

INSTITUTO TECNOLÓGICO DE AERONÁUTICA



Gabriela Loiola Vilar

**ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS
DE GERENCIAMENTO DE FLUXO NO ESPAÇO
AÉREO BRASILEIRO**

Trabalho de Graduação
2020

Curso de Engenharia Civil-Aeronáutica

Gabriela Loiola Vilar

**ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS
DE GERENCIAMENTO DE FLUXO NO ESPAÇO
AÉREO BRASILEIRO**

Orientadora

Profa. Dra. Mayara Condé Rocha Murça (ITA)

Coorientador

Prof. Dr. Marcelo Xavier Guterres (ITA)

ENGENHARIA CIVIL-AERONÁUTICA

SÃO JOSÉ DOS CAMPOS
INSTITUTO TECNOLÓGICO DE AERONÁUTICA

Dados Internacionais de Catalogação-na-Publicação (CIP)
Divisão de Informação e Documentação

Loiola Vilar, Gabriela

ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS DE GERENCIAMENTO DE FLUXO NO ESPAÇO AÉREO BRASILEIRO / Gabriela Loiola Vilar.

São José dos Campos, 2020.

43f.

Trabalho de Graduação – Curso de Engenharia Civil-Aeronáutica– Instituto Tecnológico de Aeronáutica, 2020. Orientadora: Profa. Dra. Mayara Condé Rocha Murça. Coorientador: Prof. Dr. Marcelo Xavier Guterres.

I. Instituto Tecnológico de Aeronáutica. II. Título.

REFERÊNCIA BIBLIOGRÁFICA

LOIOLA VILAR, Gabriela. **ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS DE GERENCIAMENTO DE FLUXO NO ESPAÇO AÉREO BRASILEIRO**. 2020. 43f. Trabalho de Conclusão de Curso (Graduação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DA AUTORA: Gabriela Loiola Vilar

TÍTULO DO TRABALHO: ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS DE GERENCIAMENTO DE FLUXO NO ESPAÇO AÉREO BRASILEIRO.

TIPO DO TRABALHO/ANO: Trabalho de Conclusão de Curso (Graduação) / 2020

É concedida ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias deste trabalho de graduação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. A autora reserva outros direitos de publicação e nenhuma parte deste trabalho de graduação pode ser reproduzida sem a autorização da autora.

Gabriela L. Vilar

Gabriela Loiola Vilar

Av. Dr. Nelson D'Ávila 1875 apto 1506
São José dos Campos – SP

ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS DE GERENCIAMENTO DE FLUXO NO ESPAÇO AÉREO BRASILEIRO

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação



Gabriela Loiola Vilar

Autora



Profa. Dra. Mayara Condé Rocha Murça (ITA)

Orientadora



Prof. Dr. Marcelo Xavier Guterres (ITA)

Coorientador



Prof. Dr. João Cláudio Bassan de Moraes
Coordenador do Curso de Engenharia Civil-Aeronáutica

São José dos Campos, 25 de novembro de 2020.

Dedico este trabalho aos meus pais Katia e José, minha avó, meu tio Nildo e minha madrinha Nadir.

Agradecimentos

Agradeço aos meus pais Katia e José. Sem o exemplo e dedicação de vocês, nenhuma das minhas conquistas seriam possíveis. Eu não seria honesta, dedicada e quase organizada se não fosse pelo tempo e amor que vocês investiram em mim.

Ao meu tio Nildo, pelas aulas de física e vitaminas de abacate. À minha madrinha Nadir, pelos mimos, carinho e sandubinhas. À minha avó, pela "inteligência oculta" que eu herdei.

Um agradecimento mais que especial à professora Mayara, minha orientadora, não só pela paciência e compreensão durante todo o ano, mas por ser uma inspiração de profissional. Espero um dia chegar perto de ser como você.

Agradeço também aos professores Guterres e Evandro pelo apoio e suporte. Minha eterna gratidão ao professor Pi, por ser um amigo e ouvinte.

Aos meus amigos Lincon e Rodrigo pelas risadas. O fim dessa jornada só foi possível por ter a companhia de vocês. Ao Calixto pelo apoio incondicional e a Ulli por ser a melhor dupla de trabalho e ser uma mulher forte e meio maluquinha. À Sara por ser uma irmã e companheira de quarto incrível. Ao Ney pela amizade leal, conversas e conselhos de qualidade duvidável. Ao Queiroz, que me faz sempre ter uma visão mais prática da vida e me ajuda em tudo que eu preciso, ainda não sei usar excel sem mouse, mas quando esse dia chegar, o crédito será seu. Ao Gulyás pela ajuda com as MATs no fundamental e por todos os memes sem graça. A todos os meus colegas da civil, da T3 da 20 e da T2 da 19. Não teria chegado até aqui sem vocês.

“Nunca existiu uma grande inteligência sem uma veia de loucura.”

— ARISTÓTELES

Resumo

Para atender a demanda de transporte aéreo, um complexo sistema de gerenciamento de tráfego aéreo precisa ser operado diariamente, de forma a garantir que companhias aéreas e demais operadores de aeronaves possam executar seus voos de forma segura e ordenada. O volume e a complexidade das operações aéreas, bem como a vulnerabilidade desse sistema a perturbações causadas por fatores exógenos, como meteorologia, frequentemente resultam em desequilíbrios entre demanda e capacidade. Em consequência, medidas de gerenciamento de fluxo de tráfego aéreo (*Air Traffic Flow Management* – ATFM) são comumente tomadas para ajustar os fluxos de tráfego e mitigar impactos como atrasos e cancelamentos. Este trabalho de graduação tem por objetivo realizar uma análise histórica das medidas ATFM aplicadas no espaço aéreo brasileiro e desenvolver um modelo preditivo que possa apoiar a tomada de decisão dos gerentes de tráfego e prover aos usuários do espaço aéreo uma maior previsibilidade sobre o impacto de restrições operacionais em seus voos. Os resultados da análise de dados históricos revelam que há um uso predominante da medida *Miles-In-Trail* (MIT) para o gerenciamento do fluxo no espaço aéreo brasileiro e que a Área Terminal São Paulo (TMA-SP) é o volume de espaço aéreo mais afetado por essas medidas. Dois métodos de aprendizado de máquina supervisionado, *Random Forests* e *Support Vector Machines*, são então utilizados para o desenvolvimento de um modelo preditivo da ocorrência e da severidade de medidas MIT na TMA-SP. Os resultados mostram um desempenho preditivo superior para o modelo gerado pelo método *Random Forests*, que apresenta uma acurácia de 82%. Ao analisar a importância das variáveis utilizadas para a previsão, torna-se evidente a influência dos fatores relacionados à demanda de voos, como origem do fluxo e hora do dia, e às condições meteorológicas.

Abstract

To meet the air transportation demand, a complex air traffic management system needs to be operated daily in order to ensure that airlines and other aircraft operators can execute their flights in a safe and orderly manner. The volume and complexity of air traffic operations as well as the vulnerability of the system to disturbances caused by exogenous factors, such as weather, often result in imbalances between demand and capacity. As a result, air traffic flow management (ATFM) measures are commonly taken to adjust the traffic flows and mitigate impacts such as delays and cancellations. This undergraduate work aims to carry out a historical analysis of the ATFM measures applied in the Brazilian airspace and to develop a predictive model that can support traffic managers' decision-making and provide airspace users with greater predictability about the impact of operational restrictions on their flights. The results of the historical data analysis reveal that there is a predominant use of Miles-In-Trail (MIT) measures for traffic flow management in the Brazilian airspace and that the São Paulo Terminal Area (TMA-SP) is the airspace volume most affected by these measures. Two supervised machine learning methods, Random Forests and Support Vector Machine, are then used to develop a predictive model for the occurrence and severity of MIT measures in the TMA-SP. The results show a superior predictive performance for the model generated by the Random Forests method, which presents an accuracy of 82%. When analyzing the importance of the variables used for prediction, the influence of the factors related to the flight demand, such as the origin of the flow and the time of the day, and to the weather conditions, becomes evident.

Lista de Figuras

FIGURA 2.1 – TMAs brasileiras	18
FIGURA 2.2 – FIRs brasileiras	18
FIGURA 4.1 – Participação dos 20 principais aeroportos brasileiros no número de decolagens domésticas em 2019. Fonte: ANAC (2019)	26
FIGURA 4.2 – Percentuais de atrasos nas 20 principais rotas domésticas em 2019. Fonte: ANAC (2019)	27
FIGURA 4.3 – Percentuais de atrasos nas 20 principais rotas internacionais em 2019. Fonte: ANAC (2019)	28
FIGURA 4.4 – Ilustração de uma árvore de decisão. Fonte: James et al. (2013)	30
FIGURA 4.5 – Nomenclatura típica de uma árvore de decisão. Fonte: Boehmke et al. (2020)	30
FIGURA 4.6 – Ilustração de um classificador baseado em <i>Support Vector Machines</i> . Fonte: James et al. (2013)	32
FIGURA 5.1 – Número de medidas MIT aplicadas em 2019, por aeroporto, TMA ou FIR de destino do fluxo afetado	33
FIGURA 5.2 – Número de medidas MIT aplicadas em 2019, por dia da semana	34
FIGURA 5.3 – Número de medidas MIT aplicadas em 2019, por mês do ano	35
FIGURA 5.4 – Evolução dos percentuais de atrasos e cancelamentos – indústria, por mês, 2019. Fonte: ANAC (2019)	35
FIGURA 5.5 – Percentagem de medidas MIT aplicadas em 2019 por tipo de restrição	36
FIGURA 5.6 – <i>Boxplot</i> do tempo de duração, em segundos, das medidas MIT aplicadas em 2019	36

FIGURA 5.7 – <i>Boxplot</i> do tempo de duração, em segundos, das medidas MIT aplicadas em 2019, por tipo de restrição e por aeroporto/TMA/FIR de destino do fluxo afetado	37
FIGURA 5.8 – Matriz de confusão para o modelo <i>Random Forests</i>	38
FIGURA 5.9 – Matriz de confusão para o modelo SVM	38
FIGURA 5.10 – Estimativas de importância das variáveis de <i>input</i> geradas pelo modelo <i>Random Forests</i>	39

Lista de Abreviaturas e Siglas

ACC	<i>Area Control Center</i>
ANAC	Agência Nacional de Aviação Civil
APP	<i>Approach Control Center</i>
ATC	<i>Air Traffic Control</i>
ATFM	<i>Air Traffic Flow Management</i>
ATM	<i>Air Traffic Management</i>
CGNA	Centro de Gerenciamento da Navegação Aérea
FIR	<i>Flight Information Region</i>
GDP	<i>Ground Delay Program</i>
MIT	<i>Miles-in-Trail</i>
OACI	Organização da Aviação Civil Internacional
TMA	<i>Terminal Maneuvering Area</i>
TMI	<i>Traffic Management Initiative</i>
TWR	<i>Aerodrome Control Tower</i>
SBGR	Aeroporto Internacional de São Paulo/Guarulhos
SBKP	Aeroporto Internacional de Viracopos/Campinas
SBSP	Aeroporto de São Paulo/Congonhas
SVM	<i>Support Vector Machines</i>
TMA-SP	Área Terminal São Paulo

