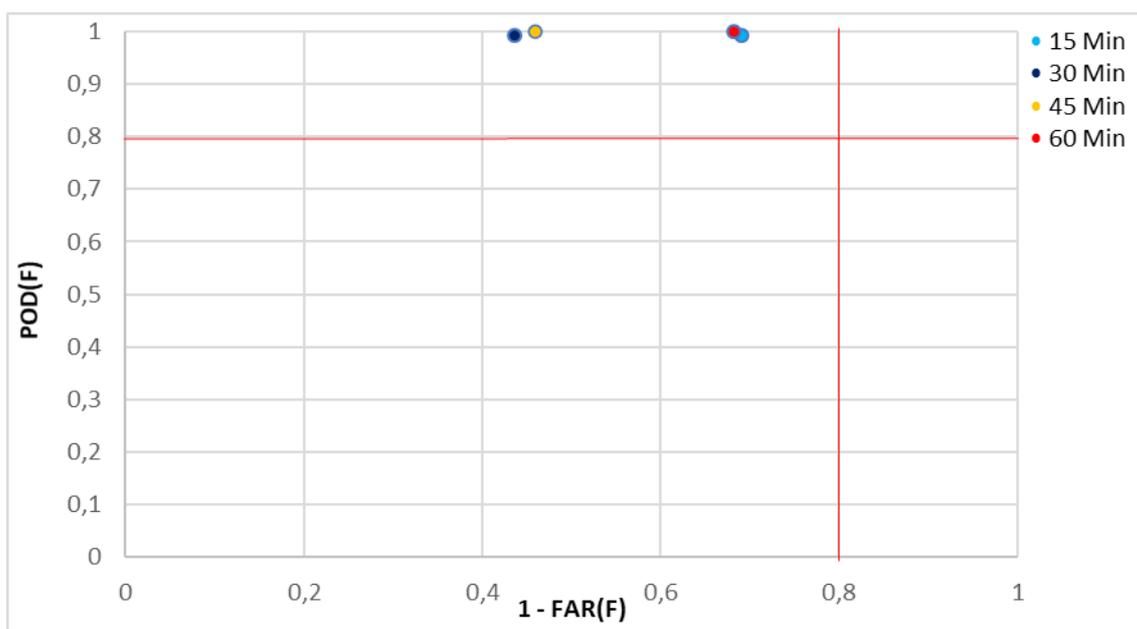


Gráfico 6.4: POD (F) x 1-FAR (F) com as melhores previsões para 15, 30, 45 e 60 minutos. Fonte: O autor.

### 6.7 Modelos classificatórios para previsão de visibilidade de 4.500, 3.700 e 1.600 metros com os dados de 2016 a 2018, com e sem as informações do sodar, utilizando o Auto-WEKA

Esses experimentos foram realizados visando verificar os desempenhos dos algoritmos com o acréscimo das variáveis oriundas do SODAR. Para isso, teve que ser selecionado um período dos dados com essas informações, e após a seleção, esse conjunto de dados foi inserido no *software* e executado com o Auto-Weka. Logo em seguida, com o mesmo conjunto de dados, porém sem as informações do equipamento, foi treinado e testado novamente, e ao final, os resultados com e sem as informações do SODAR foram comparados. Destaca-se na tabela 6.6 e nos gráficos 6.5 e 6.6, que para as previsões de 15 minutos, onde os resultados apresentaram percentuais acima de 85%, não houve diferença significativa entre os desempenhos com e sem a informação do equipamento. Para as previsões de 30 minutos, a maioria das variáveis estatísticas com os dados do SODAR obtiveram melhores desempenhos do que sem esses dados, e o POD (V), 1 - FAR (F) e F - Measure (V) foram as que mais evoluíram de 76.8%, 76.8% e 82.2% para 88.1%, 88.1% e 92.3% respectivamente. Nas previsões para 45 minutos e 1 hora, todas as avaliações com os dados do SODAR foram superiores, dentre as quais destacaram-se as evoluções do POD (V), 1 - FAR (F) e F - Measure (V) da

previsão de 4.500 metros para 1 hora, que subiram de 54.4%, 54.4% e 61.5% para 71.2%, 71.2% e 80% respectivamente.

Daí conclui-se que, apesar de poucos dados disponíveis do SODAR, pois o equipamento foi instalado em 2016, o mesmo contribuiu para a melhora dos desempenhos dos modelos classificatórios de visibilidade a partir de 30 minutos.

Tabela 6.6 – Algoritmos com os melhores resultados para previsão de 15, 30, 45 e 60 Min, Auto-WEKA e SODAR.

Previsão de 15 minutos com AutoWeka e SODAR										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
RandomForest <4500 C/SODAR	0,89	0,998	0,89	1	0,998	0,89	0,998	1	0,8879	AUTOWEKA
RandomForest <4500 S/SODAR	0,89	0,998	0,89	1	0,998	0,89	0,998	1	0,8518	AUTOWEKA
RandomForest <3700 C/SODAR	0,854	0,999	0,853	0,998394864	0,999	0,854	0,999	0,999987	0,8867	AUTOWEKA
RandomForest <3700 S/SODAR	0,854	0,999	0,853	0,998394864	0,999	0,854	0,999	0,999987	0,8929	AUTOWEKA
RandomForest <1600 C/SODAR	0,887	1	0,887	1	1	0,887	1	1	0,8879	AUTOWEKA
RandomForest <1600 S/SODAR	0,876	1	0,906	1,072727273	1	0,876	1	1,000155	0,8518	AUTOWEKA
Previsão de 30 minutos com AutoWeka e SODAR										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
RandomForest <4500 C/SODAR	0,824	0,999	0,874	1,130911583	0,999	0,824	0,997	1,002514	0,8717	AUTOWEKA
RandomForest <4500 S/SODAR	0,782	0,995	0,784	1,004872107	0,995	0,782	0,995	1,000105	0,7421	AUTOWEKA
RandomForest <3700 C/SODAR	0,667	0,999	0,744	1,262195122	0,999	0,667	0,998	1,001676	0,9229	AUTOWEKA
RandomForest <3700 S/SODAR	0,71	0,998	0,711	1,001612908	0,998	0,71	0,998	1,000013	0,7797	AUTOWEKA
RandomForest <1600 C/SODAR	0,881	1	0,923	1,099378882	1	0,881	1	1,000207	0,7084	AUTOWEKA
RandomForest <1600 S/SODAR	0,768	1	0,822	1,149350649	1	0,768	1	1,000297	0,8214	AUTOWEKA
Previsão de 45 minutos com AutoWeka e SODAR										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
RandomForest <4500 C/SODAR	0,744	0,998	0,818	1,223128243	0,998	0,744	0,996	1,008963	0,8147	AUTOWEKA
RandomForest <4500 S/SODAR	0,68	0,993	0,685	1,016009852	0,993	0,68	0,993	1,000342	0,614	AUTOWEKA
RandomForest <3700 C/SODAR	0,479	0,999	0,616	1,802325881	0,999	0,479	0,998	1,008585	0,8205	AUTOWEKA
RandomForest <3700 S/SODAR	0,36	0,999	0,487	2,101694915	0,999	0,36	0,997	1,004221	0,6786	AUTOWEKA
RandomForest <1600 C/SODAR	0,712	1	0,821	1,361538462	1	0,712	1	1,000607	0,4848	AUTOWEKA
RandomForest <1600 S/SODAR	0,548	1	0,693	1,718446602	1	0,548	0,999	1,000956	0,6923	AUTOWEKA
Previsão de 60 minutos com AutoWeka e SODAR										
Algoritmo	POD(V)	1-FAR(V)	F-MEASURE(V)	VIÉS(V)	POD(F)	1-FAR(F)	F-MEASURE(F)	VIÉS(F)	KAPPA	CONFIGURAÇÃO DOS DADOS
RandomForest <4500 C/SODAR	0,712	0,999	0,8	1,285046729	0,999	0,712	0,996	1,004818	0,7965	AUTOWEKA
RandomForest <4500 S/SODAR	0,544	0,995	0,615	1,297169811	0,995	0,544	0,993	1,004976	0,5406	AUTOWEKA
RandomForest <3700 C/SODAR	0,389	1	0,543	2,313432836	1	0,389	0,997	1,004572	0,8394	AUTOWEKA
RandomForest <3700 S/SODAR	0,287	0,999	0,417	2,660944206	0,999	0,287	0,997	1,005027	0,6074	AUTOWEKA
RandomForest <1600 C/SODAR	0,74	1	0,84	1,311111111	1	0,74	1	1,000542	0,4148	AUTOWEKA
RandomForest <1600 S/SODAR	0,684	1	0,799	1,404761905	1	0,684	1	1,000659	0,7983	AUTOWEKA

