

INSTITUTO TECNOLÓGICO DE AERONÁUTICA



Igor Galhano Gomes

**ESTUDO DA CAPACIDADE DO SISTEMA DE PISTAS
DE UM AEROPORTO POR MEIO DE INTELIGÊNCIA
ARTIFICIAL EXPLICÁVEL**

Trabalho de Graduação
2023

Curso de Engenharia Civil-Aeronáutica

Igor Galhano Gomes

**ESTUDO DA CAPACIDADE DO SISTEMA DE PISTAS
DE UM AEROPORTO POR MEIO DE INTELIGÊNCIA
ARTIFICIAL EXPLICÁVEL**

Orientador

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

Galhano Gomes, Igor
Estudo da capacidade do sistema de pistas de um aeroporto por meio de Inteligência Artificial Explicável / Igor Galhano Gomes.
São José dos Campos, 2023.
69f.

Trabalho de Graduação – Curso de Engenharia Civil-Aeronáutica– Instituto Tecnológico de Aeronáutica, 2023. Orientador: Prof. Dr. Marcelo Xavier Guterres.

I. Instituto Tecnológico de Aeronáutica. II. Título.

REFERÊNCIA BIBLIOGRÁFICA

GALHANO GOMES, Igor. **Estudo da capacidade do sistema de pistas de um aeroporto por meio de Inteligência Artificial Explicável**. 2023. 69f. Trabalho de Conclusão de Curso (Graduação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Igor Galhano Gomes

TÍTULO DO TRABALHO: Estudo da capacidade do sistema de pistas de um aeroporto por meio de Inteligência Artificial Explicável.

TIPO DO TRABALHO/ANO: Trabalho de Conclusão de Curso (Graduação) / 2023

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. O autor reserva outros direitos de publicação e nenhuma parte deste trabalho de graduação pode ser reproduzida sem a autorização do autor.



Igor Galhano Gomes
Rua H8B, 204
12.228-461 – São José dos Campos–SP

ESTUDO DA CAPACIDADE DO SISTEMA DE PISTAS DE UM AEROPORTO POR MEIO DE INTELIGÊNCIA ARTIFICIAL EXPLICÁVEL

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação



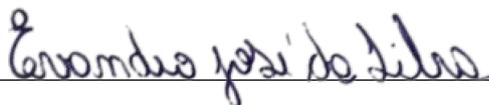
Igor Galhano Gomes

Autor



Marcelo Xavier Guterres (ITA)

Orientador



Prof. Dr. Evandro José da Silva

Coordenador do Curso de Engenharia Civil-Aeronáutica

São José dos Campos, 20 de novembro de 2023.

Dedico este trabalho aos meus pais Arnaldo (in memoriam) e Silvane, e à minha irmã Carol, pelo incentivo e pelo apoio ao longo de minha trajetória.

Agradecimentos

Primeiramente, gostaria de agradecer aos meus pais, que me incentivaram em todos os momentos a seguir meus sonhos.

Ao Prof. Marcelo Xavier Guterres, à Profa. Mayara Condé Rocha Murça e aos colegas do LABGETA, Wallace Sant'Anna, Carolina Ansélmo, João Basílio, João Vitor Turchetti e Guilherme Tolentino por toda a orientação e apoio no desenvolvimento do trabalho.

Agradeço aos colegas de turma que compartilharam a jornada no ITA, que me apoiaram nos momentos de insegurança. A Due Jie Wan, João Carlos Barros, Pedro Henrique Santos, João Pedro Spíndola, Vinícius Lima, Vitor Lyra, Ricardo Vilalba, Fábio Filho, Gustavo Vieira, Matheus Mota e tantos outros, obrigado!

"A única maneira de fazer um trabalho excelente é amar o que você faz."

— STEVE JOBS

Resumo

Embora métodos de machine learning tenham sido amplamente utilizados em estudos da indústria da aviação recentemente, houve progresso limitado em tornar os resultados desses modelos compreensíveis para os humanos. Dada a importância de previsões explicáveis para um suporte à decisão confiável no Gerenciamento de Tráfego Aéreo (ATM), este estudo explora o uso de Multilayer Perceptron e Random Forests, combinados com uma abordagem de Local Interpretable Model-agnostic Explanations (LIME), para desenvolver modelos preditivos capazes de gerar previsões interpretáveis da configuração ativa de pistas e da capacidade dinâmica do sistema de pistas de aeroportos. Uma abordagem de aprendizado supervisionado foi usada para construir os modelos a partir de dados históricos de demanda, meteorologia e operações em Aeroporto Internacional de São Paulo/Guarulhos, Aeroporto Internacional de Viracopos/Campinas e Aeroporto de São Paulo/Congonhas. Os modelos preditivos foram capazes de fornecer previsões da configuração da pista com uma precisão superior a 90,00% e previsões da capacidade de pousos/decolagens com erros abaixo de 1,589. Com LIME, de forma geral, explicações consistentes foram obtidas através dos modelos em cada previsão. Uma ferramenta preditiva interativa foi criada para fornecer as previsões da configuração da pista e da capacidade, bem como os principais fatores contribuintes para cada previsão, dentro de um horizonte de previsão de 24 horas. Esta pesquisa visa melhorar a tomada de decisão, integrando modelos preditivos e modelos explicativos em aplicações que fornecem informações úteis para ATM.

Abstract

Although machine learning methods have been widely used in aviation industry studies recently, there has been limited progress in making the results of these models understandable to humans. Given the importance of explainable predictions for trustworthy decision support in Air Traffic Management (ATM), this study explores the use of Multilayer Perceptron and Random Forests, combined with a Local Interpretable Model-agnostic Explanations (LIME) approach, to develop predictive models capable of generating interpretable forecasts of airport runway configuration and dynamic capacity. A supervised learning approach was used for building the models from historical demand, weather and traffic data at Sao Paulo/Guarulhos International Airport, Campinas/Viracopos International Airport and Sao Paulo/Congonhas Airport. The predictive models are able to deliver runway configuration forecasts with an accuracy higher than 90.00% and arrival/departure capacity forecasts with errors as low as 1.589. With LIME, overall consistent explanations are obtained through the models on each prediction. An interactive predictive tool is created to output the runway configuration and capacity forecasts as well as the main contributing factors for each forecast within a 24-hour forecasting horizon. This research aims to improve decision-making by integrating predictive models and explanatory models into applications that provide useful information for ATM.

Lista de Figuras

FIGURA 1.1 – Média móvel de 7 dias para movimentos diários de aeronaves dos últimos 4 anos. Fonte: CGNA (2023)	17
FIGURA 1.2 – Dados e projeções comparativas de movimentos mensais de aeronaves dos últimos 4 anos. Fonte: CGNA (2023)	18
FIGURA 2.1 – Funcionamento do algoritmo para gerar explicações de LIME. Fonte: Cid (2023)	26
FIGURA 4.1 – Fluxograma da metodologia.	30
FIGURA 5.1 – Frequência de uso das configurações principais de GRU. Fonte: Autor.	40
FIGURA 5.2 – Ocorrências de configurações de pista observadas para direção e velocidade do vento em GRU. Fonte: Autor.	41
FIGURA 5.3 – Frequência de uso das configurações principais de VCP. Fonte: Autor.	42
FIGURA 5.4 – Ocorrências de configurações de pista observadas para direção e velocidade do vento em VCP. Fonte: Autor.	43
FIGURA 5.5 – Frequência de uso das configurações principais de CGH. Fonte: Autor.	44
FIGURA 5.6 – Ocorrências de configurações de pista observadas para direção e velocidade do vento em CGH. Fonte: Autor.	45
FIGURA 5.7 – Curvas de desempenho de fluxo de pousos e decolagens para GRU. Fonte: Autor.	46
FIGURA 5.8 – Curvas de desempenho de fluxo de pousos e decolagens para VCP. Fonte: Autor.	46
FIGURA 5.9 – Curvas de desempenho de fluxo de pousos e decolagens para CGH. Fonte: Autor.	47
FIGURA 5.10 – Distribuição de taxas de pousos antes e depois do processo de filtragem para GRU. Fonte: Autor.	48

FIGURA 5.11 –Distribuição de taxas de decolagens antes e depois do processo de filtragem para GRU. Fonte: Autor.	48
FIGURA 5.12 –Distribuição de taxas de pousos antes e depois do processo de filtragem para VCP. Fonte: Autor.	49
FIGURA 5.13 –Distribuição de taxas de decolagens antes e depois do processo de filtragem para VCP. Fonte: Autor.	49
FIGURA 5.14 –Distribuição de taxas de pousos antes e depois do processo de filtragem para CGH. Fonte: Autor.	50
FIGURA 5.15 –Distribuição de taxas de decolagens antes e depois do processo de filtragem para CGH. Fonte: Autor.	50
FIGURA 5.16 –Importâncias das variáveis encontradas nos modelos de RF para configuração de pista em GRU. Fonte: Autor.	51
FIGURA 5.17 –Importâncias das variáveis encontradas nos modelos de RF para configuração de pista em VCP. Fonte: Autor.	52
FIGURA 5.18 –Importâncias das variáveis encontradas nos modelos de RF para configuração de pista em CGH. Fonte: Autor.	52
FIGURA 5.19 –Importâncias das variáveis encontradas nos modelos de RF para capacidade de pousos em GRU. Fonte: Autor.	53
FIGURA 5.20 –Importâncias das variáveis encontradas nos modelos de RF para capacidade de pousos em VCP. Fonte: Autor.	53
FIGURA 5.21 –Importâncias das variáveis encontradas nos modelos de RF para capacidade de pousos em CGH. Fonte: Autor.	54
FIGURA 5.22 –Importâncias das variáveis encontradas nos modelos de RF para capacidade de decolagens em GRU. Fonte: Autor.	54
FIGURA 5.23 –Importâncias das variáveis encontradas nos modelos de RF para capacidade de decolagens em VCP. Fonte: Autor.	55
FIGURA 5.24 –Importâncias das variáveis encontradas nos modelos de RF para capacidade de decolagens em CGH. Fonte: Autor.	55
FIGURA 5.25 –Interface interativa que exibe previsões explicadas de configuração e capacidade de pista para um horizonte de previsão de até 24 horas. Fonte: Autor.	57
FIGURA 5.26 –Explicações de LIME para previsões de 2023-06-27 06:00:00 para os modelos de previsão de capacidade de decolagens de MLP, na esquerda, e RF, na direita, em GRU. Fonte: Autor.	58

FIGURA 5.27 –Previsões de visibilidade e teto de TAF para 2023-06-27 06:00:00 em GRU. Fonte: Autor.	58
FIGURA 5.28 –Explicações de LIME de MLP e RF para capacidade de pousos em 2022-10-22 08:18:00, em GRU. Fonte: Autor.	60
FIGURA 5.29 –Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-10-22 08:18:00, em GRU. Fonte: Autor.	60
FIGURA 5.30 –Explicações de LIME de MLP e RF para capacidade de pousos em 2022-08-01 08:12:00, em GRU. Fonte: Autor.	61
FIGURA 5.31 –Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-08-01 08:12:00, em GRU. Fonte: Autor.	61
FIGURA 5.32 –Explicações de LIME de MLP e RF para capacidade de pousos em 2022-07-29 06:21:00, em VCP. Fonte: Autor.	62
FIGURA 5.33 –Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-07-29 06:21:00, em VCP. Fonte: Autor.	62
FIGURA 5.34 –Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-12-29 23:00:00, em VCP. Fonte: Autor.	63
FIGURA 5.35 –Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-09-07 10:11:00, em CGH. Fonte: Autor.	64

Lista de Tabelas

TABELA 4.1 – Variáveis utilizadas na modelagem	32
TABELA 5.1 – Arquiteturas utilizadas nos modelos de MLP.	51
TABELA 5.2 – Desempenho dos modelos preditivos em GRU.	56
TABELA 5.3 – Desempenho dos modelos preditivos em VCP.	56
TABELA 5.4 – Desempenho dos modelos preditivos em CGH.	56
TABELA 5.5 – Dados de operações e previsões dos modelos para 2022-10-22 08:18:00, em GRU.	59
TABELA 5.6 – Dados de operações e previsões dos modelos para 2022-08-01 08:12:00, em GRU.	60
TABELA 5.7 – Dados de operações e previsões dos modelos para 2022-07-29 06:21:00, em VCP.	62
TABELA 5.8 – Dados de operações e previsões dos modelos para 2022-12-29 23:00:00, em VCP.	63
TABELA 5.9 – Dados de operações e previsões dos modelos para 2022-09-07 10:11:00, em CGH.	64

Lista de Abreviaturas e Siglas

AAR	Airport Acceptance Rate
ANAC	Agência Nacional de Aviação Civil
ATCO	Controlador de Tráfego Aéreo
ATFM	Gerenciamento do Fluxo de Tráfego Aéreo
ATM	Gerenciamento de Tráfego Aéreo
CGH	Aeroporto de São Paulo/Congonhas
GRU	Aeroporto Internacional de São Paulo/Guarulhos
IA	Inteligência Artificial
LIFR	Low Instrument Flight Rules
LIME	Local Interpretable Model-agnostic Explanations
METAR	METEorological Aerodrome Reports
MLP	Multilayer Perceptron
MSE	Mean Squared Error
PPD	Pista de Pouso e Decolagem
RF	Random Forest
RMSE	Root Mean Squared Error
SIROS	Sistema de Registro de Operações
TAF	Terminal Aerodrome Forecasts
TWY	Taxiway
VCP	Aeroporto Internacional de Viracopos/Campinas
VFR	Visual Flight Rules
XAI	Inteligência Artificial Explicável

Sumário

1	INTRODUÇÃO	17
1.1	Problema de Pesquisa	19
1.2	Objetivo Geral	19
1.3	Objetivos Específicos	20
1.4	Justificativa	21
1.5	Organização do trabalho	21
2	REVISÃO TEÓRICA	22
2.1	Configuração de pista de aeroporto	22
2.2	Taxa de Aceitação de Aeroporto	23
2.3	Inteligência Artificial Explicável	23
2.3.1	Local Interpretable Model-agnostic Explanations	24
3	REVISÃO DE LITERATURA	27
3.1	Previsão de configuração de pista	27
3.2	Previsão de capacidade dinâmica	27
3.3	XAI e gerenciamento de tráfego aéreo	28
3.4	Conclusões	29
4	METODOLOGIA	30
4.1	Descrição das bases de dados	31
4.1.1	METAR	31
4.1.2	TAF	31
4.1.3	SIROS	31

4.1.4	FlightRadar24	32
4.2	Variáveis utilizadas na modelagem	32
4.3	Processamento dos dados de treino	32
4.3.1	Inicialização do banco de dados	33
4.3.2	Cálculo das variáveis em intervalos de 1 minuto	33
4.3.3	Filtragem dos dados	34
4.3.4	One-hot encoding	34
4.3.5	Normalização do tipo min-max	35
4.3.6	Separação entre dados de treino e teste	35
4.4	Processamento dos dados de previsão	35
4.5	Modelagem	35
4.5.1	Previsão de capacidade dinâmica	36
4.5.2	Modelos	36
4.5.3	Função de perda	37
4.5.4	Métrica de desempenho	38
4.6	Previsões em horizonte de 24 horas	38
4.7	Explicações locais dos modelos preditivos	39
4.8	Apresentação de resultados em dashboard	39
5	RESULTADOS E DISCUSSÕES	40
5.1	Análise exploratória	40
5.2	Desempenho dos modelos preditivos	51
5.3	Explicações das previsões	57
5.4	Estudos de instâncias específicas	59
5.4.1	2022-10-22 08:18:00 GRU	59
5.4.2	2022-08-01 08:12:00 GRU	59
5.4.3	2022-07-29 06:21:00 VCP	61
5.4.4	2022-12-29 23:00:00 VCP	63
5.4.5	2022-09-07 10:11:00 CGH	64
6	CONCLUSÕES	65

REFERÊNCIAS 67

1 Introdução

Nos últimos anos, a previsão da capacidade de operações aeroportuárias tem apresentado uma crescente importância devido ao aumento da movimentação de aeronaves. De acordo com o relatório comparativo de tráfego aéreo de abril de 2023 (CGNA, 2023), a movimentação total nos aeroportos está se aproximando dos níveis pré-pandêmicos registrados em 2019.

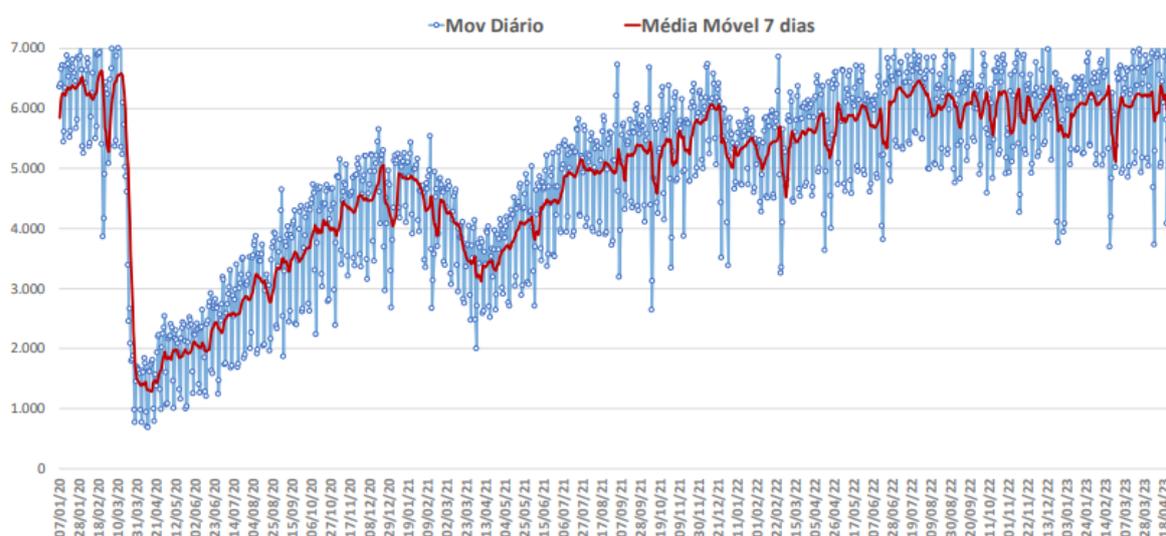


FIGURA 1.1 – Média móvel de 7 dias para movimentos diários de aeronaves dos últimos 4 anos.
Fonte: CGNA (2023)

As projeções indicam que a demanda prevista para o ano de 2023 superará a movimentação de 2019. Com o aumento da demanda de operações aéreas, a saturação do sistema de pistas dos aeroportos ocorre em intervalos de tempo maiores, o que ressalta a importância de buscar modelos mais precisos para a previsão da capacidade aeroportuária. Essa necessidade se manifesta tanto no contexto de planejamento de demanda quanto no gerenciamento do tráfego aéreo.