Sumário

1	INTRODUÇÃO	14
2	REFERENCIAL TEÓRICO	16
2.1	Gerenciamento de Tráfego Aéreo	16
2.2	Controle de Tráfego Aéreo	17
2.3	Gerenciamento de Fluxo de Tráfego Aéreo	19
2.3.1	Centro de Gerenciamento de Navegação Aérea	19
2.3.2	Medidas de Gerenciamento de Fluxo de Tráfego Aéreo	20
3	REVISÃO DE LITERATURA	21
4	METODOLOGIA	23
4.1	Descrição da Base de Dados	23
4.1.1	Base de Dados de Medidas ATFM	23
4.1.2	Base de Dados de Meteorologia	24
4.2	Processamento dos Dados	24
4.3	Modelo Preditivo	25
4.3.1	Estudo de Caso	25
4.3.2	Variáveis de <i>Input</i> e <i>Output</i>	28
4.3.3	Método de Aprendizado de Máquina Supervisionado	29
5	RESULTADOS E DISCUSSÃO	33
5.1	Análise Exploratória da Base de Dados de Medidas ATFM	33
5.2	Análise de Desempenho Preditivo do Modelo	37
5.3	Análise de Importância das Variáveis de Input	39

SUMÁRIO	xiii
6 CONCLUSÃO	40
REFERÊNCIAS	42

1 Introdução

O sistema de gerenciamento de tráfego aéreo (*Air Traffic Management* – ATM) opera em um delicado equilíbrio entre a sua capacidade e a demanda de voos. Frequentemente, este equilíbrio é afetado por fatores dinâmicos e estocásticos que estão fora do controle do sistema ATM. Por exemplo, condições meteorológicas adversas podem reduzir a capacidade em aeroportos e no espaço aéreo, bem como incertezas nas operações aéreas podem gerar um volume excessivo de voos em determinados períodos de tempo, gerando desequilíbrios entre demanda e capacidade. Tais desequilíbrios são uma das principais causas de atrasos e cancelamentos de voo no mundo. Por exemplo, em 2019, condições meteorológicas adversas foram responsáveis por 57% dos atrasos no Sistema Nacional de Aviação dos Estados Unidos e volume de demanda foram responsáveis por 35% (Departamento de Transportes dos EUA, 2019).

Para mitigar os impactos de desequilíbrios entre demanda e capacidade, o sistema ATM precisa realizar a gestão do fluxo aéreo. Juntamente com o controle de tráfego aéreo e o gerenciamento do espaço aéreo, o gerenciamento de fluxo de tráfego aéreo (*Air Traffic Flow Management* – ATFM) é uma das principais funções do sistema ATM. O ATFM tem o objetivo de ajustar os fluxos de tráfego quando desequilíbrios entre demanda e capacidade acontecem, de forma a minimizar impactos como atrasos e cancelamentos de voos. O ATFM é realizado por meio de diversas medidas de gerenciamento de fluxo (*Traffic Management Initiatives* – TMI) estabelecidas a partir de diferentes horizontes de planejamento. Um exemplo de uma medida de gerenciamento de fluxo em nível mais estratégico é o Programa de Atraso em Solo (*Ground Delay Program* – GDP), que consiste em atrasar aeronaves em solo no aeroporto de origem quando se tem uma previsão de redução da capacidade no aeroporto de destino. Quando as aeronaves já estão em voo, medidas de gerenciamento de fluxo podem ser aplicadas de forma mais reativa pelos controladores de tráfego aéreo. Por exemplo, uma aeronave pode receber uma instrução de roteamento para desviar de uma formação meteorológica. Ou ainda, uma aeronave pode receber uma instrução de redução de velocidade devido à uma medida *Miles-in-Trail* (MIT), que consiste na aplicação de uma separação longitudinal mais restritiva entre aeronaves para controlar o fluxo de aeronaves em um determinado volume de espaço aéreo.

Apesar da disponibilidade de muitas fontes de previsões meteorológicas e da demanda de voos, a aplicação de medidas ATFM é normalmente realizada pelos gerentes de tráfego aéreo de forma empírica. Poucas ferramentas estão disponíveis para auxiliar diretamente os gerentes de tráfego aéreo nesse processo de tomada de decisão. Alguns estudos recentes nos Estados Unidos e na Europa tem explorado a grande disponibilidade de dados do sistema ATM e os avanços da ciência de dados para gerar modelos preditivos de apoio à decisão (Bloem et al., 2012; Wang e Grabbe, 2013; Mukherjee et al., 2014; Mangortey et al., 2019). Tais modelos tem o potencial de aumentar a eficiência do gerenciamento de fluxo, ao contribuir para evitar a ocorrência de decisões tomadas empiricamente que sobrecarreguem ou subutilizem a capacidade de aeroportos e do espaço aéreo. Além disso, eles permitem que os usuários do espaço aéreo tenham uma maior previsibilidade sobre o impacto de medidas ATFM em suas operações, antecipando atrasos e viabilizando um gerenciamento mais estratégico destas contingências. Estudos apontam, por exemplo, que medidas ATFM como MIT podem reduzir a eficiência horizontal de trajetórias de voo, aumentando o tempo de voo e o consumo de combustível (Liu et al., 2017; Murça et al., 2020).

Neste contexto, o objetivo deste trabalho de graduação é, primeiramente, realizar uma análise histórica das medidas ATFM aplicadas no espaço aéreo brasileiro, identificando as principais medidas utilizadas e as variáveis de decisão no emprego destas medidas pelos gerentes de tráfego aéreo. Com base neste conhecimento, será desenvolvido um modelo de previsão de medidas ATFM utilizando métodos de aprendizado de máquina supervisionado. Dados históricos de medidas ATFM e de meteorologia para um ano de operações (2019) são utilizados para o desenvolvimento do trabalho. A Área Terminal São Paulo (TMA-SP) é utilizada como estudo de caso no desenvolvimento do modelo preditivo, por se tratar do espaço aéreo terminal mais complexo e denso no sistema aéreo brasileiro.

2 Referencial Teórico

2.1 Gerenciamento de Tráfego Aéreo

O sistema ATM tem a função de garantir um fluxo seguro, ordenado e eficiente de aeronaves no espaço aéreo. A capacidade do sistema ATM depende de muitos fatores, como a estrutura de rotas, as separações de segurança regulamentares entre aeronaves, as condições meteorológicas, a capacidade cognitiva de controladores, entre outros. O número de aeronaves ao qual é proporcionado um serviço ATC não deverá exceder aquele que possa ser atendido, de forma segura, pelo órgão ATC responsável, em situações rotineiras. O sistema ATM também assegura o balanceamento entre a capacidade declarada e a demanda, ou seja, a quantidade de aeronaves que requisitam os serviços do sistema ATM em um dado período, buscando permitir que as aeronaves cumpram seus perfis ideais de voo. Os serviços prestados pelo sistema ATM no Brasil e no mundo estão baseados nas normas e nos métodos recomendados pela Organização de Aviação Civil Internacional (OACI).

Os principais serviços providos pelo sistema ATM são:

- Controle de tráfego aéreo: tem como finalidade a garantia das separações de segurança entre aeronaves no espaço aéreo e entre aeronaves e obstáculos para evitar colisões;
- Serviços de informação de voo e alerta: tem como finalidade garantir que os usuários do espaço aéreo tenham acesso a informações críticas para a realização das suas operações de forma segura, bem como notificar autoridades competentes sobre aeronaves em situação de emergência;
- Gerenciamento de fluxo de tráfego aéreo: tem como objetivo ajustar os fluxos de tráfego aéreo para balancear demanda e capacidade;
- Gerenciamento do espaço aéreo: tem como finalidade alocar e estruturar o espaço aéreo para atender os diferentes usuários.

Para prover estes serviços, qualquer sistema ATM depende dos seguintes componentes (Belobaba et al., 2016):

- Procedimentos e regras de acordo com as quais o sistema ATM opera;
- Controladores de tráfego aéreo, recursos humanos responsáveis por prover serviços ATM;
- Sistemas de comunicação que permitem a comunicação ar-solo, solo-solo, ar-ar por voz ou dados;
- Sistemas de vigilância que geram informação posicional em tempo real aos controladores de tráfego aéreo para rastreamento de aeronaves e controle do tráfego;
- Sistema de navegação que geram informações em tempo real para uma dada aeronave sobre sua posição e a auxilia na navegação pelo espaço aéreo;
- Sistemas de informação que compilam e distribuem informações aeronáuticas e meteorológicas para os diversos usuários;
- Sistemas de automação que auxiliam a tomada de decisão dos agentes humanos na gestão segura do fluxo de tráfego aéreo.

2.2 Controle de Tráfego Aéreo

Conforme descrito anteriormente, o controle de tráfego aéreo é o processo exercido no nível operacional, que tem a finalidade de garantir as separações de segurança entre aeronaves no espaço aéreo e entre aeronaves e obstáculos durante procedimentos de chegada e partida, de forma a evitar colisões. De acordo com cada fase do voo, determinados órgãos de controle são responsáveis pela prestação do serviço de tráfego aéreo (Belobaba et al., 2016):

- Torre de Controle de Aeródromo (*Aerodrome Control Tower* - TWR): responsável pelo espaço aéreo nas imediações de um aeródromo, abrangendo o circuito de tráfego e as áreas de manobra;
- Centro de Controle de Aproximação (*Approach Control Center* - APP): responsável pela área de controle terminal (*Terminal Maneuvering Area* - TMA), região no entorno de aeródromos de grande volume de operações, abrangendo os procedimentos de chegada e saída;
- Centro de Controle de Área (*Area Control Center* - ACC): responsável pelo espaço aéreo de rota, englobando as aerovias.

A Figura 2.1 mostra a distribuição das TMAs pelo território brasileiro e a Figura 2.2 mostra as Regiões de Informação de Voo (*Flight Information Regions* - FIRs) gerenciadas pelos quatro ACCs brasileiros (CINDACTAS I, II, III e IV).



FIGURA 2.1 – TMAs brasileiras.



FIGURA 2.2 – FIRs brasileiras.

2.3 Gerenciamento de Fluxo de Tráfego Aéreo

O gerenciamento de fluxo de tráfego aéreo é uma outra função muito importante do sistema ATM, que visa a mitigar os impactos de desequilíbrios entre demanda e capacidade, os quais frequentemente acontecem devido à natureza dinâmica e estocástica da demanda e da capacidade de aeroportos e do espaço aéreo (De Neufville e Odoni, 2013). As ações de gerenciamento de fluxo de tráfego aéreo podem ser tomadas com uma antecedência que pode variar de 1 h até 24 h ou 48 h antes da operação.

A OACI divide o planejamento do ATFM em 3 fases:

- Planejamento Estratégico

Realizado em coordenação com os órgãos de controle de tráfego e os operadores de aeronaves, consiste na análise da demanda e da capacidade ATC. É realizado no período que antecede em mais de um dia o início das ações a serem efetuadas. As ações decorrentes são: coordenação com órgão ATC para aumento da capacidade, redirecionamento do fluxo, reprogramação de voos e detecção da necessidade de medidas táticas.

- Planejamento Pré-tático

Corresponde ao planejamento efetuado no dia anterior à utilização do espaço aéreo. O planejamento existente é atualizado considerando alterações da capacidade e da demanda, tais como condições meteorológicas, eventos especiais e intenções de voo. Nessa fase ocorrem redirecionamentos de fluxo e voos, seleção de medidas táticas e divulgação de planejamento.

- Operações Táticas

Acompanha a ocorrência de imprevistos como eventos meteorológicos ou inoperâncias de equipamentos que afetam a demanda ou a capacidade. Além de aplicar as medidas táticas, monitora a evolução da situação do tráfego aéreo para garantir que as mesmas tenham os efeitos desejados.

