

INSTITUTO TECNOLÓGICO DE AERONÁUTICA



Bruno Sampaio Passos Homem

**UMA ABORDAGEM BASEADA EM DADOS PARA
CARACTERIZAÇÃO DA COMPLEXIDADE DO
TRÁFEGO ÁEREO**

Trabalho de Graduação
2020

Curso de Engenharia Civil-Aeronáutica

Bruno Sampaio Passos Homem

**UMA ABORDAGEM BASEADA EM DADOS PARA
CARACTERIZAÇÃO DA COMPLEXIDADE DO
TRÁFEGO ÁEREO**

Orientadora

Prof. Dra. Mayara Condé Rocha Murça (ITA)

Coorientador

Prof. Dr. Marcelo Xavier Guterres (ITA)

ENGENHARIA CIVIL-AERONÁUTICA

SÃO JOSÉ DOS CAMPOS
INSTITUTO TECNOLÓGICO DE AERONÁUTICA

Dados Internacionais de Catalogação-na-Publicação (CIP)

Divisão de Informação e Documentação

Homem, Bruno Sampaio Passos

Uma Abordagem Baseada em Dados para Caracterização da Complexidade do Tráfego Áereo /
Bruno Sampaio Passos Homem.

São José dos Campos, 2020.

56f.

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

1. Controle de tráfego aéreo. 2. Complexidade. 3. Espaço aéreo. I. Instituto Tecnológico de Aeronáutica. II. Uma Abordagem Baseada em Dados para Caracterização da Complexidade do Tráfego Áereo.

REFERÊNCIA BIBLIOGRÁFICA

HOMEM, Bruno Sampaio Passos. **Uma Abordagem Baseada em Dados para Caracterização da Complexidade do Tráfego Áereo**. 2020. 56f. Trabalho de Conclusão de Curso (Graduação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Bruno Sampaio Passos Homem

TÍTULO DO TRABALHO: Uma Abordagem Baseada em Dados para Caracterização da Complexidade do Tráfego Áereo.

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

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

Bruno Sampaio Passos Homem

Bruno Sampaio Passos Homem

Rua H8B, 227

12.228-461 – São José dos Campos-SP

UMA ABORDAGEM BASEADA EM DADOS PARA CARACTERIZAÇÃO DA COMPLEXIDADE DO TRÁFEGO ÁEREO

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação

Bruno Sampaio Passos Homem

Bruno Sampaio Passos Homem

Autor

Mayara Condé Rocha Murça

Prof. Dra. Mayara Condé Rocha Murça (ITA)

Orientadora

Marcelo Xavier Guterres

Prof. Dr. Marcelo Xavier Guterres (ITA)

Coorientador

João Cláudio Bassan

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

São José dos Campos, 25 de Novembro de 2020.

Ao meu pai Gladstone Bicalho (in memorian), que sempre me apoiou e nunca perdeu a fé nos meus sonhos.

Agradecimentos

Acima de tudo, à minha mãe, Néli Sampaio Passos Homem, por toda a luta e dedicação que teve por mim, e ao meu pai, Gladstone Bicalho Passos Homem, por toda a fé e confiança que teve em mim.

Às minhas irmãs, Bárbara Sampaio Passos Homem e Monike Sampaio Passos Homem, à minha sobrinha, Maria Júlia Guimarães Passos Homem, por todo amor e apoio. Ao meu amigo de todas as horas, Eduardo da Silva Guimarães, por todo o apoio.

Ao meu avô, Héres Surubiú Passos Homem, pela dedicação e incentivo.

Às minhas avós, Stella Matutina Bicalho Passos Homem e Neide Almeida Sampaio, por todo amor e carinho.

Aos meus amigos: Lucas França de Oliveira, Daniel Custódio, Matheus F. S. B. F. Rodrigues, e, em especial, a Lucas Barroso Knupp e a Iago Pinheiro Moura por todo o suporte que me deram e todos os momentos memoráveis.

À Prof. Dra. Cristiane Pessôa da Cunha Lacaz, por todo o carinho e pelo apoio fundamental na minha trajetória na Instituição.

À AAEITA, ao João Francisco Mazariolli, à Ten Cássia Souza Guerreiro e à Ten Camila Jacometti Pinheiro Nagarol, pelo suporte a minha formação.

Aos meus orientadores Profa. Dra. Mayara Condé Rocha Murça e Prof. Dr. Marcelo Xavier Guterres, pela dedicação e incentivo.

“Se não existe esforço, não existe progresso”
— POR FREDERICK DOUGLASS

Resumo

A complexidade do tráfego aéreo é um conceito subjetivo utilizado para expressar o nível de dificuldade do controle de tráfego e o potencial de geração de carga de trabalho para o controlador, sendo um fator determinante da capacidade de setor. O desenvolvimento de indicadores para quantificar a complexidade é fundamental para apoiar a tomada de decisão no gerenciamento da capacidade do espaço aéreo e do fluxo de tráfego, de forma a torná-lo mais dinâmico, proativo e eficiente. Este trabalho de graduação tem por objetivo estudar os principais fatores que afetam a complexidade do tráfego aéreo e propor uma abordagem baseada em dados para caracterização e previsão da complexidade. O estudo de caso é a área terminal São Paulo (TMA-SP), espaço aéreo terminal de maior movimentação de aeronaves no Brasil. Dados históricos de trajetórias de voo e de meteorologia durante três meses de operações são utilizados para o desenvolvimento do trabalho. Primeiramente, calcula-se um indicador de complexidade horária para diferentes volumes de espaço aéreo da TMA-SP a partir dos dados de trajetória. Técnicas de visualização de dados são utilizadas para apresentação da magnitude, variabilidade e distribuição espacial da complexidade. A partir da quantificação da complexidade, utiliza-se o método de Florestas Aleatórias para o aprendizado de máquina supervisionado para desenvolver um modelo preditivo de complexidade. Os resultados indicam que a complexidade, bem como o erro de previsão, apresentam uma grande variação espacial. Por fim, observa-se que a demanda e a configuração de operação determinada pela direção do vento são os principais fatores que contribuem para o nível de complexidade na TMA-SP.

Abstract

The air traffic control complexity is a subjective concept used to express the level of difficulty of air traffic control and the potential for generating controller workload, being a determining factor of the sector's capacity. The development of indicators for complexity quantification is key to support decision-making in airspace capacity and traffic flow management, allowing for a more dynamic, proactive and efficient management. This undergraduate work aims to study the main factors that affect the complexity of air traffic and to propose a data-driven approach to characterize and predict complexity. Our case study is the São Paulo terminal area (TMA-SP), which is the terminal airspace with the highest number of aircraft movements in Brazil. Historical flight trajectory data and meteorological data for three months of operations are used to develop the work. First, an hourly complexity indicator for different airspace volumes of the TMA-SP is calculated from the trajectory data. Data visualization techniques are used to display the magnitude, variability and spatial distribution of complexity. From the quantification of complexity, we use the Random Forests method for supervised machine learning to develop a predictive model of complexity. The results indicate that both the complexity and the prediction error present significant spatial variation. Finally, we observe that the demand and the operational configuration determined by the wind direction are the main factors that contribute to the complexity level in the TMA-SP.

Lista de Figuras

FIGURA 1.1 – Evolução do mercado global de transporte aéreo antes e depois da COVID-19. Fonte: Garcia (2020)	15
FIGURA 1.2 – Evolução do mercado global doméstico e internacional de transporte aéreo antes e depois da COVID-19. Fonte: Garcia (2020)	16
FIGURA 1.3 – Evolução das demandas e das capacidades de pista agregadas dos três principais aeroportos de São Paulo. Fonte: MTPA (2018)	17
FIGURA 3.1 – Trajetórias de voo na TMA-SP para o dia 13/01/2020	23
FIGURA 3.2 – Subdivisão da TMA-SP em células de 20x20 milhas náuticas para a faixa de altitude 5000-8000 pés	26
FIGURA 4.1 – <i>Boxplot</i> da complexidade para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor	31
FIGURA 4.2 – <i>Boxplot</i> da complexidade para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor	31
FIGURA 4.3 – <i>Boxplot</i> da complexidade para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor	32
FIGURA 4.4 – <i>Boxplot</i> da complexidade para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor	32
FIGURA 4.5 – <i>Boxplot</i> da complexidade para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor	33
FIGURA 4.6 – Variação do erro de previsão em função do número de árvores. Fonte: O Autor	34
FIGURA 4.7 – Gráfico de barras da importância das variáveis de entrada. Fonte: O Autor	36
FIGURA 4.8 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor	38

FIGURA 4.9 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor	39
FIGURA 4.10 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor	40
FIGURA 4.11 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor	41
FIGURA 4.12 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor	42
FIGURA 4.13 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor	43
FIGURA 4.14 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor	44
FIGURA 4.15 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor	45
FIGURA 4.16 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor	46
FIGURA 4.17 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor	47
FIGURA 4.18 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor	48
FIGURA 4.19 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor	49
FIGURA 4.20 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor	50
FIGURA 4.21 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor	51
FIGURA 4.22 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor	52

Lista de Tabelas

TABELA 4.1 – Valores da importância das variáveis de entrada	35
TABELA 4.2 – Erro de previsão por célula	37

Lista de Abreviaturas e Siglas

ICAO	International Civil Aviation Organization (<i>Organização Internacional de Aviação Civil</i>)
MTPA	Ministerio dos Transportes, Portos e Aviação Civil
IATA	International Air Transport Association (<i>Associação Internacional de Transporte Aéreo</i>)
EUROCONTROL	European Organization for the Safety of Air Navigation (<i>Organização Europeia para a Segurança da Navegação Aérea</i>)
COVID-19	Doença causada pelo coronavírus, denominado SARS-CoV-2, que apresenta um espectro clínico variando de infecções assintomáticas a quadros graves e o responsável pela pandemia mundial ocorrendo no presente ano (2020).
RPK	Revenue Passenger Kilometres (<i>Passageiros-Quilômetros Pagos</i>)
GRU	Aeroporto Internacional de Guarulhos/São Paulo
CGH	Aeroporto de Congonhas/São Paulo
VCP	Aeroporto Internacional de Viracopos/Campinas
PAN	Plano Aeroviário Nacional
TMA-SP	Terminal Maneuvering Area of São Paulo (<i>Área de Controle Terminal de São Paulo</i>)
RMSE	Root Mean Squared Error (<i>Raiz Quadrada do Erro Quadrático Médio</i>)

Lista de Símbolos

T_k	Horas de voo
D_k	Horas de potenciais interações
H_k	Horas de interações horizontais
V_k	Horas de interações verticais
S_k	Horas de interações de velocidade
<i>AdjustedDensity</i>	Métrica de complexidade que reflete a densidade do tráfego
<i>HDIF</i>	Métrica de complexidade que reflete a estrutura do fluxo
<i>VDIF</i>	Métrica de complexidade que reflete o tráfego aéreo em manobra
<i>SDIF</i>	Métrica de complexidade que reflete o mix de aeronaves
<i>StructuralIndex</i>	Métrica de complexidade que reflete a estrutura do fluxo de tráfego desrelacionada à densidade de tráfego
<i>ComplexityScore</i>	Métrica de complexidade adotada nesse trabalho

Sumário

1	INTRODUÇÃO	15
2	REFERENCIAL TEÓRICO	19
3	METODOLOGIA	22
3.1	Descrição da Base de Dados	22
3.2	Pré-processamento dos Dados	24
3.3	Cálculo de Métricas de Complexidade	26
3.4	Modelo Preditivo de Complexidade	28
4	RESULTADOS E DISCUSSÃO	30
4.1	Caracterização da Complexidade na TMA-SP	30
4.2	Análise de Desempenho Preditivo do Modelo de Complexidade	33
5	CONCLUSÃO	53
	REFERÊNCIAS	54
	GLOSSÁRIO	56
8	DESCARTAR	57

1 Introdução

A demanda mundial de transporte aéreo tem dobrado a cada 15 anos desde 1977 (ICAO, 2014), e a previsão era que o número de passageiros transportados atingisse 8,2 bilhões em 2037 (IATA, 2018). A situação da pandemia de COVID-19 no ano de 2020 trouxe uma redução acentuada na demanda do transporte aéreo e gerou um impacto significativo na indústria da aviação. No entanto, segundo a Associação Internacional de Transporte Aéreo (International Air Transport Association - IATA), a previsão é que, em 2024, o mercado já se reestruture, com o número de passageiros-quilômetros pagos (RPK) a apenas 10% abaixo das previsões anteriores à situação da COVID-19 (GARCIA, 2020), como mostra a Figura 1.1. Ainda segundo a IATA, a recuperação do RPK no mercado doméstico será mais rápida que no mercado internacional (GARCIA, 2020), como mostra a Figura 1.2.

Return to growth post-COVID but at a lower level Global RPKs forecast to be 32%-41% below expected levels in 2021

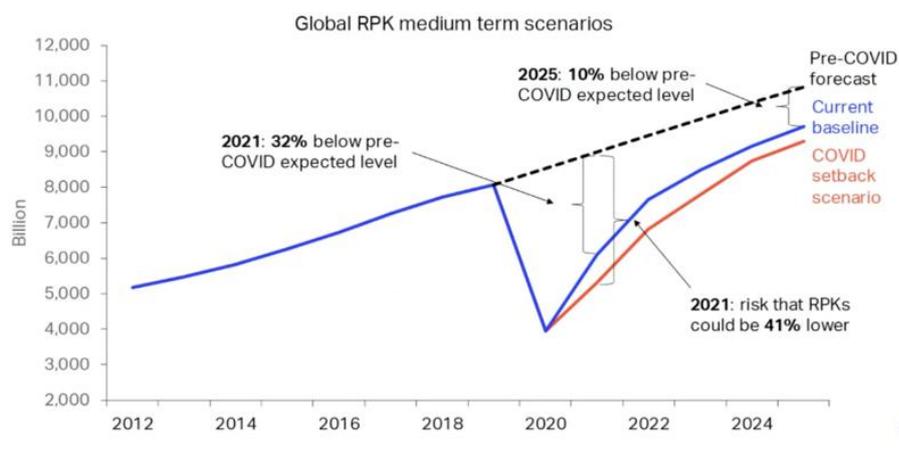


FIGURA 1.1 – Evolução do mercado global de transporte aéreo antes e depois da COVID-19. Fonte: Garcia (2020)

International RPKs will lag domestic air travel markets International air travel may not recover 2019 levels until 2023-24

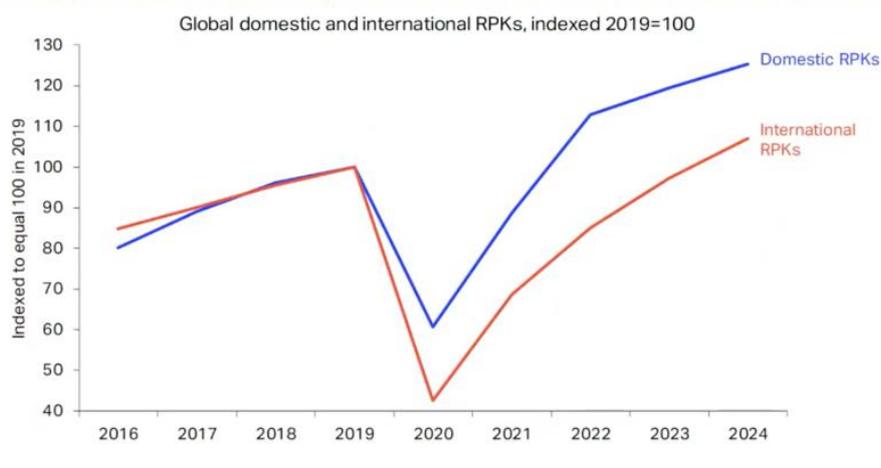


FIGURA 1.2 – Evolução do mercado global doméstico e internacional de transporte aéreo antes e depois da COVID-19. Fonte: Garcia (2020)

Com a expectativa de retomada do crescimento da demanda de transporte aéreo, os esforços para ampliação da capacidade de aeroportos e do espaço aéreo serão intensificados. Em fevereiro de 2019, os três principais aeroportos de São Paulo, Aeroporto de Congonhas (CGH), Aeroporto Internacional de Guarulhos (GRU) e Aeroporto Internacional de Viracopos (VCP), concentravam 36% da demanda do transporte aéreo brasileiro (AEROIN, 2019). Estimativas indicavam que, já em 2022, a soma das demandas superariam a soma das capacidades dos três aeroportos (MTPA, 2018), como mostra a Figura 1.3. Apesar da retração da demanda causada pela COVID-19, esta é uma situação temporária e uma análise de longo prazo evidencia a necessidade de estratégias para aumento da capacidade dos aeroportos e do espaço aéreo terminal.