A capacidade aeroportuária refere-se ao número máximo de operações de pouso e decolagem que um aeroporto pode suportar em uma unidade de tempo, atendendo a todos os critérios de níveis de serviço estabelecidos. No planejamento de longo prazo, calcula-se uma capacidade teórica com base em condições específicas de configuração e

Ano	Tipo de Voo	Acumulado	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2019	Total	2.259.099	199.102	174.988	188.417	183.089	181.005	175.638	197.368	191.873	186.018	197.978	188.197	195.426
	Comercial	1.598.138	149.178	127.799	134.152	125.292	123.000	119.518	139.418	133.187	131.988	137.364	132.932	144.310
	Geral	499.013	41.067	36.417	40.984	42.366	41.834	42.202	42.816	43.718	39.771	45.043	42.313	40.482
	Militar	161.947	8.857	10.772	13.281	15.431	16.171	13.918	15.134	14.968	14.259	15.571	12.952	10.633
2022	Total	2.121.595	164.448	146.795	170.373	168.709	182.238	175.023	194.943	188.680	181.306	186.066	177.886	185.128
	Comercial	1.408.574	118.637	94.368	109.471	107.393	116.599	109.955	128.055	122.600	118.268	124.372	124.277	134.579
	Geral	538.639	38.087	41.537	46.151	45.863	47.668	46.934	48.691	48.322	46.350	45.075	41.819	42.142
	Militar	174.382	7.724	10.890	14.751	15.453	17.971	18.134	18.197	17.758	16.688	16.619	11.790	8.407
2023	Total	2.307.494	186.618	166.533	192.140	181.060	197.295	193.201	205.262	199.931	188.994	200.353	193.842	202.265
	Comercial	1.617.011	138.362	115.441	129.904	122.197	132.938	129.157	142.113	139.577	134.819	140.475	139.704	152.324
	Geral	518.598	38.593	39.195	46.352	43.973	46.737	46.195	45.969	44.135	39.833	43.748	42.232	41.635
	Militar	171.885	9.663	11.897	15.884	14.890	17.620	17.849	17.180	16.219	14.342	16.130	11.906	8.306
Variação 2022/2019	Total	-6,1%	-17,4%	-16,1%	-9,6%	-7,9%	0,7%	-0,4%	-1,2%	-1,7%	-2,5%	-6,0%	-5,5%	-5,3%
	Comercial	-11,9%	-20,5%	-26,2%	-18,4%	-14,3%	-5,2%	-8,0%	-8,2%	-7,9%	-10,4%	-9,5%	-6,5%	-6,7%
	Geral	7,9%	-7,3%	14,1%	12,6%	8,3%	13,9%	11,2%	13,7%	10,5%	16,5%	0,1%	-1,2%	4,1%
	Militar	7,7%	-12,8%	1,1%	11,1%	0,1%	11,1%	30,3%	20,2%	18,6%	17,0%	6,7%	-9,0%	-20,9%
Variação 2023/2019	Total	2,1%	-6,3%	-4,8%	2,0%	-1,1%	9,0%	10,0%	4,0%	4,2%	1,6%	1,2%	3,0%	3,5%
	Comercial	1,2%	-7,3%	-9,7%	-3,2%	-2,5%	8,1%	8,1%	1,9%	4,8%	2,1%	2,3%	5,1%	5,6%
	Geral	3,9%	-6,0%	7,6%	13,1%	3,8%	11,7%	9,5%	7,4%	1,0%	0,2%	-2,9%	-0,2%	2,8%
	Militar	6,1%	9,1%	10,4%	19,6%	-3,5%	9,0%	28,2%	13,5%	8,4%	0,6%	3,6%	-8,1%	-21,9%

FIGURA 1.2 – Dados e projeções comparativas de movimentos mensais de aeronaves dos últimos 4 anos. Fonte: CGNA (2023)

operação utilizando modelos analíticos e de simulação. Alguns fatores de performance utilizados nessa abordagem são o tempo médio de ocupação de pista e a separação da esteira de turbulência entre aeronaves. (DECEA, 2015)

No entanto, a capacidade do sistema de pistas de um aeroporto pode variar significativamente ao longo do dia devido a variações nas condições operacionais, como fatores meteorológicos. Desbalanços entre a demanda planejada e a capacidade dinâmica podem resultar em atrasos significativos de voos, pois voos que não puderam ser realizados no horário programado devido à restrição de capacidade serão colocados em uma fila de espera, juntamente com voos subsequentes. O Gerenciamento do Fluxo de Tráfego Aéreo (ATFM) é um serviço fundamental fornecido pelo sistema de Gerenciamento de Tráfego Aéreo (ATM) para mitigar os impactos de tais desequilíbrios. Isso é alcançado por meio de estratégias para ajustar os fluxos de tráfego a fim de adequar a demanda com a capacidade disponível em qualquer momento. Portanto, para fins de ATFM, é necessário prever a capacidade dinâmica do aeroporto em tempo real com base na evolução das condições operacionais. Esta estimativa de capacidade dinâmica é de interesse particular neste estudo.

Além disso, fornecer apenas previsões de capacidade dinâmica sem explicações não é suficiente no contexto do gerenciamento do tráfego aéreo, pois a segurança é uma prioridade. Os controladores de tráfego aéreo (ATCO) são responsáveis pelas decisões tomadas e, portanto, precisam entender as razões por trás dos resultados gerados pelos modelos de aprendizado de máquina. Isso lhes permite avaliar as condições que levaram a determinadas decisões e, possivelmente, validar essas decisões.

Nesse contexto, o campo de Inteligência Artificial Explicável (Explainable Artificial

Intelligence - XAI) surge como uma possível abordagem para o problema, que permite tornar os resultados dos modelos de *caixa preta* compreensíveis e explicáveis para os seres humanos. Os modelos de XAI são capazes de gerar explicações para os modelos de aprendizado de máquina, mantendo a performance alcançada em suas previsões, mas fornecendo uma compreensão dos resultados obtidos. Essa abordagem aumenta a confiança nas decisões fornecidas pelos modelos.

1.1 Problema de Pesquisa

Dada a importância da interpretabilidade dos resultados dos modelos discutida na seção anterior, essa pesquisa busca responder a seguinte pergunta:

“Como tornar previsões de um modelo de machine learning de previsão de capacidade dinâmica mais confiáveis para o gerenciamento de tráfego aéreo, tendo em vista que elas precisam ser explicáveis?”

1.2 Objetivo Geral

Esse trabalho tem como objetivo geral a validação de uma metodologia para a criação de modelos de aprendizado de máquina explicáveis para a previsão da configuração e da capacidade dinâmica do sistema de pistas de um aeroporto e apresentação dos resultados em uma interface.

1.3 Objetivos Específicos

Enumera-se os seguintes objetivos específicos para alcançar o resultado desejado:

- Coletar e tratar as bases de dados necessárias para o desenvolvimento dos modelos preditivos.
- Abordagem de aprendizado supervisionado para desenvolver modelos de machine learning de Multilayer Perceptron (MLP) e Random Forest (RF) para previsão de configuração e de capacidade do sistema de pistas do Aeroporto Internacional de São Paulo/Guarulhos (GRU), Aeroporto Internacional de Viracopos/Campinas (VCP) e Aeroporto de São Paulo/Congonhas (CGH).
- Criar rotinas para obter previsões de configuração e de capacidade em GRU, VCP e CGH para um horizonte de previsão de até 24 horas baseadas em Terminal Aerodrome Forecasts (TAF).
- Obter explicações de LIME (Local Interpretable Model-agnostic Explanations) a partir das previsões dos modelos.
- Comparar o desempenho dos modelos de previsão e a analisar a consistência das explicações obtidas entre modelos.
- Criação de um dashboard para apresentação prática de previsões e explicações dos modelos em horizonte de 24 horas.

1.4 Justificativa

No contexto do gerenciamento do tráfego aéreo, é essencial que as previsões de capacidade dinâmica sejam acompanhadas de explicações adequadas, já que os ATCOs têm a responsabilidade de tomar decisões fundamentadas, e isso requer uma compreensão das razões por trás dos resultados gerados pelos modelos de aprendizado de máquina. Essa compreensão permite avaliar as circunstâncias que levaram a essas decisões específicas, o que permite que os ATCOs validem essas decisões.

A validação de uma metodologia para obter modelos de previsão de capacidade explicáveis e com bom desempenho abre caminho para a integração desses modelos em aplicações que oferecem uma ampla variedade de informações úteis para o suporte à decisão em gerenciamento do tráfego aéreo. Essa integração pode levar a uma melhoria na tomada de decisões, promovendo um gerenciamento mais eficaz do fluxo de tráfego aéreo.

1.5 Organização do trabalho

A presente monografia está organizada em 6 capítulos da seguinte forma:

1. *Introdução*, onde são explicados o problema de pesquisa e a sua relevância.
2. *Revisão Teórica*, onde é feita uma revisão teórica de conceitos de engenharia de aeroportos e de XAI necessários para o entendimento do trabalho.
3. *Revisão de Literatura*, onde é feita a revisão de outros trabalhos relacionados e é discutida a relevância do presente trabalho nesse contexto.
4. *Metodologia*, onde são discutidos os procedimentos realizados para se alcançar os resultados desejados.
5. *Resultados e Discussões*, onde são apresentados e discutidos os resultados obtidos ao seguir a metodologia definida.
6. *Conclusões*, onde são feitas considerações finais e discussões sobre a possibilidade de melhoria da pesquisa.

2 Revisão Teórica

Nesse capítulo, serão discutidos conceitos específicos da área de engenharia de aeroportos e de inteligência artificial explicável necessários para o entendimento do trabalho desenvolvido.

2.1 Configuração de pista de aeroporto

Nesse estudo, configuração de pista se refere ao conjunto de pistas e respectivas cabeceiras ativas para operações de pousos e decolagens de um aeroporto em um determinado instante, que é definida pelos ATCO.

A numeração de uma cabeceira de pista é o inteiro mais próximo à sua orientação em relação ao norte magnético dividido por 10. Caso hajam 2 pistas com mesma orientação, elas são diferenciadas acrescentando L (esquerda) ou R (direita) ao final do nome.

A notação da configuração de pista de um aeroporto em um dado instante pode ser dada por $P_1, P_2, \dots, P_{N_P} | D_1, D_2, \dots, D_{N_D}$, onde P_k é a cabeceira utilizada da k -ésima pista de pouso e N_P é o número de cabeceiras de pistas de pouso em uso. Analogamente para as pistas de decolagem, tem-se que D_k é a cabeceira utilizada da k -ésima pista de decolagem e N_D é o número de cabeceiras de pistas de decolagem em uso. Como exemplo, a configuração $10R|10L$ representa a utilização da cabeceira 10R para pousos e da cabeceira 10L para decolagens.

O Aeroporto Internacional de Guarulhos (SBGR) admite duas configurações principais: $10R|10L$ e $28L|28R$, que correspondem às duas possíveis orientações das duas Pistas de Pouso e Decolagem (PPDs) existentes. Por conta disso, a direção do vento é um dos fatores mais relevantes para a determinação de configuração de pista nesse cenário, de forma a evitar ventos de cauda superiores ao limite admitido.

No entanto, a configuração de pista também depende de outros fatores além da direção e velocidade do vento, como outras variáveis meteorológicas, demanda de voos, abatimento de ruídos e coordenação com outros aeroportos. (AVERY; BALAKRISHNAN, 2015)

A configuração de pista ativa está correlacionada com a capacidade dinâmica do aero-

porto. Por conta disso, a previsão correta da configuração ajuda a reduzir a incerteza da previsão de capacidade.

2.2 Taxa de Aceitação de Aeroporto

Segundo a Organização da Aviação Civil Internacional (ICAO), AAR (Airport Acceptance Rate - Taxa de Aceitação de Aeroporto) é um parâmetro dinâmico que especifica o número de aeronaves pousando que um aeroporto consegue aceitar em condições específicas durante um período consecutivo de 60 minutos (FAA, 2023), que remete ao conceito de capacidade dinâmica discutido na seção 1, mas somente para pousos.

Ainda segundo a ICAO, a definição de AAR é dividida entre potencial e real. AAR potencial se refere a uma taxa teórica obtida a partir da seguinte fórmula:

$$AAR = \frac{V}{s}, \quad (2.1)$$

onde V é a velocidade média de solo da aeronave, e s é o intervalo espacial entre 2 pousos. AAR potencial não leva em conta diversos fatores meteorológicos e operacionais que levam à sua redução.

Já AAR real leva em conta fatores de ajuste. Esses fatores incluem mix de aeronaves, condições das PPDs e TWYs, manutenções e limitações operacionais, além de outros fatores que forem julgados relevantes. A previsão de AAR real afeta as decisões de gerenciamento de tráfego, dado que superestimar leva a possíveis atrasos, e subestimar leva ao não aproveitamento ótimo dos recursos disponíveis.

Nesse trabalho, a capacidade dinâmica para pousos pode ser entendida como o equivalente de AAR real definida pela ICAO, com uma amostragem de dados em intervalos de 15 minutos. A capacidade dinâmica de decolagens também será explorada.

2.3 Inteligência Artificial Explicável

Como já explicado na seção 1, XAI é um campo de pesquisa de IA dedicado a gerar modelos explicáveis, e que permite gerar explicações para modelos que originalmente são modelos de “caixa preta”.

Explicar um modelo significa apresentar textos ou representações gráficas que permitem a interpretação qualitativa da relação entre a previsão do modelo e as variáveis usadas para gerar a previsão. (RIBEIRO *et al.*, 2016)

Modelos de XAI podem ser classificados em dois tipos quanto à aplicabilidade do

modelo em relação ao modelo a ser explicado: agnóstico ao modelo, que é aplicável a todos os modelos; e específico ao modelo, que é aplicável somente para um grupo específico de modelos.

Já quanto ao escopo das explicações, eles também podem ser classificados em dois tipos: explicações globais, que explicam as previsões do modelo como um todo; e explicações locais, que explicam individualmente cada previsão.

Nesse estudo, será explorado LIME para gerar explicações de modelos clássicos desenvolvidos de previsão de capacidade dinâmica e para posteriormente gerar uma interface com grande diversidade de informações úteis para ATFM.

2.3.1 Local Interpretable Model-agnostic Explanations

LIME (Local Interpretable Model-agnostic Explanations) é um grupo de modelos interpretáveis agnósticos de explicações locais. Ele se baseia em treinar modelos substitutos mais simples, como modelos lineares, para gerar explicações de uma previsão.

Explicar um modelo significa fornecer representações textuais ou gráficas que permitam a interpretação qualitativa da relação entre a previsão do modelo e as variáveis usadas para gerar essa previsão (RIBEIRO *et al.*, 2016). Especificamente para LIME, as explicações envolvem quantificar a contribuição das variáveis mais relevantes em uma determinada previsão, o que é determinado pelos pesos obtidos para cada variável no modelo substituto.

Seja f o modelo treinado a ser explicado e g o modelo substituto usado para gerar explicações pertencente a uma família G de modelos. Seja também x um conjunto de dados e π_x a vizinhança de x . O algoritmo de LIME otimiza a Equação 2.2 para determinar os parâmetros de g , e assim determinar a explicação $\xi(x)$:

$$\xi(x) = \underset{g \in G}{\operatorname{argmin}} (L(f, g, \pi_x) + \Omega(g)) , \quad (2.2)$$

onde L é a função de perda que penaliza o quanto que as previsões do modelo f diferem da explicação g na vizinhança π_x , e Ω é uma função que penaliza a complexidade da explicação g (RIBEIRO *et al.*, 2016).

Nesse trabalho, foi utilizada a regressão de Ridge com pesos obtidos por distância euclidiana para gerar as explicações. Dessa forma, g será um modelo de regressão linear com Ω sendo a penalização de uma regularização L2, dada por:

$$\Omega(g) = \alpha \sum_{i=1}^n w_i^2 , \quad (2.3)$$

onde n é o número de variáveis utilizadas para gerar as explicações, w_i são os pesos de

cada variável no modelo de regressão linear e α é um hiperparâmetro.

A figura 2.1 mostra um esquema do passo a passo para se obter as explicações de lime de uma previsão, mas em um contexto simplificado utilizando 2 variáveis (CID, 2023). Os passos consistem em:

1. Escolha da previsão a ser explicada.
2. Gerar perturbações da previsão.
3. Usar o modelo a ser explicado para gerar as previsões das perturbações.
4. Atribuir pesos a cada uma das perturbações com base na distância em relação à previsão original.
5. Aplicar a Equação 2.2 para obter o modelo linear que otimiza a função de custo.

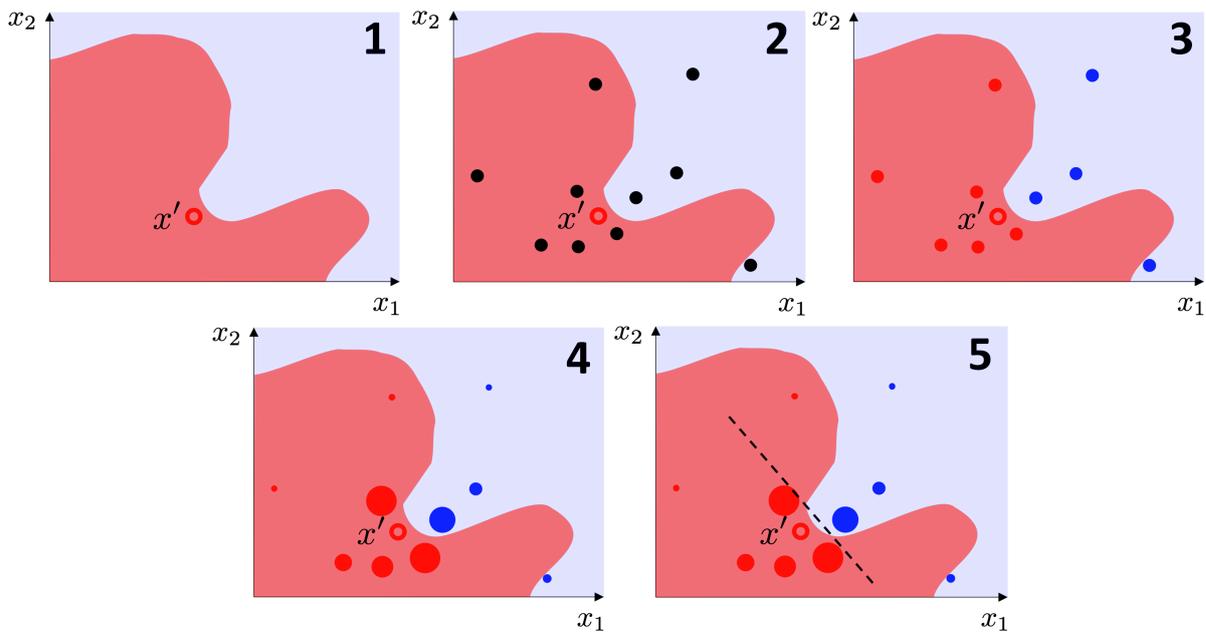


FIGURA 2.1 – Funcionamento do algoritmo para gerar explicações de LIME.

Fonte: Cid (2023)

3 Revisão de Literatura

Nesse capítulo, são apresentados outros estudos nos campos de previsão de configuração de pista, previsão de capacidade dinâmica e XAI aplicado a ATM. Em seguida, será descrito como esse trabalho se situa em relação a outros já desenvolvidos nesses temas.

3.1 Previsão de configuração de pista

Avery e Balakrishnan (2015) treinaram modelos de escolha discreta para prever configuração de pista no Aeroporto de LaGuardia (LGA) e no Aeroporto Internacional de São Francisco (SFO) em horizonte de 15 minutos. Os modelos eram utilizados de forma recursiva, de forma a obter a configuração a partir da previsão anterior, assim obtendo também horizontes de 3 horas e 6 horas. O estudo considerou também a influência de procedimentos de abatimento de ruídos, da coordenação entre aeroportos vizinhos e da coordenação necessária para mudar entre cada par de configurações.

Rebollo *et al.* (2021) desenvolveu modelos de XGBoost e Random Forest para prever configuração de pista nos 6 maiores aeroportos dos Estados Unidos em horizontes de até 6 horas. Os modelos também foram utilizados de forma recursiva. O estudo adotou um baseline que consistia em manter a mesma configuração ao longo de todo o horizonte de previsão e, em geral, alcançou um desempenho próximo em previsões imediatas e superior em previsões de horizontes maiores.

3.2 Previsão de capacidade dinâmica

Choi e Kim (2021) testam diferentes modelos de redes neurais artificiais rasas para prever capacidade aeroportuária para o Aeroporto Internacional Hartsfield-Jackson Atlanta (ATL), incluindo multilayer perceptron (MLP), recurrent neural networks (RNN) e long-short term memory (LSTM). Posteriormente, provou a eficácia da transferência dos modelos treinados para a previsão de capacidade do Aeroporto Internacional de Boston Logan (BOS), com a qual foi possível obter resultados satisfatórios após ajustar o modelo com

os dados novos.

Jiao *et al.* (2023) utilizou modelo de deep learning baseado em mecanismo de atenção, a partir da junção de um modelo de MLP com LSTM, para prever AAR no Aeroporto Internacional de Hong Kong no instante atual. Os modelos utilizaram dados de AAR e de meteorologia de até 3 horas anteriores para prever a atual. Obteve desempenhos superiores a modelos tradicionais, como Random Forest e Support Vector Machine, e superiores ao método tradicional de AAR potencial da ICAO.

Murça e Hansman (2018) desenvolveram um framework baseado em dados para previsão de AAR, utilizando modelos probabilísticos de regressão por processos gaussianos a partir da clusterização de dados históricos de trajetória, e para suporte de tomadas de decisões relacionadas ao gerenciamento do tráfego aéreo, com modelos de alocação de capacidade e de atrasos em solo. Os modelos desenvolvidos levaram em conta a interdependência de aspectos operacionais em sistemas multi aeroportos, havendo um grande aumento de desempenho nas previsões em relação a trabalhos anteriormente desenvolvidos.

Wang e Zhang (2021) utilizaram dados de previsão de tempo gradeados para prever tanto configuração de pistas quanto AAR para sistemas multi aeroportos. Para isso, foram utilizados modelos de redes neurais convolucionais, que processam os dados de previsão de toda a região do sistema multi aeroportos ao invés de estações isoladas. Os modelos captam aspectos de interdependência entre os aeroportos e alcançaram desempenho maior que os trabalhos anteriores.

3.3 XAI e gerenciamento de tráfego aéreo

A pesquisa desenvolvida por Degas *et al.* (2022) realizou uma revisão sistemática da literatura de XAI aplicada no contexto de ATM. O estudo diferencia XAI descritivo, preditivo e prescritivo, concluindo que a maior parte dos estudos atualmente se restringem ao XAI descritivo, se limitando a somente explicar as previsões do modelo. O estudo também conclui que sistemas de AI aplicados a ATM necessitam de mais pesquisas para que sejam aceitos por usuários e pelas autoridades.