2.3.1 Centro de Gerenciamento de Navegação Aérea

O gerenciamento do fluxo de tráfego aéreo é realizado por um órgão central de coordenação. No Brasil, este órgão é o Centro de Gerenciamento da Navegação Aérea (CGNA). O CGNA foi inicialmente concebido em 1998 devido ao crescimento da demanda do setor aéreo. Foi criado em agosto de 2005 e ativado em 31 de agosto de 2007. O órgão é integrante do Sistema de Aviação Civil e tem como responsabilidade a análise das intenções de voos das aeronaves com o objetivo de estabelecer um fluxo de tráfego harmônico.

O início das operações do CGNA foi um marco na modernização do gerenciamento do

tráfego aéreo no Brasil, trazendo melhorias para a segurança dos voos e proporcionando as economias de combustível sempre almejadas, uma vez que o combustível representa grande parte dos custos das companhias aéreas.

É atribuição do CGNA aplicar e aferir medidas de gerenciamento de fluxo de tráfego aéreo para manter o balanceamento entre a demanda dos movimentos aéreos e as capacidades declaradas, além de realizar as ações necessárias quanto ao uso flexível do espaço aéreo, conduzir o processo de tomada de decisões colaborativas junto aos provedores e operadores, coordenar as atividades de gerenciamento do espaço aéreo brasileiro, entre outras.

2.3.2 Medidas de Gerenciamento de Fluxo de Tráfego Aéreo

O ATFM pode ser realizado através de diferentes mecanismos ou medidas para ajustar os fluxos de tráfego. Entre as principais medidas de ajuste do fluxo, destacam-se:

- Espera em solo (*ground holding*): consiste em atrasar a aeronave em solo intencionalmente se o voo estiver destinado a alguma região em que está previsto um desbalanceamento entre demanda e capacidade;
- Reroteamento: consiste em realizar uma mudança da rota solicitada no plano de voo para modificar a distribuição dos fluxos de tráfego no espaço aéreo;
- *Metering*: consiste em controlar a taxa de fluxo de chegada em um determinado volume do espaço aéreo, por exemplo, com a imposição de um horário para que a aeronave passe por um determinado fixo ou com o ajuste da separação longitudinal entre duas aeronaves consecutivas. Quando a restrição de separação é em distância (milhas náuticas), a medida chama-se "*Miles-In-Trail*"(MIT). Quando a restrição de separação é em tempo (minutos), a medida chama-se "*Minutes-In-Trail*"(MINIT).

As medidas ATFM são tipicamente aplicadas de forma isolada. Por exemplo, um Programa de Atraso em Solo (*Ground Delay Program - GDP*) pode ser estabelecido em um determinado aeroporto em que há uma previsão de redução de capacidade, de forma a segurar as aeronaves em solo nos aeroportos de origem. No entanto, quando necessário, uma combinação das medidas existentes pode ser usada, visando o menor impacto possível aos usuários.

3 Revisão de Literatura

Aproveitando a grande disponibilidade de dados operacionais produzidos pelo sistema ATM e os avanços na ciência de dados, estudos recentes tem explorado o desenvolvimento de modelos preditivos para o apoio à tomada de decisão no gerenciamento do fluxo de tráfego aéreo.

Bloem et al. (2012) desenvolveram uma ferramenta de apoio à decisão na aplicação de medidas MIT no aeroporto de Newark usando algoritmos de aprendizado de máquina. A ferramenta gera probabilidades para cada restrição MIT que pode ser aplicada em uma determinada situação. A partir das probabilidades obtidas, eles fizeram o cálculo do custo do uso da medida MIT recomendada pela ferramenta. Foram avaliados quatro algoritmos: *Random Forest*, *Decision Trees*, *Support Vector Machines* e *Logistic Regression*. O modelo de previsão baseado em *Decision Trees* gerou o menor custo esperado da aplicação das medidas MIT.

Mukherjee et al. (2014) desenvolveram modelos de previsão da ocorrência de Programas de Atraso em Solo a partir das condições meteorológicas e da demanda programada de voos utilizando dois métodos de aprendizado de máquina, *Decision Trees* e *Logistic Regression*. Os modelos de previsão foram desenvolvidos para o Aeroporto Internacional Newark Liberty e para o Aeroporto Internacional de São Francisco. Os resultados indicaram que os modelos geraram previsões significativamente melhores que uma previsão randômica da ocorrência de um Programa de Atraso em Solo nestes aeroportos. Além disso, observou-se que as variáveis de *input* contribuíram de forma diferente nas previsões de cada aeroporto. Enquanto atividade convectiva em rota se mostrou um fator dominante no aeroporto de Newark, visibilidade e teto baixos foram os principais fatores determinantes da aplicação da medida ATFM no aeroporto de São Francisco. Estes resultados ressaltam a importância de uma análise local, ainda mais para países de dimensões continentais, onde o clima pode variar bastante de uma região para outra, como no Brasil.

Mangortey et al. (2019) também aplicaram diversos algoritmos de aprendizado de máquina para a previsão da ocorrência de Programas de Atraso em Solo no Aeroporto Internacional de Los Angeles, usando *inputs* relacionados a volume e clima. Os métodos analisados foram: *Naive Bayes*, *Support Vector Machines*, *Decision Trees*, *Bagging*

Ensemble, *Boosting Ensemble* e *Random Forests*. Para analisar o desempenho preditivo dos diferentes modelos, foi utilizado a estatística Kappa. O método *Boosting Ensemble* apresentou o melhor desempenho preditivo na base de dados de teste.

Contribuindo nesta linha de pesquisa, este trabalho busca desenvolver modelos preditivos da aplicação de medidas de gerenciamento de fluxo no espaço aéreo brasileiro, de forma a apoiar a tomada de decisão dos gerentes de tráfego aéreo e aumentar a previsibilidade do impacto destas medidas nas operações para os usuários do espaço aéreo.

4 Metodologia

4.1 Descrição da Base de Dados

Para o desenvolvimento deste trabalho, foram utilizados dados históricos de medidas ATFM e de meteorologia para o ano de 2019. A base de dados de medidas ATFM aplicadas no espaço aéreo brasileiro foi obtida através do Portal Operacional do CGNA. A base de dados de meteorologia foi obtida através do repositório de dados climatológicos da Universidade Estadual de Iowa e consiste dos relatórios METAR para os aeroportos brasileiros. O METAR é um informe codificado horário que apresenta as condições meteorológicas de superfície em um aeródromo específico, contendo dados de direção e velocidade do vento, pressão atmosférica, altura das nuvens, visibilidade, temperatura e condição do tempo (chuva, tempestade, etc).

4.1.1 Base de Dados de Medidas ATFM

A base de dados de medidas ATFM apresenta, para todas as medidas ATFM aplicadas no espaço aéreo brasileiro em 2019, o tipo de medida, o horário de aplicação e os fluxos afetados, contendo as seguintes variáveis:

- *orig*: aeroporto/área terminal de origem do fluxo afetado;
- *dest*: aeroporto/área terminal de destino do fluxo afetado;
- *t_begin*: data e hora (horário UTC) de início da aplicação da medida ATFM;
- *t_end*: data e hora (horário UTC) de término da aplicação da medida ATFM;
- *tmi*: descrição da medida ATFM;
- *rate*: restrição utilizada na medida ATFM.

4.1.2 Base de Dados de Meteorologia

A base de dados de meteorologia apresenta, para cada hora em 2019, as condições meteorológicas de superfície para os aeroportos brasileiros, contendo as seguintes variáveis:

- *drct*: direção do vento (graus);
- *sknt*: velocidade do vento (kt);
- *vsby*: visibilidade (milhas);
- *ceiling*: teto (ft);
- *ts*: presença de chuva ou tempestade (binária; igual a 1 se há presença de chuva ou tempestade);
- *wind_gust*: velocidade do vento de rajada (kt).

4.2 Processamento dos Dados

As bases de dados de medidas ATFM e meteorologia foram consolidadas e filtradas, de forma a criar a base de dados final para o desenvolvimento do modelo preditivo. Todo o processamento e análise de dados foi realizado neste trabalho usando o software R (Boehmke e Greenwell, 2020).

Uma vez que o estudo de caso para o desenvolvimento do modelo preditivo foi a TMA-SP, foram filtradas as observações de medidas ATFM aplicadas apenas aos fluxos destinados a TMA-SP. A base de dados consolidada contém, para cada hora de 2019, a indicação da ocorrência de uma medida ATFM para os voos com destino a TMA-SP, bem como da condição meteorológica nos principais aeroportos desta TMA, ou seja, SBGR, SBSP, SBKP. Ela contém as seguintes variáveis:

- *date*: data;
- *hour*: hora;
- *weekdays*: dia da semana;
- *tmi*: descrição da medida ATFM aplicada na hora indicada ("*none*", caso nenhuma medida ATFM tenha sido aplicada naquela hora);
- *tmi_rate*: restrição utilizada na medida ATFM aplicada na hora indicada ("*none*", caso nenhuma medida ATFM tenha sido aplicada naquela hora);
- *orig*: aeroporto/TMA/FIR de origem do fluxo afetado pela medida ATFM aplicada na hora indicada ("*none*", caso nenhuma medida ATFM tenha sido aplicada naquela hora);
- *wind_dir_sbgr*: direção do vento (graus) no aeroporto SBGR;

- *wind_dir_sbsp*: direção do vento (graus) no aeroporto SBSP;
- *wind_dir_sbkp*: direção do vento (graus) no aeroporto SBKP;
- *wind_speed_sbgr*: velocidade do vento (kt) no aeroporto SBGR;
- *wind_speed_sbsp*: velocidade do vento (kt) no aeroporto SBSP;
- *wind_speed_sbkp*: velocidade do vento (kt) no aeroporto SBKP;
- *visibility_sbgr*: visibilidade (NM) no aeroporto SBGR;
- *visibility_sbsp*: visibilidade (NM) no aeroporto SBSP;
- *visibility_sbkp*: visibilidade (NM) no aeroporto SBKP;
- *ceiling_sbgr*: teto (ft) no aeroporto SBGR;
- *ceiling_sbsp*: teto (ft) no aeroporto SBSP;
- *ceiling_sbkp*: teto (ft) no aeroporto SBKP;
- *ts_sbgr*: presença de chuva ou tempestade no aeroporto SBGR (binária; igual a 1 se há presença de chuva ou tempestade);
- *ts_sbsp*: presença de chuva ou tempestade no aeroporto SBSP (binária; igual a 1 se há presença de chuva ou tempestade);
- *ts_sbkp*: presença de chuva ou tempestade no aeroporto SBKP (binária; igual a 1 se há presença de chuva ou tempestade);
- *wind_gust_sbgr*: velocidade do vento de rajada (kt) no aeroporto SBGR;
- *wind_gust_sbsp*: velocidade do vento de rajada (kt) no aeroporto SBSP;
- *wind_gust_sbkp*: velocidade do vento de rajada (kt) no aeroporto SBKP.

4.3 Modelo Preditivo

4.3.1 Estudo de Caso

Para o desenvolvimento do modelo preditivo de medidas ATFM, utilizou-se a Área Terminal São Paulo (TMA-SP) como estudo de caso, por se tratar do espaço aéreo terminal mais denso e complexo do Brasil. A TMA-SP abrange as operações de chegada e partida dos três principais aeroportos do estado de São Paulo: SBGR, SBSP e SBKP. Esses três aeroportos foram responsáveis por quase 30% das decolagens domésticas de 2019. A Figura 4.1, retirada do Anuário do Transporte Aéreo de 2019 da Agência Nacional de Aviação Civil (ANAC), mostra a distribuição de decolagens domésticas nos 20 principais aeroportos brasileiros. Os aeroportos SBGR, SBSP e SBKP ocupam a primeira, segunda

e quarta posições em volume de decolagens, respectivamente.