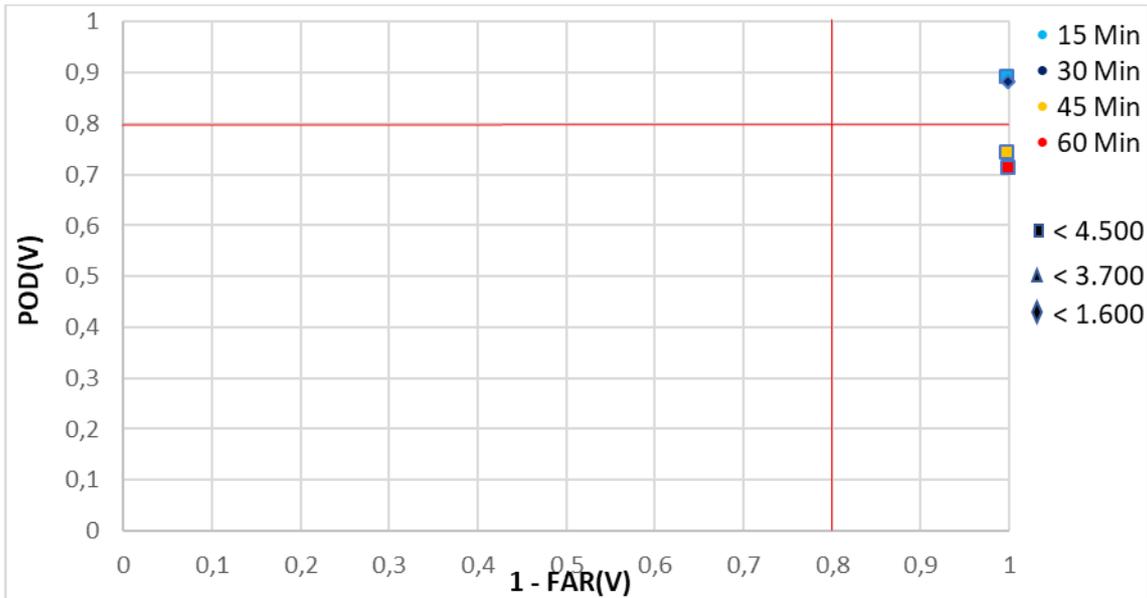


Gráfico 6.5: POD (V) x 1-FAR (V) com as melhores previsões para 15, 30, 45 e 60 minutos.

Fonte: O autor

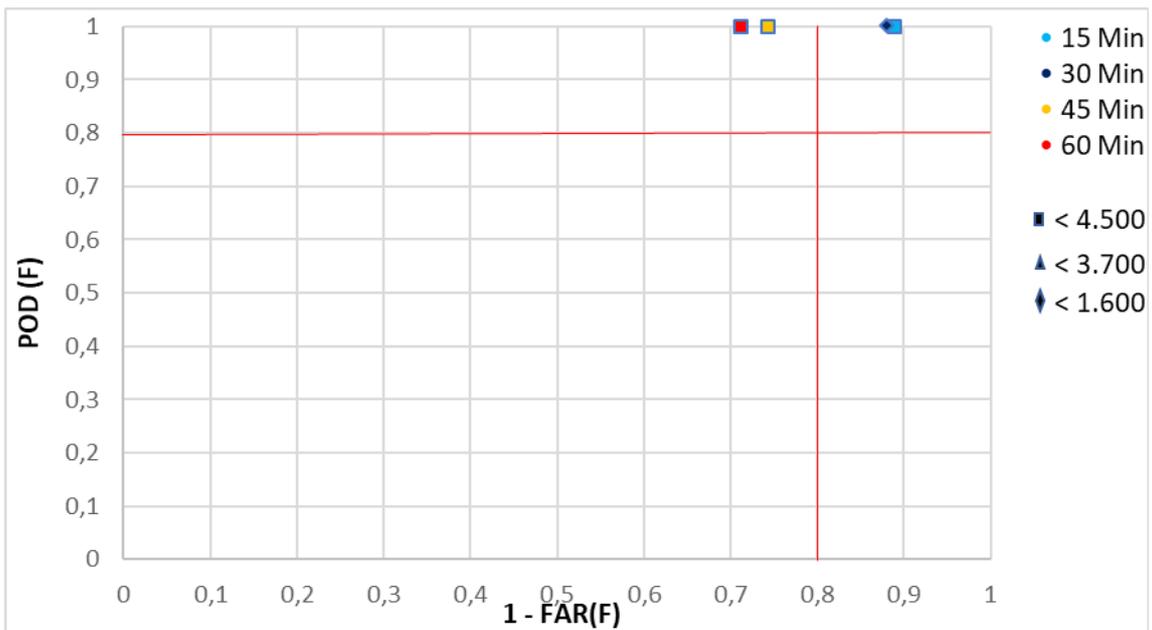


Gráfico 6.6: POD (F) x 1-FAR (F) com as melhores previsões para 15, 30, 45 e 60 minutos.