Já Woo *et al.* (2022) treinaram modelos de XGBoost para previsão de saída de pista utilizada durante o pouso de uma aeronave a partir de dados de trajetória e de condições meteorológicas. Em seguida, foi criada uma interface gráfica interativa, na qual modelos de LIME são gerados a partir das previsões dos modelos treinados, gerando explicações para os outputs fornecidos pelos modelos. Dessa forma, a interface providencia informações valiosas para o ATCO para o gerenciamento do uso das pistas e planejamento de pousos e decolagens.

3.4 Conclusões

Os campos de previsão de capacidade dinâmica e de XAI aplicado a ATM ainda possuem bastante potencial de evolução a ser explorado. Explorar mais as técnicas de XAI existentes, bem como criar novas, pode levar à criação de diversas aplicações úteis para ATM.

A contribuição da presente monografia consiste na utilização de um framework de XAI para desenvolver modelos preditivos explicáveis que geram previsões localmente interpretáveis de capacidade e de configuração de pista. Essa abordagem aumenta a confiança em ferramentas automatizadas de suporte à decisão que utilizam modelos que usualmente não seriam localmente interpretáveis, ou seja, não se teriam informações a respeito de como as variáveis influenciaram os resultados em uma instância específica de previsão. Para obter os modelos preditivos, foi feita uma abordagem de aprendizado supervisionado a partir de dados históricos de demanda de voos, meteorologia e de operações ocorridas em Aeroporto Internacional de São Paulo/Guarulhos, Aeroporto Internacional de Viracopos/Campinas e Aeroporto de São Paulo/Congonhas. Finalmente, foi desenvolvido um protótipo de interface interativa que exhibe previsões de capacidade e configuração de pista, bem como principais fatores contribuintes para as previsões, em um horizonte de previsão de até 24 horas.

4 Metodologia

Nesse capítulo, será discutida a metodologia utilizada no desenvolvimento do trabalho, bem como conceitos necessários que não foram discutidos nos capítulos anteriores. O fluxograma da figura 4.1 apresenta uma visão geral esquemática da metodologia, que está detalhada nas próximas seções.

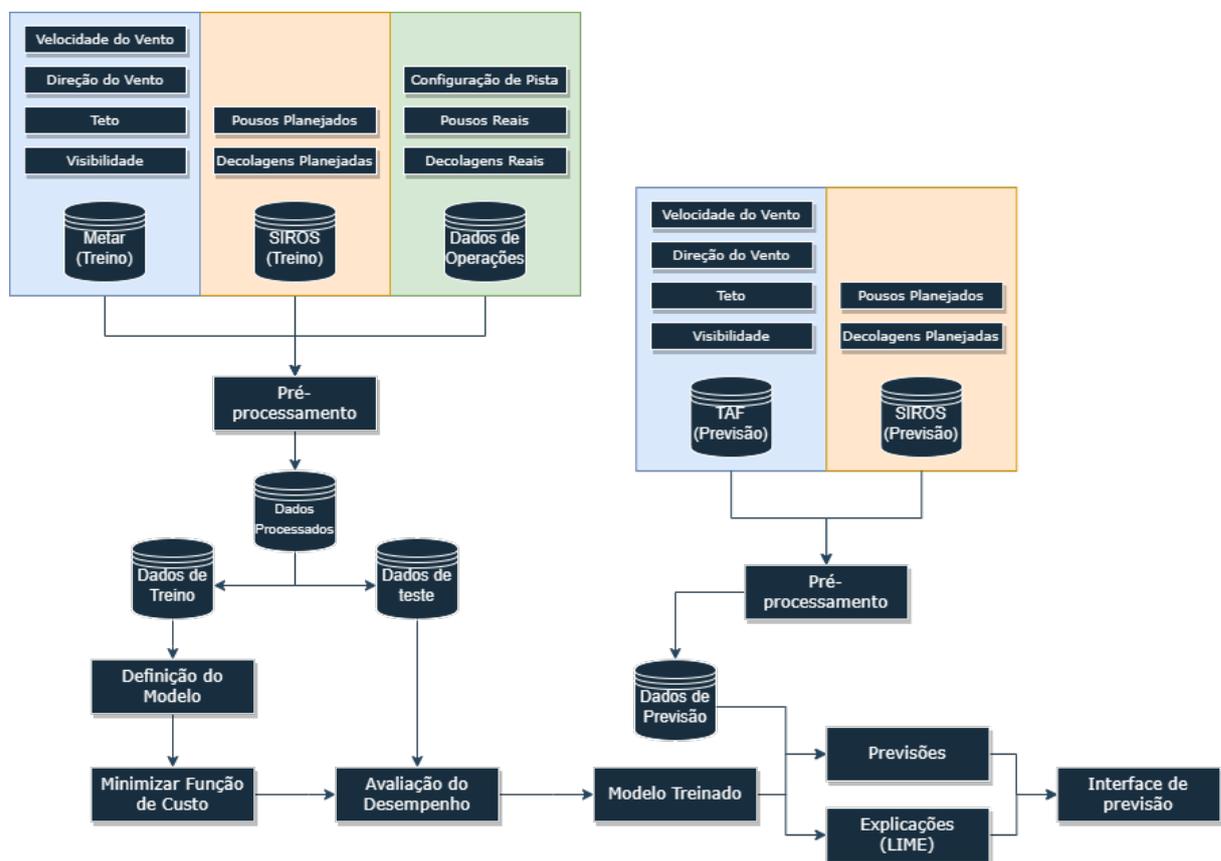


FIGURA 4.1 – Fluxograma da metodologia.

4.1 Descrição das bases de dados

Para o desenvolvimento desse trabalho, são utilizados dados de METAR (METeoro-logical Aerodrome Reports - Relatórios Meteorológicos do Aeródromo) e TAF (Terminal Aerodrome Forecasts - Previsão Terminal de Aeródromo) para obtenção de dados meteorológicos, SIROS (Sistema de Registro de Operações) para dados de demanda planejada de vôos e dados da Torre de Controle de Tráfego Aéreo e FlightRadar24 para dados reais de operações realizadas e suas trajetórias. As bases estão descritas nas próximas subseções.

4.1.1 METAR

Meteorological Aerodrome Reports (METAR) consiste de informes codificados que são emitidos de hora em hora e que dão informações meteorológicas observadas de um aeródromo específico, obtidas através de estações meteorológicas.

Quando ocorrem mudanças meteorológicas bruscas relativas à operacionalidade do aeródromo, um informe especial pode ser feito antes do próximo informe previsto. Por conta disso, o último informe emitido é, em princípio, uma boa aproximação para o estado atual do aeródromo em questão.

Os dados de METAR podem ser obtidos da Rede de Meteorologia do Comando da Aeronáutica (REDEMET, 2023), que providencia dados históricos de METAR a partir de sua API.

4.1.2 TAF

Terminal Aerodrome Forecasts (TAF) também consiste em informes codificados, mas que são emitidos de 6 em 6 horas e que dão previsões em horizontes de até 30 horas de informações meteorológicas de um aeródromo específico, feitas por um centro meteorológico de aeródromo.

Assim como METAR, informes especiais podem ser emitidos a qualquer momento do dia quando ocorrerem mudanças bruscas de condições meteorológicas esperadas.

Os dados históricos de TAF também podem ser obtidos a partir da API da REDEMET (2023).

4.1.3 SIROS

Sistema de Registro de Operações (SIROS) é uma base de dados fornecida pela Agência Nacional de Aviação Civil (ANAC, 2023) composta por informações de voos comerciais

TABELA 4.1 – Variáveis utilizadas na modelagem

Grupo	Nome da variável	Descrição da variável	Tipo(unidade)
Temporal	local_time	Horário do dia	categórica(horas)
	day_of_the_week	Dia da semana	categórica(dia)
Operações reais	configuration	Configuração de pista	categórica(Pouso Decolagem)
	actual_arrivals	Pousos realizados	numérica(voos/15min)
	actual_departures	Decolagens realizadas	numérica(voos/15min)
SIROS	scheduled_arrivals	Pousos planejados	numérica(voos/15min)
	scheduled_departures	Decolagens planejadas	numérica(voos/15min)
METAR/TAF	wind_speed	Velocidade do vento	numérica(kt)
	wind_direction	Direção do vento	numérica(º)
	visibility	Visibilidade	numérica(NM)
	ceiling	Altura das nuvens	numérica(ft)

programados. A base histórica pode ser obtida, de forma a utilizar esses dados tanto para o treino dos modelos quanto para alimentar os modelos para previsões futuras.

4.1.4 FlightRadar24

FlightRadar24 é uma plataforma global de rastreamento de voos que utiliza a tecnologia Automatic Dependent Surveillance–Broadcast (ADS-B) para obter posições das aeronaves. Com a base histórica das posições, são definidas as trajetórias das aeronaves. Essa base de dados pode ser utilizada, portanto, para obter a quantidade de aeronaves chegando na área terminal de aeroporto.

4.2 Variáveis utilizadas na modelagem

A descrição das variáveis utilizadas na modelagem foram sintetizadas na tabela 4.1

4.3 Processamento dos dados de treino

Foram utilizadas as bases de dados de METAR, SIROS e de dados históricos de movimentações reais para obter os dados de treino. O tratamento desses dados será especificado nessa seção.

4.3.1 Inicialização do banco de dados

Após obtidas as bases de dados não tratadas, é inicializada uma base de dados nova que possui a variável *time* do tipo *datetime* em intervalos de 1 minuto, de forma que a primeira linha e a última linha coincidam com o período escolhido para treino.

4.3.2 Cálculo das variáveis em intervalos de 1 minuto

Para cada intervalo de 1 minuto obtido são calculadas as variáveis a serem utilizadas nos modelos preditivos de forma que o início do intervalo corresponde à variável *time* armazenada em cada linha do banco de dados inicializado.

4.3.2.1 Variáveis de tempo

A partir da variável *time*, foram obtidas as variáveis *day_of_the_week* e *local_time*. A variável *local_time* armazena um valor decimal em horas, enquanto que a outra armazena um valor inteiro.

4.3.2.2 Variáveis de taxa de voos

Para as bases SIROS e Sistema de Gerenciamento da Torre de Controle de Tráfego Aéreo, foi feito o processamento do número de ocorrências de voos em intervalos de tempo de 15 minutos, com tempo inicial definido pela amostragem de 1 minuto da base inicializada, e tempo final 15 minutos após o tempo da linha, assim definindo taxas de 15 minutos de operações. Esse procedimento é feito separadamente para pousos e decolagens. Quando não encontradas ocorrências, significa que não ocorreu operações daquele tipo para o intervalo de tempo dado.

Desse procedimento, obteve-se as variáveis *scheduled_arrivals*, *scheduled_departures*, *actual_arrivals* e *actual_departures*. Os resultados foram então unidos ao banco de dados de treino de forma a filtrar para o período selecionado para treino.

4.3.2.3 Variável de configuração de pista

Para cada linha da base de dados, foi identificada a pista mais utilizada para pousos e a mais utilizada para decolagens. Então, verifica-se se a configuração de pista decorrente da concatenação das duas é uma das configurações estudadas. Caso contrário, a configuração é preenchida com a última configuração válida. Assim, foi obtida a variável *configuration*.

4.3.2.4 Variáveis meteorológicas

Para as variáveis meteorológicas de METAR, inicialmente criou-se um dataframe auxiliar a partir da união dos dataframes de METAR com o dataframe principal.

Em seguida, foram preenchidos os dados faltantes com os últimos dados preenchidos de intervalos anteriores, de forma a aproveitar os dados que advém de informes especiais fora do horário previsto.

Feito isso, os resultados foram filtrados novamente para os intervalos do dataframe principal e armazenados em colunas dele, obtendo-se as variáveis *wind_speed*, *wind_direction*, *visibility* e *ceiling*.

4.3.3 Filtragem dos dados

O desenvolvimento do modelo de previsão da capacidade do aeroporto com aprendizado supervisionado requer conhecimento sobre a taxa real de chegadas/partidas do aeroporto. Para isso, foram utilizados dados de movimentação do tráfego aéreo e aplicado um método empírico para estimar a capacidade a partir do desempenho observado no processamento de operações do aeroporto. O propósito deste método era identificar os períodos nos quais a demanda era suficientemente alta e o aeroporto operava sob pressão, de modo que as taxas de pousos e decolagens observadas refletissem a capacidade do aeroporto. Caso contrário, a capacidade poderia ser subestimada devido a períodos de voos não saturados. Primeiramente, o número de aeronaves simultaneamente em trânsito do gate para a Pista de Pouso e Decolagem (PPD) no início de cada intervalo e a taxa de decolagens para este intervalo foram utilizados para estimar uma curva de saturação de decolagens para o aeroporto. Esta curva permite estimar o número de aeronaves partindo em solo que leva à saturação do sistema de pistas. Após determinar essa quantidade, os dados foram filtrados para períodos em que ocorre saturação, pois o número de decolagens nesses períodos torna-se uma boa representação da capacidade de decolagens do aeroporto naquele momento. De maneira similar, o número de aeronaves chegando dentro de um raio de 40 NM do centro do aeroporto foi determinado para cada intervalo de tempo, e uma curva de saturação para pousos foi estimada. Posteriormente, uma nova base de dados foi gerada, contendo os intervalos de tempo nos quais ocorre a saturação de pousos.

4.3.4 One-hot encoding

Foi feita uma codificação do tipo *one-hot* nas variáveis do tipo categóricas de configuração de pista. Nesse tipo de codificação, para cada possibilidade de valor assumido pela variável categórica, é criada uma variável *dummy* que assume o valor 1 quando a variável

possui o valor da possibilidade, e 0 quando não possui.

4.3.5 Normalização do tipo min-max

As variáveis foram então normalizadas com o método min-max para o intervalo $[0,1]$. Essa normalização é feita através da seguinte fórmula:

$$Z = \frac{x - x_{min}}{x_{max} - x_{min}}, \quad (4.1)$$

onde x_{max} e x_{min} correspondem respectivamente aos máximos e mínimos valores da variável contidos nos dados de treino.

Os vetores de máximos e mínimos das variáveis são armazenados para posteriormente serem usados na previsão final dos modelos.

4.3.6 Separação entre dados de treino e teste

Os dados foram então divididos entre treino e teste, adotando-se 75% para treino e 25% para teste. O desempenho foi calculado com dados de distribuição estatística que inclui o uso de METAR ao invés de TAF. O desempenho real dos modelos em previsões pode ser obtido ao separar dados de teste que utilizam dados de TAF, já que essa é a base utilizada para obter previsões futuras.

4.4 Processamento dos dados de previsão

Para os dados de previsão, são utilizados dados de METAR e TAF das próximas 24 horas, que são atualizados de hora em hora. Foi feito um pré-processamento análogo aos dados de treino para obter os dados tratados de TAF em um horizonte de 24 horas, que são então utilizadas para alimentar os modelos.

4.5 Modelagem

Nessa seção, serão discutidos os procedimentos utilizados para criar, treinar e escolher os modelos de previsão desenvolvidos.

4.5.1 Previsão de capacidade dinâmica

Foram desenvolvidos modelos de Multilayer Perceptron (MLP) e Random Forest (RF) para previsão de capacidade dinâmica de pousos e de decolagens utilizando as variáveis disponíveis na tabela 4.1. A capacidade dinâmica de pousos para um intervalo de 15 minutos é representada pela variável *actual_arrivals*, enquanto que a de pousos é representada pela variável *actual_departures*. Todas as outras variáveis da tabela são utilizadas para prever essas duas variáveis.

4.5.2 Modelos

Nessa seção, serão explicados os tipos de modelos desenvolvidos para a previsão de configuração de pista e de capacidade dinâmica.

4.5.2.1 Random Forest

Random Forest (RF) é um tipo de modelo baseado em árvores de decisão que utiliza *Ensemble* com *Bagging*.

Tree Ensemble é um grupo de modelos que usam múltiplas árvores de decisão para gerar a predição. A desvantagem de utilizar uma única árvore de decisão é que o modelo se torna muito sensível a variações pequenas na base de dados. Para contornar esse problema, algoritmos de *Ensemble* constroem múltiplas árvores a partir de inputs diferentes, e geram o output final a partir do output de maior frequência para modelos de classificação, e média dos outputs para modelos de regressão.

Um tipo de amostragem da base de dados para gerar árvores diferentes é o método *Bagging*, que é uma amostragem com reposição dos dados. Para gerar essa amostra, cada dado é selecionado aleatoriamente na base original, sem removê-lo das possibilidades ao selecionar o próximo dado. Isso significa que o um dado da base original pode aparecer na amostra mais de uma vez, com uma dada probabilidade.

A particularidade de Random Forest é que, além de utilizar *Ensemble* com *Bagging*, sorteia aleatoriamente k variáveis para gerar a decisão de um nó, onde k é um hiperparâmetro a ser otimizado, ao invés de sempre utilizar todas as variáveis para gerar a decisão. Essa alteração faz com que ocorra mais variabilidade durante o processo de gerar árvores, corrigindo o problema das árvores geradas serem muito parecidas com somente *Bagging*, e assim diminuindo *overfitting*.

4.5.2.2 Multilayer Perceptron

Multilayer Perceptron (MLP) é um tipo de rede neural artificial que possui uma ou mais camadas ocultas. Consiste em múltiplos nós interconectados em camadas, onde cada nó é conectado a todos os nós da camada anterior. Cada nó faz a combinação linear de todos os outputs da camada anterior com parâmetros de pesos e bias dele e, em seguida, é aplicada uma função de ativação. Com a exceção da última camada da rede, é importante adotar uma função de ativação não linear, pois isso garante o caráter não linear do modelo, assim permitindo que o modelo consiga se ajustar a funções extremamente complexas com o aumento do número de camadas. Para uma camada l , o output de seus neurônios é dado por essas duas equações:

$$z^{[l]} = W^{[l]} \cdot a^{[l-1]} + b^{[l]} \quad (4.2)$$

$$a^{[l]} = g^{[l]}(z^{[l]}), \quad (4.3)$$

onde $a^{[l]}$ é o vetor de output dos neurônios da camada l , $g^{[l]}$ é a função de ativação da camada l , $W^{[l]}$ é a matriz de pesos da camada l e $b^{[l]}$ é o vetor de bias dos neurônios da camada l .

4.5.3 Função de perda

Para os modelos de MLP de classificação desenvolvidos, adotou-se como função de perda entropia cruzada binária, que é dada por:

$$L = -\frac{1}{n} \sum_{i=1}^n (y_i \cdot \log(p(y_i)) + (1 - y_i) \cdot \log(1 - p(y_i))), \quad (4.4)$$

onde n é o número de exemplos na amostra disponível, y_i é o valor real do rótulo do exemplo, podendo ser 0 ou 1, e $p(y_i)$ é a probabilidade do rótulo ser 1, obtida pelo modelo.

Já para os modelos de MLP de regressão desenvolvidos, adotou-se como função de perda MSE (Mean Squared Error - Erro Quadrático Médio), que é dada por:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_{i_{norm}} - y_{i_{norm}})^2, \quad (4.5)$$

onde n é o número de exemplos na amostra disponível, $y_{i_{norm}}$ é o valor real normalizado da variável a se prever em um exemplo da amostra e $\hat{y}_{i_{norm}}$ é o valor normalizado estimado pelo modelo.

Na função de custo final, a depender do modelo desenvolvido, poderão ser incluídos termos adicionais referentes à regularização do modelo, assim penalizando a complexidade dele. Já em modelos sem regularização, a função de custo será equivalente à função de perda definida. Dessa forma, o treinamento dos modelos busca minimizar essa função de custo.

4.5.4 Métrica de desempenho

Como métrica de desempenho para os modelos de previsão de configuração de pista, por se tratarem de modelos de classificação, adotou-se acurácia, dada por:

$$Acurácia = \frac{N_{corretas}}{N_{total}}, \quad (4.6)$$

onde $N_{corretas}$ é o número de previsões corretas e N_{total} é o número total de exemplos.

Já para os modelos de previsão de capacidade de pousos e decolagens, por se tratarem de modelos de regressão, adotou-se como métrica de desempenho RMSE (Root Mean Squared Error - Raiz do Erro Quadrático Médio), de forma a se ter a unidade da métrica na mesma escala da variável y , e que é dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y} - y)^2}, \quad (4.7)$$

onde n é o número de exemplos na amostra disponível, y é o valor real e \hat{y} é o valor estimado pelo modelo.

O processo de treinamento é repetido de forma não exaustiva para encontrar o conjunto de hiperparâmetros de cada modelo com melhor desempenho em dados de teste, que corresponde ao desempenho com utilização de dados de METAR no período selecionado.