FIGURA 31: ANÁLISE DAS DEMANDAS E CAPACIDADES DE PISTA AGREGADAS DOS AEROPORTOS DE SÃO PAULO

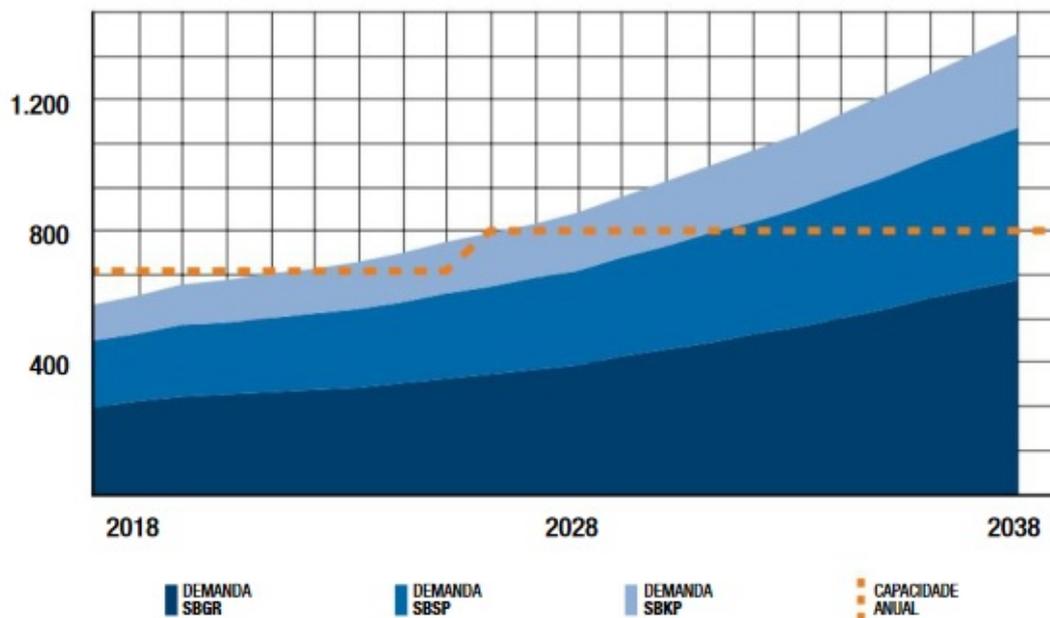


FIGURA 1.3 – Evolução das demandas e das capacidades de pista agregadas dos três principais aeroportos de São Paulo. Fonte: MTPA (2018)

Paralelamente à ampliação da capacidade de aeroportos e do espaço aéreo, devem ser exploradas soluções para aumentar a eficiência na utilização da capacidade existente. Uma das iniciativas da próxima geração de sistemas de gerenciamento de tráfego aéreo aborda o conceito de “Configuração Dinâmica do Espaço Aéreo” ou “Setorização Dinâmica”. Este conceito propõe uma solução mais adaptável para a alocação do espaço aéreo, levando em consideração as mudanças temporais da complexidade sobre uma região do espaço aéreo. A complexidade do controle de tráfego aéreo é o conjunto de fatores ambientais, de tráfego e do espaço aéreo que afetam a carga de trabalho do controlador e, portanto, a capacidade de setor. Conhecendo-se a dinâmica da complexidade, os recursos de controle de tráfego aéreo podem ser empregados de forma mais eficaz, de forma a evitar situações de sobrecarga e subutilização.

Neste contexto, este trabalho de graduação tem como objeto desenvolver uma abordagem baseada em dados para quantificação e previsão da complexidade do tráfego aéreo, visando apoiar a tomada de decisão no gerenciamento dinâmico da capacidade do espaço aéreo. O estudo de caso será a Área Terminal de São Paulo (TMA-SP), dada a sua importância no sistema de transporte aéreo brasileiro. A trabalho utilizará dados históricos de trajetória de voo e de meteorologia para CGH, GRU e VCP durante o período de dezembro de 2019 a fevereiro de 2020, período anterior à drástica queda da demanda do transporte aéreo devido à situação da COVID-19 (MALICKI, 2020).

Subdivide-se a região da TMA-SP em 210 células e, a partir da interpolação dos dados de trajetória, obtém-se, para cada hora e para cada célula, um indicador de complexidade, denominado *ComplexityScore*, e métricas intermediárias. A partir dessa quantificação da complexidade, busca-se correlacionar fatores que possivelmente influenciam a complexidade, como: número de decolagens, número de pousos, mix de aeronaves, meteorologia, dentre outros (MOGFORD *et al.*, 1995). Além disso, experimenta-se correlacionar também à célula e ao horário, para analisar a influência das variáveis espacial e temporal na complexidade. Seleciona-se para a análise fatores os quais sejam possíveis de se determinar instrumentalmente, sejam constantemente documentados e já possuam métodos de previsão de valores futuros. Aplicando métodos de aprendizado de máquina supervisionado para mapear este fatores em nível de complexidade, desenvolve-se um modelo para prever, quantitativamente, a complexidade futura. A partir disso, gera-se recursos ao Gerenciamento do Tráfego Aéreo brasileiro para otimizar o uso do espaço aéreo a partir da relação entre a complexidade, a carga de trabalho do controlador e a capacidade de setor.

2 Referencial Teórico

O gerenciamento de tráfego aéreo abrange os serviços de controle de tráfego aéreo, informação de voo e alerta, gerenciamento de fluxo de tráfego aéreo e gerenciamento do espaço aéreo (DURAND *et al.*, 2016). O controle de tráfego aéreo é o processo exercido no nível operacional, que tem o objetivo de garantir as separações de segurança entre aeronaves no espaço aéreo e entre aeronaves e obstáculos durante procedimentos de chegada e partida, de forma a evitar colisões. O serviço de informação de voo garante que os usuários do espaço aéreo tenham acesso a informações críticas para a realização das suas operações de forma segura, como meteorologia, condição operacional de aeródromos e existência de potenciais riscos à operação. Já o serviço de alerta é responsável por notificar autoridades competentes sobre aeronaves em situação de emergência que precisem de assistência. O gerenciamento do fluxo de tráfego aéreo é responsável por ajustar os fluxos de tráfego aéreo de forma a mitigar os impactos causados por desequilíbrios entre demanda e capacidade. ICAO (2008) define capacidade e demanda do tráfego aéreo como sendo, respectivamente, o número máximo de aeronaves capazes de serem atendidas em um determinado período de tempo pelo sistema ou um de seus componentes e o número de aeronaves requisitando usar o sistema de gerenciamento de tráfego aéreo em um determinado período de tempo. Por fim, o sistema de gerenciamento de tráfego aéreo também gerencia o espaço aéreo, alocando e estruturando o espaço aéreo de forma a acomodar os diferentes volumes de tráfego e tipos de operação e atender os interesses dos diferentes usuários.

A capacidade do espaço aéreo é definida pela capacidade de setor. Os setores são as menores subdivisões de espaço aéreo sob a responsabilidade de um controlador de tráfego aéreo. A capacidade de setor é fundamentalmente determinada pela carga de trabalho do controlador que, por sua vez, é afetada pela complexidade do controle de tráfego aéreo.

Majumdar e Ochiend (2002) definem a carga de trabalho do controlador de tráfego aéreo como a quantidade de carga física e mental para a realização de suas tarefas, que, na prática, pode variar conforme diversos fatores relacionados à dinâmica do tráfego, à rede de rotas e a aspectos estocásticos. Welch *et al.* (2007) dividiram as tarefas do controlador em quatro categorias: tarefas de segundo plano, de transição, recorrentes e de conflito. Tarefas de segundo plano incluem atividades de rotina que são realizadas independente-

mente da presença de aeronaves no setor, como coordenação com supervisores ou análise de previsões do tempo. As tarefas de transição são associadas a transferências entre setores sempre que uma aeronave cruza a fronteira do setor. Tarefas recorrentes são atividades repetitivas que ocorrem enquanto a aeronave está presente no setor e incluem escaneamento do tráfego, monitoramento de conformidade da trajetória ou vetoração para desvio de condições climáticas adversas. Finalmente, as tarefas de conflito ocorrem sempre que o controlador precisa tomar medidas para prevenir um conflito entre duas aeronaves.

Mogford et al. (1995) relacionam o conceito de carga de trabalho do controlador com a complexidade do tráfego aéreo, abordando possíveis fatores de influência na complexidade. O termo "complexidade do controle do tráfego aéreo" pode ser resumido como a coleção de fatores ambientais, de tráfego e de espaço aéreo que determina a dificuldade de controle e afeta a taxa de aumento da carga de trabalho do controlador. A complexidade do controle de tráfego aéreo também é normalmente referida como "densidade dinâmica", descrito como os "fatores essenciais que afetam a taxa de conflito tanto em rota como no espaço aéreo terminal"(HUGHES, 2000).

Mogford et al. (1995) dividiram a complexidade do controle de tráfego aéreo em dois componentes principais: a complexidade do setor e complexidade de tráfego. A complexidade do setor se refere aos aspectos físicos do setor (por exemplo, geometria, tamanho, número de setores vizinhos), enquanto a complexidade do tráfego engloba os fatores associados ao fluxo de aeronaves (por exemplo, número de fluxos descendentes e ascendentes, número de fluxos que se cruzam). Fatores de complexidade comumente discutidos nos trabalhos revisados incluem o número de aeronaves, a geometria do setor, os padrões de separação, o *mix* de aeronaves e as condições climáticas.

A análise da complexidade do controle de tráfego aéreo é importante para o processo de desenho do espaço aéreo. Uma série de critérios de "melhores práticas" para a setorização do espaço aéreo (ou seja, divisão do espaço aéreo em setores) são extraídos de fatores de complexidade relevantes. Por exemplo, os setores devem ter formas convexas para evitar a reentrada da trajetória, os fluxos dominantes devem cruzar os limites do setor quase perpendicularmente para minimizar o tempo perto do limite, os pontos de interseção, bem como os fluxos dominantes, devem permanecer suficientemente dentro do setor para garantir tempo suficiente para o gerenciamento conflitos e deixar espaço para manobras, etc (SABHNANI *et al.*, 2010).

A quantificação da complexidade do tráfego aéreo também é fundamental para o gerenciamento tático do espaço aéreo. Uma das iniciativas no contexto da modernização dos sistemas de gerenciamento de tráfego aéreo diz respeito ao conceito de "Setorização Dinâmica". Este novo conceito propõe uma solução mais adaptativa para a alocação do espaço aéreo, levando em consideração a natureza dinâmica e estocástica da demanda e da complexidade do tráfego. Como resultado, os recursos humanos podem ser empregados

de forma mais otimizada, evitando situações de sobrecarga e subutilização, o que, por sua vez, tem o potencial de gerar benefícios como aumento de capacidade e redução de atrasos de voo.

3 Metodologia

3.1 Descrição da Base de Dados

Dados históricos de trajetórias de voo e de meteorologia para os meses de Dezembro/2019, Janeiro/2020 e Fevereiro/2020 são utilizados para o desenvolvimento do estudo.

A base de dados de trajetória é obtida através do serviço *online* de rastreamento de voos *FlightRadar24* (FLIGHTRADAR24, 2019-2020). Consideram-se os voos que tenham como origem ou destino um dos três principais aeroportos da região metropolitana de São Paulo, Aeroporto de Congonhas (CGH), Aeroporto Internacional de Guarulhos (GRU) e Aeroporto Internacional de Viracopos (VCP), os quais representam a maioria do tráfego aéreo na TMA-SP. A Figura 3.1 ilustra a amostra dos dados das operações na TMA-SP obtidos pela plataforma *FlightRadar24* referentes ao dia 13 de janeiro de 2020.