Fonte: O autor

### 6.8 Modelos regressivos com as visibilidades menores ou iguais a 6.000 metros, utilizando o Auto-WEKA

Além das redes classificatórias demonstradas anteriormente, foram feitos experimentos também com redes regressivas, visando alcançar melhores resultados principalmente nas previsões de visibilidade para 45 minutos e 1 hora, e nas previsões

de teto para todas as resoluções temporais, uma vez que nestas condições os algoritmos classificatórios não alcançaram resultados satisfatórios. Os resultados com essa técnica para as previsões de visibilidade foram satisfatórios, principalmente nos coeficientes de correlação, que tiveram resultados superiores a 97% em todas as avaliações, conforme destacado na tabela 6.7. Os erros absolutos relativos ficaram abaixo de 20%, dentro do limite considerado satisfatório, e os melhores resultados continuam sendo das resoluções temporais de 15 e 30 minutos. Foi inserido na mesma tabela, um intervalo de confiança levando em consideração os procedimentos operacionais RNAV/GNSS e NDB, que possuem limites de visibilidade de até 4.500 metros para o primeiro e menores que 4.500 até 3.700 para o segundo, com uma margem de erro de mais ou menos 10% do menor limite de visibilidade de cada parâmetro, ou seja, 450 metros para o RNAV/GNSS e 370 metros para o NDB. Pode-se observar que todos os resultados foram satisfatórios, ficando acima de 92% para o procedimento RNAV/GNSS e acima de 88% para o NDB. Sendo assim, os modelos regressivos são possíveis de serem utilizados operacionalmente, pois obtiveram coeficientes de correlação e erros absolutos relativos dentro dos limites considerados satisfatórios.

Tabela 6.7 – Algoritmos com os melhores resultados para previsão de 15, 30, 45 e 60 Min com AutoWEKA.

ALGORITMOS	REGRESSIVA VISIBILIDADE (AUTOWEKA)				
	Coefficiente de Correlação	Erro Médio Absoluto	Erro Absoluto Relativo	IN. CF. (Margem de erro +10%) RNAV/GNSS (4.500 $\leq$ Vis $\leq$ 6.000)	IN. CF. (Margem de erro +10%) NDB (3.700 $\leq$ Vis $<$ 4.500)
RandomForest 15Min VIS $\leq$ 6000M	0,9818	99,0805 Metros	0,115869	0,96	0,935
RandomForest 30Min VIS $\leq$ 6000M	0,9766	135,6361 Metros	0,158624	0,946	0,914
RandomForest 45Min VIS $\leq$ 6000M	0,9744	155,6227 Metros	0,182002	0,941	0,89
RandomForest 60 Min VIS $\leq$ 6000M	0,9754	160,3108 Metros	0,187495	0,929	0,882

Nos gráficos 6.7 a 6.14, destacam-se os histogramas de erros e as plotagens comparativas das visibilidades previstas pelas observadas, relativos aos experimentos regressivos com as visibilidades selecionadas iguais ou abaixo de 6.000 metros. Pode-se observar no histograma que a maioria dos erros ocorreram entre (-200) e (+200) metros, ou seja, a previsão subestimou ou superestimou na maioria das vezes entre esses valores. Para a previsão de 15 minutos, os erros dentro desse parâmetro foram equivalentes à 83%, na resolução de 30 minutos foi de 78%, 72% para 45 minutos e 69% para 60 minutos. O pior erro acontece quando a previsão estima acima do mínimo

do aeródromo e o observado está abaixo deste mínimo, uma vez que neste caso o modelo induz o tomador de decisão a liberar decolagens de outros aeroportos para pouso no Santos Dumont, vindo a causar o direcionamento destes voos para aeroportos de alternativa. Tomando-se como base o parâmetro intermediário de 3.700 metros, que é bastante impactante para o Santos Dumont, isso ocorreu em apenas 8% do total de previsões. Observou-se também nas plotagens das visibilidades previstas pelas observadas, que os erros mais grosseiros, ou seja, acima ou abaixo de 10% (600 metros) do limite máximo de 6.000 metros, foram bem reduzidos, iguais a 2.45% para 15 minutos, 3% para 30 minutos, 3.64% para 45 minutos e 3.95% para 60 minutos.

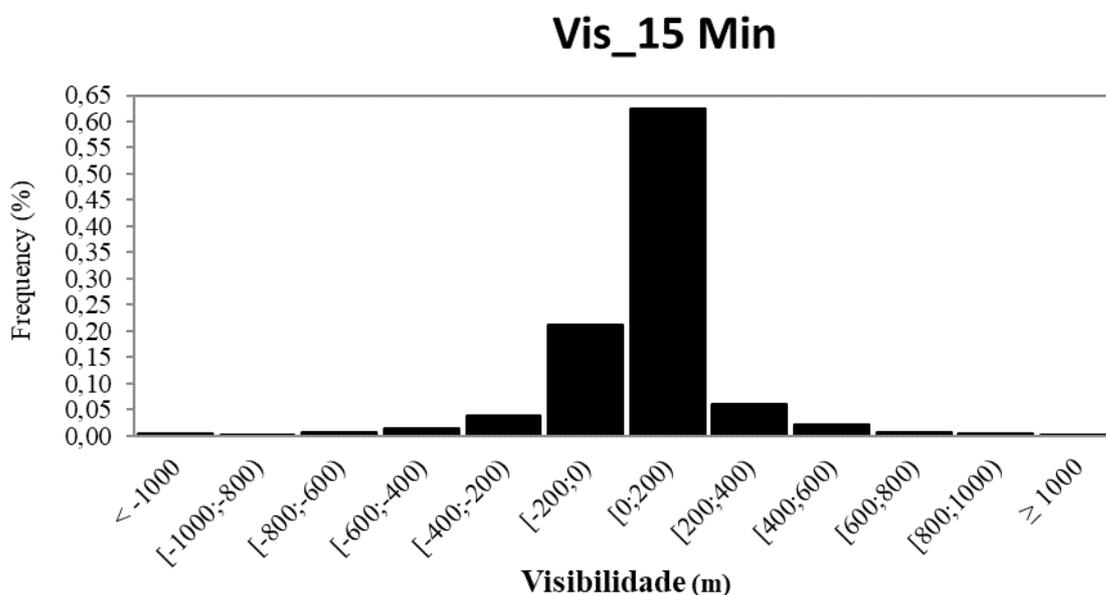


Gráfico 6.7: Histograma de erros para previsão de 15 min. e Vis. abaixo de 6.000 metros.  
Fonte: O autor.

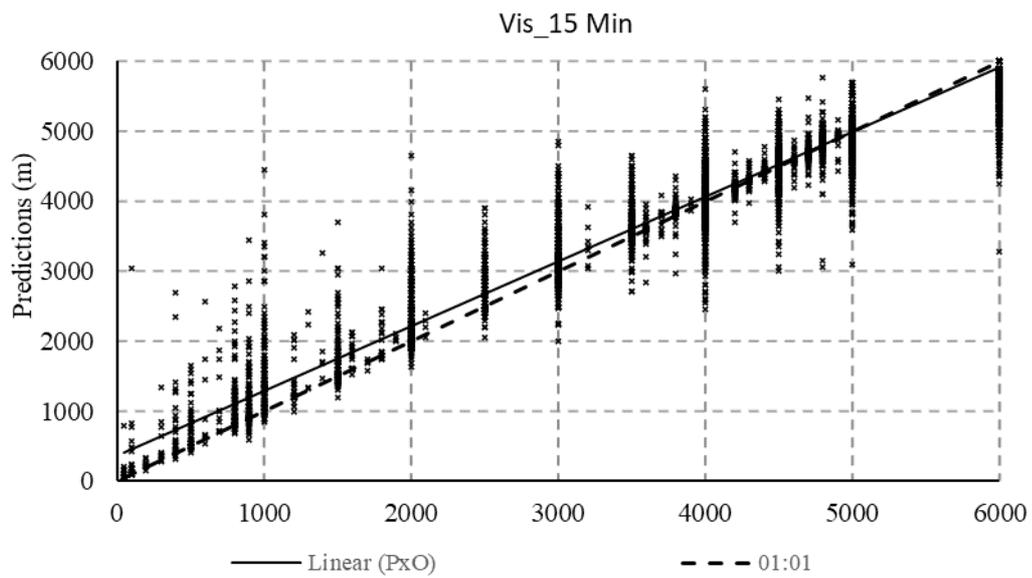


Gráfico 6.8: Plotagem linear do previsto versus observado de 15 min. e Vis. abaixo de 6.000 metros.