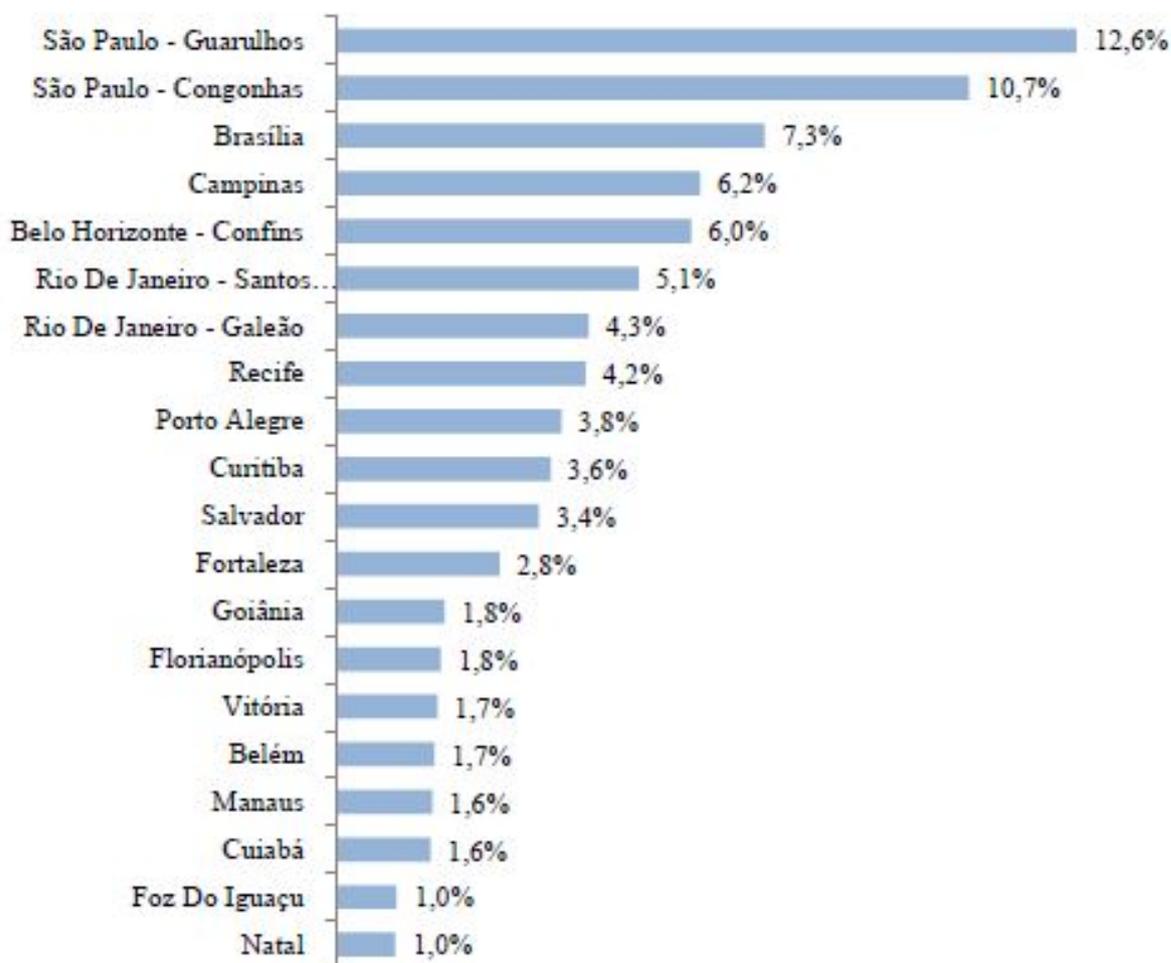


FIGURA 4.1 – Participação dos 20 principais aeroportos brasileiros no número de decolagens domésticas em 2019. Fonte: ANAC (2019)

Observa-se, ainda, que os aeroportos SBGR, SBSP e SBKP participam de 18 das 20 principais rotas domésticas do país e de 17 das 20 mais importantes rotas internacionais. As Figuras 4.2 e 4.3 mostram os percentuais de atrasos destas principais rotas domésticas e internacionais.

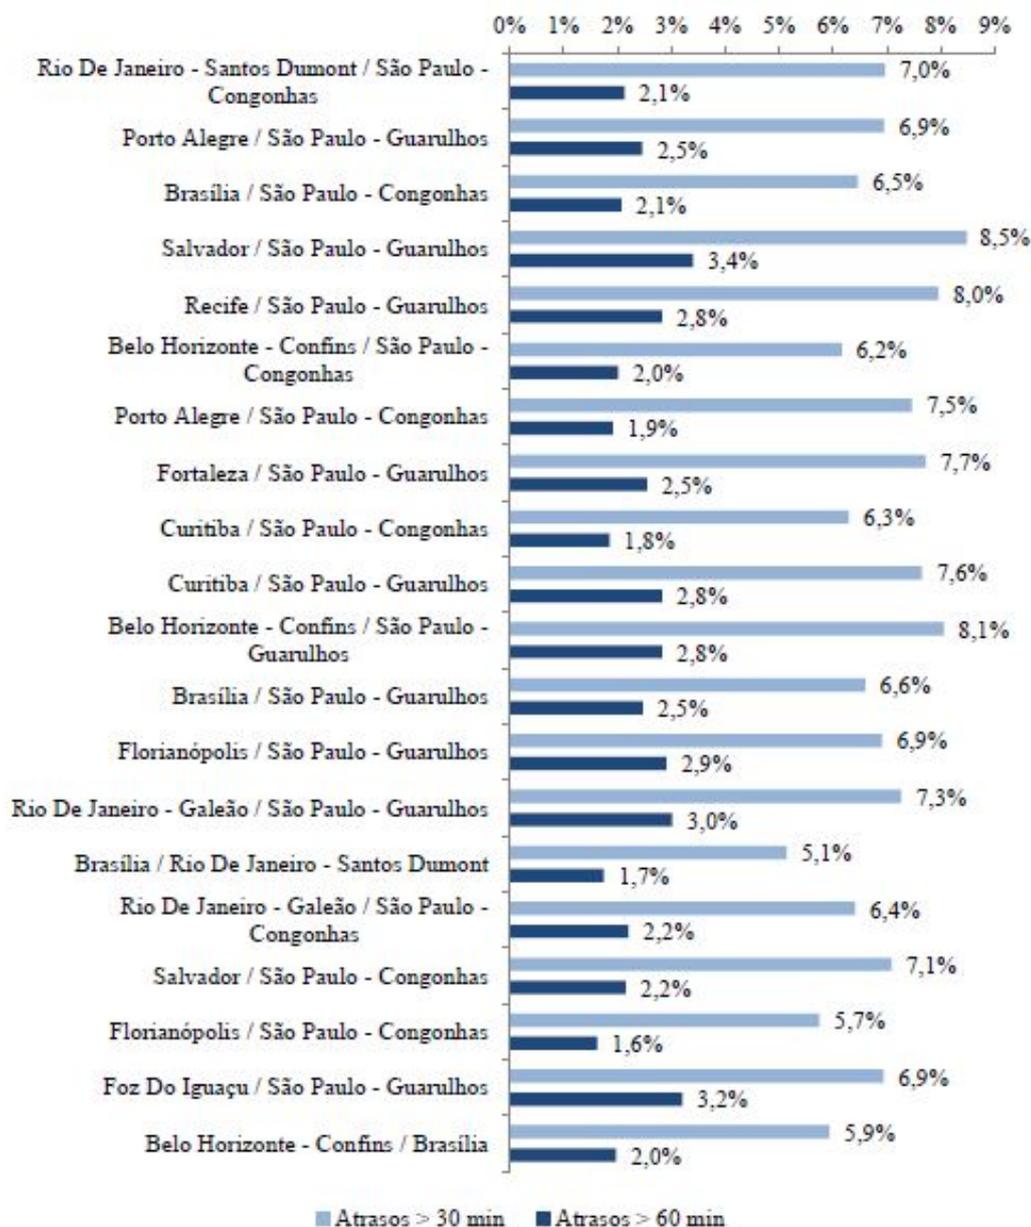


FIGURA 4.2 – Percentuais de atrasos nas 20 principais rotas domésticas em 2019. Fonte: ANAC (2019)

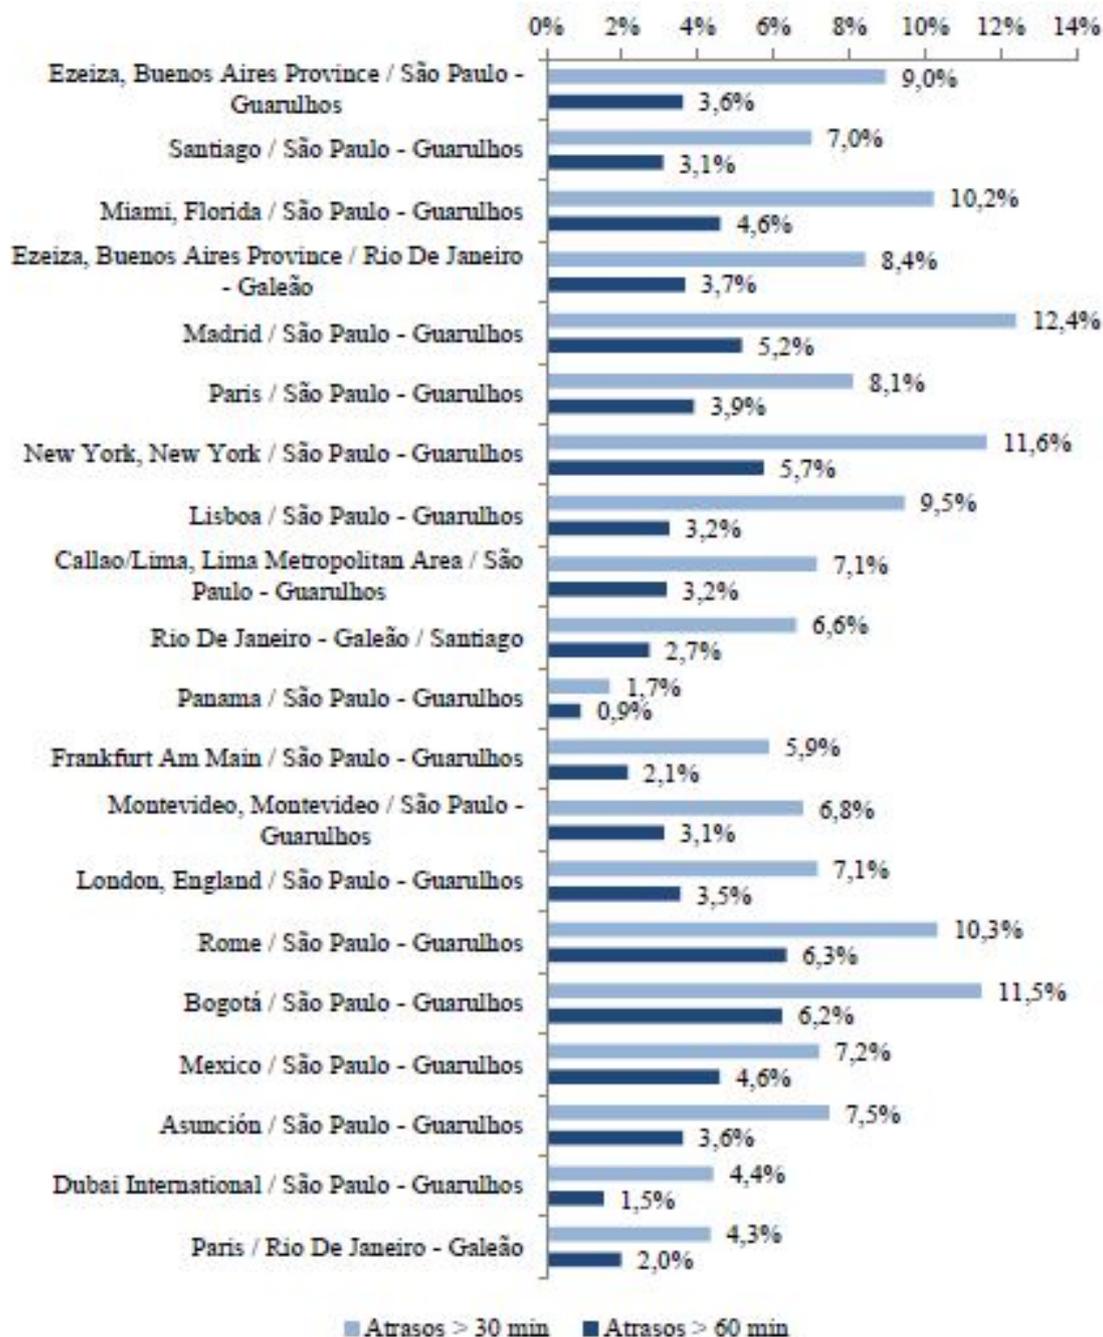


FIGURA 4.3 – Percentuais de atrasos nas 20 principais rotas internacionais em 2019. Fonte: ANAC (2019)