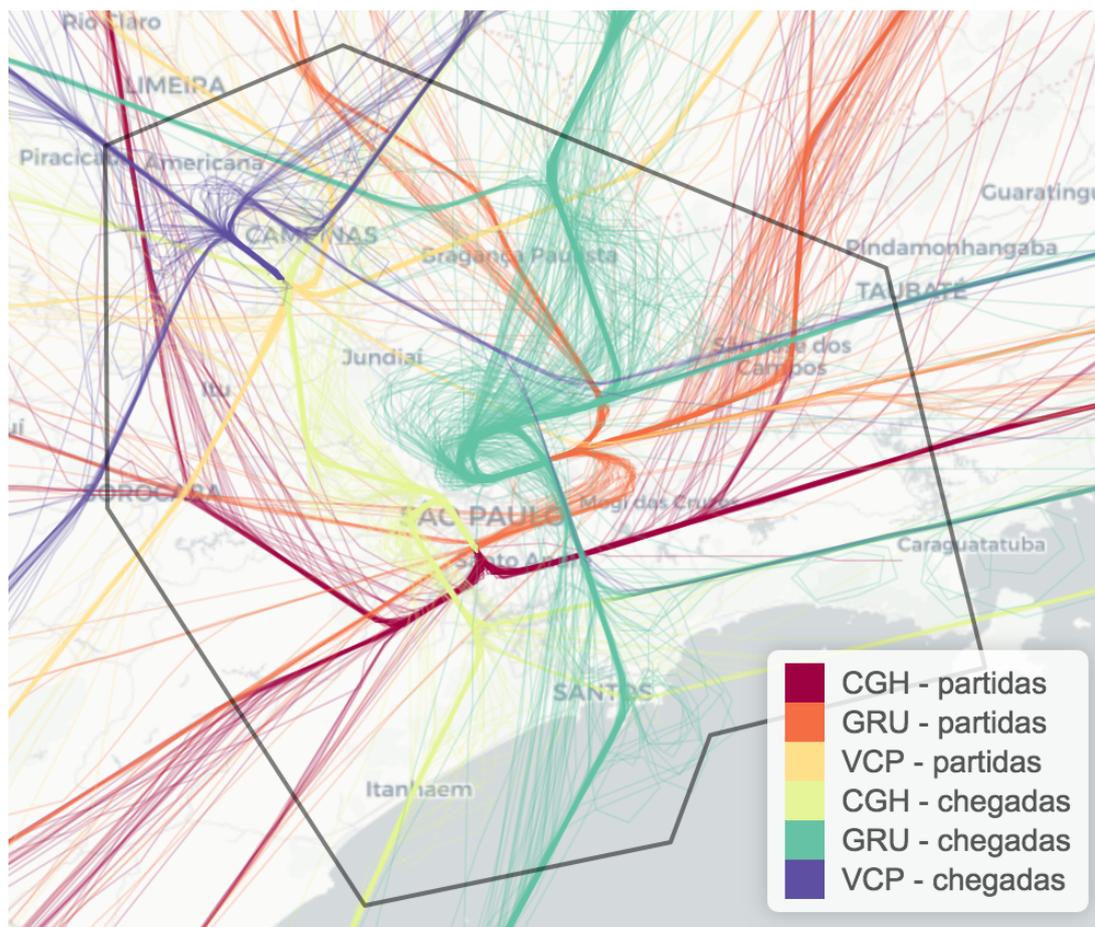


FIGURA 3.1 – Trajetórias de voo na TMA-SP para o dia 13/01/2020

Cada trajetória de voo é representada por um conjunto de observações, descritas a seguir:

<i>indicat</i>	Número inteiro <i>indicativo</i> da trajetória de voo
<i>time</i>	Data e horário da observação
<i>unix</i>	Número inteiro <i>indicativo</i> do instante em segundos da observação em referência às 00:00:00 UTC de 01/01/1970.
<i>lat</i>	Latitude da aeronave, em graus, no instante descrito por ' <i>time</i> ' e ' <i>unix</i> '
<i>lon</i>	Longitude da aeronave, em graus, no instante descrito por ' <i>time</i> ' e ' <i>unix</i> '
<i>alt</i>	Altitude da aeronave, em pés, no instante descrito por ' <i>time</i> ' e ' <i>unix</i> '
<i>speed</i>	Velocidade horizontal da aeronave, em nós, isto é, em milhas náuticas por hora, no instante descrito por ' <i>time</i> ' e ' <i>unix</i> '
<i>head</i>	Rumo da aeronave, em graus, no instante descrito por ' <i>time</i> ' e ' <i>unix</i> '
<i>equip</i>	Modelo da aeronave
<i>dest</i>	Aeroporto de destino do voo
<i>orig</i>	Aeroporto de origem do voo

A base de dados de meteorologia é obtida através do repositório de dados climatológicos da Universidade Estadual de Iowa (HERZMANN, 2020) e consiste dos relatórios METAR para CGH, GRU e VCP. O METAR é um informe codificado horário que apresenta as condições meteorológicas de superfície em um aeródromo específico, contendo dados de direção e velocidade do vento, pressão atmosférica, altura das nuvens, visibilidade, temperatura e condição do tempo (chuva, tempestade, etc).

3.2 Pré-processamento dos Dados

A base de dados de trajetórias contém observações registradas aproximadamente a cada minuto ao longo do voo. Para aumentar a precisão no cálculo da complexidade, realizou-se uma interpolação de forma a gerar um novo banco de dados com espaçamento padronizado de 20 segundos entre observações de uma mesma trajetória. Optou-se por adotar o método de Interpolação Cúbica de Hermite, devido à presença significativa de patamares constantes na progressão das variáveis de voo, como ocorre, por exemplo, nas variáveis *'speed'*, *'head'* e *'alt'*, em situações em que a aeronave voa em cruzeiro.

Com os dados mais granulares, determina-se, para cada observação, uma aproximação da velocidade vertical. Em seguida, determina-se a atitude da aeronave a partir da variação de altitude ao longo da trajetória para criar uma nova variável *'attitude'*:

attitude Variável que define a atitude da aeronave no instante descrito por *'time'* e *'unix'*, sendo +1 (para voo em subida, isto é, voo em que a componente vertical da velocidade é de sentido ascendente e possui módulo igual ou superior a 500 pés por minuto), 0 (para voo em cruzeiro, isto é, para voo em que o módulo da componente vertical da velocidade seja menor que 500 pés por minuto), e -1 (para voo em descida, isto é, voo em que a componente vertical da velocidade é de sentido descendente e possui módulo igual ou superior a 500 pés por minuto)

A partir das variáveis *'lat'* e *'lon'*, aplica-se a Projeção Cônica de Albers, como descrito pelo IBGE (2019), para se obter as variáveis *'x'* e *'y'*, e, a partir da variável *'alt'*, se obtém a variável *'z'*:

- x* Posição horizontal da aeronave, em milhas náuticas, no instante descrito por *'time'* e *'unix'*, obtida pelo método de projeção cônica de Albers a partir de *'lat'* e de *'lon'*
- y* Posição vertical da aeronave, em milhas náuticas, no instante descrito por *'time'* e *'unix'*, obtida pelo método de projeção cônica de Albers a partir de *'lat'* e de *'lon'*

z Altitude da aeronave, em milhas náuticas, no instante descrito por ‘ $time$ ’ e ‘ $unix$ ’

A partir dos dados de trajetória interpolados e da decodificação dos dados meteorológicos, é gerada uma nova base de dados para o desenvolvimento do modelo preditivo de complexidade, com as seguintes variáveis calculadas para cada hora:

<i>Time</i>	Variável que identifica o intervalo de uma hora, cujos valores se encontram entre ‘00:00:00 01/12/2019 — 01:00:00 01/12/2019’ e ‘23:00:00 29/02/2020 — 00:00:00 01/03/2020’
<i>Unix</i>	Número inteiro determinado pelo instante em segundos em referência às 00:00:00 UTC de 01/01/1970 do início do intervalo descrito por ‘ <i>Time</i> ’
<i>N_Arr_GRU</i>	Número de pousos efetuados em GRU
<i>N_Dep_GRU</i>	Número de decolagens efetuadas em GRU
<i>N_Arr_CGH</i>	Número de pousos efetuados em CGH
<i>N_Dep_CGH</i>	Número de decolagens efetuadas em CGH
<i>N_Arr_VCP</i>	Número de pousos efetuados em VCP
<i>N_Dep_VCP</i>	Número de decolagens efetuadas em VCP
<i>Wind_Speed_GRU</i>	Velocidade do vento em GRU
<i>Wind_Direction_GRU</i>	Direção do vento em GRU
<i>Visibility_GRU</i>	Visibilidade horizontal em GRU
<i>Ceiling_GRU</i>	Teto em GRU
<i>CU_or_TCU_GRU</i>	Presença de cumulus nimbus em GRU, sendo 1 para verdadeiro e 0 para falso
<i>RA_or_TS_GRU</i>	Presença de chuva ou tempestade em GRU, sendo 1 para verdadeiro e 0 para falso
<i>Wind_Speed_CGH</i>	Velocidade do vento em CGH
<i>Wind_Direction_CGH</i>	Direção do vento em CGH
<i>Visibility_CGH</i>	Visibilidade horizontal em CGH
<i>Ceiling_CGH</i>	Teto em CGH
<i>CU_or_TCU_CGH</i>	Presença de cumulus nimbus em CGH, sendo 1 para verdadeiro e 0 para falso
<i>RA_or_TS_CGH</i>	Presença de chuva ou tempestade em CGH, sendo 1 para verdadeiro e 0 para falso
<i>Wind_Speed_VCP</i>	Velocidade do vento em VCP
<i>Wind_Direction_VCP</i>	Direção do vento em VCP
<i>Visibility_VCP</i>	Visibilidade horizontal em VCP
<i>Ceiling_VCP</i>	Teto em VCP
<i>CU_or_TCU_VCP</i>	Presença de cumulus nimbus em VCP,

sendo 1 para verdadeiro e 0 para falso
RA_or_TS_VCP Presença de chuva ou tempestade em VCP,
 sendo 1 para verdadeiro e 0 para falso

Por fim, exclui-se as observações para as quais há presença de valores indeterminados nas variáveis meteorológicas.

3.3 Cálculo de Métricas de Complexidade

Para a quantificação da complexidade na TMA-SP, é utilizado o método de cálculo proposto pelo EUROCONTROL (2006). Subdivide-se a região da TMA-SP em células de 20 milhas náuticas por 20 milhas náuticas por 3000 pés. Considerando os valores mínimo e máximo de 'x' e 'y' que definem a fronteira da TMA-SP e considerando os limites verticais de 5000 e 20000 pés para a análise, obtém-se, de forma simplificada, um total de 210 células. A Figura 3.2 apresenta as células criadas para a faixa de altitude 5000-8000 pés.

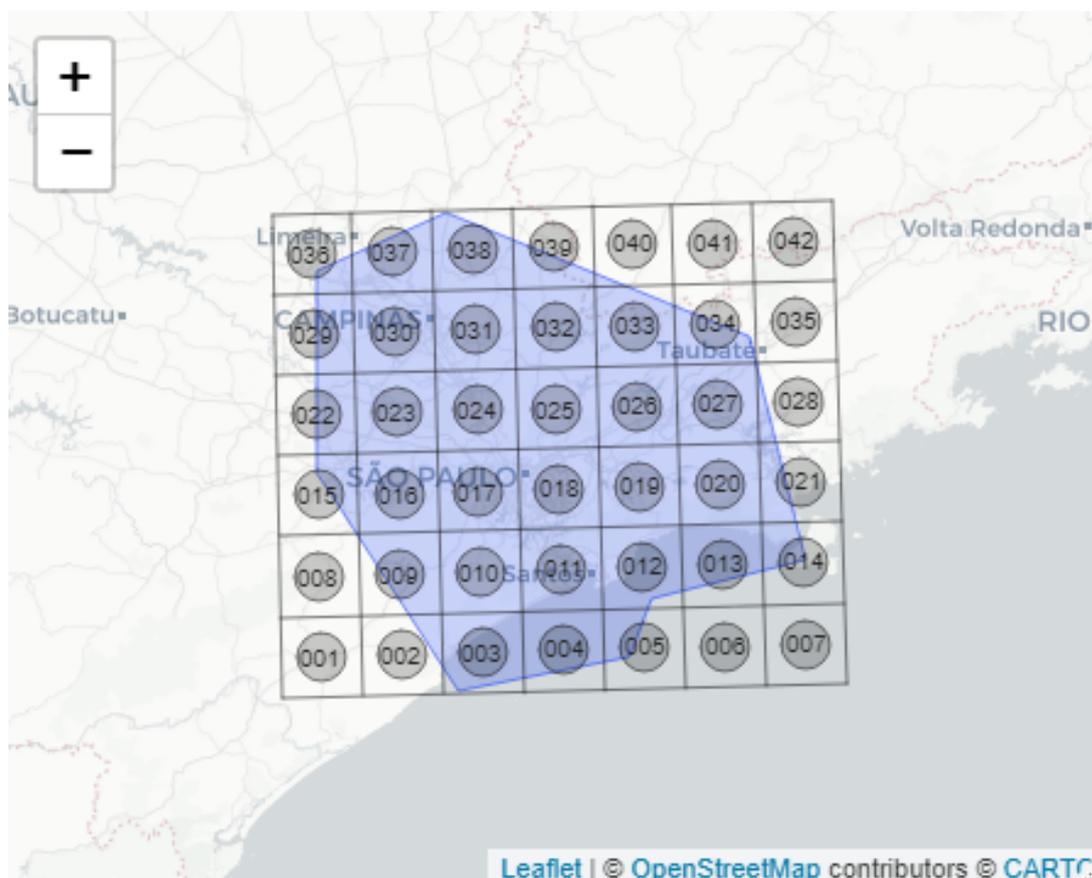


FIGURA 3.2 – Subdivisão da TMA-SP em células de 20x20 milhas náuticas para a faixa de altitude 5000-8000 pés

Considerando apenas as 170 células que possuem interseção com a TMA-SP e as 2184 horas entre 00:00:00 de 01/12/2019 e 00:00:00 de 01/03/2020, obtém-se 371280 combinações célula-hora para o cálculo da complexidade. Para a identificação de cada célula, foi criada a variável 'Cell':

Cell Variável identificadora de cada célula de 20 milhas náuticas por 20 milhas náuticas por 3000 pés

Para o cálculo da complexidade, o EUROCONTROL (2006) propõe o uso de indicadores que representem as principais dimensões de complexidade relacionadas às características do fluxo de tráfego aéreo, como a densidade do tráfego, a estrutura do fluxo e o *mix* de aeronaves. Como elemento central desta metodologia, utiliza-se a noção de interação entre aeronaves. Define-se a existência de "potenciais interações" quando duas aeronaves distintas trafegam em algum momento da mesma hora numa mesma célula, "interações verticais" quando duas aeronaves distintas trafegam em algum momento da mesma hora numa mesma célula com atitudes (em subida, em descida ou em cruzeiro) diferentes, "interações horizontais" quando duas aeronaves distintas trafegam em algum momento da mesma hora numa mesma célula com rumos diferentes de pelo menos 20° e, finalmente, "interações de velocidade" quando duas aeronaves distintas trafegam em algum momento da mesma hora numa mesma célula com velocidades diferentes de pelo menos 35 nós.