Fonte: O autor (2019).

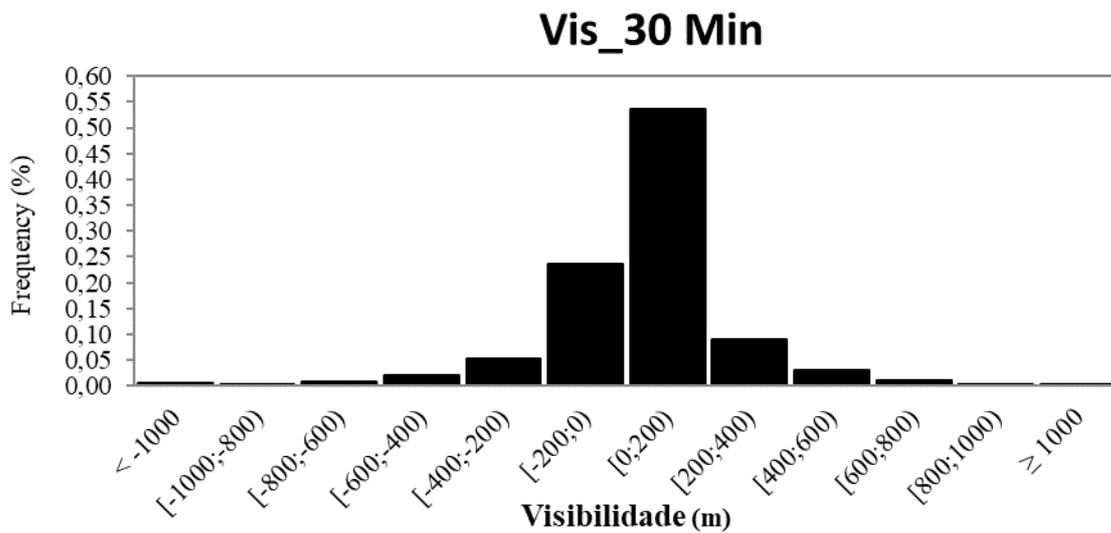


Gráfico 6.9: Histograma de erros para previsão de 30 Min e Vis. abaixo de 6.000 metros.

Fonte: O autor

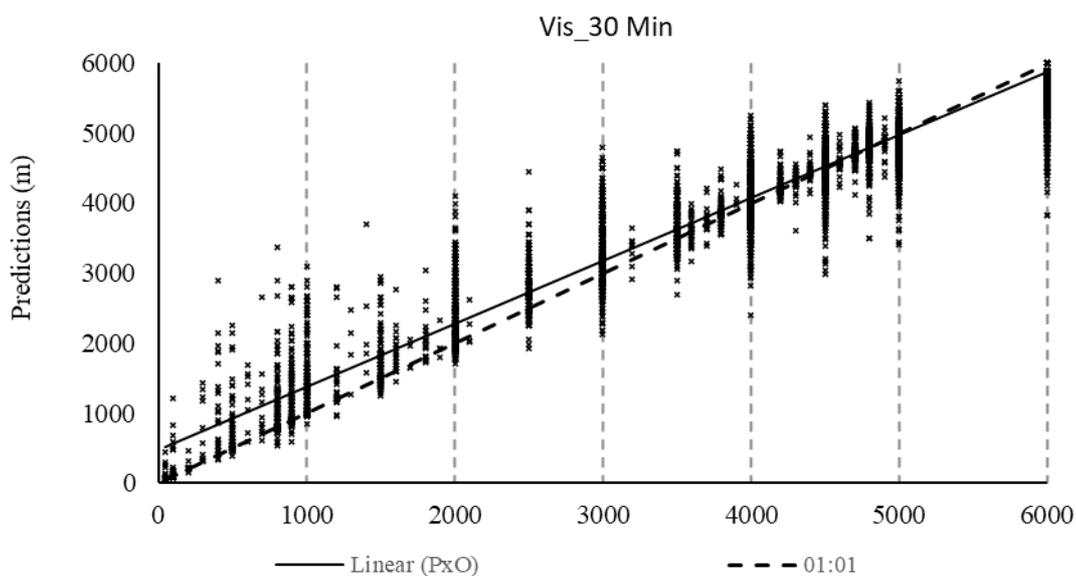


Gráfico 6.10: Plotagem linear do previsto versus observado de 30 min e Vis. abaixo de 6.000 metros.

Fonte: O autor

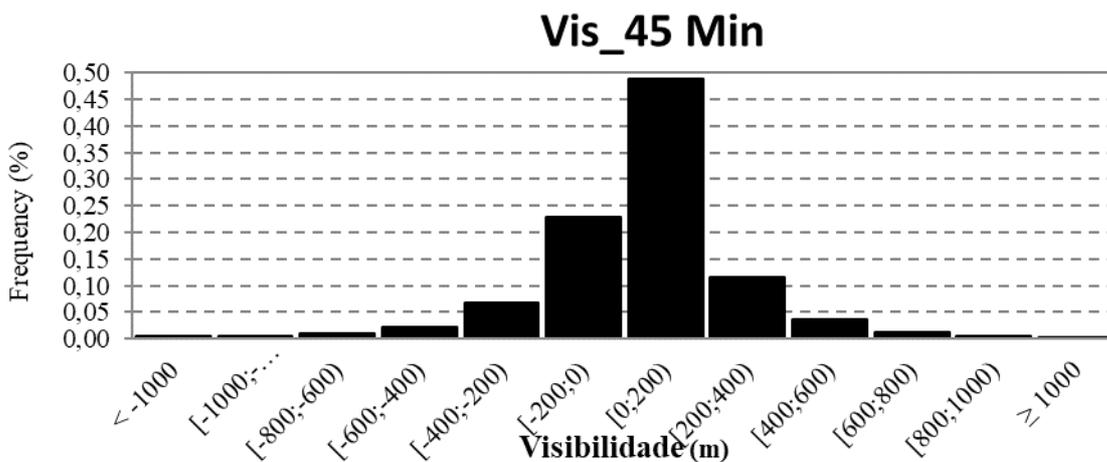


Gráfico 6.11: Histograma de erros para previsão de 45 min e Vis. abaixo de 6.000 metros.

Fonte: O autor).