4.3.2 Variáveis de *Input* e *Output*

O modelo preditivo visa a prever a aplicação ou não de uma medida ATFM, bem como da restrição que deve ser utilizada na aplicação da medida. Portanto, utilizou-se como output a variável *tmi_rate*. Por se tratar de uma variável categórica, o problema de previsão é enquadrado como um problema de classificação.

Como variáveis de input, foram considerados os principais fatores que afetam a demanda e a capacidade e que podem causar desequilíbrios, gerando a necessidade da aplicação de uma medida ATFM. Dessa forma, origem, hora do dia e dia da semana foram utilizadas como variáveis de input relacionadas ao volume de aeronaves chegando na região. Velocidade e direção do vento, teto, visibilidade, vento de rajada, e presença de chuva/tempestade foram utilizadas como variáveis de *input* relacionadas às condições meteorológicas que podem afetar a capacidade dos aeroportos e do espaço aéreo terminal.

4.3.3 Método de Aprendizado de Máquina Supervisionado

O modelo preditivo foi desenvolvido através da aplicação de métodos de aprendizado de máquina supervisionado na base de dados final. Na aprendizagem supervisionada, o objetivo é aprender um mapeamento entre um conjunto de variáveis de *input* e uma determinada variável de output a partir de uma base de dados de treinamento com exemplos. Quando a variável de *output* é categórica, tem-se um problema de classificação, buscando-se uma fronteira de decisão que discrimina as diferentes classes existentes nos dados.

Para a aprendizagem supervisionada, selecionou-se aleatoriamente 70% das observações como dados de treinamento e 30% como dados de teste. Dois métodos de aprendizado de máquina foram utilizados para o aprendizado do modelo de classificação: *Random Forests* e *Support Vector Machines*. Estes métodos serão descritos a seguir.

4.3.3.1 *Random Forests*

Para a descrição do método de aprendizado de máquina *Random Forests*, precisamos, inicialmente, apresentar o método de árvores de decisão e o processo de *bagging*.

As árvores de decisão são um método de aprendizado de máquina que pode ser usado tanto para classificação de dados qualitativos quanto regressão de dados quantitativos (James et al., 2013). O método funciona com a segmentação ou estratificação do espaço multidimensional que representa as variáveis de input em regiões. A Figura 4.4 apresenta uma ilustração de uma árvore de decisão.

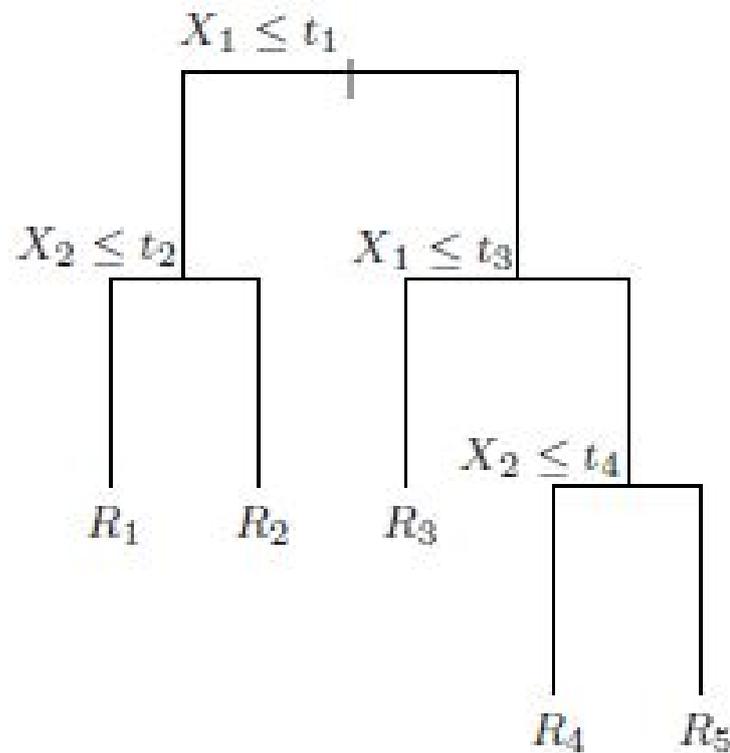


FIGURA 4.4 – Ilustração de uma árvore de decisão. Fonte: James et al. (2013)

Analogamente a uma árvore, o nó inicial é chamado de nó raiz (*root node*). As folhas são os nós terminais (*leaf nodes*). Já os pontos em que há uma subdivisão são chamados nós internos (*internal nodes*) e a ligação entre dois nós é chamada de galho (*branch*). Dessa forma, a representação mais comum de uma árvore de decisão é uma árvore de cabeça para baixo. A Figura 4.5 apresenta a nomenclatura típica de uma árvore de decisão.

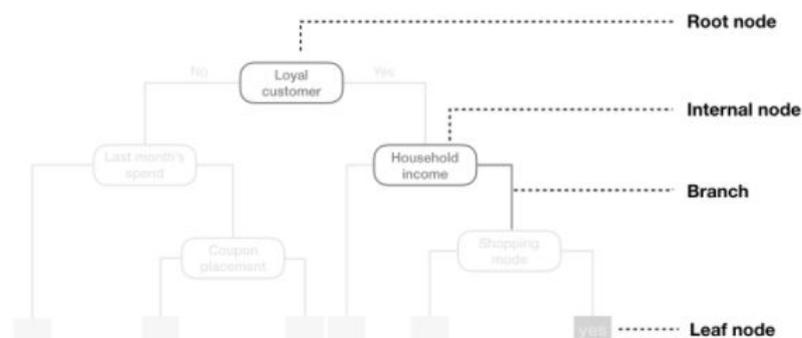


FIGURA 4.5 – Nomenclatura típica de uma árvore de decisão. Fonte: Boehmke et al. (2020)

Cada nó de decisão avalia o valor de uma variável de *input* para particionar os dados. A qualidade de uma divisão é quantificada com uma medida de impureza. Em um problema

de classificação, o índice de Gini é normalmente usado. O processo de particionamento é repetido até que um critério de parada seja atendido (por exemplo, o nó é puro ou um número mínimo de observações é alcançado).

Para evitar a criação de árvores muito grandes e um potencial sobreajuste nos dados de treinamento, a poda da árvore de decisão é comumente realizada durante o processo de validação cruzada.

A previsão da classe para uma nova observação é obtida identificando-se a classe mais frequente na folha em que esta observação cai quando é passada pela árvore.

O método de *bagging* tem como objetivo a redução da variância que pode ocorrer com o uso do método de árvore de decisão. Para isso, esse processo realiza um procedimento de reamostragem aleatória com reposição da base de dados de treinamento para gerar várias árvores de decisão diferentes a partir de diferentes amostras de treinamento. As árvores treinadas no processo de *bagging* não passam pelo processo de poda, o que gera árvores com grande variância, porém baixo viés. A previsão do método *bagging* é feita agregando-se os resultados da previsão das árvores individuais.

Finalmente, o método *Random Forests* nada mais é que um processo de *bagging*, mas com a característica única de selecionar apenas um subconjunto aleatório das variáveis de *input* para determinar cada divisão nos nós de decisão durante a construção das árvores. Isso evita que um preditor muito forte restrinja a utilização de outros preditores menos fortes, já que parte dos nós de decisão não vai considerar o preditor mais forte. O método possui poucos parâmetros que são ajustados durante o treinamento através de um processo de validação. São eles: o número de árvores de decisão e o número de variáveis consideradas para a divisão de cada nó durante a construção de cada árvore.

4.3.3.2 *Support Vector Machines*

O método SVM baseia-se na construção de um hiperplano ótimo que separa as classes presentes na base de dados de treinamento (James et al., 2013). Para a construção desse hiperplano, almeja-se separar perfeitamente as classes, maximizando a margem de separação entre elas. Contudo, normalmente não é possível realizar uma separação perfeita entre as classes e, então, permite-se que uma certa quantidade de observações estejam do lado incorreto do hiperplano, dentro de uma tolerância. A Figura 4.6 ilustra um classificador SVM para os casos de separação perfeita e imperfeita entre classes.

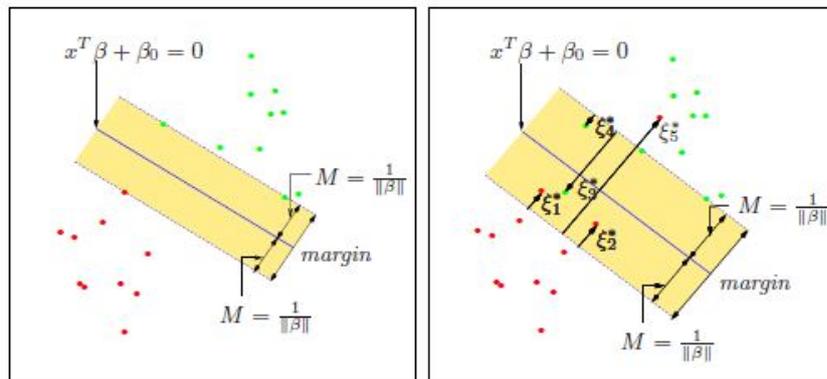


FIGURA 4.6 – Ilustração de um classificador baseado em *Support Vector Machines*. Fonte: James et al. (2013)

Quando o problema de classificação não é linearmente separável, o método SVM permite, ainda, que funções *kernel* sejam utilizadas para mapear os dados de entrada para um espaço de maior dimensão onde um classificador linear pode ser aplicado.

A escolha do *kernel* e da tolerância para erros de classificação durante o treinamento de um classificador SVM deve ser feita através de um processo de validação cruzada.