A cada hora do período analisado, calcula-se, para cada célula k , onde $k \in \{1, 2, 3, \dots, 170; \text{onde célula}_k \text{ intersecta a TMA-SP}\}$, as horas de voo (T_k), as horas de potenciais interações (D_k), as horas de interações horizontais (H_k), as horas de interações verticais (V_k) e as horas de interações de velocidade (S_k), sendo t_i o tempo, em horas, que a aeronave i permanece na célula k para a hora determinada. Estas métricas são definidas como:

$$T_k = \sum_{i \in \text{célula}_k} t_i \quad (3.1)$$

$$D_k = \sum_{i \in \text{célula}_k} \sum_{j \in \text{célula}_k, i \neq j} t_i \cdot t_j \quad (3.2)$$

$$H_k = \sum_{i \in \text{célula}_k} \sum_{j \in \text{célula}_k, i \neq j, i \text{ e } j \text{ possuem direções diferentes de pelo menos } 20 \text{ graus}} t_i \cdot t_j \quad (3.3)$$

$$V_k = \sum_{i \in \text{célula}_k} \sum_{j \in \text{célula}_k, i \neq j, i \text{ e } j \text{ possuem atitudes diferentes}} t_i \cdot t_j \quad (3.4)$$

$$S_k = \sum_{i \in \text{célula}_k} \sum_{j \in \text{célula}_k, i \neq j, i \text{ e } j \text{ possuem velocidades diferentes de pelo menos 35 nós}} t_i \cdot t_j \quad (3.5)$$

O indicador de complexidade *ComplexityScore* é, então, definido pelo EUROCONTROL (2006) a partir de uma composição de métricas que refletem fatores distintos de complexidade: a densidade de tráfego (*AdjustedDensity*), as interações verticais decorrentes do tráfego em manobra (*Vertical Different Interacting Flows - VDIF*), as interações horizontais decorrentes da estrutura do fluxo (*Horizontal Different Interacting Flows - HDIF*) e as interações de velocidade decorrentes do mix de aeronaves (*Speed Different Interacting Flows - SDIF*). Estas métricas são calculadas, para cada hora, da seguinte forma:

$$\text{AdjustedDensity} = \frac{D_k}{T_k} \quad (3.6)$$

$$\text{VDIF} = \frac{V_k}{T_k} \quad (3.7)$$

$$\text{HDIF} = \frac{H_k}{T_k} \quad (3.8)$$

$$\text{SDIF} = \frac{S_k}{T_k} \quad (3.9)$$

$$\text{StructuralIndex} = \frac{\text{VDIF}}{\text{AdjustedDensity}} + \frac{\text{HDIF}}{\text{AdjustedDensity}} + \frac{\text{SDIF}}{\text{AdjustedDensity}} \quad (3.10)$$

$$\text{ComplexityScore} = \text{AdjustedDensity} \cdot \text{StructuralIndex} \quad (3.11)$$

3.4 Modelo Preditivo de Complexidade

Os indicadores de complexidade (*ComplexityScore*) calculados para cada hora são adicionados ao banco de dados horários para o desenvolvimento de um modelo preditivo de complexidade através de aprendizado de máquina supervisionado. Na aprendizagem supervisionada, o objetivo é aprender um mapeamento entre um conjunto de variáveis de entrada e uma determinada variável de saída com base no conhecimento extraído de um

conjunto de dados de treinamento.

Como variáveis de entrada, considera-se a célula, a hora, o número de pousos e decolagens e as condições meteorológicas nos aeroportos da TMA-SP. Todos estes fatores são possíveis de se determinar instrumentalmente e/ou já possuem métodos de previsão de valores futuros, podendo ser utilizados em uma aplicação em tempo real. A variável de saída é o nível de complexidade definido pelo indicador *ComplexityScore*.

Para a aprendizagem supervisionada, seleciona-se aleatoriamente 70% das observações como dados de treinamento e 30% como dados de teste. Utiliza-se o método de Florestas Aleatórias (*Random Forests*) para o aprendizado do modelo de regressão.

Florestas Aleatórias é um método não paramétrico para classificação e regressão que consiste em um conjunto de árvore de decisão (WRIGHT *et al.*, 2017). Uma árvore de decisão é definida por uma estrutura hierárquica de nós de decisão que progressivamente particiona o espaço multidimensional dos dados de entrada usando uma sequência de divisões binárias desde o nó raiz até as folhas (nós terminais). Cada nó de decisão avalia o valor de uma variável de entrada para decidir qual ramificação será obtida dele. A qualidade de uma divisão é quantificada com uma medida de impureza. Em uma configuração de regressão, o erro quadrático médio das respostas nos nós filhos é normalmente usado. O processo de particionamento é repetido até que um critério de parada seja atendido (por exemplo, o nó é puro ou um número mínimo de observações é alcançado). A previsão para uma nova observação é obtida calculando a média dos valores de saída observados na folha em que esta observação cai quando é passada pela árvore. O método de Florestas Aleatórias cria várias árvores de decisão com amostras bootstrap dos dados de treinamento, mas tem a característica única de selecionar apenas um subconjunto aleatório das variáveis de entrada para determinar cada divisão nos nós de decisão durante a construção das árvores. A previsão final do método é calculada agregando os resultados das árvores individuais. O método possui poucos parâmetros que são ajustados durante o treinamento através de um processo de validação:

<i>num.trees</i>	Número de árvores de decisão
<i>mtry</i>	Número de variáveis consideradas para a divisão de cada nó
<i>min.node.size</i>	Tamanho mínimo das folhas

Uma vez obtido o modelo de regressão, aplica-se o mesmo para previsão da complexidade na base de dados de teste. Para avaliação do desempenho preditivo, utiliza-se a raiz do erro quadrático médio (*Root Mean Squared Error - RMSE*).

4 Resultados e Discussão

4.1 Caracterização da Complexidade na TMA-SP

O processamento da base de dados para interpolação das trajetórias resultou em 5084595 linhas para GRU, 4699955 linhas para CGH e 3547294 para VCP, evidenciando o tamanho considerável da base. Com esses dados, calculou-se, para cada hora e para cada uma das 170 células que intersectam a TMA-SP, o indicador *ComplexityScore*, totalizando 371280 observações. A média do indicador de complexidade foi 0.05, com valor mínimo igual a zero e valor máximo igual a 4.18.

As Figuras 4.1, 4.2, 4.3, 4.4 e 4.5 mostram a distribuição dos valores de complexidade para cada célula da TMA-SP em cada faixa de altitude considerada. Os resultados indicam que a TMA-SP é composta por muitas regiões de baixa complexidade e algumas regiões de média/alta complexidade. Em altitudes mais baixas, são observados os maiores níveis médios de complexidade, embora em poucas células concentradas no entorno dos aeródromos. Em altitudes mais elevadas, os níveis médios de complexidade são menores, com maior dispersão espacial.

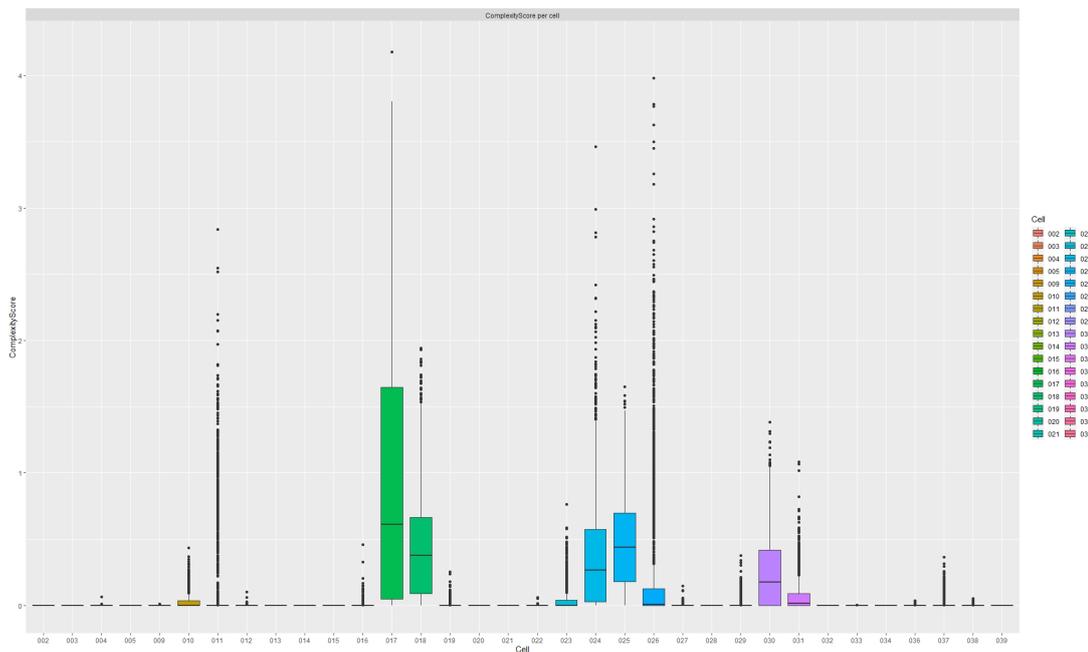


FIGURA 4.1 – *Boxplot* da complexidade para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor

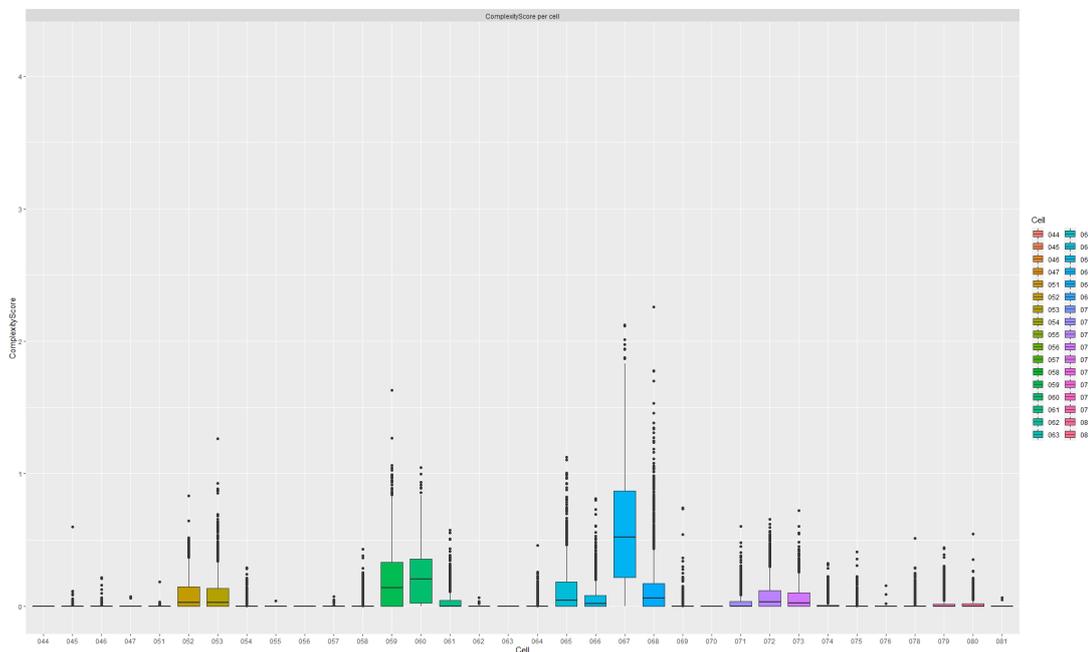


FIGURA 4.2 – *Boxplot* da complexidade para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor

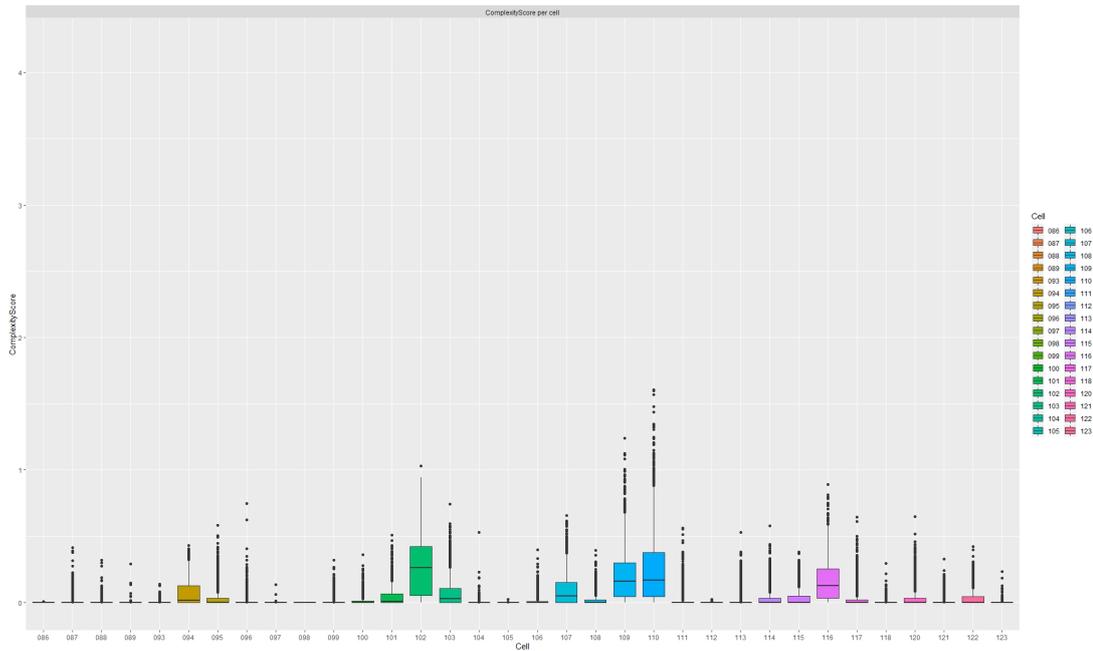


FIGURA 4.3 – *Boxplot* da complexidade para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor

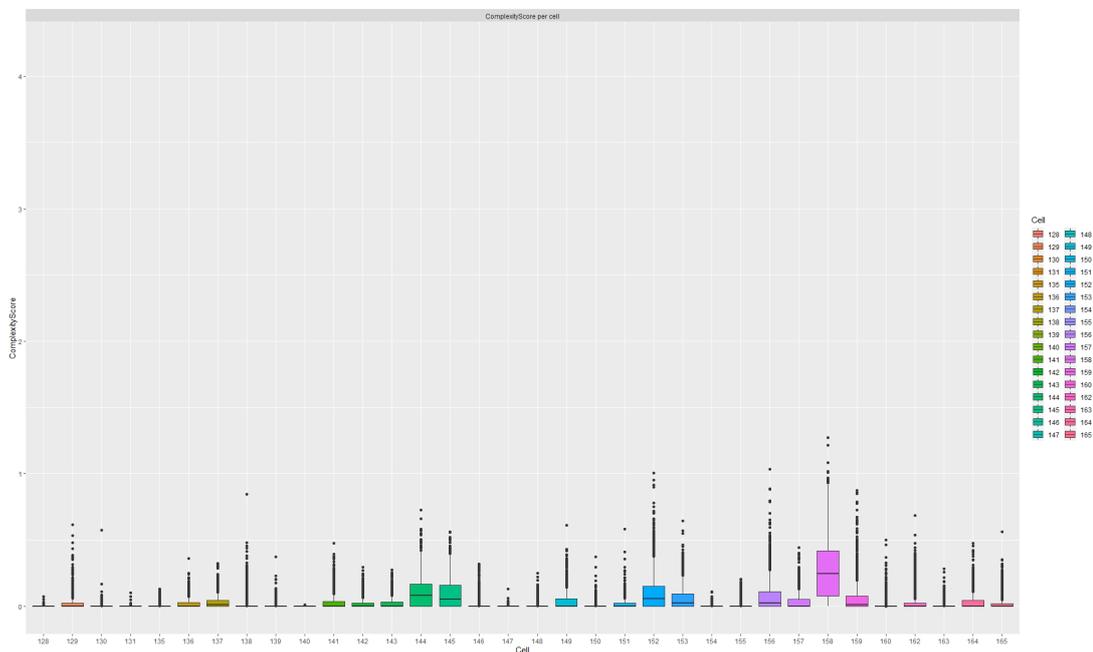


FIGURA 4.4 – *Boxplot* da complexidade para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor

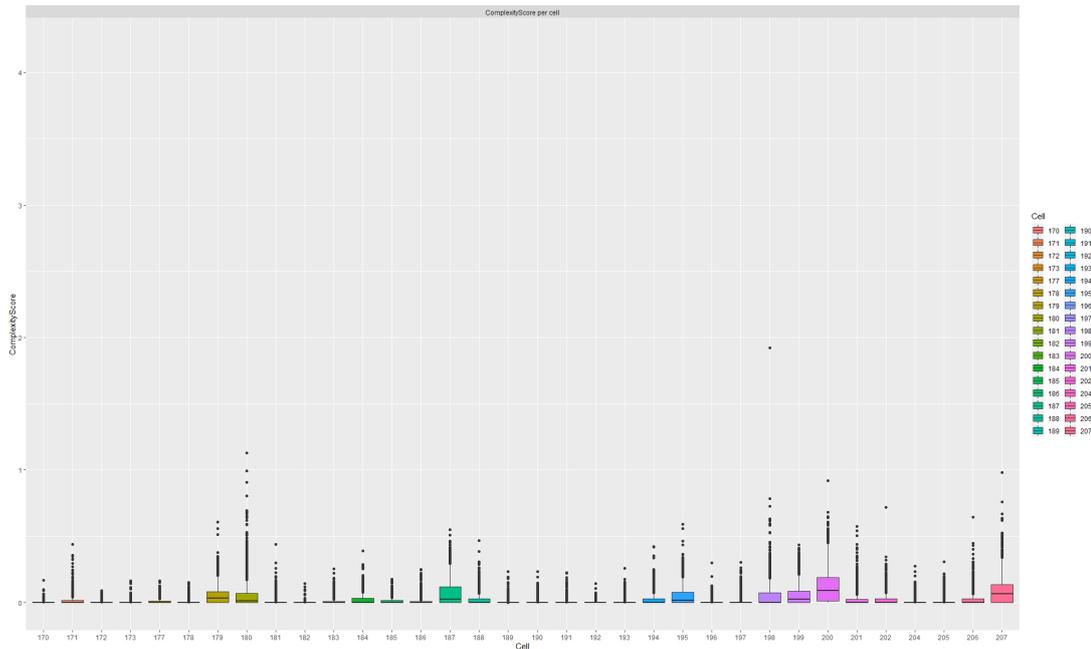


FIGURA 4.5 – *Boxplot* da complexidade para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor

4.2 Análise de Desempenho Preditivo do Modelo de Complexidade

Aplicando o método de Florestas Aleatórias nos dados de treinamento, obtém-se o modelo de regressão para previsão da complexidade. Verificou-se que o RMSE do modelo converge para *num.tree* aproximadamente igual a 200, conforme Figura 4.6. Calibrou-se os demais parâmetros do método adotando *num.tree* = 200 para se decidir a melhor configuração de árvores, obtendo o melhor modelo para *mtry* = 12 e *min.node.size* = 3. Esse modelo apresenta RMSE de 0.084.

A Tabela 4.1 e a Figura 4.7 mostram a importância das variáveis de entrada no modelo de regressão aprendido com o método de Florestas Aleatórias. Observa-se que, além da localização espacial da célula, a demanda de voos e a configuração de operação determinada pela direção do vento são os principais fatores que contribuem para o nível de complexidade na TMA-SP. As demais variáveis meteorológicas mostraram menor contribuição, sendo o teto a mais significativa entre elas.

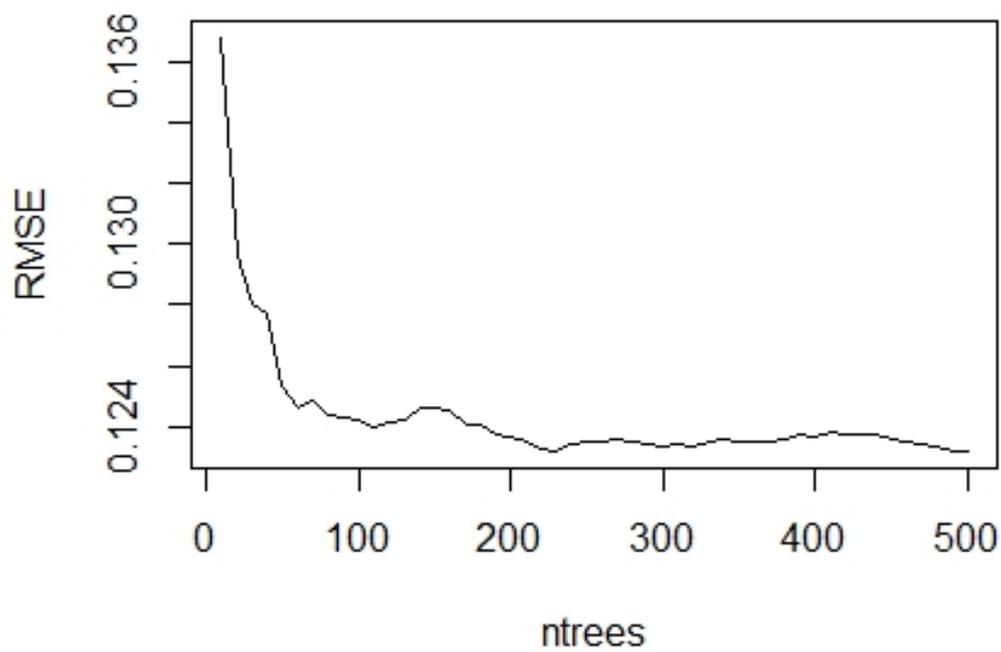


FIGURA 4.6 – Variação do erro de previsão em função do número de árvores. Fonte: O Autor

TABELA 4.1 – Valores da importância das variáveis de entrada

Variável	Importância
<i>RA_or_TS_CGH</i>	7.707563
<i>RA_or_TS_VCP</i>	7.967939
<i>RA_or_TS_GRU</i>	8.585282
<i>CU_or_TCU_CGH</i>	9.168926
<i>CU_or_TCU_GRU</i>	9.175776
<i>CU_or_TCU_VCP</i>	11.342760
<i>Visibility_VCP</i>	13.591586
<i>Visibility_GRU</i>	23.577548
<i>Visibility_CGH</i>	30.758385
<i>Ceiling_VCP</i>	44.582559
<i>Wind_Speed_GRU</i>	66.172304
<i>Ceiling_CGH</i>	66.812978
<i>Wind_Speed_VCP</i>	67.365612
<i>Wind_Speed_CGH</i>	69.305648
<i>Ceiling_GRU</i>	71.806147
<i>N_Dep_VCP</i>	77.724634
<i>N_Arr_VCP</i>	83.510297
<i>N_Dep_GRU</i>	94.334733
<i>Wind_Direction_VCP</i>	101.460145
<i>Unix</i>	108.754922
<i>Wind_Direction_GRU</i>	114.899939
<i>N_Arr_GRU</i>	126.874630
<i>N_Arr_CGH</i>	164.594489
<i>N_Dep_CGH</i>	198.709549
<i>Wind_Direction_CGH</i>	203.945723
<i>Cell</i>	3296.844027

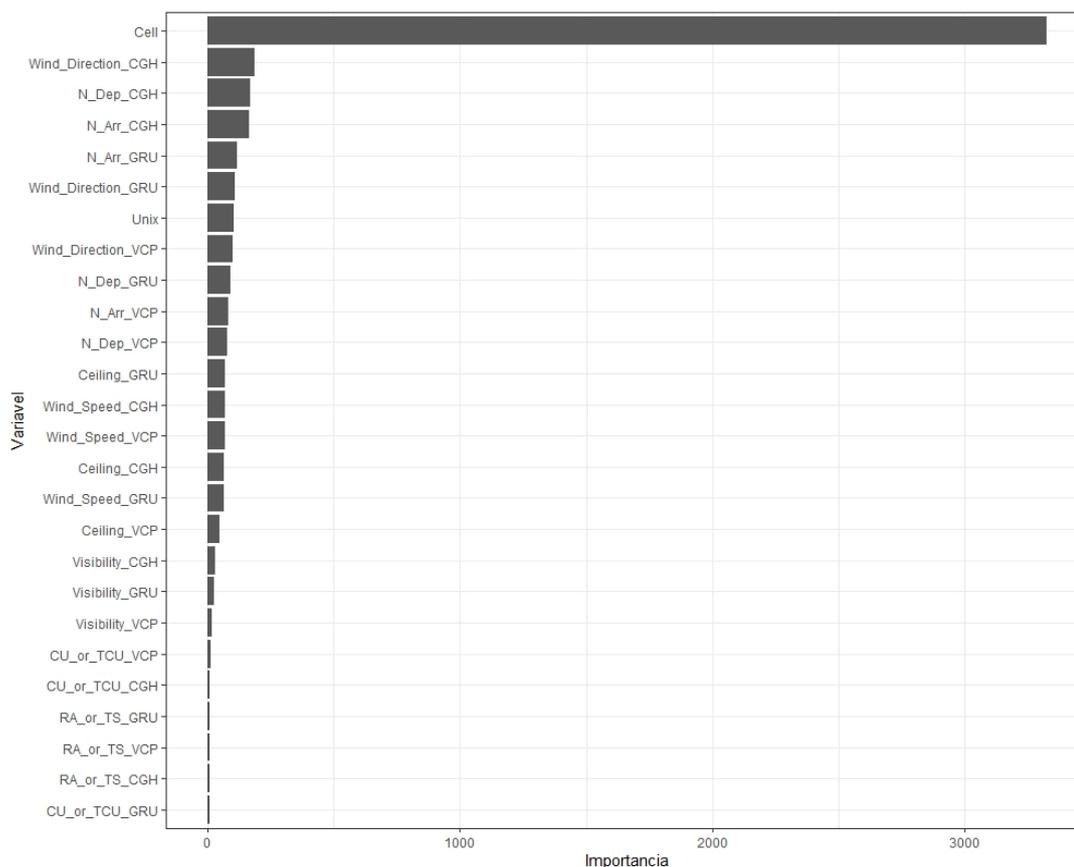


FIGURA 4.7 – Gráfico de barras da importância das variáveis de entrada. Fonte: O Autor

Ao aplicar o modelo nos dados de teste para previsão da complexidade, obteve-se RMSE de 0.082. Para uma análise da possibilidade de células específicas estarem influenciando o erro de previsão, calculou-se o RMSE para cada célula. Os resultados mostrados na Tabela 4.2 indicam que, de fato, há uma grande variabilidade no erro de previsão, sugerindo que o desenvolvimento de modelos individuais para as células pode contribuir para aperfeiçoar o desempenho preditivo devido à variabilidade espacial da complexidade na TMA-SP.

Para melhor visualização dos resultados, construiu-se mapas dos valores de média de complexidade, de mediana de complexidade e de erro de previsão (RMSE) para cada célula, exibidos nas Figuras 4.8 a 4.22.

TABELA 4.2 – Erro de previsão por célula

<i>Cell</i>	RMSE								
2	0,0045	44	0,0023	86	0,0057	128	0,0075	170	0,0101
3	0,0045	45	0,0142	87	0,022	129	0,0318	171	0,0246
4	0,0046	46	0,0082	88	0,0124	130	0,0114	172	0,0078
5	0,0045	47	0,0033	89	0,0084	131	0,008	173	0,0079
9	0,0063	51	0,0043	93	0,0085	135	0,0118	177	0,0137
10	0,0315	52	0,0587	94	0,0483	136	0,0248	178	0,0118
11	0,1782	53	0,0732	95	0,0431	137	0,0321	179	0,0407
12	0,0121	54	0,0148	96	0,0289	138	0,0372	180	0,068
13	0,0074	55	0,0053	97	0,0088	139	0,0128	181	0,0177
14	0,0069	56	0,0048	98	0,0073	140	0,0077	182	0,0099
15	0,007	57	0,0052	99	0,0204	141	0,0374	183	0,0194
16	0,014	58	0,0236	100	0,0219	142	0,0242	184	0,0234
17	0,2943	59	0,1023	101	0,037	143	0,0248	185	0,0164
18	0,1466	60	0,0967	102	0,0933	144	0,0615	186	0,0185
19	0,0144	61	0,0426	103	0,0562	145	0,0583	187	0,0468
20	0,006	62	0,0108	104	0,0161	146	0,0245	188	0,0309
21	0,0056	63	0,0103	105	0,011	147	0,0111	189	0,011
22	0,006	64	0,024	106	0,0254	148	0,0177	190	0,0124
23	0,0471	65	0,0879	107	0,0653	149	0,039	191	0,0133
24	0,2155	66	0,0558	108	0,0319	150	0,0186	192	0,0077
25	0,1442	67	0,1988	109	0,0997	151	0,026	193	0,0143
26	0,2915	68	0,1279	110	0,133	152	0,0725	194	0,0269
27	0,0125	69	0,0315	111	0,0365	153	0,0505	195	0,0455
28	0,01	70	0,0122	112	0,0179	154	0,0168	196	0,0145
29	0,0205	71	0,038	113	0,0357	155	0,0198	197	0,0239
30	0,1167	72	0,0568	114	0,0391	156	0,0686	198	0,0723
31	0,0669	73	0,0567	115	0,0401	157	0,0425	199	0,0467
32	0,0039	74	0,0238	116	0,0864	158	0,1152	200	0,0703
33	0,0031	75	0,0211	117	0,0432	159	0,069	201	0,0382
34	0,0029	76	0,0089	118	0,0164	160	0,0302	202	0,0303
36	0,0037	78	0,0238	120	0,0461	162	0,0467	204	0,0179
37	0,0225	79	0,0346	121	0,024	163	0,0199	205	0,0178
38	0,0037	80	0,0245	122	0,0312	164	0,0391	206	0,0329
39	0,0026	81	0,0058	123	0,0097	165	0,03	207	0,061