Para a busca de hiperparâmetros, adotou-se busca manual para os modelos de rede neural e grid search para os modelos de RF.

4.6 Previsões em horizonte de 24 horas

Com os modelos treinados na seção 4.5 e o procedimento de obtenção de dados de previsão descrito na seção 4.4, são geradas previsões dos modelos em um horizonte de previsão de 24 horas no momento de execução do código a partir dos últimos dados fornecidos de SIROS e TAF.

Para obtenção da performance real do modelo em dados de previsão é gerado um novo

banco de dados com procedimento análogo ao descrito na seção 4.5.4, mas com dados históricos de TAF ao invés de Metar, assim possibilitando obter dados de teste com a mesma distribuição estatística que os dados de previsão.

4.7 Explicações locais dos modelos preditivos

Para obter as explicações de LIME das previsões obtidas, foi utilizado o pacote *lime* do R. A partir dos dados de treino, foram gerados explicadores. Em seguida, com os dados de previsão, são geradas as explicações com 6 variáveis explicadas. Então, os pesos do modelo substituto local da previsão a ser analisada são plotados, obtendo-se a visualização gráfica das explicações.

A função de custo utilizada para obter as explicações foi o MSE referente ao ajuste do modelo substituto em relação aos outputs gerados pelo modelo original, utilizando os dados obtidos a partir da vizinhança dos dados de treino, como explicado em 2.3.1.

4.8 Apresentação de resultados em dashboard

Os resultados de previsão e explicação são então apresentados em um dashboard, com uma rotina pronta para se obter as previsões e explicações em um horizonte de 24 horas a partir do último TAF emitido.

A interface permite mais praticidade para a análise de uma grande variedade de informações obtidas a partir das previsões dos modelos, das explicações das previsões com LIME e das previsões de TAF.

5 Resultados e discussões

Nesse capítulo, serão discutidos os resultados obtidos ao aplicar a metodologia descrita na seção anterior.

5.1 Análise exploratória

GRU possui duas pistas paralelas próximas que são tipicamente operadas em duas principais configurações: 10R|10L (ou seja, pousos realizados na cabeceira 10R e decolagens na cabeceira 10L) e 28L|28R (pousos realizados na cabeceira 28L e decolagens na cabeceira 28R). A Figura 5.1 ilustra a frequência de uso dessas configurações de pista com base nos dados processados.

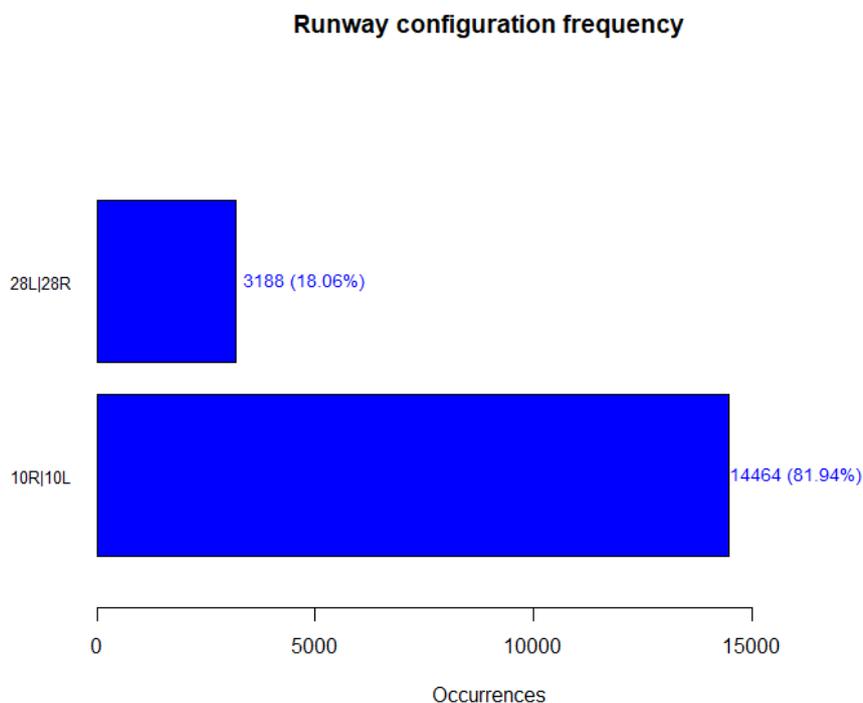


FIGURA 5.1 – Frequência de uso das configurações principais de GRU.
Fonte: Autor.

A Figura 5.2 apresenta a correlação extremamente alta entre a configuração ativa das pistas de GRU e a direção do vento. Conforme esperado, as configurações das pistas são tipicamente selecionadas para evitar componentes de vento de cauda. Portanto, espera-se que a direção do vento seja uma variável relevante para a previsão da configuração das pistas.

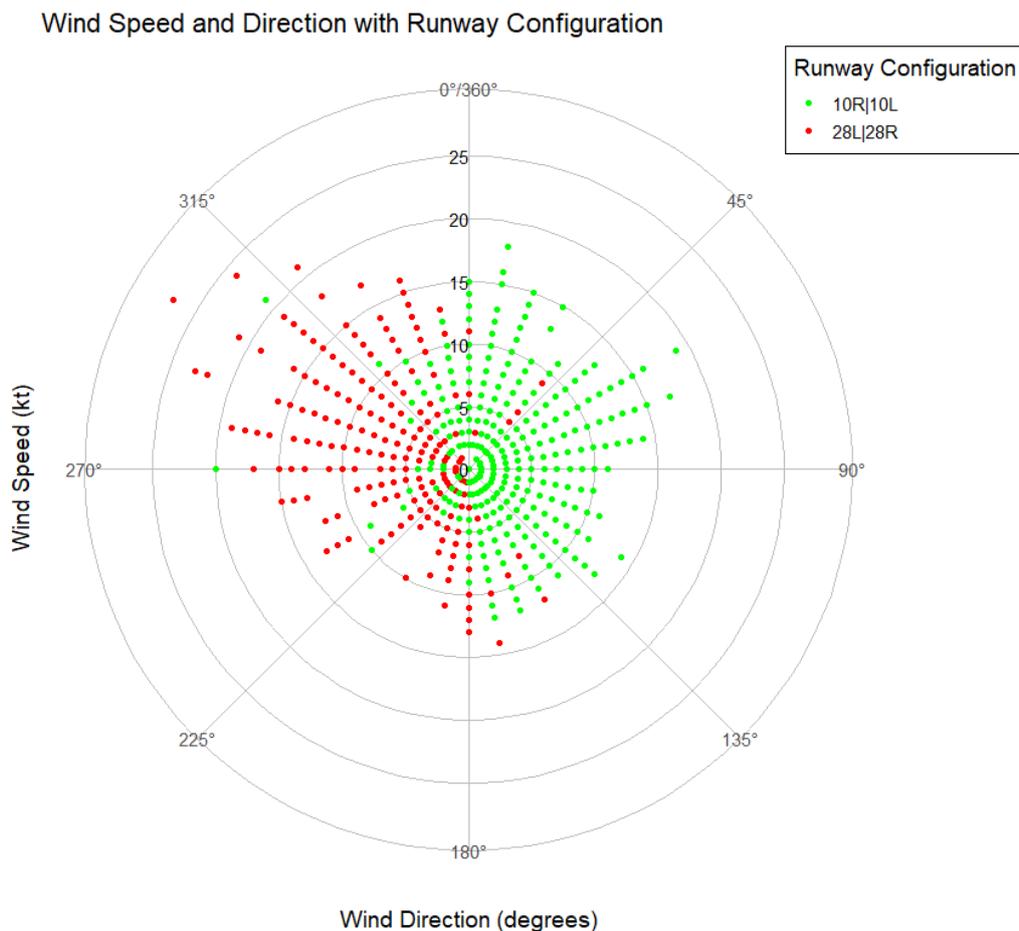


FIGURA 5.2 – Ocorrências de configurações de pista observadas para direção e velocidade do vento em GRU.

Fonte: Autor.

Já VCP possui somente uma PPD que pode ser operada em dois sentidos, definindo duas configurações: 33|33 (pousos e decolagens na cabeceira 33) e 15|15 (pousos e decolagens na cabeceira 15). A Figura 5.3 ilustra a frequência de uso dessas configurações de pista com base nos dados processados.

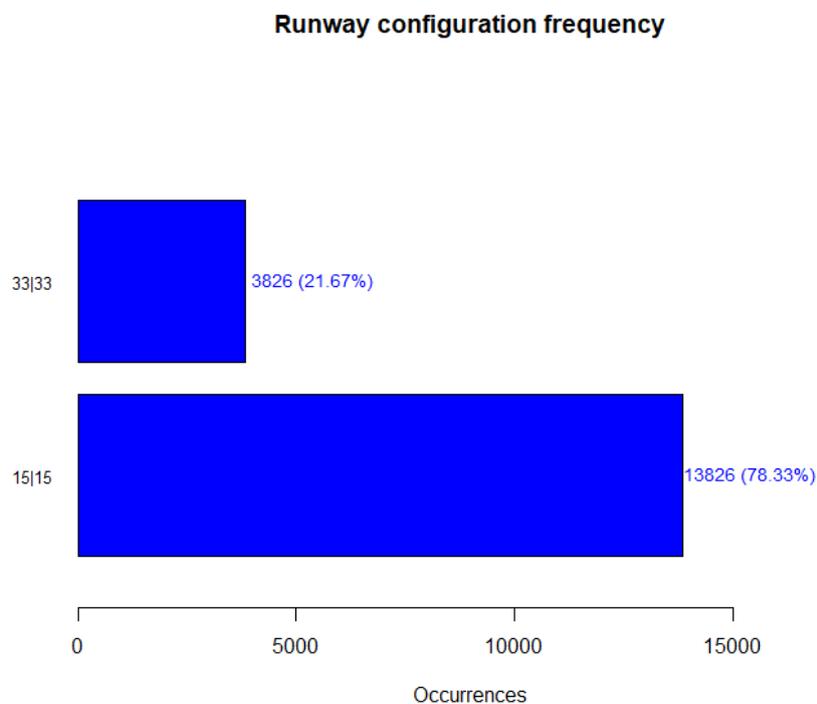


FIGURA 5.3 – Frequência de uso das configurações principais de VCP.
Fonte: Autor.

Novamente, a Figura 5.4 apresenta a correlação extremamente alta entre a configuração ativa das pistas de VCP e a direção do vento, de forma a evitar componentes de vento de cauda.

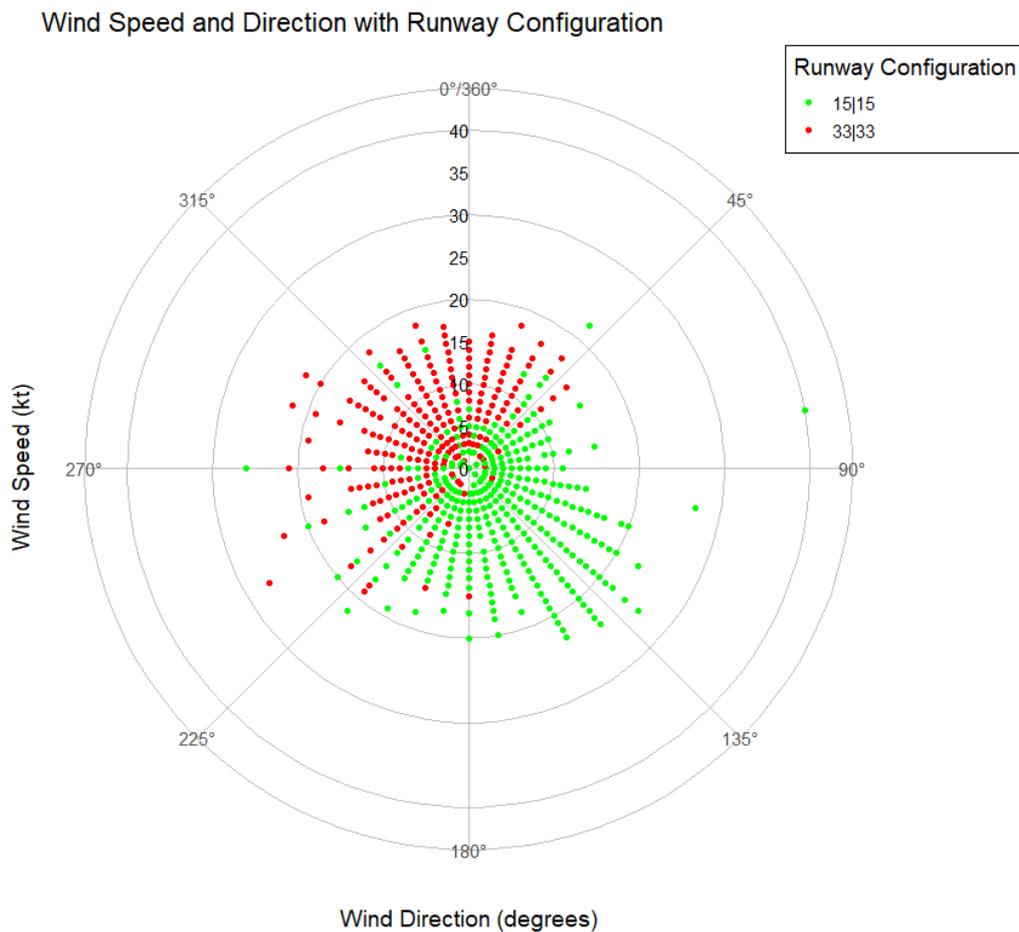


FIGURA 5.4 – Ocorrências de configurações de pista observadas para direção e velocidade do vento em VCP.

Fonte: Autor.

Assim como GRU, CGH possui duas pistas paralelas. No entanto, a maior parte das operações ocorre na pista principal, seja na cabeceira 35L ou na cabeceira 17R, a depender da configuração. A qualquer momento do dia, eventualmente ocorrem operações na outra pista, seja na cabeceira 35R ou na cabeceira 17L, novamente, a depender da configuração. Dessa forma, as duas principais configurações são: 35L,35R|35L,35R (pousos e decolagens nas cabeceiras 35L e 35R), e 17L,17R|17L,17R (pousos e decolagens nas cabeceiras 35L e 35R). A Figura 5.3 ilustra a frequência de uso dessas configurações de pista com base nos dados processados.

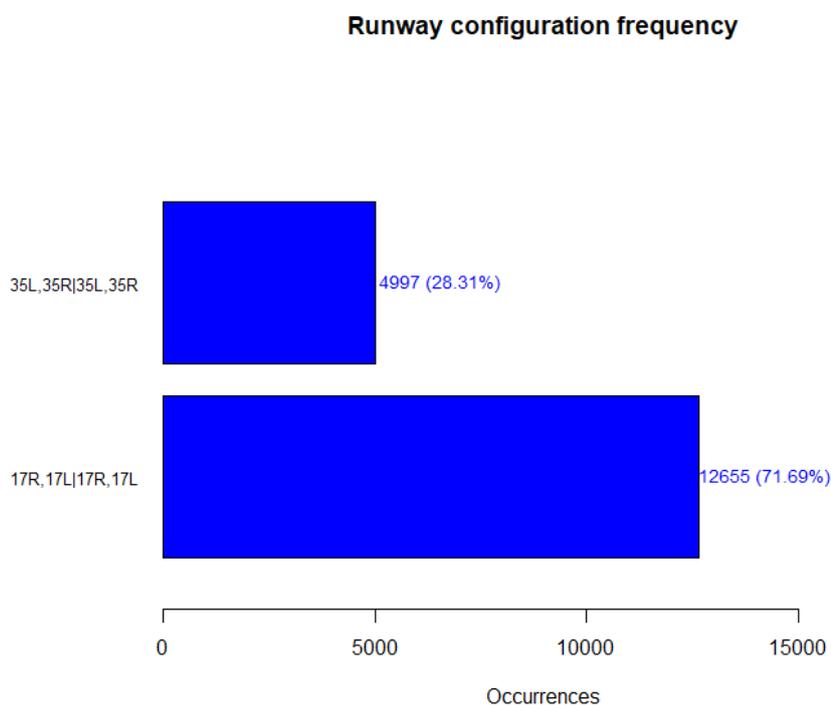


FIGURA 5.5 – Frequência de uso das configurações principais de CGH.

Fonte: Autor.

Novamente, a Figura 5.6 apresenta a correlação extremamente alta entre a configuração ativa das pistas de CGH e a direção do vento, de forma a evitar componentes de vento de cauda.

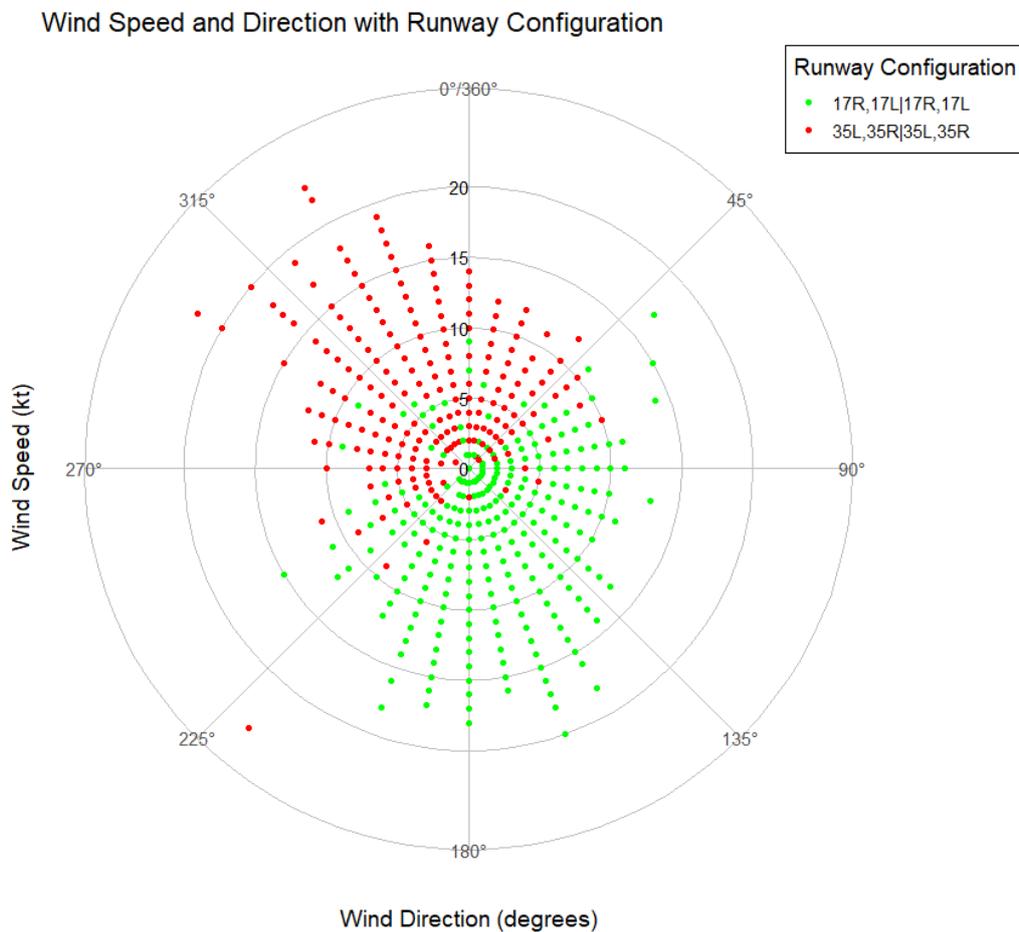


FIGURA 5.6 – Ocorrências de configurações de pista observadas para direção e velocidade do vento em CGH.

Fonte: Autor.

Durante o pré-processamento inicial dos dados descrito na Seção 4.3, obtivemos as curvas de desempenho de taxas de pousos e decolagens para o aeroporto GRU, conforme ilustrado na Figura 5.7. Constatou-se que o aeroporto está saturado para pousos quando o número de aeronaves na área terminal excede 9. De maneira similar, observou-se que o aeroporto está saturado para decolagens quando o número de aeronaves em trânsito do gate até a PPD ultrapassa 8.