5 Resultados e Discussão

5.1 Análise Exploratória da Base de Dados de Medidas ATFM

Primeiramente, foi realizada uma análise exploratória da base de dados de medidas ATFM para analisar como o ATFM é realizado na prática no espaço aéreo brasileiro. A primeira observação foi a predominância da utilização das medidas MIT para o gerenciamento do fluxo no Brasil. A Figura 5.1 mostra a distribuição de medidas MIT aplicadas no ano de 2019, por aeroporto, FIR ou TMA de destino do fluxo afetado. Observa-se que a TMA-SP (SBXP) destaca-se como o volume de espaço aéreo mais afetado por medidas ATFM, reforçando a importância de sua escolha como estudo de caso neste trabalho. A Área Terminal Rio de Janeiro (SBWJ) também apresentou um número razoável de medidas, embora bem menor que a TMA-SP. Entre os aeroportos mais impactados por medidas ATFM, destacam-se SBGR e SBSP, novamente evidenciando a densidade e a complexidade das operações na TMA-SP. Finalmente, entre as FIRs, a FIR Brasília (SBBS) e a FIR Curitiba (SBCW) apresentaram o maior número de medidas MIT.

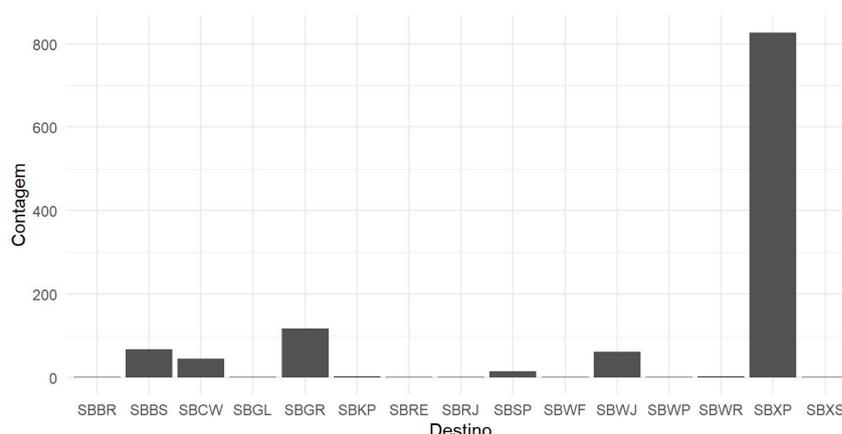


FIGURA 5.1 – Número de medidas MIT aplicadas em 2019, por aeroporto, TMA ou FIR de destino do fluxo afetado.

A Figura 5.2 mostra a distribuição das medidas MIT por dia da semana. Percebe-se a influência da variação no volume de voos ao longo semana na quantidade de medidas aplicadas. Nos finais de semana, quando há uma menor frequência de voos, percebe-se

uma menor ocorrência de medidas, quando comparados aos dias do meio da semana.

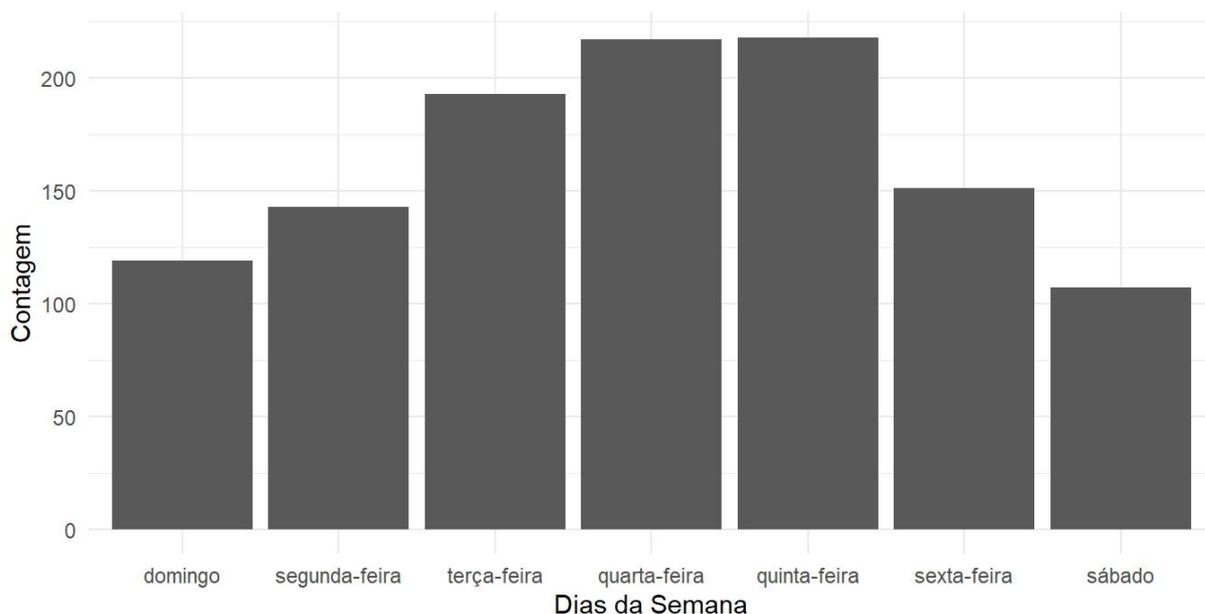


FIGURA 5.2 – Número de medidas MIT aplicadas em 2019, por dia da semana.

A Figura 5.3 mostra a distribuição das medidas MIT por mês do ano. Na análise mensal, existem dois fatores interessantes que podem ser estudados. Além do fator volume, que foi analisado previamente em outros tipos de agrupamento, as variações climáticas que ocorrem durante o ano também podem gerar resultados importantes. Em termos de volume, tem-se tipicamente uma alta demanda de dezembro a março. Esse período reúne os principais feriados nacionais: natal, ano novo e carnaval. Além disso, nesse período, também ocorrem as férias escolares. Esses fatores podem colaborar para um aumento considerável no volume de voos nesses meses. Com relação ao clima, o mesmo período representa o verão, apresentando muitas chuvas e atividade convectiva.

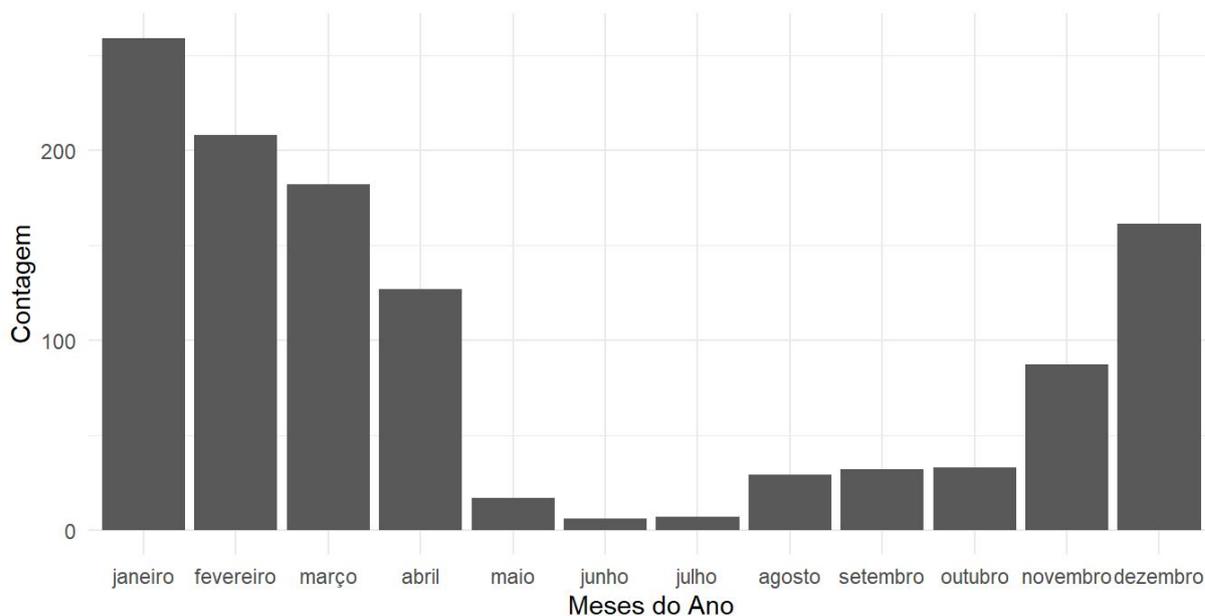


FIGURA 5.3 – Número de medidas MIT aplicadas em 2019, por mês do ano.

A maior ocorrência de medidas MIT nos meses de verão apresenta uma correlação com o maior percentual de atrasos e cancelamentos de voos nestes meses, como fica evidenciado na Figura 5.4.



FIGURA 5.4 – Evolução dos percentuais de atrasos e cancelamentos – indústria, por mês, 2019. Fonte: ANAC (2019)

A Figura 5.5 mostra a distribuição das medidas MIT por tipo de restrição. Percebe-se que as restrições de separação longitudinal tipicamente usadas são de 15, 20 e 30 NM, com predominância dos valor de 20 NM.

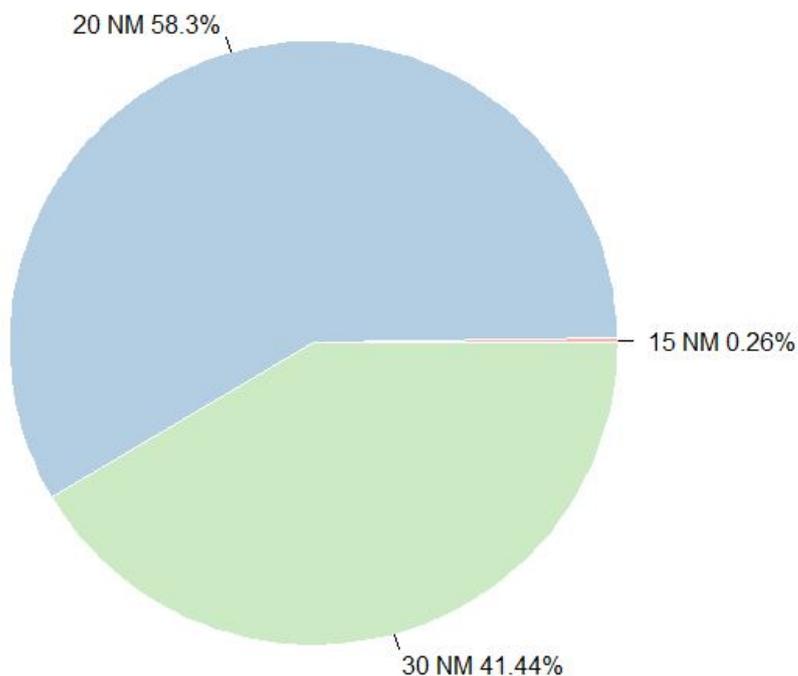


FIGURA 5.5 – Percentagem de medidas MIT aplicadas em 2019 por tipo de restrição.

A Figura 5.6 mostra a distribuição do tempo de duração de todas as medidas MIT aplicadas em 2019. A média do tempo de duração foi de 8822 segundos. Observa-se também um grande variabilidade nos tempos de duração.