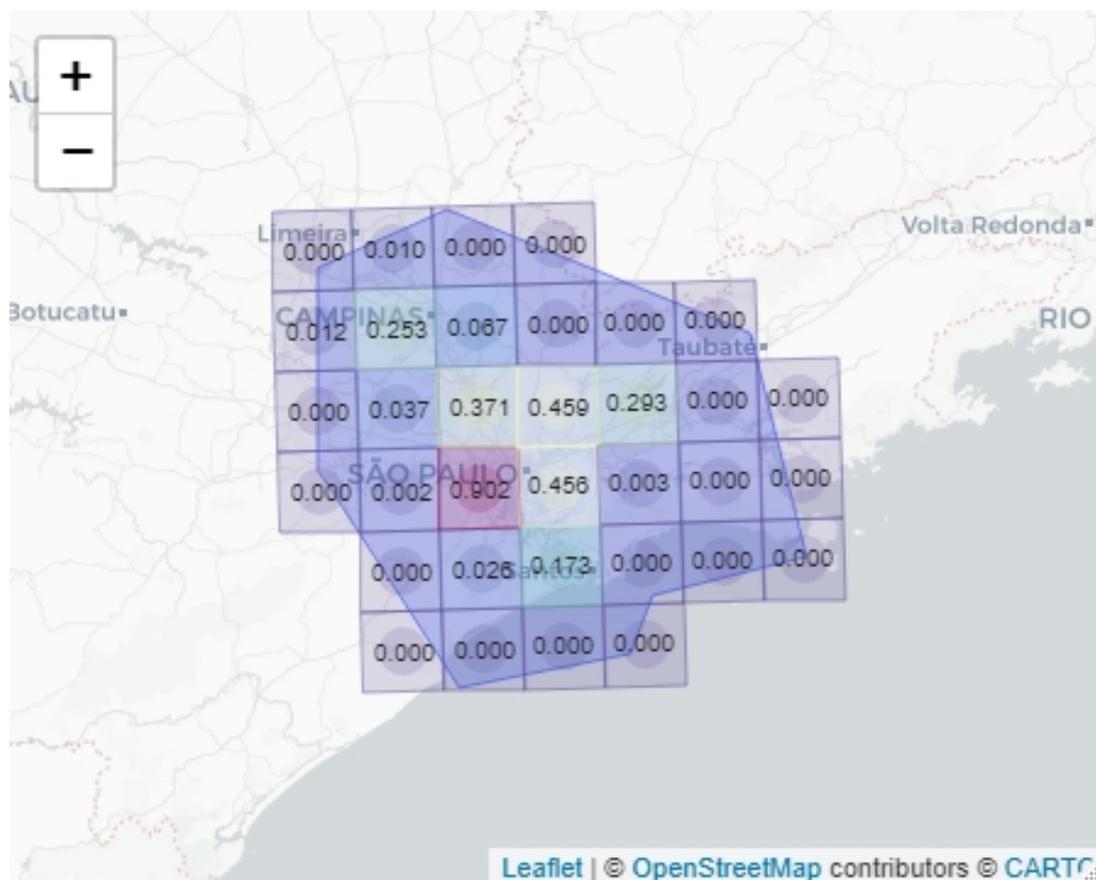


FIGURA 4.8 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor

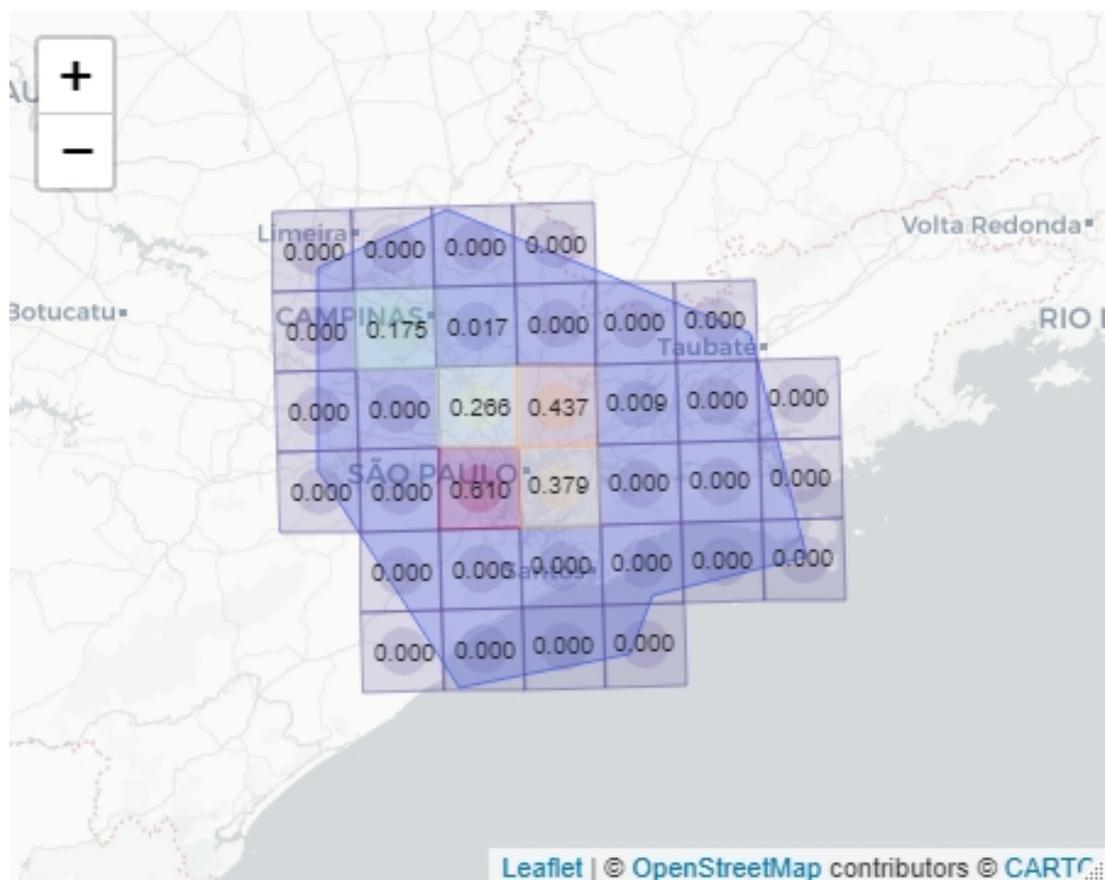


FIGURA 4.9 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor

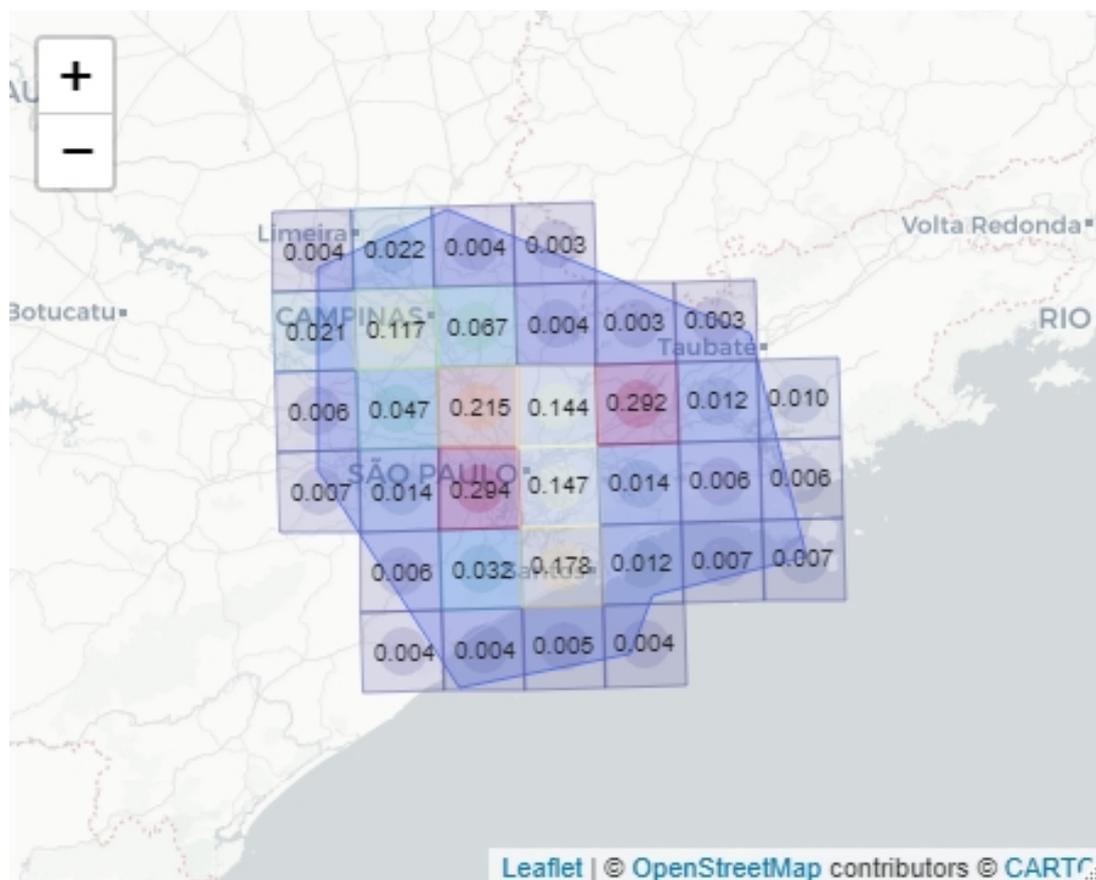


FIGURA 4.10 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 5000-8000 pés. Fonte: O Autor