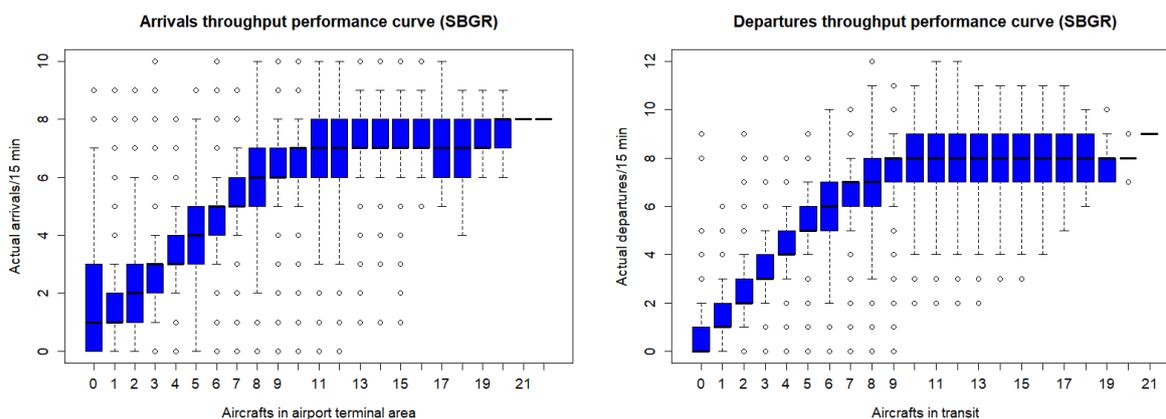


FIGURA 5.7 – Curvas de desempenho de fluxo de pousos e decolagens para GRU.
Fonte: Autor.

Analogamente para VCP, constatou-se que o aeroporto encontra-se saturado para pousos quando o número de aeronaves na área terminal excede 6, e para decolagens quando o número de aeronaves em trânsito do gate até a PPD ultrapassa 7, conforme a Figura 5.8.

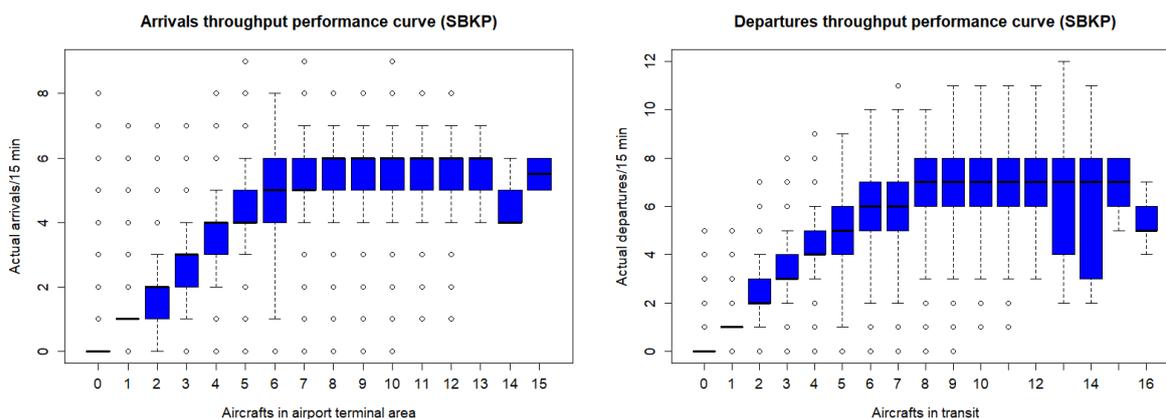


FIGURA 5.8 – Curvas de desempenho de fluxo de pousos e decolagens para VCP.
Fonte: Autor.

Analogamente para CGH, constatou-se que o aeroporto encontra-se saturado para pousos quando o número de aeronaves na área terminal excede 5, e para decolagens quando o número de aeronaves em trânsito do gate até a PPD ultrapassa 6, conforme a Figura 5.9.

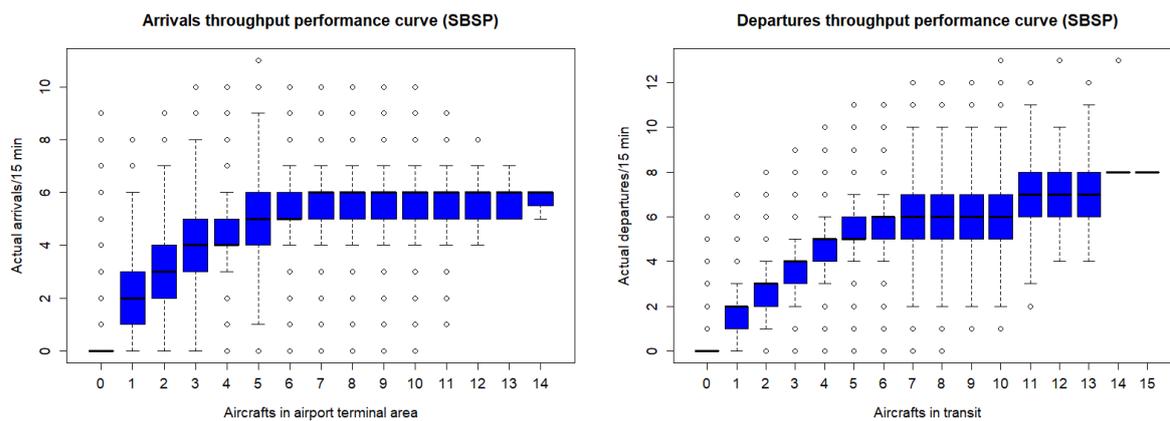


FIGURA 5.9 – Curvas de desempenho de fluxo de pousos e decolagens para CGH.
Fonte: Autor.

Considerando os níveis de demanda descritos anteriormente, os dados foram então filtrados para manter apenas as observações associadas aos períodos em que o aeroporto estava operando em sua capacidade máxima. As Figuras 5.10, 5.11, 5.12, 5.13, 5.14 e 5.15 demonstram que o processo de filtragem alcançou o efeito desejado para todos os aeroportos, pois a distribuição das taxas de pousos e decolagens tornou-se menos afetada pelos padrões de demanda horária. Portanto, é razoável assumir que as taxas de chegadas e partidas refletem a capacidade do aeroporto para as instâncias filtradas.

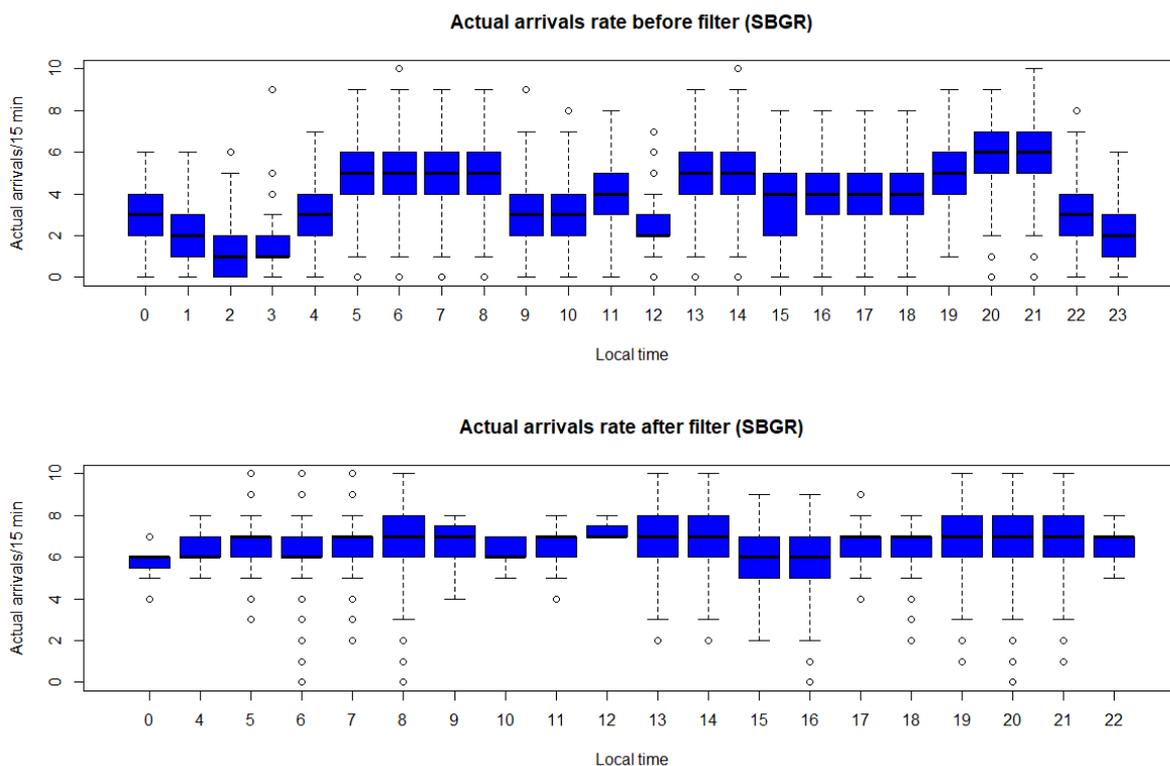


FIGURA 5.10 – Distribuição de taxas de pousos antes e depois do processo de filtragem para GRU. Fonte: Autor.

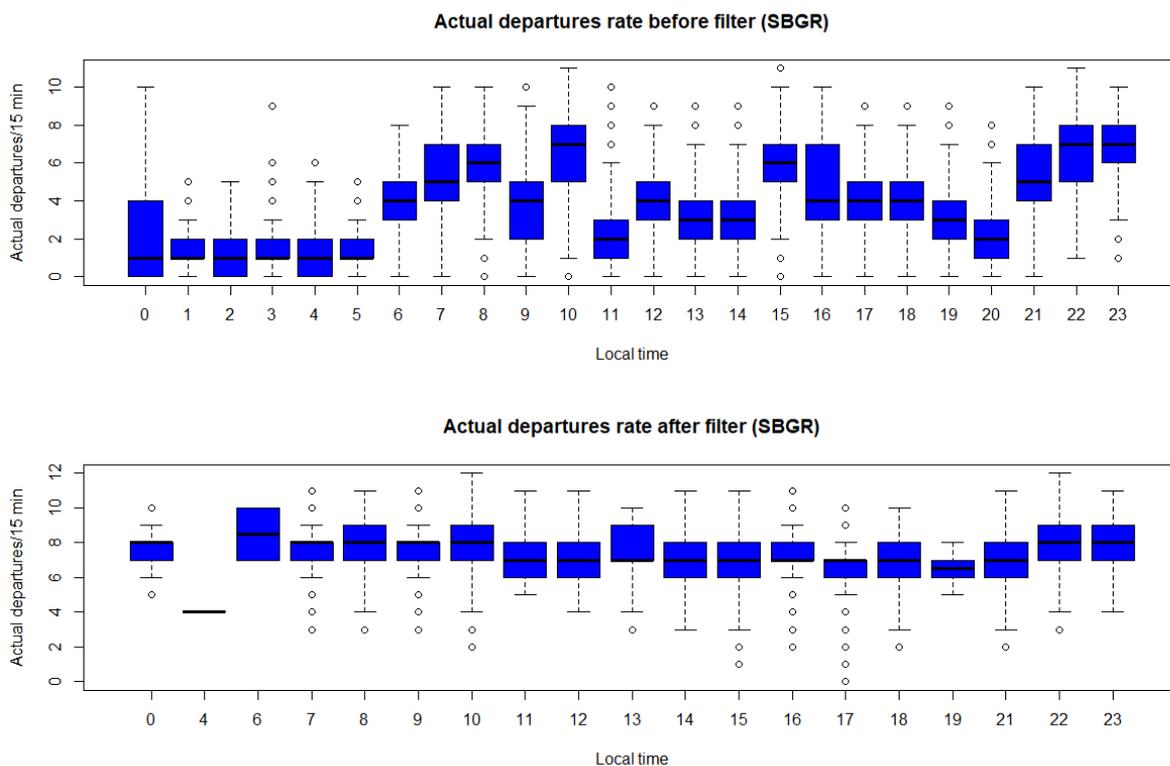


FIGURA 5.11 – Distribuição de taxas de decolagens antes e depois do processo de filtragem para GRU. Fonte: Autor.

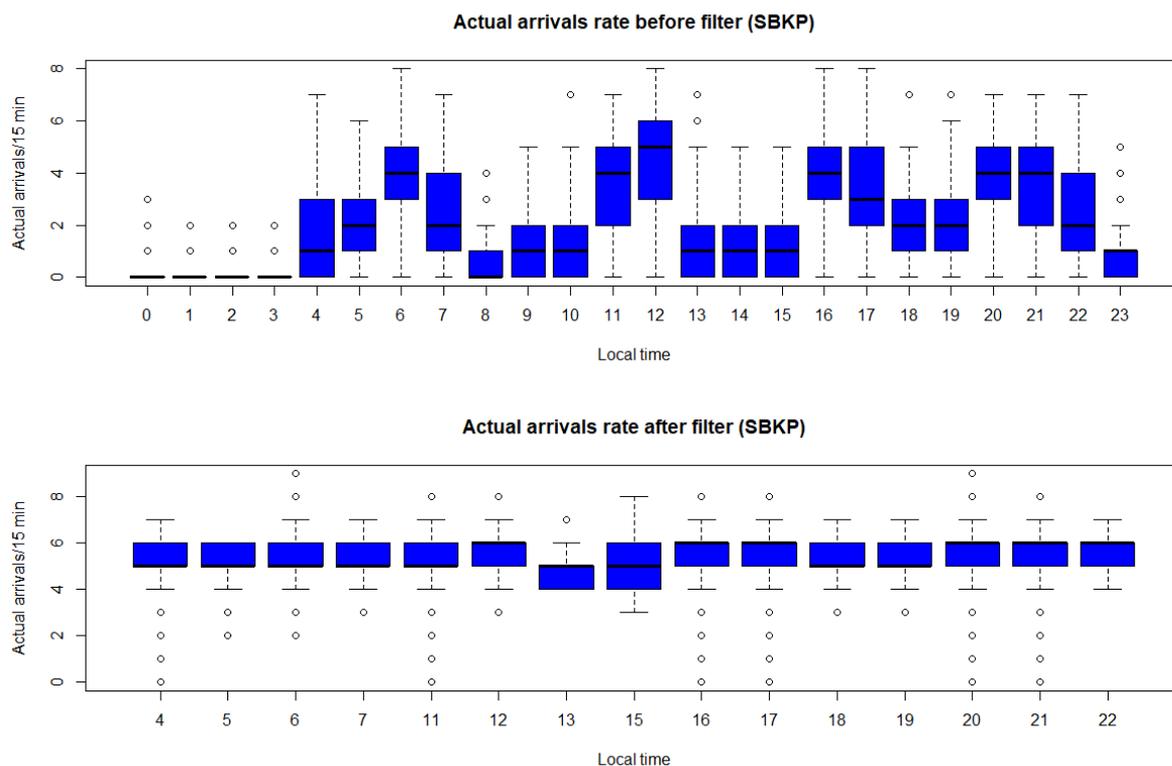


FIGURA 5.12 – Distribuição de taxas de pousos antes e depois do processo de filtragem para VCP.
Fonte: Autor.

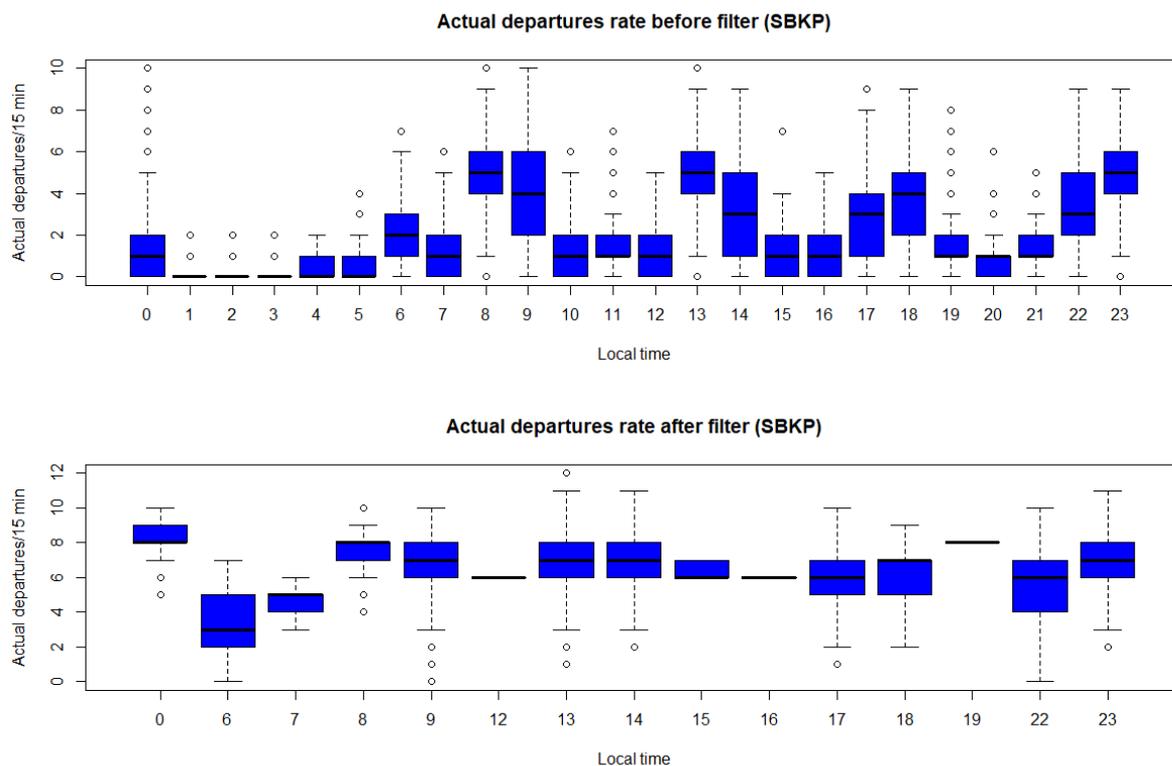


FIGURA 5.13 – Distribuição de taxas de decolagens antes e depois do processo de filtragem para VCP.
Fonte: Autor.

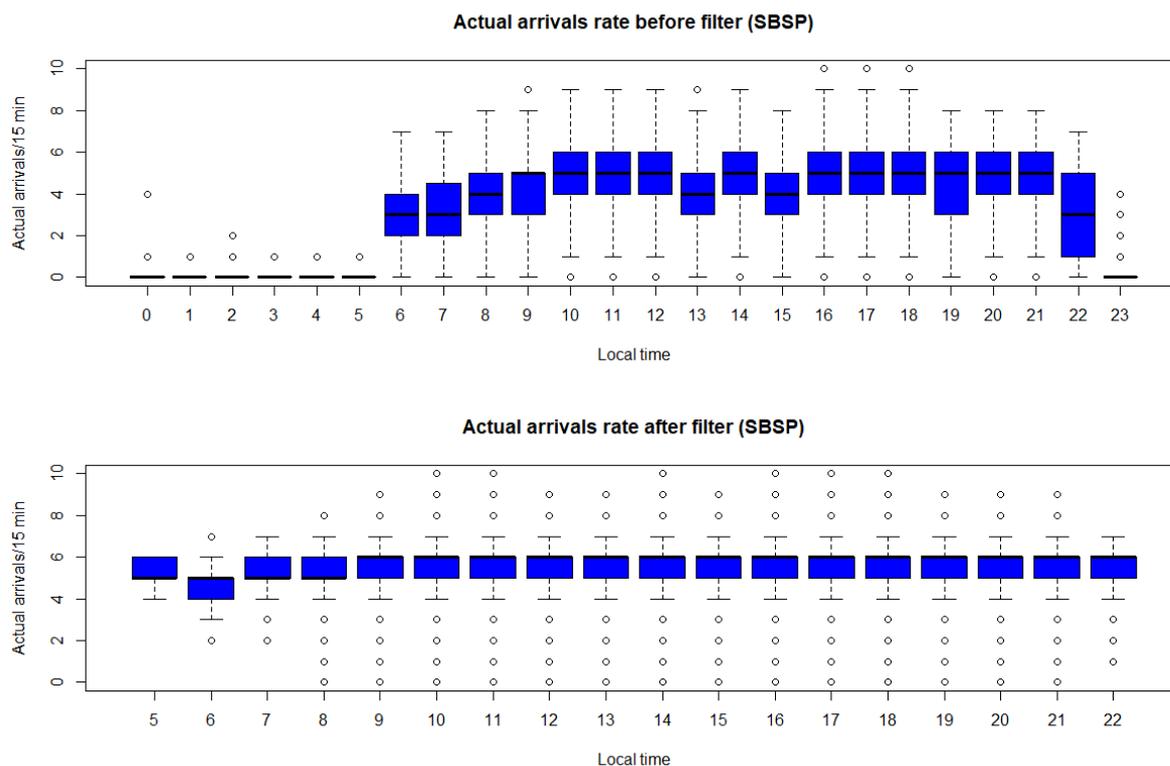


FIGURA 5.14 – Distribuição de taxas de pousos antes e depois do processo de filtragem para CGH. Fonte: Autor.