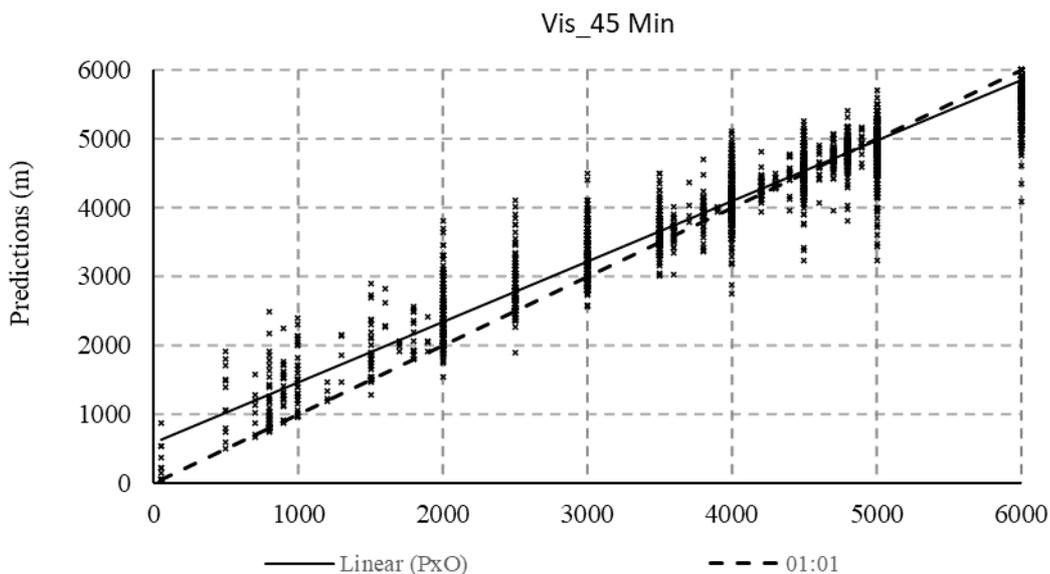


Gráfico 6.12: Plotagem linear do previsto versus observado de 45 min. e Vis. abaixo de 6.000 metros.

Fonte: O autor.

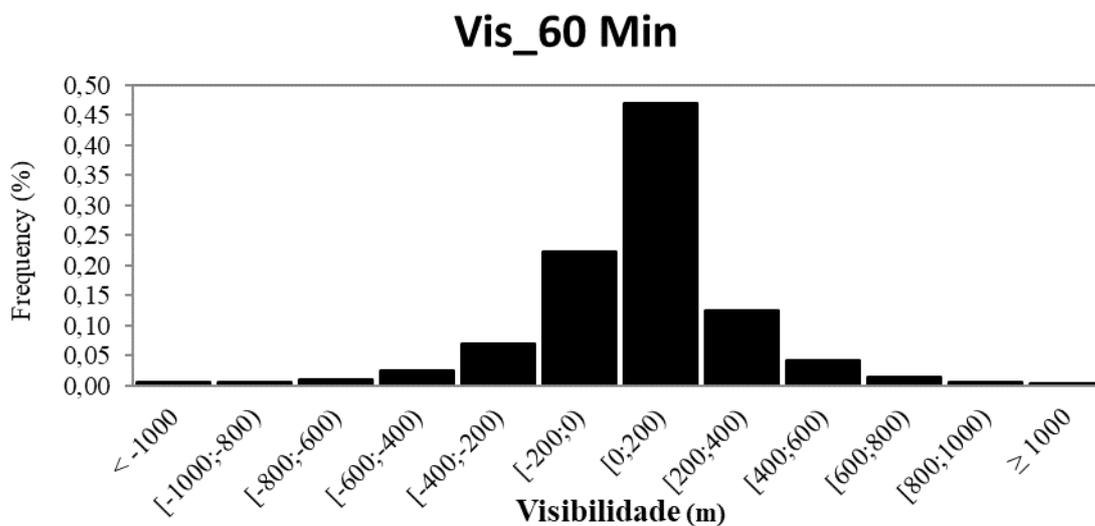


Gráfico 6.13: Histograma de erros para previsão de 60 Min e Vis. abaixo de 6.000 metros.

Fonte: O autor

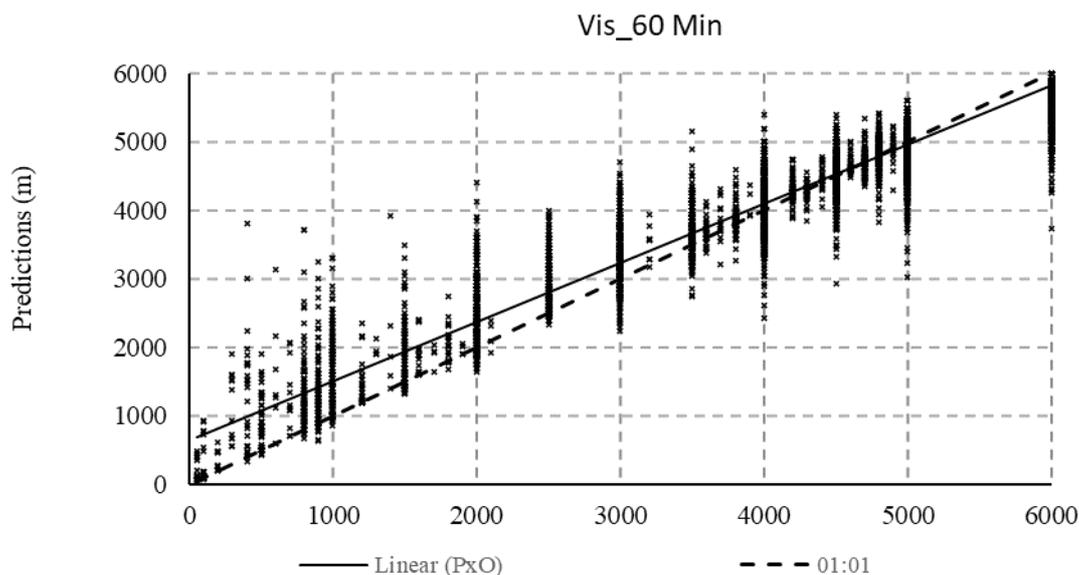


Gráfico 6.14: Plotagem linear do previsto versus observado de 60 min e Vis. abaixo de 6.000 metros.

Fonte: O autor

### 6.9 Modelos regressivos de visibilidade com os dados de 2016 a 2018, com e sem as informações do sodar, utilizando o Auto-WEKA

Na tabela 6.8 são demonstrados os resultados dos modelos regressivos utilizando o Auto-Weka com e sem as informações do SODAR, na qual pode-se observar que as informações do equipamento não impactaram significativamente nos desempenhos. Observou-se que em todos os modelos, a correlação ficou acima do limite satisfatório, pois os coeficientes foram superiores a 98% para todas as resoluções temporais, denotando que quando os resultados já estão com desempenhos próximos ao ideal, os dados do SODAR não são significativos. Destaca-se também que os melhores resultados foram para as previsões de 15 e 30 minutos, com os maiores coeficientes de correlação e os menores erros absolutos médios e relativos.

Tabela 6.8 – Algoritmos para previsão da Visibilidade com e sem SODAR de 15, 30, 45 e 60 Min com Auto-WEKA.