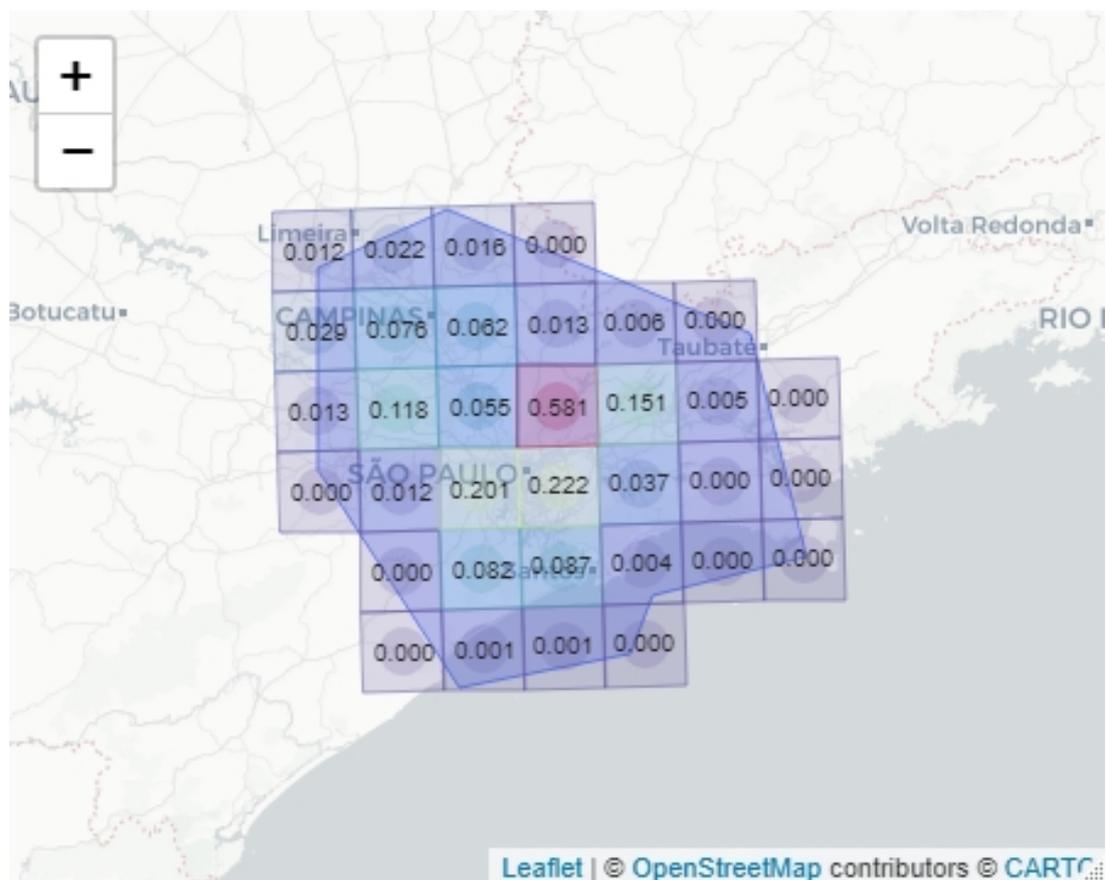


FIGURA 4.11 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor

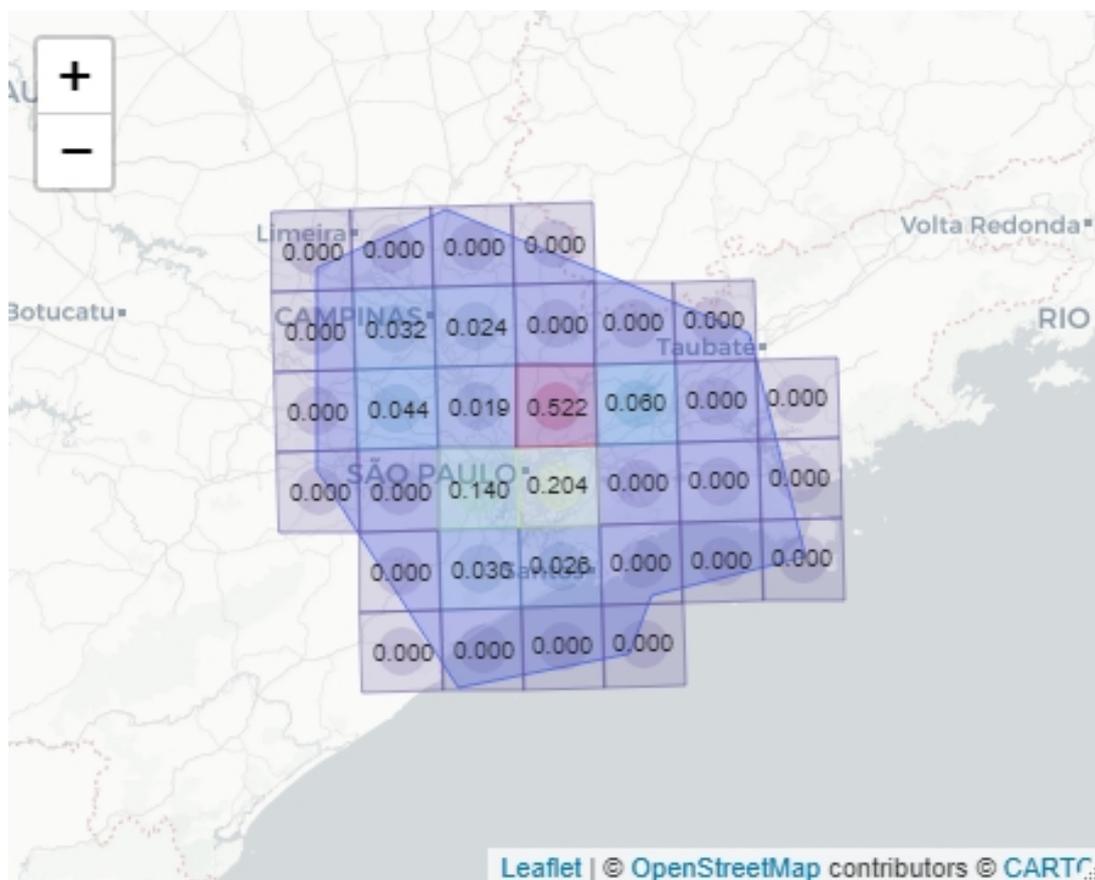


FIGURA 4.12 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor

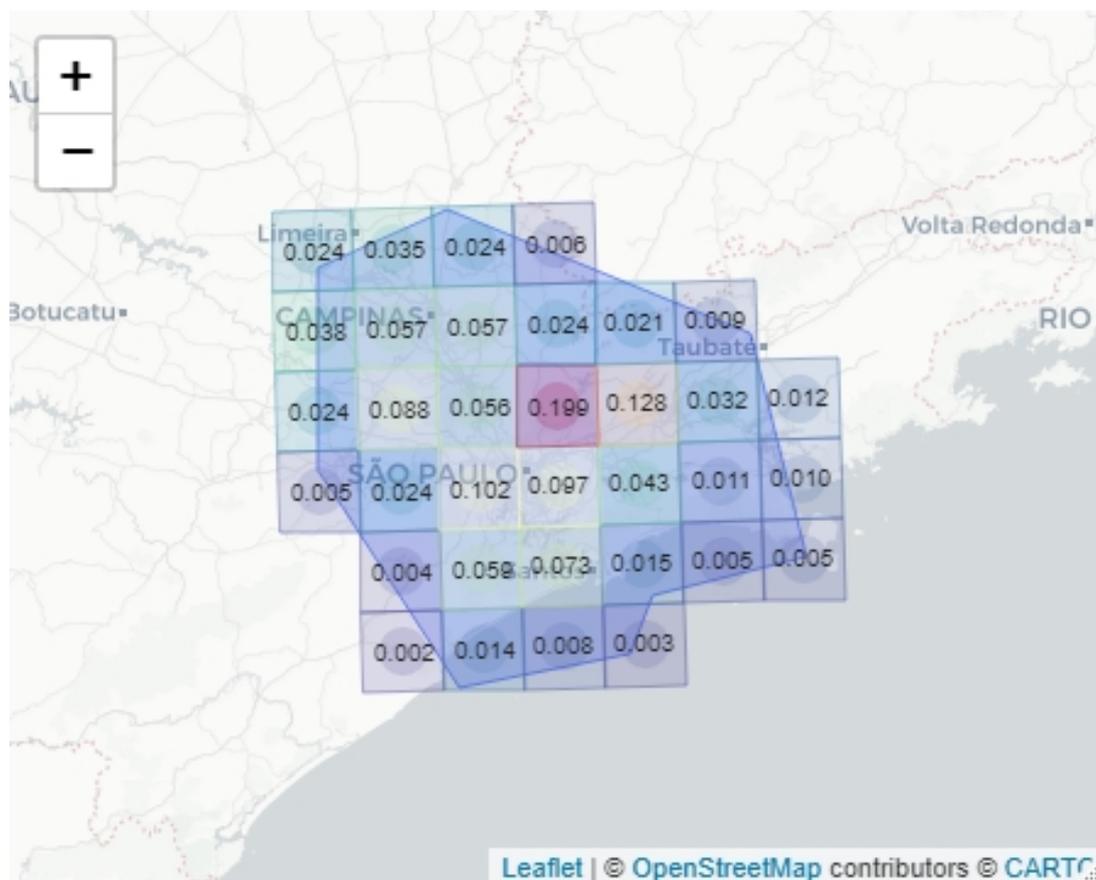


FIGURA 4.13 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 8000-11000 pés. Fonte: O Autor

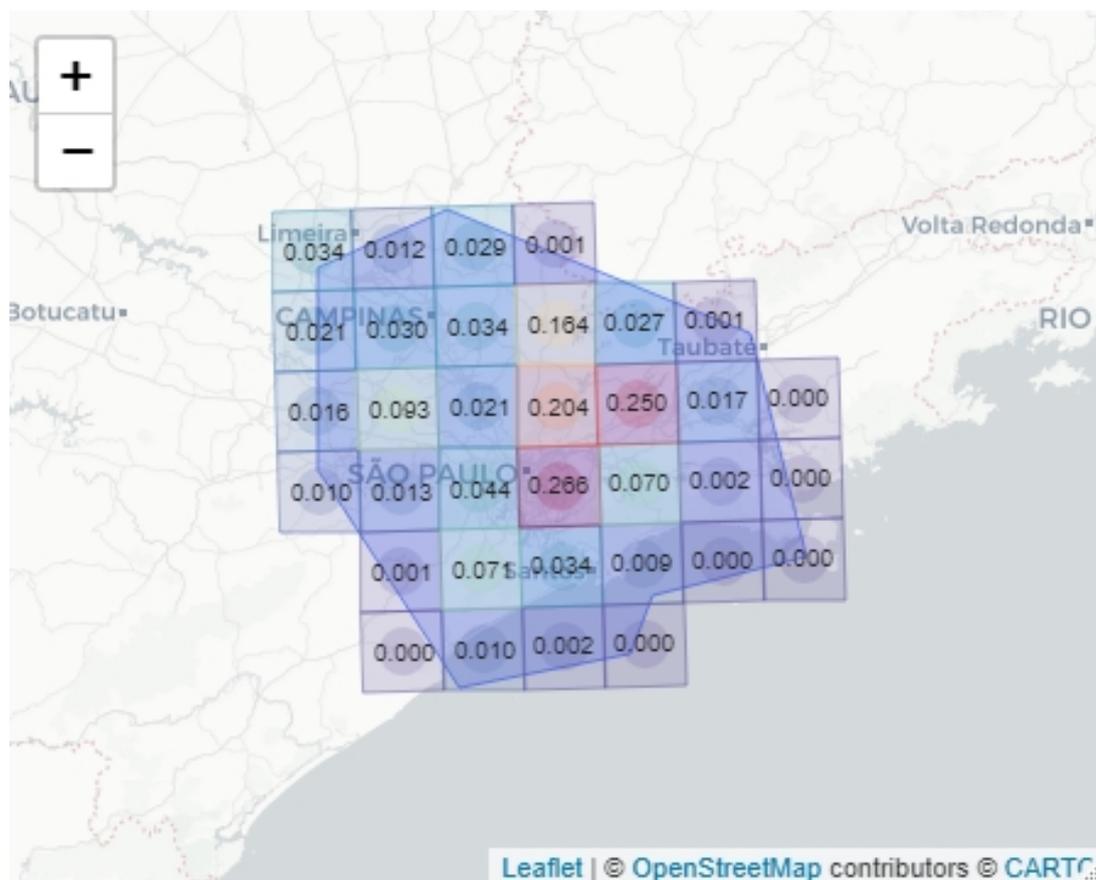


FIGURA 4.14 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor

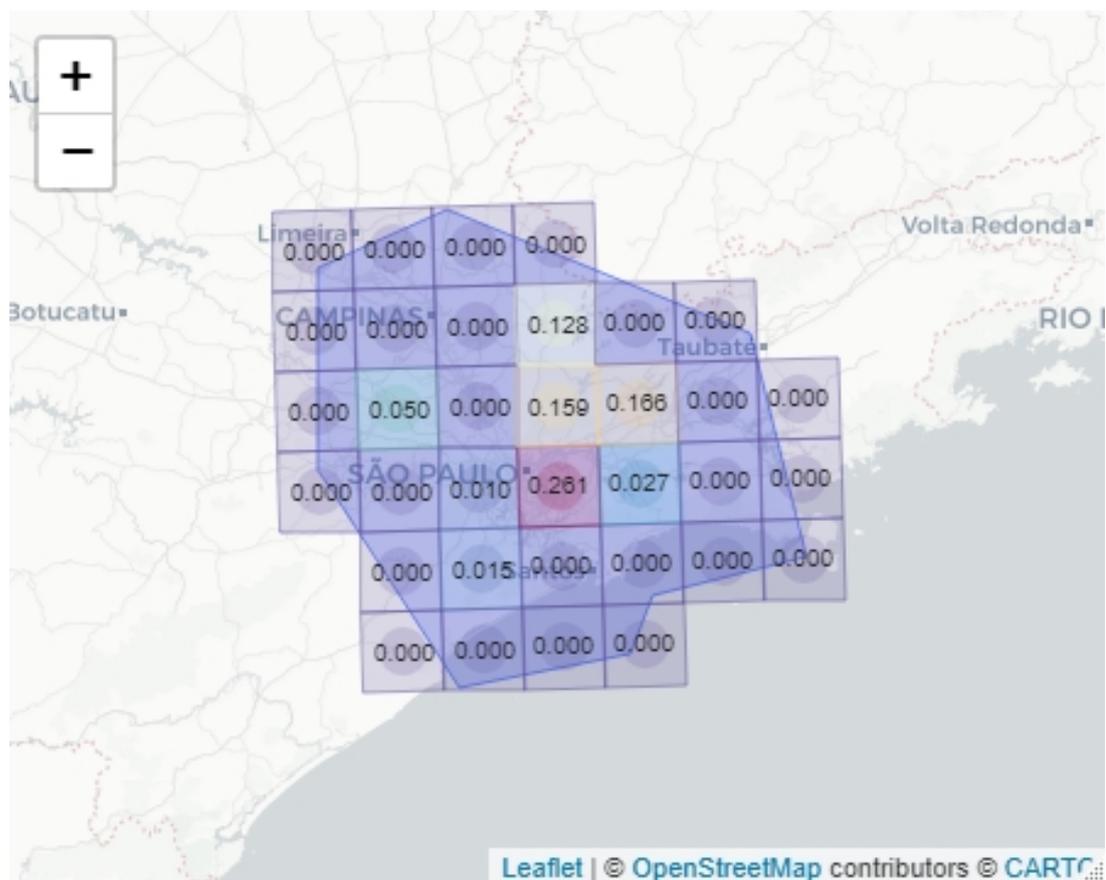


FIGURA 4.15 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor

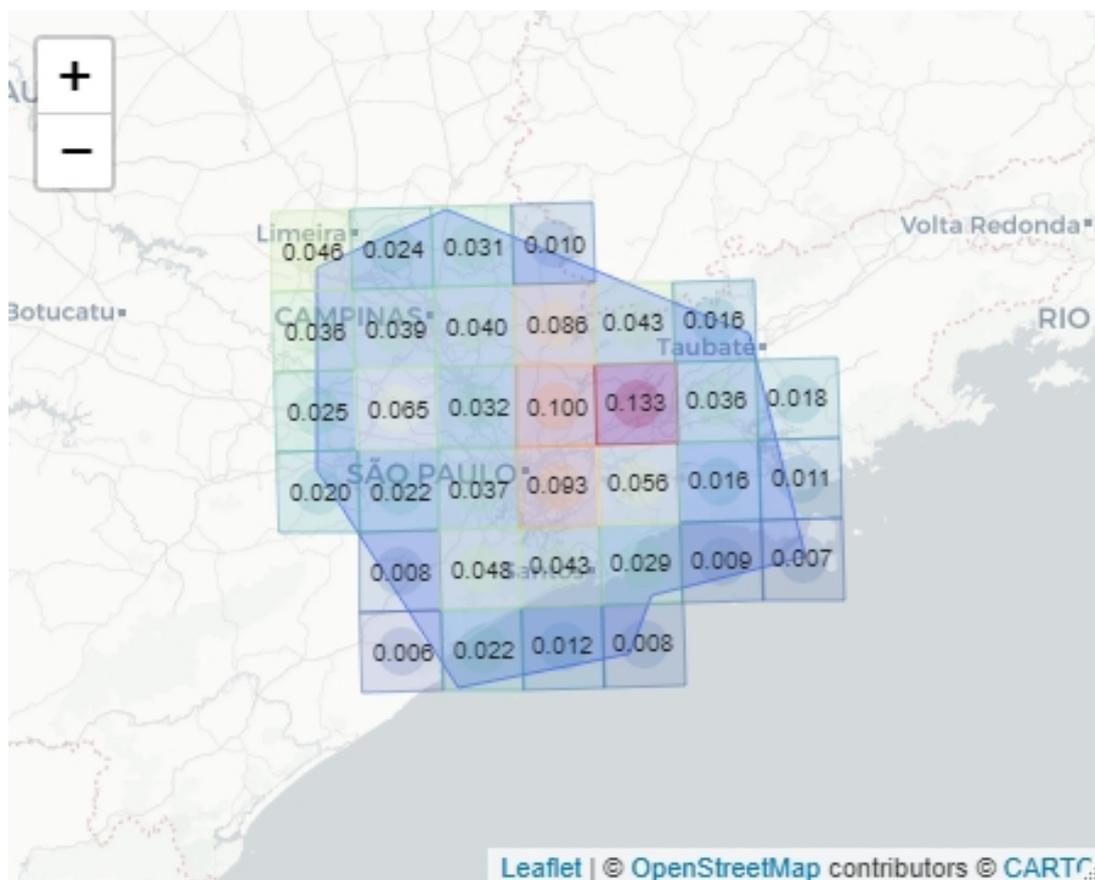


FIGURA 4.16 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 11000-14000 pés. Fonte: O Autor