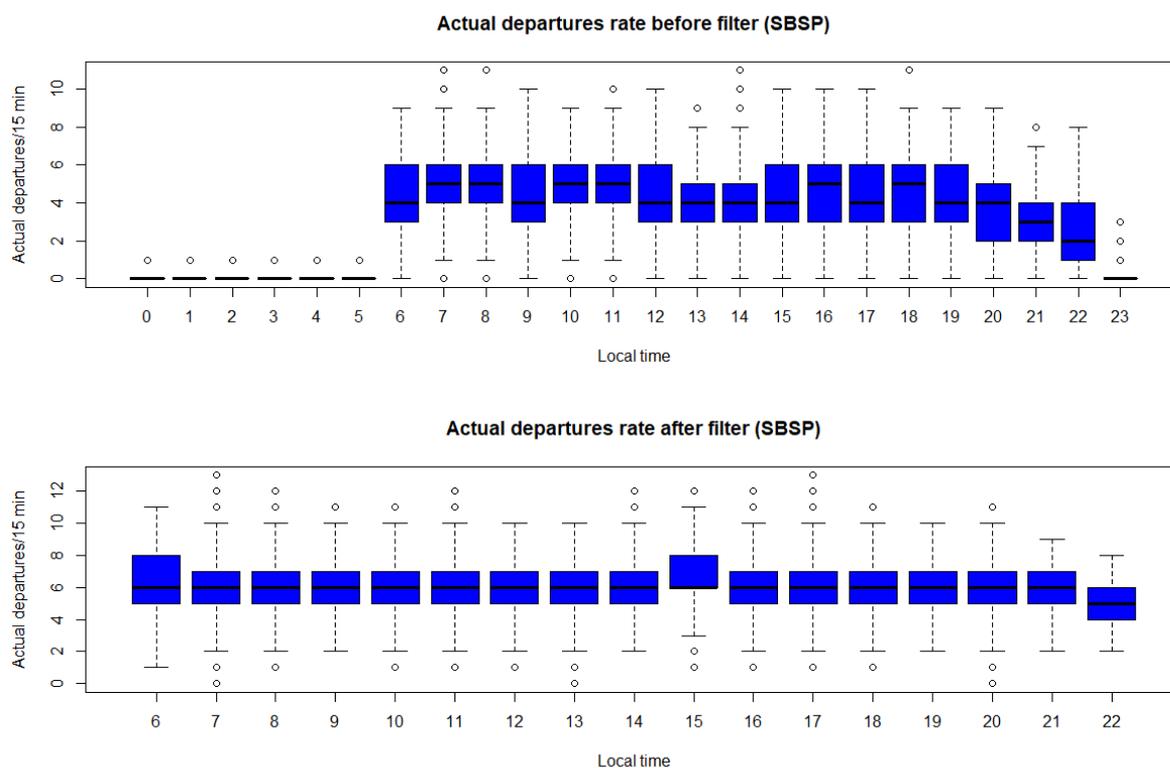


FIGURA 5.15 – Distribuição de taxas de decolagens antes e depois do processo de filtragem para CGH. Fonte: Autor.

5.2 Desempenho dos modelos preditivos

Para MLP, por meio do ajuste manual de hiperparâmetros com 100 épocas, as arquiteturas apresentadas na Tabela 5.1 alcançaram o melhor desempenho. Regularizadores de dropout foram aplicados às camadas ocultas com uma probabilidade de 10%. O treinamento foi realizado utilizando o algoritmo de Adam com um tamanho de batch de 128 e uma taxa de aprendizado de 0.01, sendo 10% dos dados de treinamento usados para validação.

TABELA 5.1 – Arquiteturas utilizadas nos modelos de MLP.

<i>Prediction model</i>	<i>Neurons</i>	<i>Activation function</i>
Configuração de pista	[60, 35, 1]	[tanh, tanh, sigmoid]
Capacidade de pousos	[60, 35, 1]	[tanh, tanh, linear]
Capacidade de decolagens	[60, 35, 1]	[tanh, tanh, linear]

Para os modelos de RF, utilizaram-se 500 árvores para treinar com validação cruzada de 4-folds e 2 repetições a fim de otimizar o número de variáveis usadas para gerar decisões em cada nó das árvores.

As Figuras 5.16, 5.17 e 5.18 exibem a importância obtida para cada variável nos modelos de RF treinados para previsão de configuração de pista. Observou-se que a variável mais relevante para os modelos de previsão de configuração de pista foi *wind_direction*, o que está de acordo com os resultados apresentados pela análise exploratória de dados.

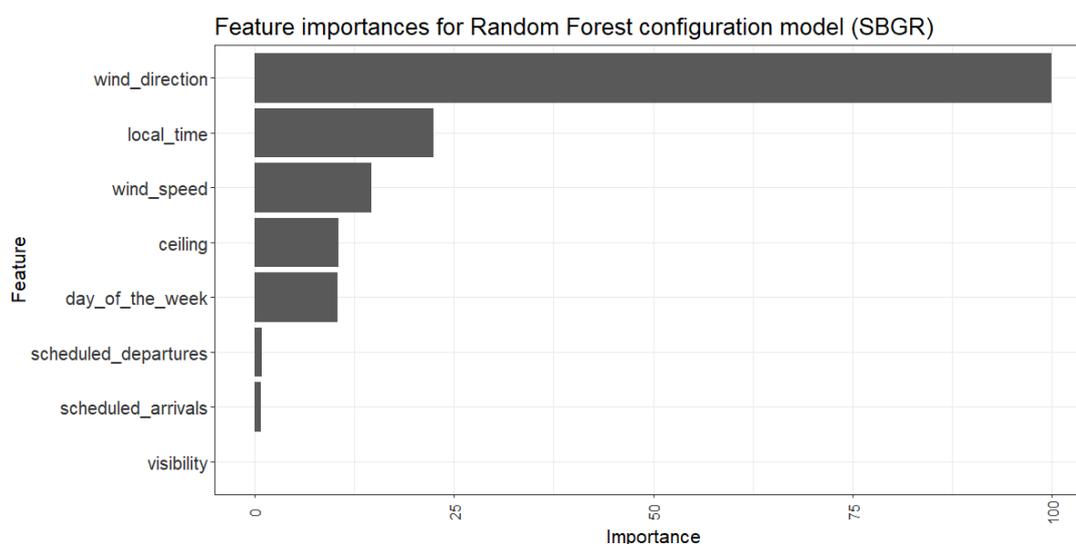


FIGURA 5.16 – Importâncias das variáveis encontradas nos modelos de RF para configuração de pista em GRU.

Fonte: Autor.

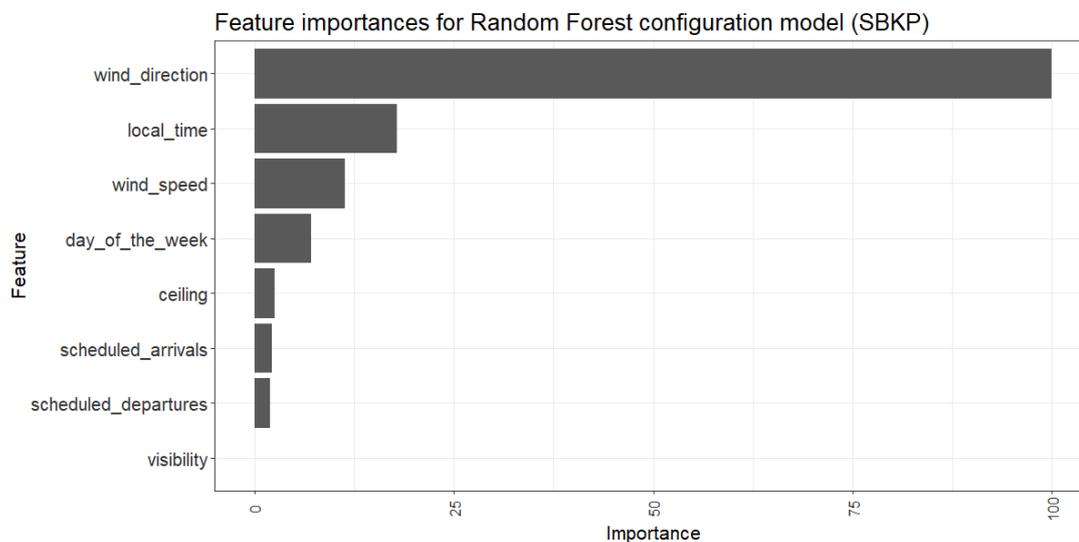


FIGURA 5.17 – Importâncias das variáveis encontradas nos modelos de RF para configuração de pista em VCP.

Fonte: Autor.

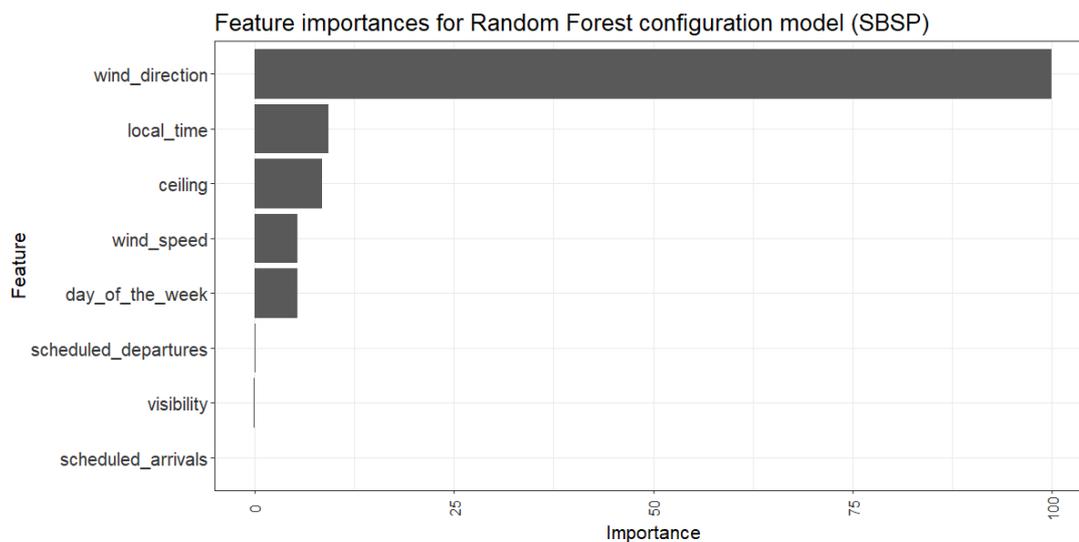


FIGURA 5.18 – Importâncias das variáveis encontradas nos modelos de RF para configuração de pista em CGH.

Fonte: Autor.

As Figuras 5.19, 5.20 e 5.21 exibem a importância obtida para cada variável nos modelos de RF treinados para previsão de capacidade de pousos, e as Figuras 5.22, 5.23 e 5.24 para capacidade de decolagens. Em ambos os casos, a variável mais relevante foi *local_time*. Isso é um indicativo de que, ainda que tenha sido realizado o tratamento das variáveis que representam capacidade de forma a mitigar efeitos de flutuação de demanda, a capacidade de pista ainda possui algum padrão cíclico diário.

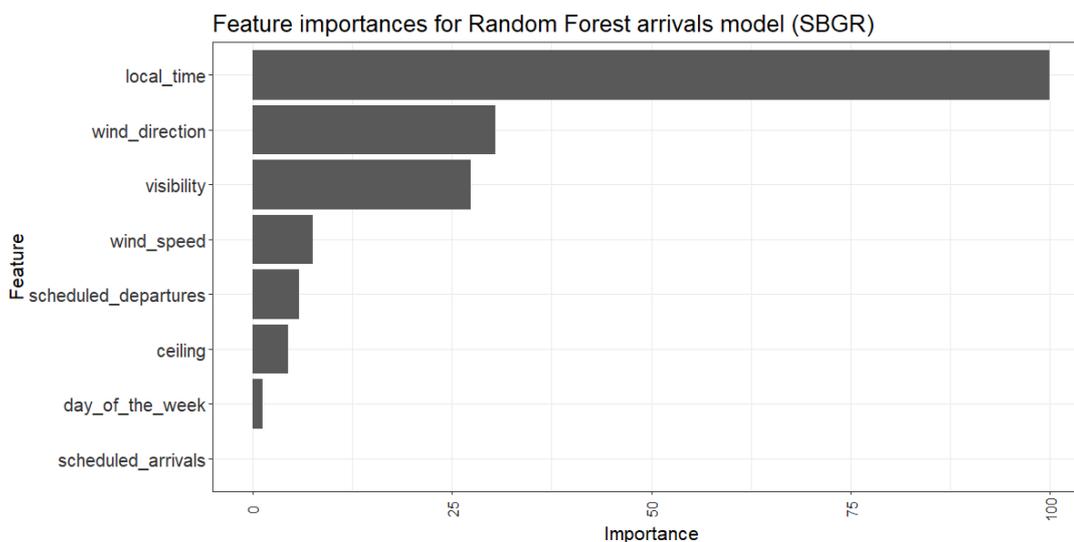


FIGURA 5.19 – Importâncias das variáveis encontradas nos modelos de RF para capacidade de pousos em GRU.

Fonte: Autor.

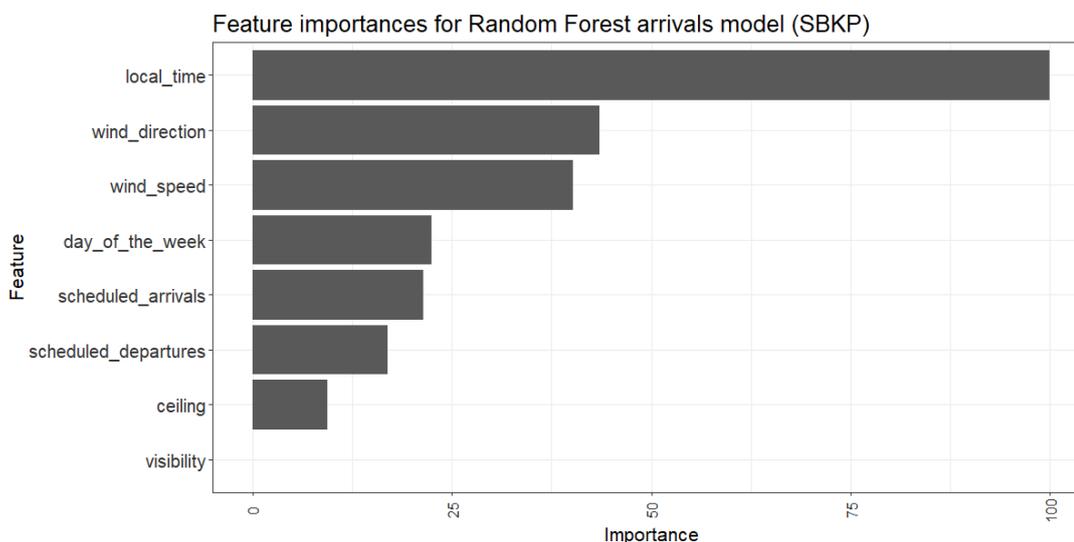


FIGURA 5.20 – Importâncias das variáveis encontradas nos modelos de RF para capacidade de pousos em VCP.

Fonte: Autor.

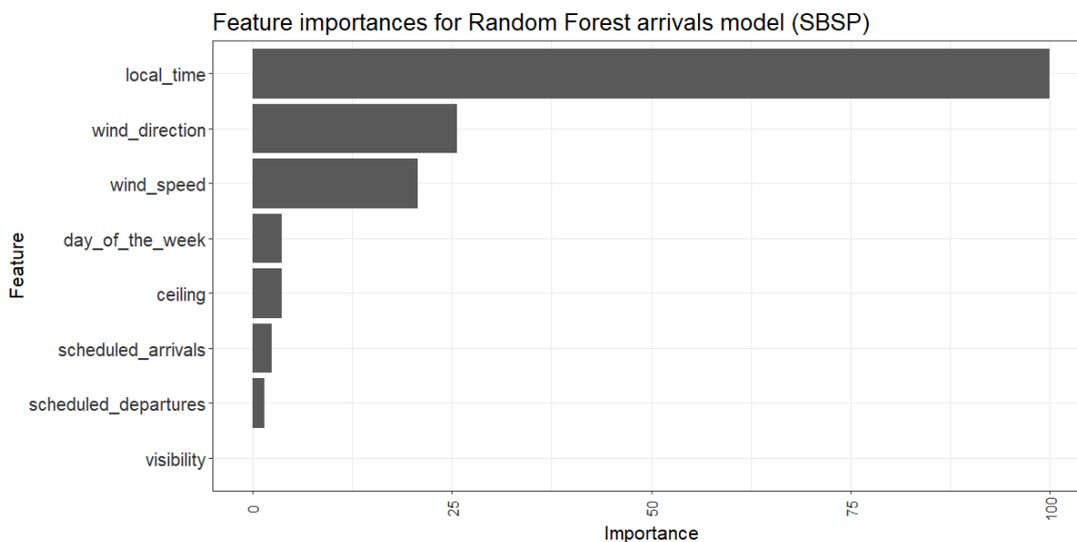


FIGURA 5.21 – Importâncias das variáveis encontradas nos modelos de RF para capacidade de pousos em CGH.

Fonte: Autor.

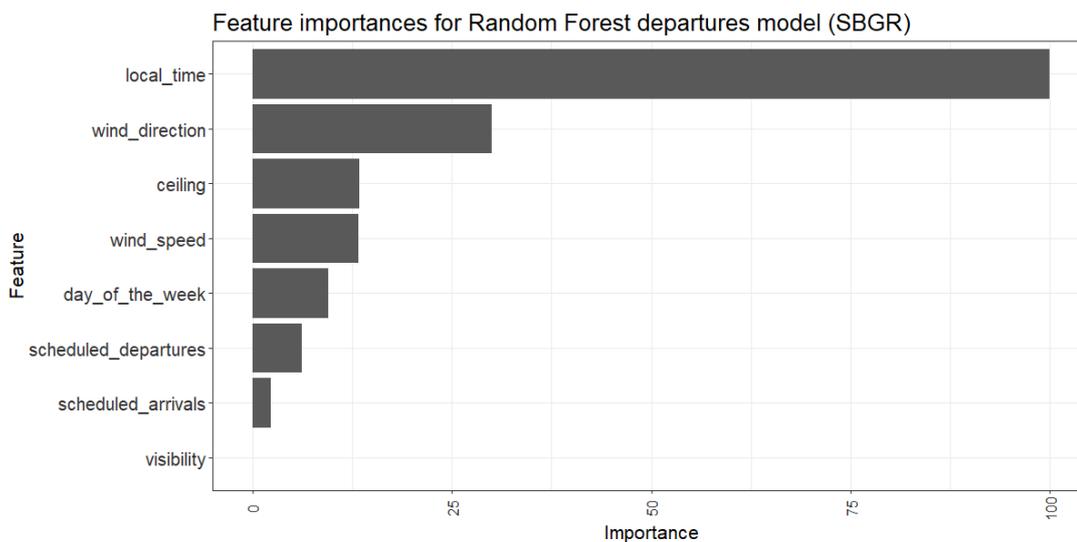


FIGURA 5.22 – Importâncias das variáveis encontradas nos modelos de RF para capacidade de decolagens em GRU.

Fonte: Autor.

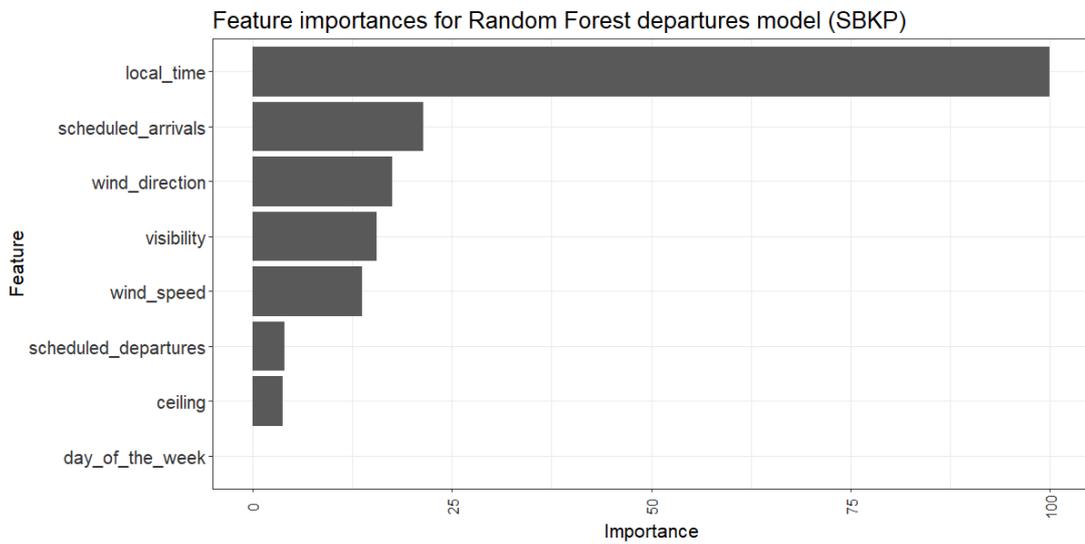


FIGURA 5.23 – Importâncias das variáveis encontradas nos modelos de RF para capacidade de decolagens em VCP.