ALGORITMOS	REGRESSIVA VISIBILIDADE (AUTOWEKA) COM E SEM SODAR		
	Coefficiente de Correlação	Erro Médio Absoluto	Erro Absoluto Relativo
RandomForest 15Min C/ SODAR	<b>0,9938</b>	<b>198,5823 Metros</b>	<b>0,041015</b>
RandomForest 15Min S/ SODAR	0,9931	189,8547 Metros	0,039213
RandomForest 30Min C/ SODAR	<b>0,9905</b>	<b>304,8621 Metros</b>	<b>0,062971</b>
RandomForest 30Min S/ SODAR	0,9904	291,3758 Metros	0,060185
RandomForest 45Min C/ SODAR	0,9878	378,6975 Metros	0,078228
RandomForest 45Min S/ SODAR	<b>0,9882</b>	<b>351,8476 Metros</b>	<b>0,072681</b>
RandomForest 1H C/ SODAR	0,9868	409,3216 Metros	0,084559
RandomForest 1H S/ SODAR	<b>0,9888</b>	<b>343,879 Metros</b>	<b>0,07104</b>

### 6.10 Modelos regressivos de teto utilizando o Auto-WEKA

Nas redes regressivas para as previsões de teto, as variáveis estão divididas em altura da base das nuvens (BA.TETO) e quantidade de nebulosidade em oitavos (QUAN.TETO), pois a rede regressiva fornece a previsão de um parâmetro selecionado por vez. Na tabela 6.9 pode-se observar que as melhores previsões foram para 15 e 45 minutos, com a variável que fornece a altura da base da nuvem obtendo sempre os melhores desempenhos, com todos os coeficientes de correlação ficando acima de 96% e erros absolutos relativos abaixo de 17%, no entanto, apesar da quantidade de nebulosidade ter alcançado desempenhos satisfatórios no coeficiente de correlação até

45 minutos, com valores acima de 83%, os erros absolutos relativos não foram satisfatórios, pois ficaram além do limite de 20%.

Face aos resultados, entende-se necessária a instalação de tetômetro, para que as observações da base e quantidade de nuvens se deem com uma resolução temporal maior, permitindo assim dados mais precisos, para que os treinamentos dos algoritmos de previsão possam obter melhores desempenhos.

Tabela 6.9 – Algoritmos para previsão de Teto de 15, 30, 45 minutos e 60 Min com Auto-WEKA

ALGORITMOS	REGRESSIVA TETO (AUTOWEKA)		
	Coeficiente de Correlação	Erro Médio Absoluto	Erro Absoluto Relativo
RandomForest 15MIN BA.TETO	<b>0,9741</b>	<b>126,1361 pés</b>	<b>0,105155</b>
RandomForest 15MIN QUAN.TETO	<b>0,8616</b>	<b>0,5579 oitavos</b>	<b>0,320856</b>
RandomForest 30MIN BA.TETO	<b>0,9661</b>	<b>166,025 pés</b>	<b>0,138411</b>
RandomForest 30MIN QUAN.TETO	<b>0,8063</b>	<b>0,6927 oitavos</b>	<b>0,398365</b>
RandomForest 45MIN BA.TETO	<b>0,9632</b>	<b>182,9589 pés</b>	<b>0,152529</b>
RandomForest 45MIN QUAN.TETO	<b>0,8315</b>	<b>0,6366 oitavos</b>	<b>0,366089</b>
RandomForest 1H BA.TETO	<b>0,9612</b>	<b>195,1919 pés</b>	<b>0,162737</b>
RandomForest 1H QUAN.TETO	<b>0,7749</b>	<b>0,7718 oitavos</b>	<b>0,443914</b>

### 6.11 Estudo de caso de evento de baixa visibilidade utilizando modelo regressivo

Na figura 6.1 é ilustrado um estudo de caso, onde foram registradas restrições de visibilidade e no qual é destacado o desempenho do conjunto de previsões e das observações para um evento de baixa visibilidade ocorrido entre 5h e 13h do dia 23 de junho de 2009.

Independentemente do horário da previsão, nota-se que as previsões de visibilidade para 15, 30, 45 e 60 minutos seguiram o comportamento da observação (linha preta na fig. 6.1) com todas as correlações maiores que 95% e seus erros absolutos médios menores que 321 metros. Isto pode ser verificado quando a visibilidade começou a diminuir, próximo às 5h45 e finalmente quando voltou a aumentar por volta das 11h45.

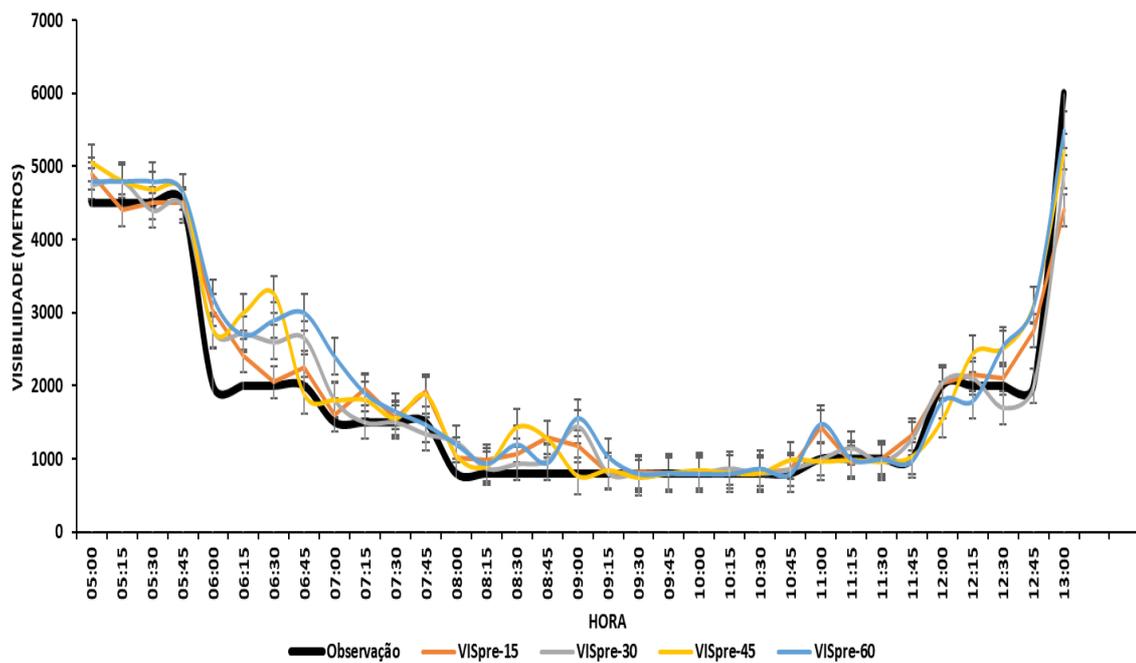


Figura 6.1: Previsões regressivas da visibilidade e observações no período das 5h às 13h do dia 23 de junho de 2009.

Fonte: O autor.

## 7 CONCLUSÕES

Devido à ausência do sensor de visibilidade e à inoperância do sensor de nebulosidade a partir de 2016, não foi possível realizar experimentos com altas resoluções temporais, o que poderia aumentar os desempenhos dos modelos de previsão na fase de aprendizado de máquinas.