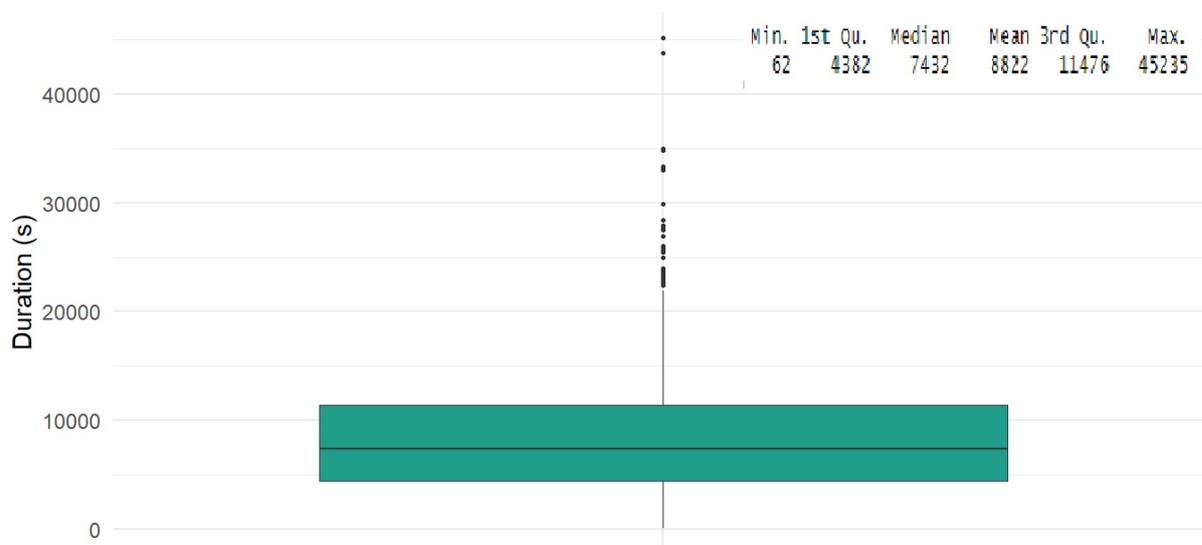


FIGURA 5.6 – *Boxplot* do tempo de duração, em segundos, das medidas MIT aplicadas em 2019.

Por fim, a Figura 5.7 apresenta a distribuição do tempo de duração das medidas MIT, por tipo de restrição e por aeroporto/TMA/FIR de destino do fluxo afetado. Observa-se que, em grande parte dos casos, apenas um tipo de restrição é utilizado. É interessante notar também que SBXS tende a sofrer restrições mais longas, porém com menor separação longitudinal entre as aeronaves.

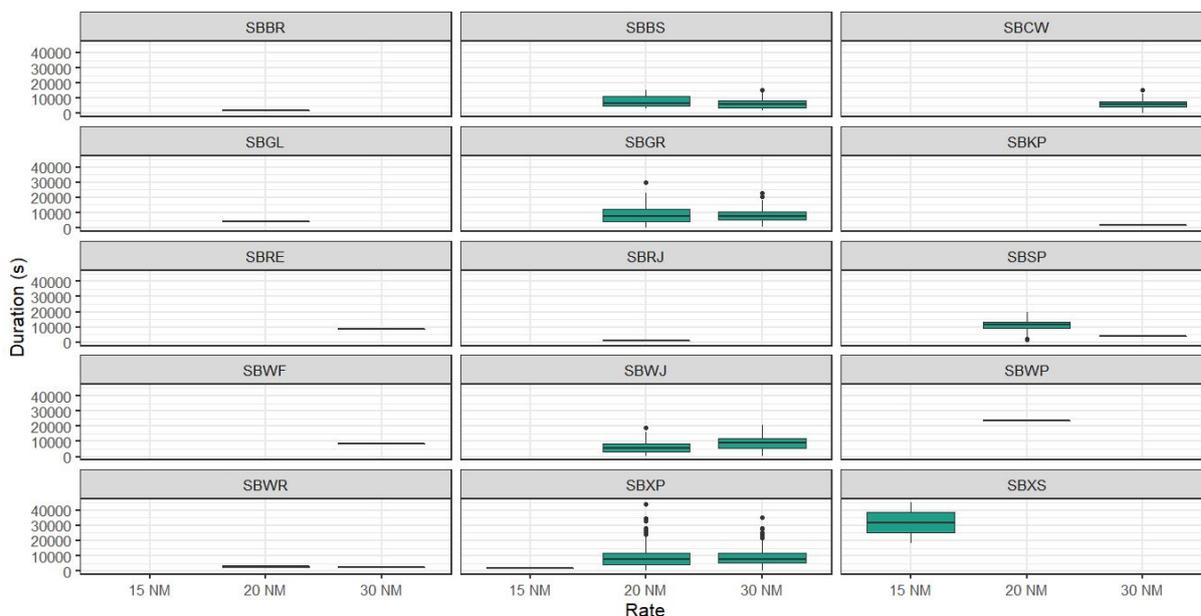


FIGURA 5.7 – *Boxplot* do tempo de duração, em segundos, das medidas MIT aplicadas em 2019, por tipo de restrição e por aeroporto/TMA/FIR de destino do fluxo afetado.

5.2 Análise de Desempenho Preditivo do Modelo

Os métodos *Random Forests* e *Support Vector Machines* foram utilizados para treinar dois modelos de classificação para previsão da ocorrência e da severidade de medidas MIT na TMA-SP. Um processo de validação cruzada *5-fold* foi realizado para ajustar os parâmetros de cada modelo. Uma vez que há um grande desbalanceamento entre as classes na base de dados de treinamento, com uma proporção muito maior de observações em que nenhuma medida MIT foi aplicada, foram adotados pesos diferenciados para as observações de cada classe durante o treinamento dos modelos. O peso utilizado para cada classe foi o inverso da percentagem de observações daquela classe.

Os modelos de classificação treinados foram aplicados na base de dados de teste para avaliação do desempenho preditivo. As métricas acurácia e índice F1 ponderado foram utilizadas para comparação do desempenho preditivo. A acurácia é a percentagem de observações que foram corretamente previstas pelo modelo. O índice F1 ponderado é média ponderada dos índices F1 para cada classe, levando em consideração tanto a precisão quanto a sensibilidade do modelo (Shmueli, 2019). É uma métrica adequada para

problemas de classificação com múltiplas classes desbalanceadas.

A Figura 5.8 mostra a matriz de confusão para o modelo *Random Forests*. A acurácia obtida foi 81,57%. Já o índice F1 ponderado obtido foi 84,37%.

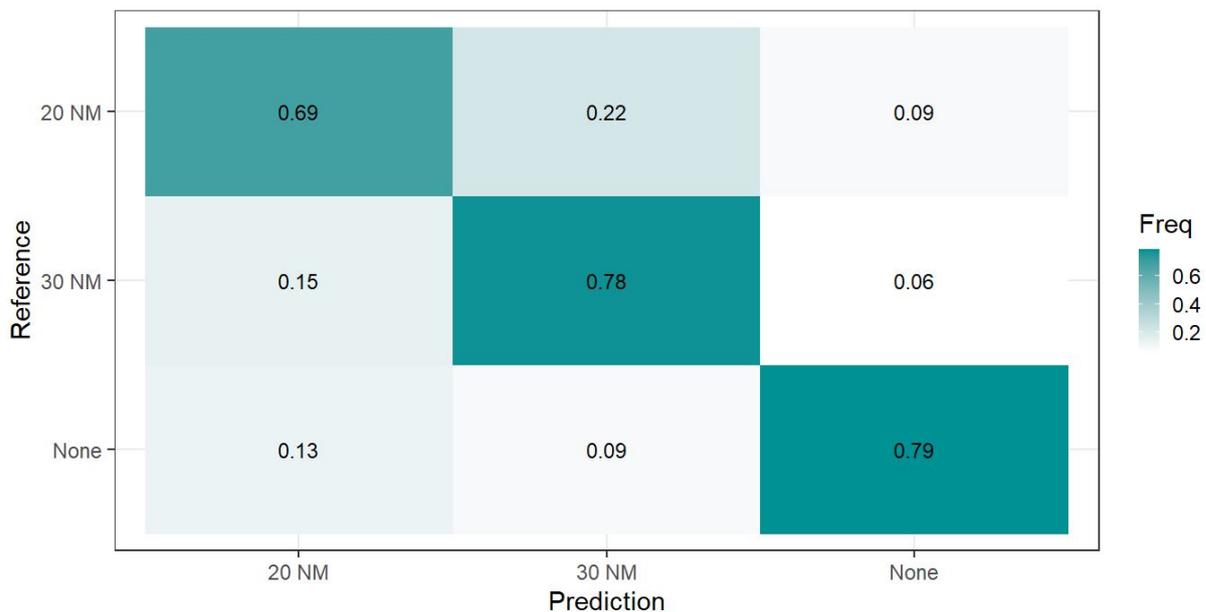


FIGURA 5.8 – Matriz de confusão para o modelo *Random Forests*.

Para o modelo SVM, a acurácia obtida foi 78,56%. Já o índice F1 ponderado foi 83,06%. A Figura 5.9 mostra a matriz de confusão para o modelo SVM.

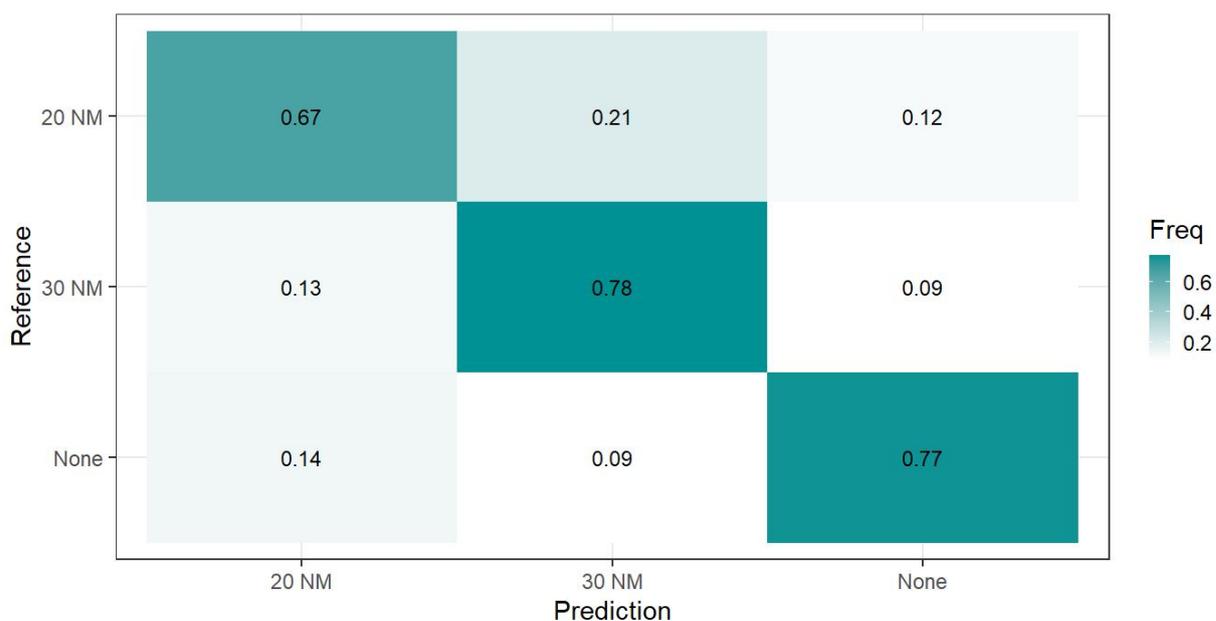


FIGURA 5.9 – Matriz de confusão para o modelo SVM.

Os resultados revelam um desempenho preditivo ligeiramente superior para o modelo

Random Forests.

5.3 Análise de Importância das Variáveis de Input

A partir do modelo *Random Forests*, foi possível obter uma estimativa da importância de cada variável de input para a previsão da ocorrência de medidas MIT. Os resultados são apresentados na Figura 5.10.

Observa-se que a origem do fluxo e a hora do dia são os fatores mais relevantes. Isso pode estar relacionado às variações da demanda ao longo do dia e à existência de fluxos de maior intensidade de voos com destino a TMA-SP.