Fonte: Autor.

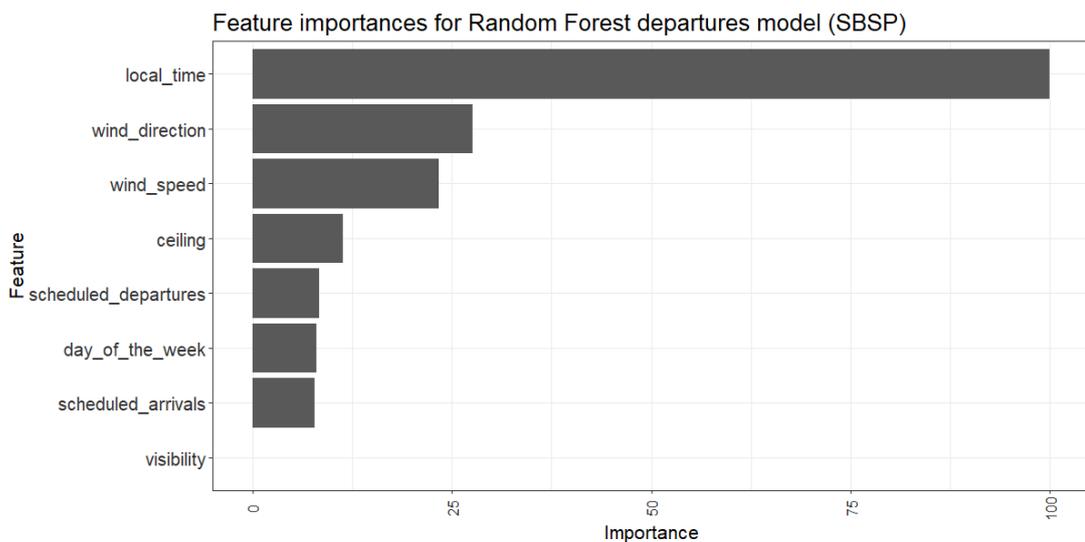


FIGURA 5.24 – Importâncias das variáveis encontradas nos modelos de RF para capacidade de decolagens em CGH.

Fonte: Autor.

Para cada um dos aeroportos, o desempenho preditivo dos modelos nos dados de teste foi resumido nas Tabelas 5.2, 5.3 e 5.4. Em geral, os modelos de MLP demonstraram um desempenho levemente superior aos de RF, com acurácias de previsão de configuração de pista de 90.59%, 91.13% e 90.00%, RMSE de capacidade de pousos de 1.042, 1.113 e 1.118 e RMSE de capacidade de decolagens de 1.341, 1.589 e 1.489 para GRU, VRP e CGH, respectivamente. Como exceção, a acurácia em configuração de pista de RF em CGH foi levemente superior à de MLP, com 90.12% de acurácia.

TABELA 5.2 – Desempenho dos modelos preditivos em GRU.

<i>Desempenho</i>	<i>MLP</i>	<i>RF</i>
Acurácia em configuração de pista	90.59%	89.50%
RMSE em capacidade de pousos	1.042	1.109
RMSE em capacidade de decolagens	1.341	1.392

TABELA 5.3 – Desempenho dos modelos preditivos em VCP.

<i>Desempenho</i>	<i>MLP</i>	<i>RF</i>
Acurácia em configuração de pista	91.13%	90.85%
RMSE em capacidade de pousos	1.113	1.176
RMSE em capacidade de decolagens	1.589	1.613

TABELA 5.4 – Desempenho dos modelos preditivos em CGH.

<i>Desempenho</i>	<i>MLP</i>	<i>RF</i>
Acurácia em configuração de pista	90.00%	90.12%
RMSE em capacidade de pousos	1.118	1.154
RMSE em capacidade de decolagens	1.489	1.582

5.3 Explicações das previsões

Os modelos treinados foram usados para gerar previsões explicáveis utilizando LIME com dados meteorológicos provenientes de TAFs para um horizonte de previsão de 24 horas. Uma ferramenta interativa foi desenvolvida para exibir as previsões e explicações de configuração de pista e de capacidade de pousos e decolagens de forma horária, com base nas previsões de TAFs, conforme ilustrado na Figura 5.25.

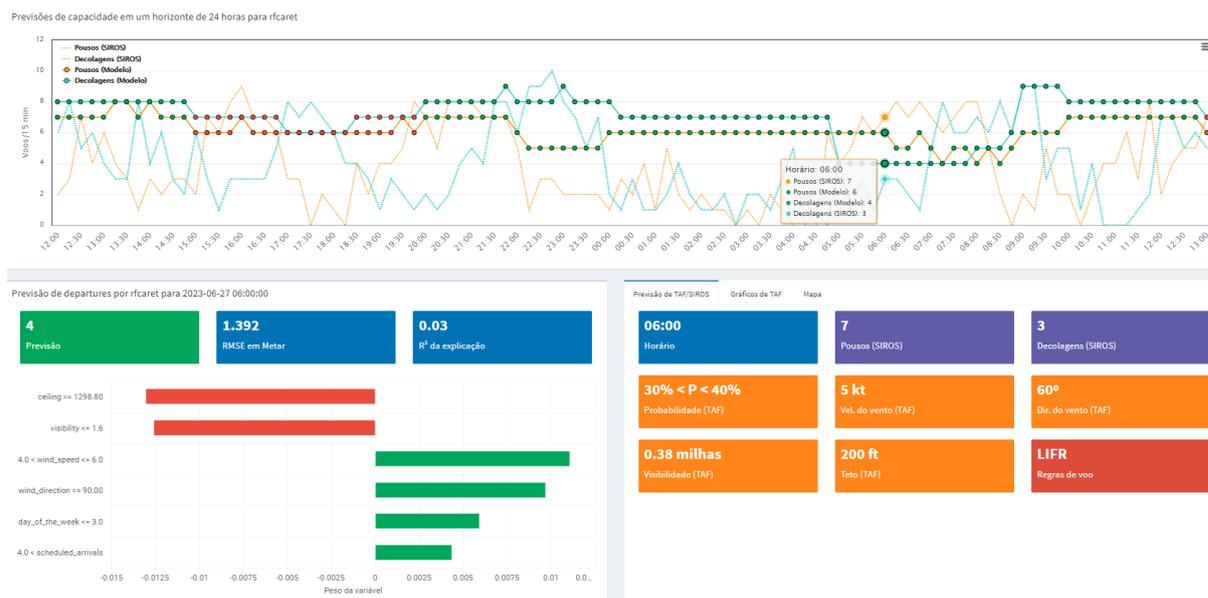


FIGURA 5.25 – Interface interativa que exibe predições explicadas de configuração e capacidade de pista para um horizonte de previsão de até 24 horas.

Fonte: Autor.

Na interface da Figura 5.25, a seção superior exibe gráficos de taxa de operações em intervalos de 15 minutos. Linhas contínuas indicam a capacidade projetada pelos modelos, enquanto as linhas tracejadas refletem a demanda prevista baseada nos dados do SIROS. A tonalidade laranja denota pousos e a azul, decolagens. Os círculos sobrepostos marcam as configurações previstas pelos modelos: os verdes simbolizam a configuração primária do aeroporto; os vermelhos, a secundária. No canto inferior esquerdo, encontram-se as previsões do modelo e as explicações de LIME para a instância selecionada. Por fim, o canto inferior direito apresenta as previsões de SIROS e de TAF para a mesma instância.

Para a instância específica (2023-06-27 06:00:00) em GRU, caracterizada pela condição meteorológica de Low Instrument Flight Rules (LIFR) (Figura 5.27), onde o teto é menor que 500 ft ou a visibilidade é menor que 1 NM, as explicações dos modelos foram obtidas e estão ilustradas na Figura 5.26. Observou-se consistência nas explicações dos modelos para a instância de previsão analisada, uma vez que eles capturaram a influência da baixa visibilidade e do teto baixo sobre a previsão da capacidade reduzida de decolagens.

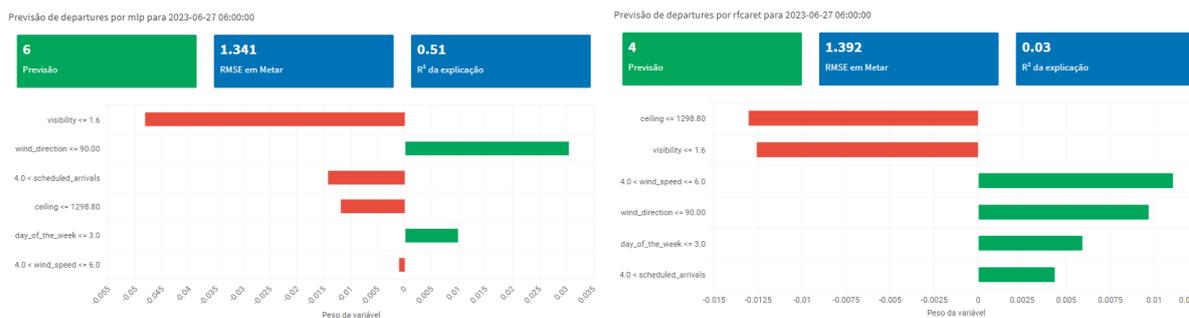


FIGURA 5.26 – Explicações de LIME para previsões de 2023-06-27 06:00:00 para os modelos de previsão de capacidade de decolagens de MLP, na esquerda, e RF, na direita, em GRU. Fonte: Autor.

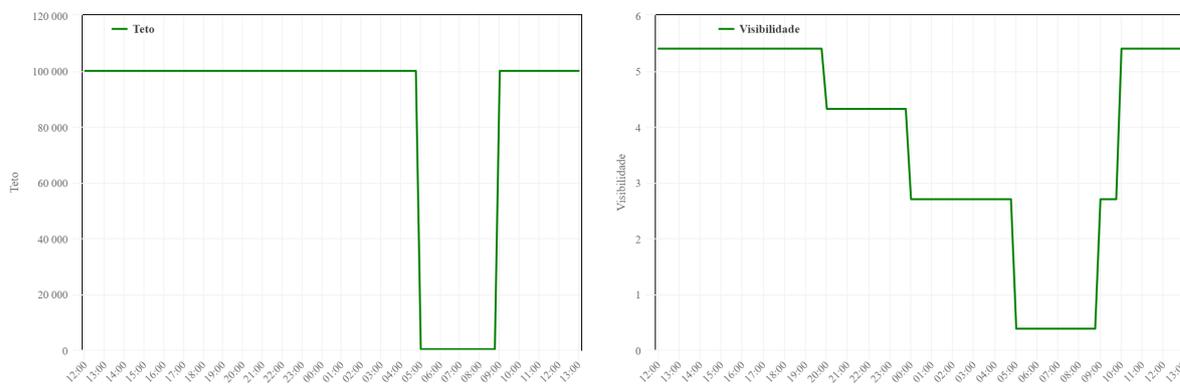


FIGURA 5.27 – Previsões de visibilidade e teto de TAF para 2023-06-27 06:00:00 em GRU. Fonte: Autor.

5.4 Estudos de instâncias específicas

Além da instância analisada com a utilização da interface em GRU, também foram feitas análises adicionais utilizando os dados de teste, de forma que fosse possível incorporar informações de operações reais para fazer as análises.

5.4.1 2022-10-22 08:18:00 GRU

A instância de 2022-10-22 08:18:00 em GRU é caracterizada pela condição meteorológica de Visual Flight Rules (VFR), onde o teto é maior que 1000 ft e a visibilidade é maior que 3 NM. Nessa instância, a visibilidade era de 5.396 NM e o teto era de 99999 ft, e o aeroporto operava sob a configuração 28L|28R. O aeroporto encontrava-se saturado tanto para pousos quanto decolagens, com 11 aeronaves na área terminal do aeroporto e 14 aeronaves em trânsito do gate para a PPD.

A Tabela 5.5 mostra que os modelos apresentaram uma previsão de capacidade próxima à capacidade declarada do aeroporto e à quantidade de operações que efetivamente ocorreram, o que é compatível com o esperado em situações de VFR, com o aeroporto operando próximo à sua capacidade limite.

Operações	Aeronaves	Operações planejadas	Operações reais	Capacidade declarada	Capacidade MLP	Capacidade RF
Pousos	11	7	8	8	7	7
Decolagens	14	5	7	8	7	8
Total	25	12	15	15	-	-

TABELA 5.5 – Dados de operações e previsões dos modelos para 2022-10-22 08:18:00, em GRU.

As Figuras 5.28 e 5.29 apresentam as explicações de LIME dos modelos para essa instância. As explicações identificaram a direção do vento como a principal variável contribuindo para uma queda de capacidade. Isso pode ser explicado pelo fato de que o aeroporto operava na sua configuração alternativa 28L|28R, dado que a configuração de pista possui uma correlação extremamente elevada com a direção do vento.

As explicações também conseguiram identificar a visibilidade e o teto como variáveis favoráveis à não ocorrência de degradação de capacidade do sistema de pistas, o que é compatível com a característica de VFR da instância analisada.

5.4.2 2022-08-01 08:12:00 GRU

A instância de 2022-08-01 08:12:00 em GRU é caracterizada pela condição meteorológica de LIFR. Nessa instância, a visibilidade era de 0.269 NM e o teto era de 200 ft, e o aeroporto operava sob a configuração 10R|10L. O aeroporto encontrava-se saturado

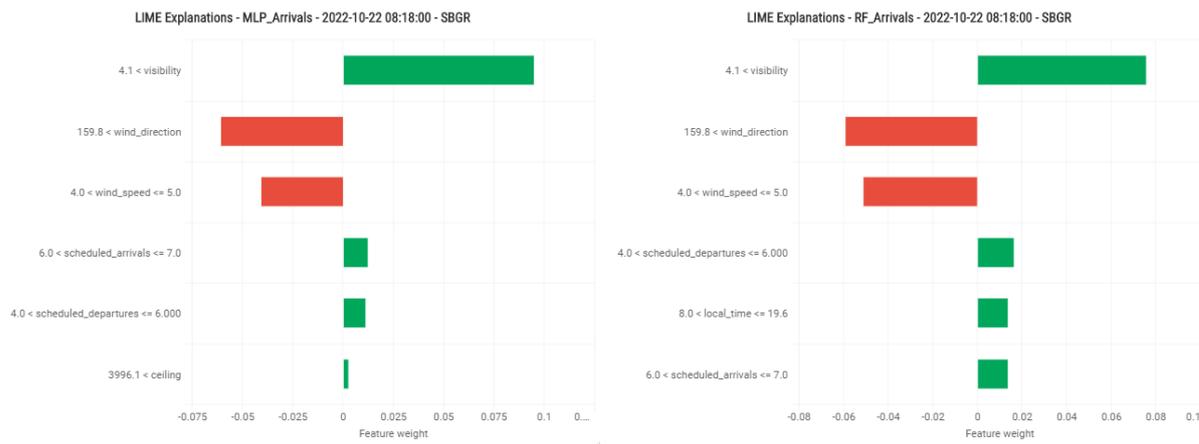


FIGURA 5.28 – Explicações de LIME de MLP e RF para capacidade de pousos em 2022-10-22 08:18:00, em GRU.
 Fonte: Autor.

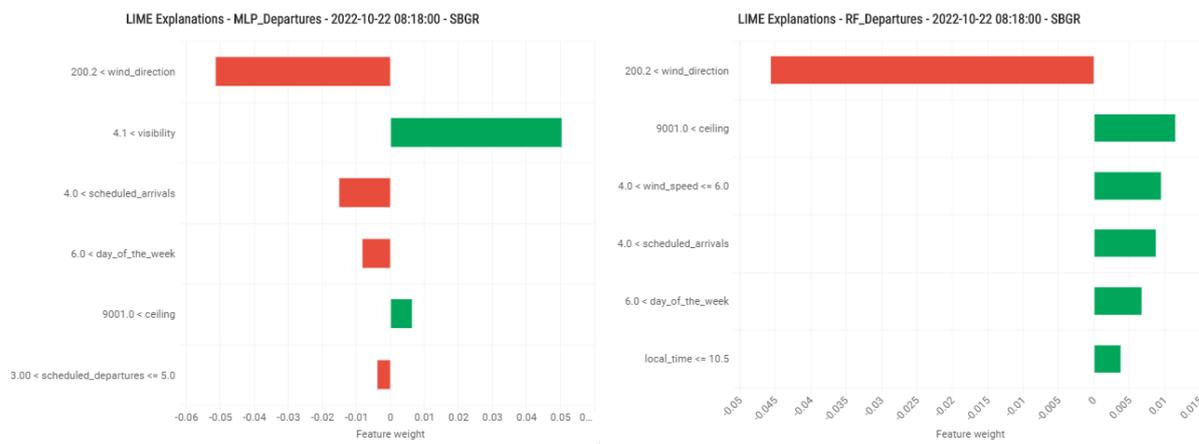


FIGURA 5.29 – Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-10-22 08:18:00, em GRU.
 Fonte: Autor.

tanto para pousos quanto decolagens, com 15 aeronaves na área terminal do aeroporto e 9 aeronaves em trânsito do gate para a PPD.

A Tabela 5.6 mostra que os modelos apresentaram uma previsão de capacidade reduzida em relação à capacidade declarada, o que é compatível com o esperado em situações de condições operacionais desfavoráveis como LIFR.

Operações	Aeronaves	Operações planejadas	Operações reais	Capacidade declarada	Capacidade MLP	Capacidade RF
Pousos	15	5	4	8	5	5
Decolagens	9	6	5	8	7	5
Total	24	11	9	15	-	-

TABELA 5.6 – Dados de operações e previsões dos modelos para 2022-08-01 08:12:00, em GRU.

As Figuras 5.30 e 5.31 apresentam as explicações de LIME dos modelos para essa instância. As explicações conseguiram captar a influência da visibilidade baixa e do teto entre as principais variáveis que levaram à redução de capacidade.

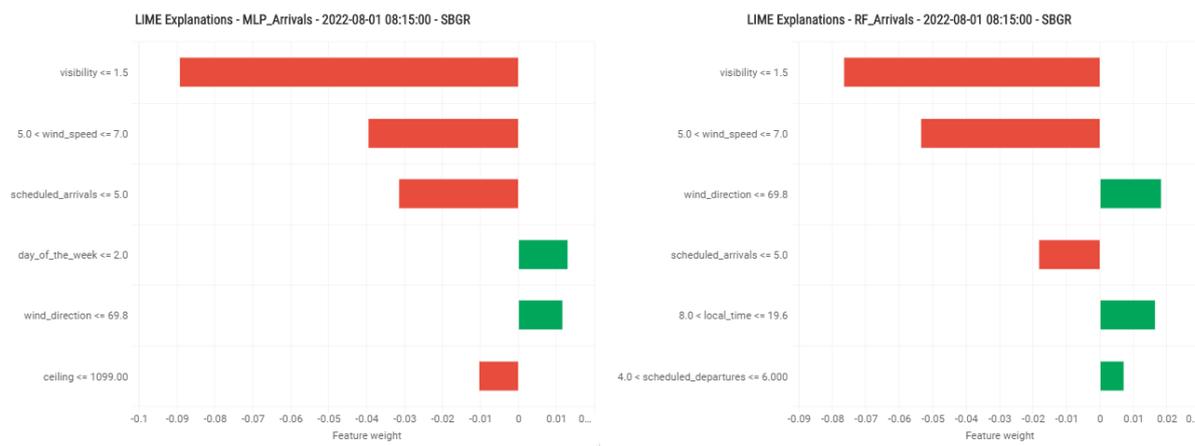


FIGURA 5.30 – Explicações de LIME de MLP e RF para capacidade de pousos em 2022-08-01 08:12:00, em GRU.

Fonte: Autor.

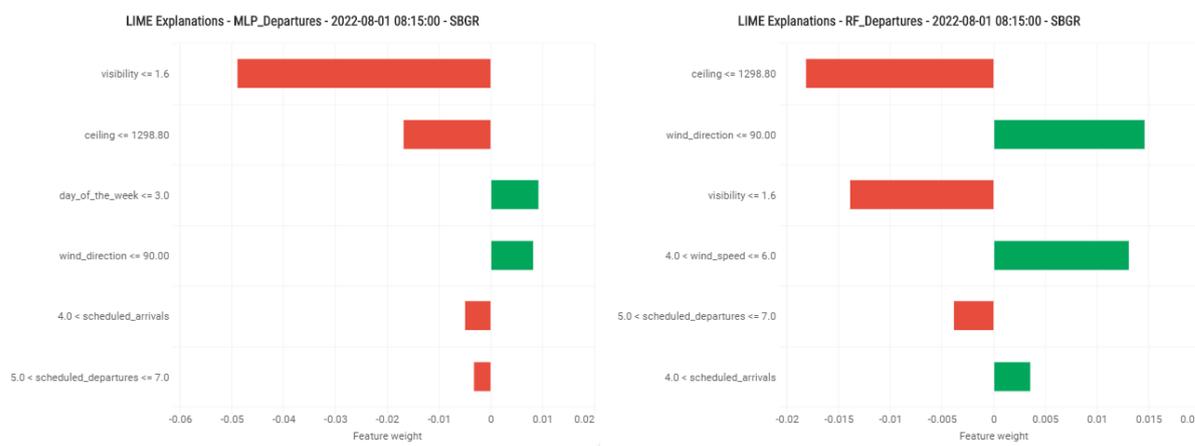


FIGURA 5.31 – Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-08-01 08:12:00, em GRU.