Em relação à aproximação da climatologia, ficou constatado que os eventos de restrições de visibilidades ocorrem em sua grande maioria nos meses de maio a agosto e no período da manhã, compreendido entre 5 e 11 horas local, e que as restrições de teto estão associadas também às restrições de visibilidade, pois em 69% dos eventos com restrições de visibilidade menores ou iguais a 10.000 metros, também ocorreram restrições de teto, o que denota ainda que ambas as restrições são características de condições estáveis da atmosfera, típicas dessa época do ano na cidade do Rio de Janeiro.

Durante a fase de aprendizado de máquinas, na qual foram realizados experimentos de treinamentos e testes com diversos algoritmos e experimentos com o Auto-WEKA, tanto para os modelos classificatórios quanto para os regressivos de previsão, pode-se concluir que as previsões classificatórias de visibilidade utilizando essa ferramenta não demonstraram desempenhos superiores significativos aos modelos que foram selecionados.

Para as previsões classificatórias da visibilidade utilizando os cinco melhores algoritmos para 15 minutos, todos os melhores resultados foram satisfatórios, independente do parâmetro, com desempenhos acima de 88%, sendo estes modelos passíveis de serem utilizados operacionalmente.

Para as previsões classificatória de 30 minutos, o melhor resultado para o parâmetro de 4.500 metros alcançou desempenho com estatísticas acima de 82%, porém, para os limites de 3.700 e 1.600 metros, os melhores resultados ficaram pouco acima de 75% e 72% respectivamente, denotando a perda de desempenho dos algoritmos de previsão com o aumento da resolução temporal, e a diminuição dos eventos devido ao aumento das restrições de visibilidade.

Já para os resultados das previsões de 45 minutos e 1 hora dos modelos classificatórios, todos ficaram abaixo do considerado satisfatório para essa pesquisa, evidenciando o limite desta tecnologia com os tipos de dados utilizados. Para as previsões de 45 minutos, apesar de não ser recomendável a utilização desse modelo de

forma isolada e com as configurações destacadas, a utilização em conjunto com outros modelos, como os regressivos, pode ser útil ao setor operacional.

Em relação às previsões classificatórias de teto, os experimentos foram realizados com as escolhas dos algoritmos e utilizando o Auto-Weka. Pode-se concluir que os resultados não obtiveram desempenhos satisfatórios, independente da estratégia utilizada, o que está relacionado ao baixo índice de ocorrências desse evento e ao período de três anos do conjunto de dados com ausência das informações de nebulosidade devido à inoperância do tetômetro. Portanto, os modelos classificatórios de teto, com as configurações destacadas aqui, não são indicados para utilização operacional.

Foram feitos experimentos utilizando as variáveis do equipamento SODAR, com o intuito de verificar se essas informações contribuiriam para melhorar o desempenho dos modelos de previsão. Pode-se concluir que para a previsão de 15 minutos, os dados do equipamento não influenciaram em melhorias significativas, no entanto, a partir de 30 minutos, todos os desempenhos com esses dados foram melhores do que sem essas informações, dentre os quais destaca-se o melhor ganho obtido pela estatística *F-Measure* (V) para a previsão de 4.500 metros para 1 hora, com uma melhora de 16,8% em relação à previsão sem as variáveis do SODAR. Sendo assim, conclui-se que o SODAR contribuiu para a melhora das previsões de visibilidade com os modelos classificatórios, a partir da resolução temporal de 30 minutos, e com isso, sugere-se a instalação desse tipo de equipamento em outros aeroportos para contribuir com estudos semelhantes ao desta pesquisa.

Sobre os experimentos com modelos regressivos para previsão de visibilidade, realizados com o intuito de aperfeiçoar os resultados dos modelos classificatórios, chegou-se à conclusão de que, os desempenhos dos modelos foram satisfatórios, com altos índices de correlação, acima de 97%, e baixos erros absolutos relativos, ficando abaixo de 19%. Pode-se concluir também, que os erros das previsões utilizando modelos regressivos, quando as visibilidades ficaram menores ou iguais a 6.000 metros, são considerados baixos, pois a maioria deles foram de até 200 metros para mais ou para menos, ou seja, superestimando ou subestimando a previsão nesse valor. E os erros mais grosseiros, acima de 600 metros, foram bem reduzidos, ficando abaixo de 4% para todas as resoluções temporais.

Para as previsões de teto, que tiveram que ser divididas em base e quantidade de nuvens, onde o parâmetro relativo à base da nuvem obteve desempenhos satisfatórios

em todas as avaliações, ficando com coeficientes de correlação acima de 96% e erros absolutos relativos abaixo de 17% para todas as resoluções temporais. Para a quantidade de nebulosidade, os coeficientes de correlação foram satisfatórios até 45 minutos, no entanto, os erros absolutos relativos não foram satisfatórios, pois ficaram além do limite de 20%. Com isso, esses modelos de previsão, com as técnicas destacadas nessa pesquisa, são indicados para serem utilizados operacionalmente somente para a avaliação da altura da base da nuvem.

Como sugestões para pesquisas futuras utilizando a técnica de aprendizado de máquinas, propõe-se que sejam utilizadas resoluções temporais menores, como de cinco minutos ou de minuto a minuto, com o intuito de fornecer à inteligência artificial mais subsídios para reconhecer o comportamento da atmosfera na área de pesquisa, bem como estender a técnica utilizada nesse trabalho para outros aeroportos. Sugere-se também às autoridades que gerenciam e controlam o aeroporto Santos Dumont, a instalação de um visibilômetro, que possibilitaria informações mais precisas e de alta resolução temporal da visibilidade, e a substituição ou o reparo do tetômetro, com a finalidade de melhorar as informações de quantidade e altura das nuvens nesse aeroporto.

## 8 REFERÊNCIAS

ALMEIDA, Manoel Valdonel de. APLICAÇÃO DE TÉCNICAS DE REDES NEURAIS ARTIFICIAIS NA PREVISÃO DE CURTÍSSIMO PRAZO DA VISIBILIDADE E TETO PARA O AEROPORTO DE GUARULHOS – SP. 2009. 206 f. Tese (Doutorado) - Curso de Engenharia Civil, Coppe, Ufrj, Rio de Janeiro, 2009.

**Árvore de Decisão.** Disponível em <https://estatsite.com/2016/06/11/1970/>. Acesso em 04/12/2019 às 23:30

BALLARD, S. P.; GOLDING, B. W.; SMITH, R. N. B. “Mesoscale model experiment forecast of the Haar of northeast Scotland”. American Meteorological Society: Monthly Weather Review, v. 119, n. 9, pp. 2107-2123, Sep. 1991.

BRASIL, Comando da Aeronáutica. Departamento de Controle do Espaço Aéreo. Instrução de Códigos Meteorológicos. ICA 105-16. Rio de Janeiro, 2017.

BRASIL, Comando da Aeronáutica. Departamento de Controle do Espaço Aéreo. Circular de Informação Aeronáutica. AIC 54/18. Rio de Janeiro, 2018.