Observa-se que as variáveis meteorológicas, apesar de possuírem menores valores de importância que as variáveis relacionadas à demanda, também influenciam a aplicação de medidas MIT na TMA-SP, sobretudo as condições de vento, visibilidade e teto.

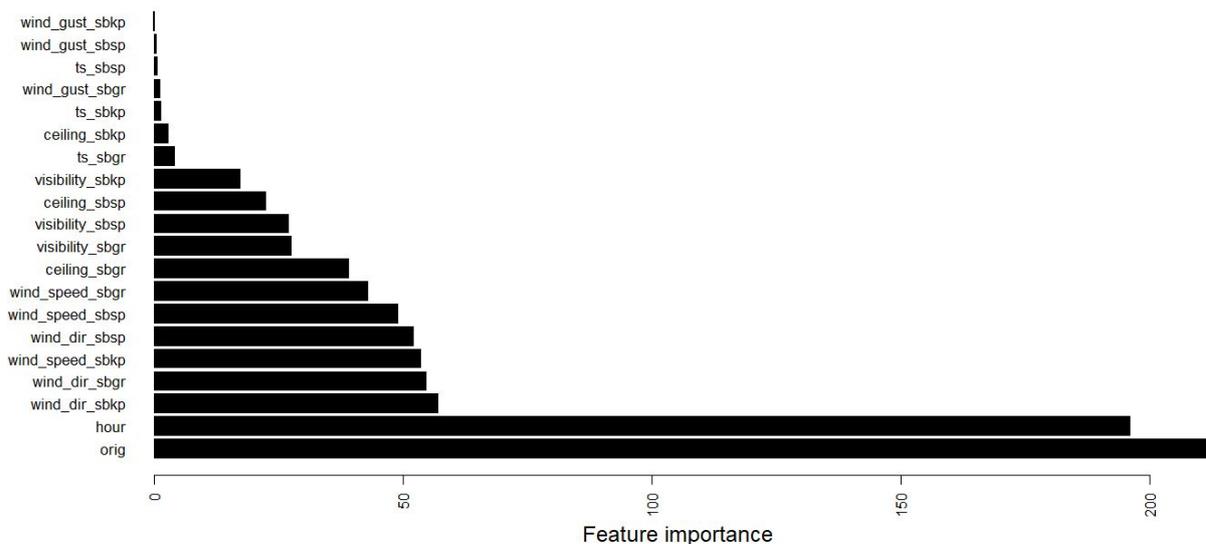


FIGURA 5.10 – Estimativas de importância das variáveis de *input* geradas pelo modelo *Random Forests*.

6 Conclusão

Este trabalho teve como objetivo realizar uma análise histórica das medidas de gerenciamento de fluxo de tráfego aéreo (ATFM) aplicadas no espaço aéreo brasileiro e desenvolver um modelo preditivo para apoiar a tomada de decisão dos gerentes de tráfego e prover aos usuários do espaço aéreo uma maior previsibilidade sobre o impacto de restrições operacionais em seus voos. Dados históricos de medidas ATFM e de meteorologia para o ano de 2019 foram utilizados para o desenvolvimento do estudo.

Os resultados da análise de dados históricos revelaram que há um uso predominante da medida *Miles-In-Trail* (MIT) para o gerenciamento do fluxo no espaço aéreo brasileiro e que a Área Terminal São Paulo (TMA-SP) é o volume de espaço aéreo mais afetado por essas medidas. Observou-se que a aplicação das medidas MIT apresenta grande variação temporal, sendo mais frequentes nos meses de verão e em dias úteis, e que as restrições de 20 NM e 30 NM de separação longitudinal são mais comumente utilizadas. Observou-se também que, em média, o tempo de duração das medidas é de, aproximadamente, 2,5 h, embora haja uma grande variabilidade, de acordo com a severidade da restrição e o fluxo afetado.

A partir dos resultados da análise de dados, desenvolveu-se um modelo preditivo da aplicação e da severidade de medidas MIT na TMA-SP. Dois métodos de aprendizado de máquina supervisionado foram utilizados: *Random Forests* e *Support Vector Machines*. Os resultados mostraram um desempenho preditivo superior para o modelo gerado pelo método *Random Forests*, que apresentou uma acurácia de 82%. Ao analisar a importância das variáveis utilizadas para a previsão, observou-se que os fatores relacionados à demanda de voos, como origem do fluxo e hora do dia, foram os mais significativos. Observou-se que as variáveis meteorológicas, apesar de possuírem menores valores de importância que as variáveis relacionadas à demanda, também influenciam a aplicação de medidas MIT na TMA-SP, sobretudo as condições de vento, visibilidade e teto.

Como sugestão para trabalhos futuros, recomenda-se aplicar outros métodos de aprendizado de máquina supervisionado para o desenvolvimento do modelo preditivo, bem como testar outras variáveis de input, como a demanda programada de voos, buscando aperfeiçoar o desempenho preditivo. Além disso, sugere-se desenvolver uma abordagem de

cálculo do custo das medidas MIT, para comparação das medidas previstas pelo modelo com as medidas reais tomadas e análise dos potenciais ganhos em eficiência no gerenciamento do fluxo de tráfego aéreo.

Referências

- JAMES, G., WITTEN, D., HASTIE, T., TIBSHIRANI, R., *An Introduction to Statistical Learning with Applications in R*. 1. ed. Nova York: Springer Texts in Statistics, 2013.
- DE NEUFVILLE, R., ODoni, A. R., *Airport Systems Planning, Design, and Management*. 2. ed. Mc Graw Hill Education, 2013.
- BELOBABA, P., ODoni, A. R., BARNHART, C., *The Global Airline Industry*. 2. ed. Chichester: Wiley, 2016.
- BLOEM, M., HATTAWAY, D., BAMBOS, N., *Evaluation of Algorithms for a Miles-in-Trail Decision Support Tool*. 5th International Conference for Research in Air Transportation, 2012.
- LIU, Y., HANSEN, M., LOVELL, D., CHUANG, C., BALL, M., GULDING, J., *Causal Analysis of En Route Flight Inefficiency – the US Experience*. 12th USA/Europe Air Traffic Management Research and Development Seminar, 2017.
- MANGORTEY, E., PINON, O. J., PURANIK, T. G., MAVRIS, D. N., *Predicting The Occurrence of Weather And Volume Related Ground Delay Programs*. 2019 AIAA Aviation Forum and Exposition, 2019.
- MUKHERJEE, A., GRABBE, S., SRIDHAR, B., *Predicting Ground Delay Program At An Airport Based On Meteorological Conditions*. 14th AIAA Aviation Technology, Integration, and Operations Conference, 2014.
- WANG, Y., GRABBE, S., *Modeling Weather Impact on Airport Arrival Miles-in-Trail Restrictions*. SAE International, 2013.
- MURÇA, M. C. R., GUTERRES, M. X., OLIVEIRA, M., SZENCZUK, J. B. T., SOUZA, W. S. S., *Characterizing the Brazilian Airspace Structure and Air Traffic*

Performance via Trajectory Data Analytics. Journal of Air Transport Management, Volume 85, 2020.

ANAC, AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL, *Anuário do Transporte Aéreo*. Brasília: ANAC, 2019. Disponível em: <<https://www.anac.gov.br/assuntos/dados-e-estatisticas/mercado-de-transporte-aereo/anuario-do-transporte-aereo/dados-do-anuario-do-transporte-aereo>>. Acesso em: 16 nov. 2020.

UNITED STATES DEPARTMENT OF TRANSPORTATION, U.S. DOT, *Airline On-Time Statistics and Delay Causes*. 2020. Disponível em: <https://www.transtats.bts.gov/OT_Delay/OT_DelayCause1.asp> .Acessoem : 16nov.2020.

BOEHMKE, B., GREENWELL, B., *Hands-On Machine Learning with R*. 2020. Disponível em: <<https://bradleyboehmke.github.io/HOML/index.html>>. Acesso em: 16 nov. 2020.

SHMUELI, B., *Multi-Class Metrics Made Simple, Part II: the F1-score*. 2019. Disponível em: <<https://towardsdatascience.com/multi-class-metrics-made-simple-part-ii-the-f1-score-ebe8b2c2ca1>>. Acesso em: 24 nov. 2020.

FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO TC	2. DATA 26 de novembro de 2020	3. DOCUMENTO N° DCTA/ITA/TC-077/2020	4. N° DE PÁGINAS 43
5. TÍTULO E SUBTÍTULO: ANÁLISE E PREVISÃO DA APLICAÇÃO DE MEDIDAS DE GERENCIAMENTO DE FLUXO NO ESPAÇO AÉREO BRASILEIRO			
6. AUTORA(ES): Gabriela Loiola Vilar			
7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica – ITA			
8. PALAVRAS-CHAVE SUGERIDAS PELA AUTORA: <i>Miles-in-Trail</i> ; Aprendizado de Máquina; <i>Random Forest</i> ; SVM			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Aprendizagem (inteligência artificial); Tráfego aéreo; Técnicas de análise de predição; Meteorologia aeronáutica; Transporte.			
10. APRESENTAÇÃO: <input checked="" type="checkbox"/> Nacional <input type="checkbox"/> Internacional ITA, São José dos Campos. Curso de Graduação em Engenharia Civil-Aeronautica. Orientadora: Profa. Dra. Mayara Condé Rocha Murça. Coorientador: Prof. Dr. Marcelo Xavier Guterres. Publicada em 2020			
11. RESUMO: Para atender a demanda de transporte aéreo, um complexo sistema de gerenciamento de tráfego aéreo precisa ser operado diariamente, de forma a garantir que companhias aéreas e demais operadores de aeronaves possam executar seus voos de forma segura e ordenada. O volume e a complexidade das operações aéreas, bem como a vulnerabilidade desse sistema a perturbações causadas por fatores exógenos, como meteorologia, frequentemente resultam em desequilíbrios entre demanda e capacidade. Em consequência, medidas de gerenciamento de fluxo de tráfego aéreo (<i>Air Traffic Flow Management – ATFM</i>) são comumente tomadas para ajustar os fluxos de tráfego e mitigar impactos como atrasos e cancelamentos. Este trabalho de graduação tem por objetivo realizar uma análise histórica das medidas ATFM aplicadas no espaço aéreo brasileiro e desenvolver um modelo preditivo que possa apoiar a tomada de decisão dos gerentes de tráfego e prover aos usuários do espaço aéreo uma maior previsibilidade sobre o impacto de restrições operacionais em seus voos. Os resultados da análise de dados históricos revelam que há um uso predominante da medida <i>Miles-In-Trail</i> (MIT) para o gerenciamento do fluxo no espaço aéreo brasileiro e que a Área Terminal São Paulo (TMA-SP) é o volume de espaço aéreo mais afetado por essas medidas. Dois métodos de aprendizado de máquina supervisionado, Random Forests e Support Vector Machines, são então utilizados para o desenvolvimento de um modelo preditivo da ocorrência e da severidade de medidas MIT na TMA-SP. Os resultados mostram um desempenho preditivo superior para o modelo gerado pelo método <i>Random Forests</i> , que apresenta uma acurácia de 82%. Ao analisar a importância das variáveis utilizadas para a previsão, torna-se evidente a influência dos fatores relacionados à demanda de voos, como origem do fluxo e hora do dia, e às condições meteorológicas.			
12. GRAU DE SIGILO: <input checked="" type="checkbox"/> OSTENSIVO <input type="checkbox"/> RESERVADO <input type="checkbox"/> SECRETO			