Fonte: Autor.

5.4.3 2022-07-29 06:21:00 VCP

A instância de 2022-07-29 06:21:00 em VCP é caracterizada pela condição meteorológica de VFR. Nessa instância, a visibilidade era de 5.396 NM e o teto era de 99999 ft, e o aeroporto operava sob a configuração 33|33. O aeroporto encontrava-se saturado tanto para pousos quanto decolagens, com 7 aeronaves na área terminal do aeroporto e 8 aeronaves em trânsito do gate para a PPD.

Assim como em GRU, a Tabela 5.5 mostra que os modelos apresentaram uma previsão de capacidade próxima à capacidade total declarada do aeroporto, o que é compatível com o esperado em situações de VFR. No entanto, é válido ressaltar que, nesse caso, as operações se distribuíram entre pousos e decolagens para a mesma cabeceira, o que faz com que somente a taxa total se aproxime da capacidade declarada.

As Figuras 5.32 e 5.33 apresentam as explicações de LIME dos modelos para essa

Operações	Aeronaves	Operações planejadas	Operações reais	Capacidade declarada	Capacidade MLP	Capacidade RF
Pousos	7	5	4	8	6	4
Decolagens	8	2	5	8	5	5
Total	15	7	9	10	-	-

TABELA 5.7 – Dados de operações e previsões dos modelos para 2022-07-29 06:21:00, em VCP.

instância. É notório que, para essa instância, as explicações obtidas são drasticamente diferentes, o que é indicativo de que a sensibilidade dos modelos na vizinhança da previsão é muito diferente para essas variáveis analisadas.

Também é possível notar na Figura 5.33 que ambos os modelos conseguiram captar a demanda de pousos da instância como uma das variáveis que influenciaram na redução de ocorrências de decolagens.

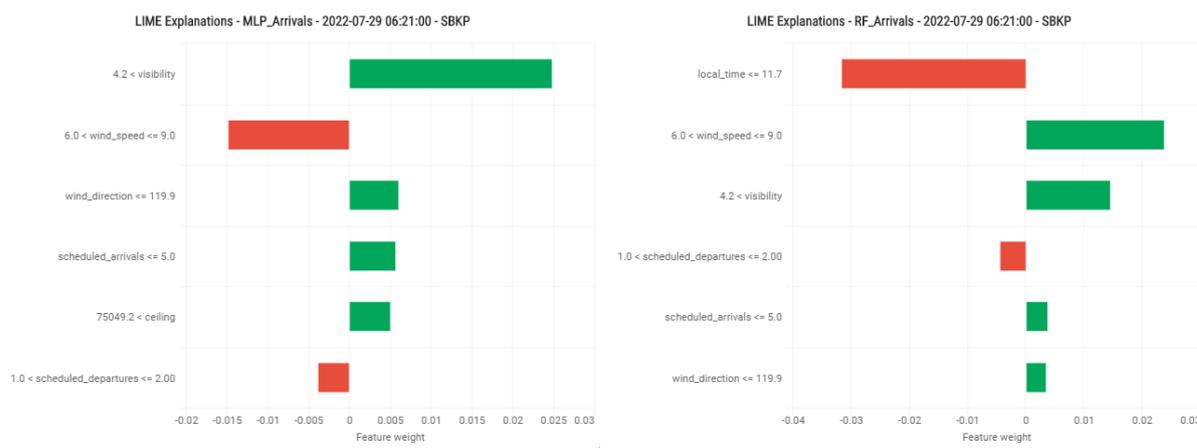


FIGURA 5.32 – Explicações de LIME de MLP e RF para capacidade de pousos em 2022-07-29 06:21:00, em VCP.

Fonte: Autor.

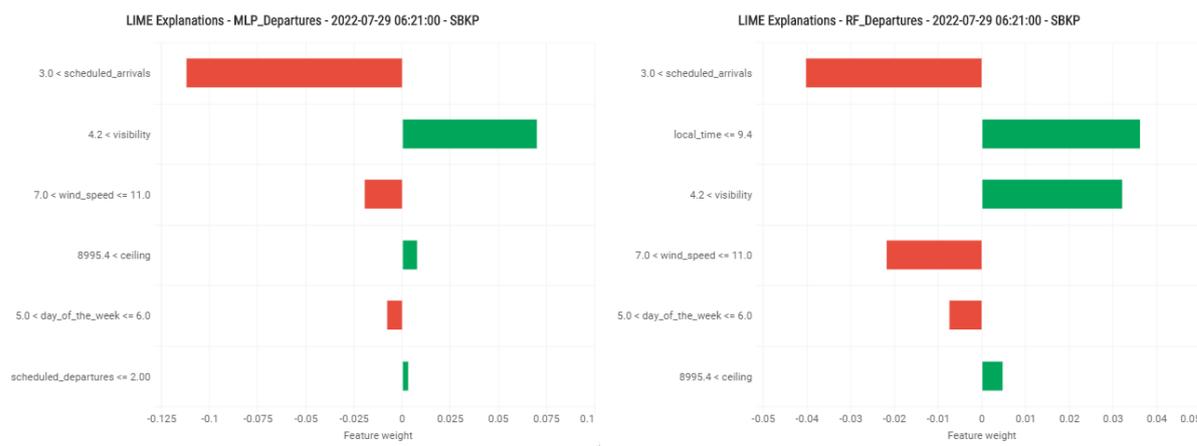


FIGURA 5.33 – Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-07-29 06:21:00, em VCP.

Fonte: Autor.

5.4.4 2022-12-29 23:00:00 VCP

A instância de 2022-12-29 23:00:00 em VCP é caracterizada pela condição meteorológica de LIFR. Nessa instância, a visibilidade era de 0.434 NM e o teto era de 400 ft, e o aeroporto operava sob a configuração 15|15. O aeroporto encontrava-se saturado somente para decolagens, com 3 aeronaves na área terminal do aeroporto e 8 aeronaves em trânsito do gate para a PPD.

A Tabela 5.8 mostra que o modelo de MLP apresentou uma previsão de capacidade reduzida em relação à capacidade declarada, o que é compatível com o esperado em situações de condições operacionais desfavoráveis como LIFR. O modelo de RF, no entanto, não detectou uma queda de capacidade de decolagens. Os modelos de pouso foram excluídos da análise dessa instância, dado que o aeroporto não se encontrava saturado para pousos.

Operações	Aeronaves	Operações planejadas	Operações reais	Capacidade declarada	Capacidade MLP	Capacidade RF
Pousos	3	2	0	8	-	-
Decolagens	8	5	6	8	4	8
Total	11	7	6	10	-	-

TABELA 5.8 – Dados de operações e previsões dos modelos para 2022-12-29 23:00:00, em VCP.

A Figura 5.34 apresenta as explicações de LIME dos modelos para essa instância. As explicações conseguiram captar a influência da visibilidade baixa entre as principais variáveis que levaram à redução de capacidade.



FIGURA 5.34 – Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-12-29 23:00:00, em VCP.

Fonte: Autor.

5.4.5 2022-09-07 10:11:00 CGH

A instância de 2022-09-07 10:11:00 em CGH é caracterizada pela condição meteorológica de LIFR. Nessa instância, a visibilidade era de 0.434 NM e o teto era de 200 ft, e o aeroporto operava sob a configuração 17R,17L|17R,17L. O aeroporto encontrava-se saturado somente para decolagens, com 3 aeronaves na área terminal do aeroporto e 7 aeronaves em trânsito do gate para a PPD.

A Tabela 5.8 mostra que os modelos apresentaram uma previsão de capacidade levemente reduzida em relação à capacidade declarada. É notório que o modelo de capacidade de decolagens sozinho não é suficiente para descrever a situação, dada a demanda existente de pousos, e dado que os modelos de previsão de capacidade de pousos não são aplicáveis a essa instância.

Operações	Aeronaves	Operações planejadas	Operações reais	Capacidade declarada	Capacidade MLP	Capacidade RF
Pousos	3	3	5	7	-	-
Decolagens	7	3	3	7	6	5
Total	10	6	8	11	-	-

TABELA 5.9 – Dados de operações e previsões dos modelos para 2022-09-07 10:11:00, em CGH.

A Figura 5.35 apresenta as explicações de LIME dos modelos para essa instância. Não houve consistência nas explicações obtidas para as variáveis, o que é indicativo da baixa confiabilidade das previsões dos modelos para essa instância.

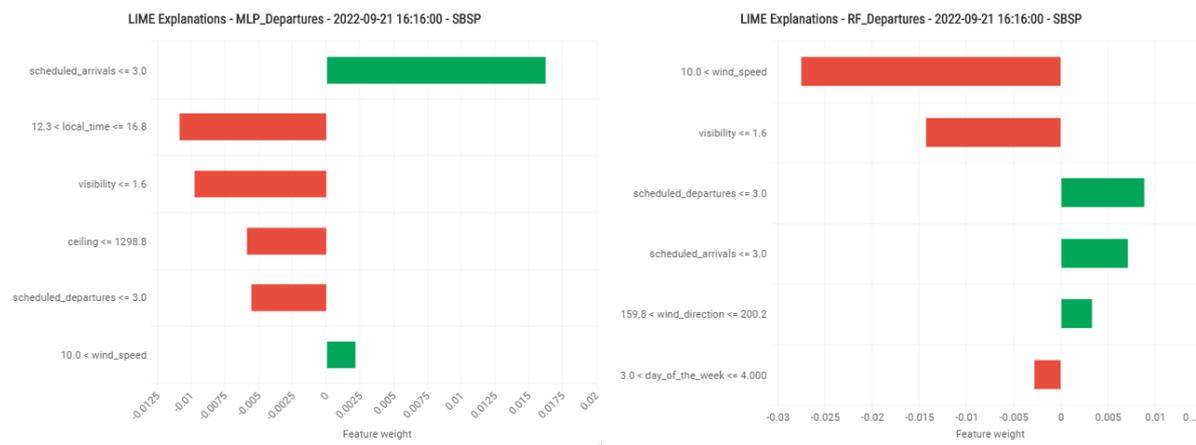


FIGURA 5.35 – Explicações de LIME de MLP e RF para capacidade de decolagens em 2022-09-07 10:11:00, em CGH.

Fonte: Autor.

6 Conclusões

Este trabalho combinou Inteligência Artificial Explicável (XAI) e técnicas de machine learning para desenvolver modelos preditivos explicáveis capazes de gerar previsões interpretáveis sobre capacidade de pistas de aeroportos, visando suporte automatizado confiável para tomada de decisões em gestão de fluxo de tráfego aéreo. Com base em dados históricos de demanda planejada de voos, meteorologia e tráfego para o Aeroporto Internacional de São Paulo/Guarulhos (GRU), Aeroporto Internacional de Viracopos/Campinas (VCP) e Aeroporto de São Paulo/Congonhas (CGH), os modelos preditivos foram aprendidos utilizando os algoritmos de Multilayer Perceptron (MLP) e Random Forest (RF). Em seguida, utilizou-se a abordagem de Local Interpretable Model-agnostic Explanations (LIME) para gerar explicações das previsões.

Os modelos aprendidos mostraram bom desempenho preditivo, com os modelos MLP entregando previsões de configuração de pistas com precisão de 90.59%, 91.13% e 90.00%, previsões de capacidade de pousos com RMSE de 1.042, 1.113 e 1.118 e previsões de capacidade de decolagens com RMSE de 1.341, 1.589 e 1.489 para GRU, VCP e CGH, respectivamente. O framework de LIME provou ser útil para rapidamente determinar as variáveis que mais influenciaram as previsões dos modelos, e as principais explicações mostraram-se consistentes entre os diferentes modelos aprendidos.

Para trabalhos futuros, melhorias potenciais no desempenho preditivo podem ser exploradas com o uso de modelos recursivos ou de outros algoritmos de aprendizado de máquina adequados para dados sequenciais, como Recurrent Neural Networks (RNN). Também podem ser medidos os desempenhos dos modelos ao utilizar dados de TAF, de forma a incorporar as incertezas associadas às previsões meteorológicas nos desempenhos medidos em dados de teste. Diferentes modelos substitutos podem ser considerados para gerar explicações locais com LIME, a fim de identificar o que melhor se ajusta localmente às previsões. Variáveis adicionais podem ser exploradas nos modelos preditivos com o objetivo de obter melhoria na qualidade das explicações, como, por exemplo, variáveis que indicam presença de tempestade ou rajada de vento. Além disso, outras técnicas de XAI podem ser exploradas, a fim de encontrar a que fornece melhor qualidade das explicações locais. Por fim, a metodologia apresentada nesta pesquisa pode ser estendida a outras aplicações para desenvolver modelos preditivos interpretáveis que possam ser integrados

em novas ferramentas de suporte à decisão confiáveis na aviação.

Referências

- ANAC. **Consulta de voos planejados - SIROS**. 2023. Disponível em: <https://siros.anac.gov.br/SIROS/view/registro/frmConsultaVoos>. Acesso em: 20 jun. 2023.
- AVERY, J.; BALAKRISHNAN, H. Predicting Airport Runway Configuration: A Discrete-Choice Modeling Approach. *In: Eleventh USA/Europe Air Traffic Management Research and Development Seminar. Proceedings [...]*. Lisbon, Portugal: [s.n.], 2015. p. 1–11.
- CGNA, C. de Gerenciamento da N. A. **Relatório Comparativo de Tráfego Aéreo 50 Aeródromos**. Abril 2023. http://portal.cgna.decea.mil.br/files/uploads/relatorios_trafego_aereo/Relatorio_Comparativo_Trafego_Aereo_50AD.pdf. Acesso em: 15 Mai. 2023.
- CHOI, S.; KIM, Y. J. Artificial neural network models for airport capacity prediction. **Journal of Air Transport Management**, v. 97, p. 102146, 2021. ISSN 0969-6997. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0969699721001277>.
- CID, G. **How LIME works | Understanding in 5 steps**. May 2023. Disponível em: <https://www.openlayer.com/blog/post/understanding-lime-in-5-steps>. Acesso em: 12 nov. 2023.
- DECEA. **Portaria DECEA n 78/DGCEA, de 23 de março de 2015. Aprova a reedição do MCA 100-14, Manual que trata da 'Capacidade do Sistema de Pistas'**. Rio de Janeiro: [s.n.], 15 de abril 2015. Boletim do Comando da Aeronáutica.
- DEGAS, A.; ISLAM, M. R.; HURTER, C.; BARUA, S.; RAHMAN, H.; POUDEL, M.; RUSCIO, D.; AHMED, M. U.; BEGUM, S.; RAHMAN, M. A.; BONELLI, S.; CARTOCCI, G.; FLUMERI, G. D.; BORGHINI, G.; BABILONI, F.; ARICÓ, P. A survey on artificial intelligence (ai) and explainable ai in air traffic management: Current trends and development with future research trajectory. **Applied Sciences**, v. 12, n. 3, 2022. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/12/3/1295>.
- FAA, F. A. A. **Order JO 7210.3Z - Facility Operation and Administration**. 2023. Disponível em: https://www.faa.gov/air_traffic/publications/atpubs/foa_html/chap10_section_7.html. Acesso em: 20 jun. 2023.
- JIAO, Q.-Y.; LI, N.; ZHENG, Z.-G.; FENG, Z.; REN, G.-S.; QIANG, Y.-G. Attention mechanism-based deep learning method for predicting airport acceptance rate: A case

study of hong kong airport. **Journal of Aeronautics, Astronautics and Aviation**, Aeronautical and Astronautical Society of the Republic of China, v. 55, n. 2, p. 185–200, 2023.

MURÇA, M. C. R.; HANSMAN, R. J. Predicting and planning airport acceptance rates in metroplex systems for improved traffic flow management decision support. **Transportation Research Part C: Emerging Technologies**, v. 97, p. 301–323, 2018. ISSN 0968-090X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0968090X18315298>.

REBOLLO, J.; KHATER, S.; COUPE, W. J. A Recursive Multi-step Machine Learning Approach for Airport Configuration Prediction. *In: AIAA AVIATION 2021 FORUM. Proceedings [...]. [S.l.: s.n.]*, 2021. p. 2406. Disponível em: <https://arc.aiaa.org/doi/abs/10.2514/6.2021-2406>.

REDEMET. 2023. Disponível em: <https://www.redemet.aer.mil.br>. Acesso em: 20 jun. 2023.

RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. "Why Should I Trust You?": Explaining the Predictions of Any Classifier. *In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Proceedings [...]. New York, NY, USA: Association for Computing Machinery, 2016. (KDD '16)*, p. 1135–1144. ISBN 9781450342322. Disponível em: <https://doi.org/10.1145/2939672.2939778>.

WANG, Y.; ZHANG, Y. Prediction of runway configurations and airport acceptance rates for multi-airport system using gridded weather forecast. **Transportation Research Part C: Emerging Technologies**, v. 125, p. 103049, 2021. ISSN 0968-090X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0968090X21000796>.

WOO, C. J.; GOH, S. K.; ALAM, S.; FERDAUS, M. M.; ELLEJMI, M. A runway exit prediction model with visually explainable machine decisions. *In: 2022 International Conference on Research in Air Transportation (ICRAT 2022). Proceedings [...]. [S.l.: s.n.]*, 2022. p. 1–9.

FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO <p style="text-align: center;">TC</p>	2. DATA <p style="text-align: center;">21 de novembro de 2023</p>	3. DOCUMENTO Nº <p style="text-align: center;">DCTA/ITA/TC-105/2023</p>	4. Nº DE PÁGINAS <p style="text-align: center;">69</p>
5. TÍTULO E SUBTÍTULO: Estudo da capacidade do sistema de pistas de um aeroporto por meio de Inteligência Artificial Explicável			
6. AUTOR(ES): Igor Galhano Gomes			
7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica – ITA			
8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: Capacidade Aeroportuária, Configuração de Pista, Machine Learning, XAI, LIME			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Aprendizagem (inteligência artificial); Aeroportos; Capacidade aeroportuária; Pistas(de pouso e decolagem); Gerenciamento; Tráfego aéreo; Tomada de decisões; Transporte aéreo; Transportes.			
10. APRESENTAÇÃO: (X) Nacional () Internacional ITA, São José dos Campos. Curso de Graduação em Engenharia Civil-Aeronáutica. Orientador: Prof. Dr. Marcelo Xavier Guterres. Publicado em 2023.			
11. RESUMO: Embora métodos de machine learning tenham sido amplamente utilizados em estudos da indústria da aviação recentemente, houve progresso limitado em tornar os resultados desses modelos compreensíveis para os humanos. Dada a importância de previsões explicáveis para um suporte à decisão confiável no Gerenciamento de Tráfego Aéreo (ATM), este estudo explora o uso de Multilayer Perceptron e Random Forests, combinados com uma abordagem de Local Interpretable Model-agnostic Explanations (LIME), para desenvolver modelos preditivos capazes de gerar previsões interpretáveis da configuração ativa de pistas e da capacidade dinâmica do sistema de pistas de aeroportos. Uma abordagem de aprendizado supervisionado foi usada para construir os modelos a partir de dados históricos de demanda, meteorologia e operações em Aeroporto Internacional de São Paulo/Guarulhos, Aeroporto Internacional de Viracopos/Campinas e Aeroporto de São Paulo/Congonhas. Os modelos preditivos foram capazes de fornecer previsões da configuração da pista com uma precisão superior a 90,00% e previsões da capacidade de pousos/decolagens com erros abaixo de 1,589. Com LIME, de forma geral, explicações consistentes foram obtidas através dos modelos em cada previsão. Uma ferramenta preditiva interativa foi criada para fornecer as previsões da configuração da pista e da capacidade, bem como os principais fatores contribuintes para cada previsão, dentro de um horizonte de previsão de 24 horas. Esta pesquisa visa melhorar a tomada de decisão, integrando modelos preditivos e modelos explicativos em aplicações que fornecem informações úteis para ATM.			
12. GRAU DE SIGILO: <p style="text-align: center;"> (X) OSTENSIVO () RESERVADO () SECRETO </p>			