BRASIL, Comando da Aeronáutica. Departamento de Controle do Espaço Aéreo. Instrução de Estações Meteorológicas de Superfície. ICA 105-15. Rio de Janeiro, 2019.

BREIMAN, L, 2001. Machine Learning 45:5. <https://doi.org/10.1023/A:1010933404324>.

COSSICH, W., PINHEIRO, F. R., MARTON, E., PIMENTEL, L. C. G., (2009). Ocorrências de nevoeiro na cidade do Rio de Janeiro no período 2003-2007. VI Workshop Brasileiro de Micrometeorologia.

DIETZ, S., J., KNERINGER, P., MAYR, G., J., ZEILERS, A., (2018). Forecasting Low-Visibility Procedure States with Tree-Based Statistical Methods. *Pure and Applied Geophysic*, <https://doi.org/10.1007/s00024-018-1914-x>.

FRANÇA, G. B., Almeida, M. V., and Rossete A. C. 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.

FRANÇA, G. B., ALMEIDA, M. V., BONNET, S., and ALBUQUERQUE NETO, F., “Nowcasting Model of Low Wind Profile Based on Neural Network Using SODAR Data at Guarulhos Airport”, *International Journal of Remote Sensing*, doi: 10.1080/01431161.2018.1425562, 39:8, 2506–2517, 2018.

Guide to Meteorological Instruments and Methods of Observations. Edition of 2014, Geneva, Switzerland, WMO (2018).

GULTEPE, I. G. PEARSON, J. A., MILBRANDT et al., “The fog remote sensing and modeling field project,” *Bulletin of the American Meteorological Society*, vol. 90, no. 3, pp. 341–359, 2009.

GULTEPE, I., SHARMAN, R., D. WILLIAMS, P., ZHOU, B., ELLROD, G., MINNIS, P., TRIER, S., GRIFFIN, S., YUM, S. S., GHARABAGHI, B., FELTZ, W., TEMIMI, M., PU, Z., STORER, L. N., KNERINGER, P., WESTON, M. J., CHUANG, H., THOBOIS, L., DIMRI, A., DIETZ, S., FRANÇA, G. B., ALMEIDA, M. V., ALBUQUERQUE NETO, F. L. A Review of High Impact Weather for Aviation Meteorology. *Pure and Applied Geophysics*, v. xxx, p. 1-53, 2019

HAEFFELIN, M., LAFFINEUR, Q., ARANDA, J., A., B., DROUIN, M., A., VERA, J., A., C., DUPONT, J., C., BACKER, H., D., (2016). Radiation fog formation alerts using attenuated backscatter power from automatic Lidars and ceilometers. *Atmospheric Measurement Techniques*, <https://doi:10.5194/amt-2016-182>, 2016.

HAYKIN, S. (2002). *Neural Networks. A Comprehensive Foundation*, Macmillan, New York, NY.

HERMSDORFF, J. PREVISÃO DE INSTABILIDADE ATMOSFÉRICA SIGNIFICATIVA USANDO ÁRVORE DE DECISÃO NA REGIÃO

METROPOLITANA DO RIO DE JANEIRO. 2018. 109 f. Dissertação (Mestrado) - Curso de Meteorologia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2018.

**Imagens do Aeroporto Santos Dumont.** Disponível em <https://oglobo.globo.com/aeroporto-santos-dumont>. Acesso em 03/08/2018 às 08:30.

**Imagens do Aeroporto Santos Dumont.** Disponível em <https://brasilturis.com.br/infraero-santos-dumont-rj/>. Acesso em 03/08/2018 às 08:40.

**Imagens do Aeroporto Santos Dumont.** Disponível em <https://pleno.news/brasil/santos-dumont-apos-reformas>. Acesso em 03/08/2018 às 08:50.

Isaac, G. A., Burrows, W. R., Cober, S. G., Crawford, R. W., Donaldson, N., Gultepe, I., Hansen, B., Heckman, I., Huang, L. X., Ling, A., Mailhot, J., Milbrandt, J. A. Reid, J., and Fournier, M.: The Canadian airport nowcasting system (CAN-Now), *Meteorol. Appl.*, 21, 30–49, 2014.

KAIMAL, J. C.; FINNIGAN, J. J. Atmospheric boundary layer flows: their structure and measurement. New York: Oxford University Press, 1994. 304 p.

KOTTHOF, L.; THORNTON, C.; HOOS, H. H.; HUTTER, F.; BROWN, K. L.; AutoWEKA 2.0: Automatic model selection and hyperparameter optimization in WEKA. Vancouver, Canadá: University of British Columbia, 2016.

LIMA, J. S. (1982). Previsão de ocorrência e duração de nevoeiro em Porto Alegre, Método Subjetivo.

LIU, J. G.; MASON, P. J. Image Processing and GIS for Remote Sensing: Techniques and Applications. Wiley Blackwell, 2016.

OLIVEIRA, L. L.; VIANELLO, R. L.; FERREIRA, N. J. Meteorologia Fundamental. 1 ed. Erechim: EdiFAPES, 2001.

PAYRA, S., MOHAN, M., Multirule Based Diagnostic Approach for the Fog Predictions Using WRF Modelling Tool, Hindawi Publishing Corporation Advances in Meteorology Volume 2014, Article ID 456065, 11 pages, DOI:10.1155/2014/456065.

PASINI, A., PELINO, V., POTESTÀ, S., (2001). A neural network model for visibility nowcasting from surface observations: Results and sensitivity to physical input variables Journal of Geophysical Research, vol. 106, no. d14, pages 14,951-14,959, july 27, 2001.

PEJOVIC, T. Implications of climate change for the UK aviation sector. 2008. p. 11-17. Centre for Transport Studies Department of Civil and Environmental Engineering Imperial College London, United Kingdom.

PEREIRA, M. C. M. EMPREGO DE REDES NEURAIAS ARTIFICIAIS RBF NA PREVISÃO DE NEVOEIRO NO AEROPORTO INTERNACIONAL AFONSO PENA. 109 p. Dissertação (Mestrado em Meteorologia), Universidade Federal do Paraná, Paraná, 2016.

SILVA, H. A. J. S. ANÁLISE DAS OCORRÊNCIAS DE CISALHAMENTO DE VENTO NO AEROPORTO DE GUARULHOS (SP) PARA A PREVENÇÃO DE ACIDENTES AERONÁUTICOS. 98 p. Dissertação (Mestrado em Meteorologia), Universidade de São Paulo, São Paulo, 2016.

STULL, R. B. An introduction to boundary layer meteorology. Dordrecht: Kluwer Academic Publishers, 1988. 666 p

VAREJÃO-SILVA, M. A. Meteorologia e Climatologia. Versão Digital 2 ed. Brasília: INMET. Pax, 2006.

“Vocabulário Meteorológico Internacional”. In: Curso de Geografia, UFJF, Juiz de Fora, MG.

WILKS, S. D. – Statistical Methods in the Atmospheric Sciences. 2ª ed., New York, USA, Academic Press, 2006.

WITTEN, I. H.; FRANK, E.; HALL, M. A; PAL, C. J. Data Mining: Practical Machine Learning Tools and Techniques. 4 ed. British Library, 2017. 642 p.