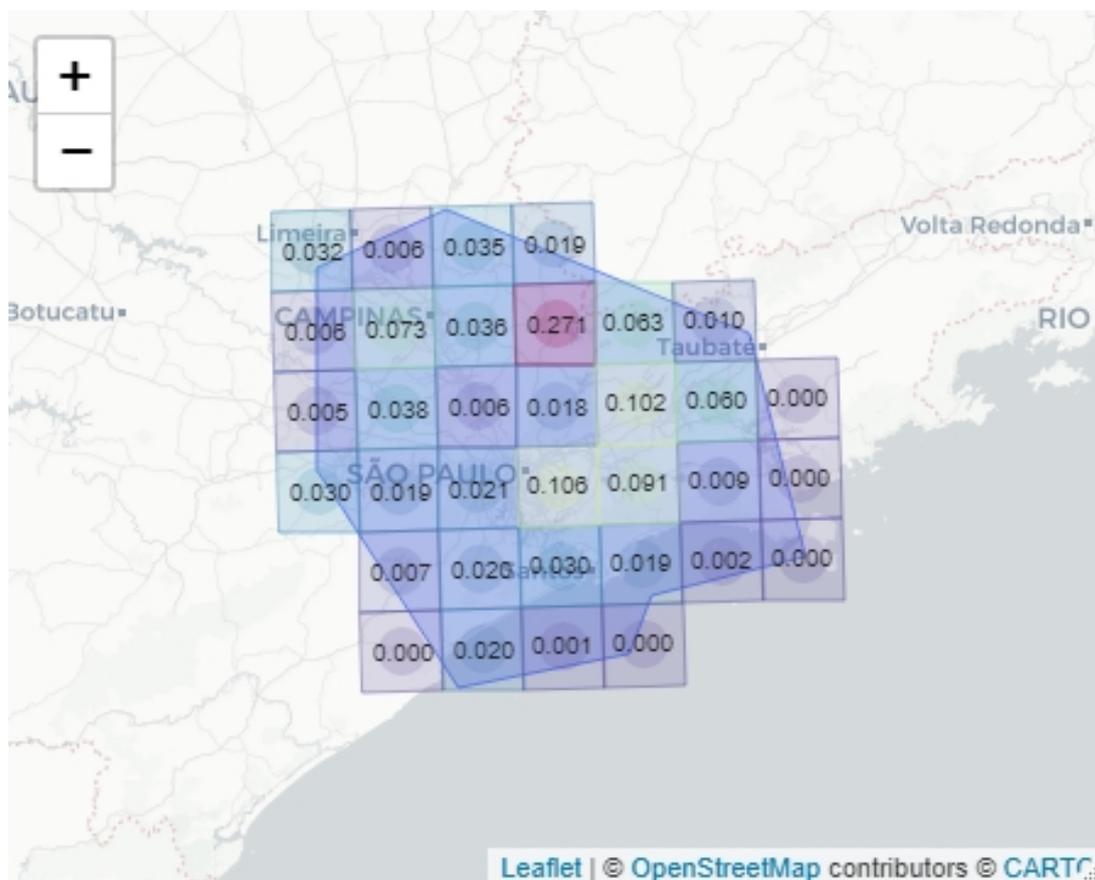


FIGURA 4.17 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor

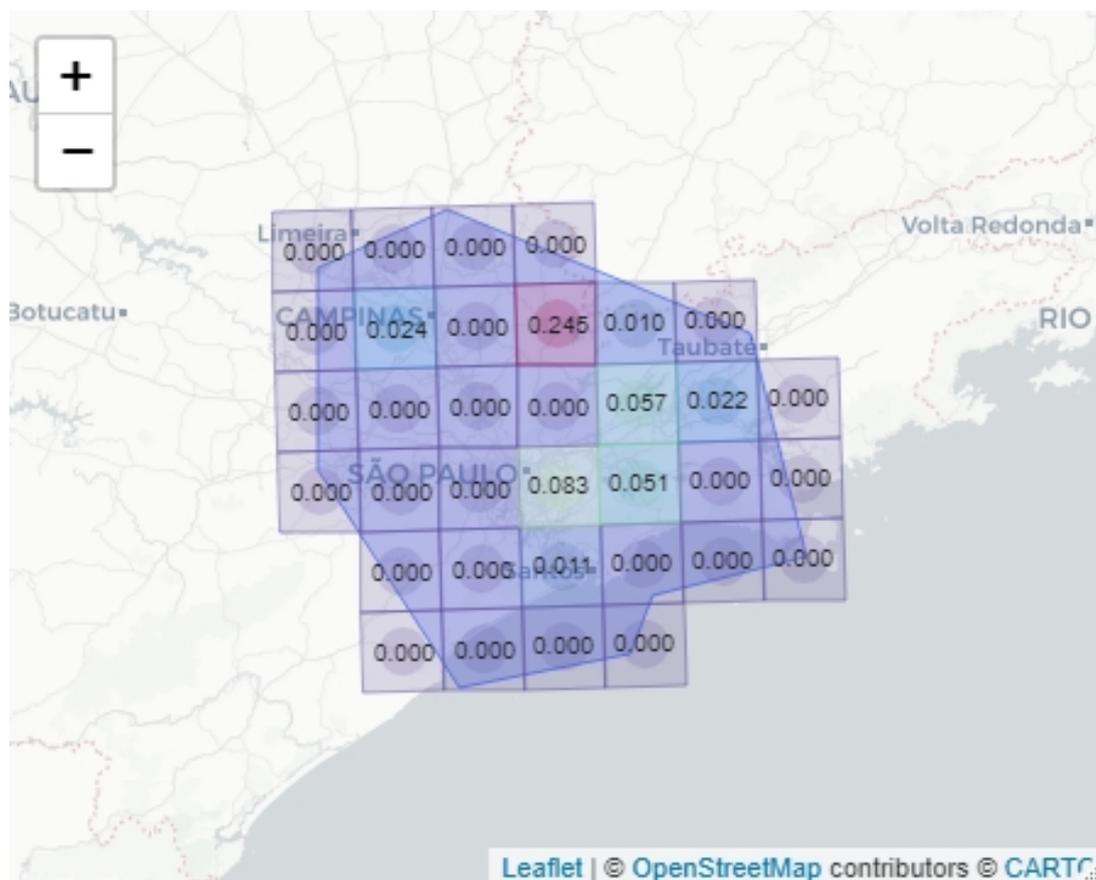


FIGURA 4.18 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor

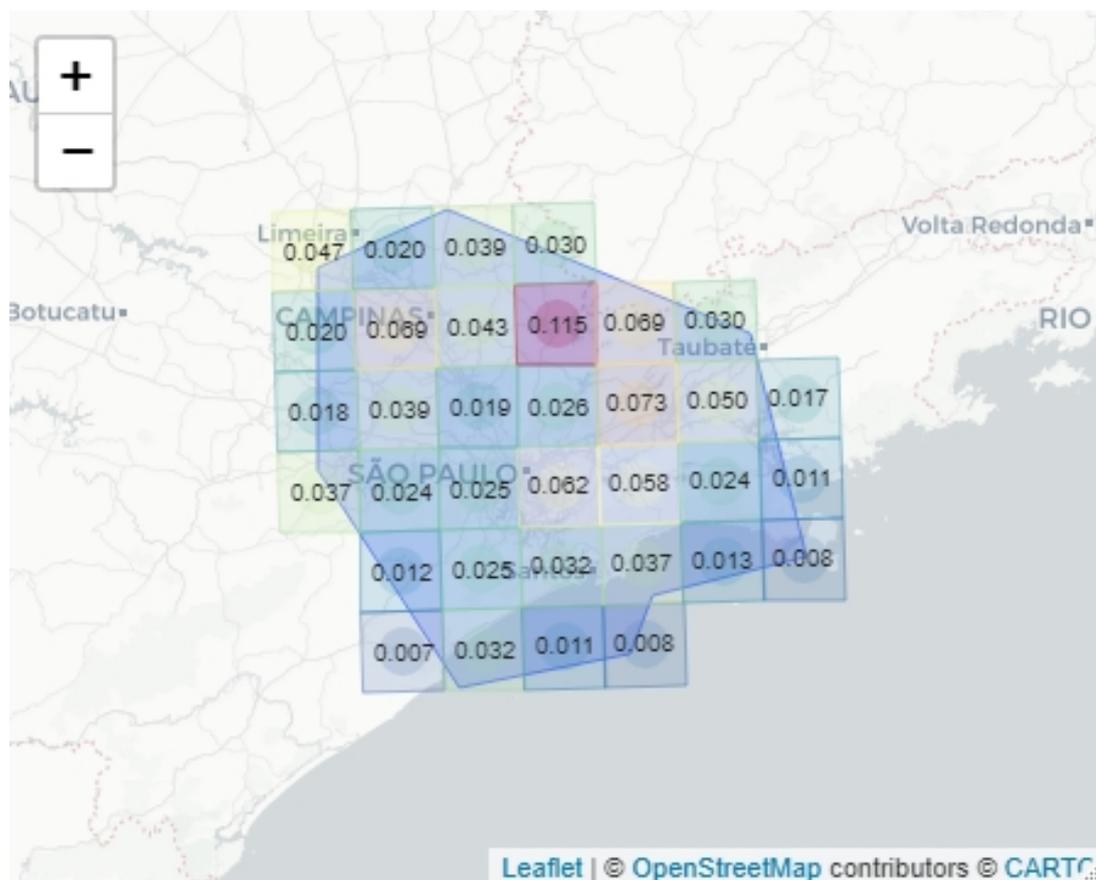


FIGURA 4.19 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 14000-17000 pés. Fonte: O Autor

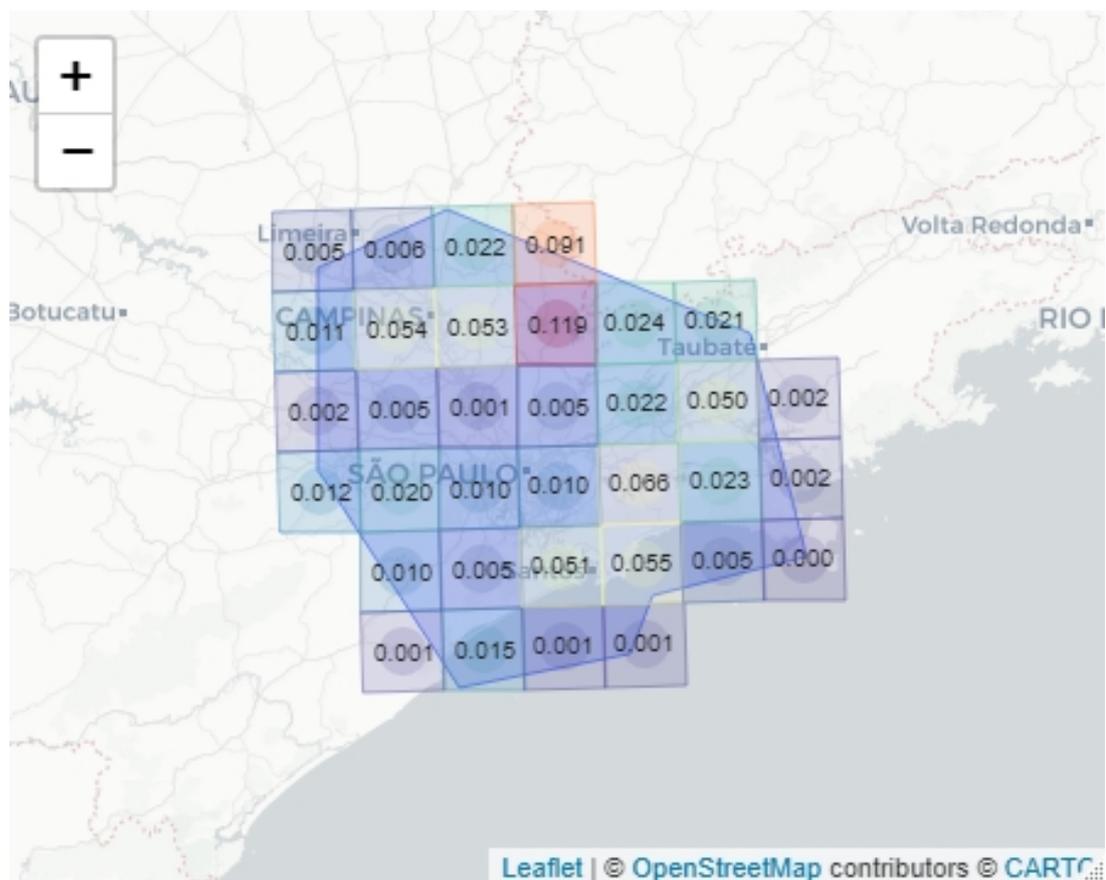


FIGURA 4.20 – Visualização da média dos valores de complexidade para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor

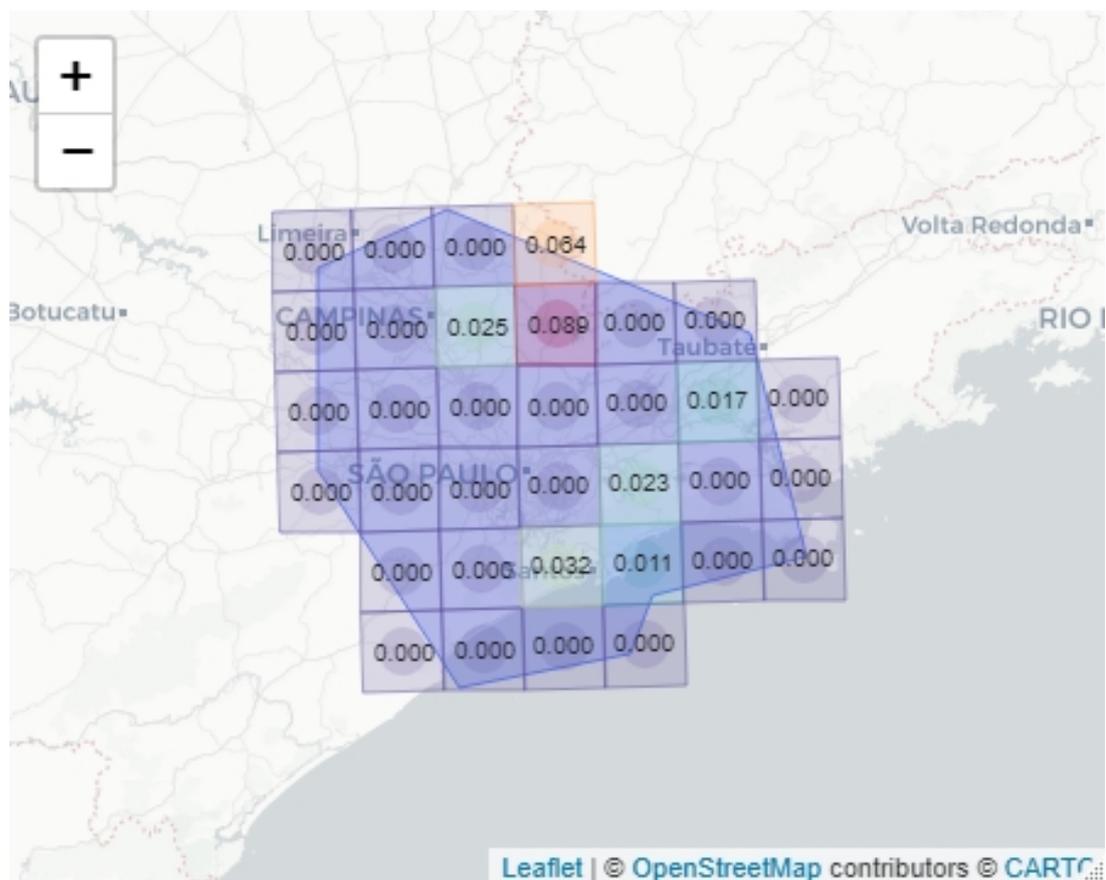


FIGURA 4.21 – Visualização da mediana dos valores de complexidade para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor

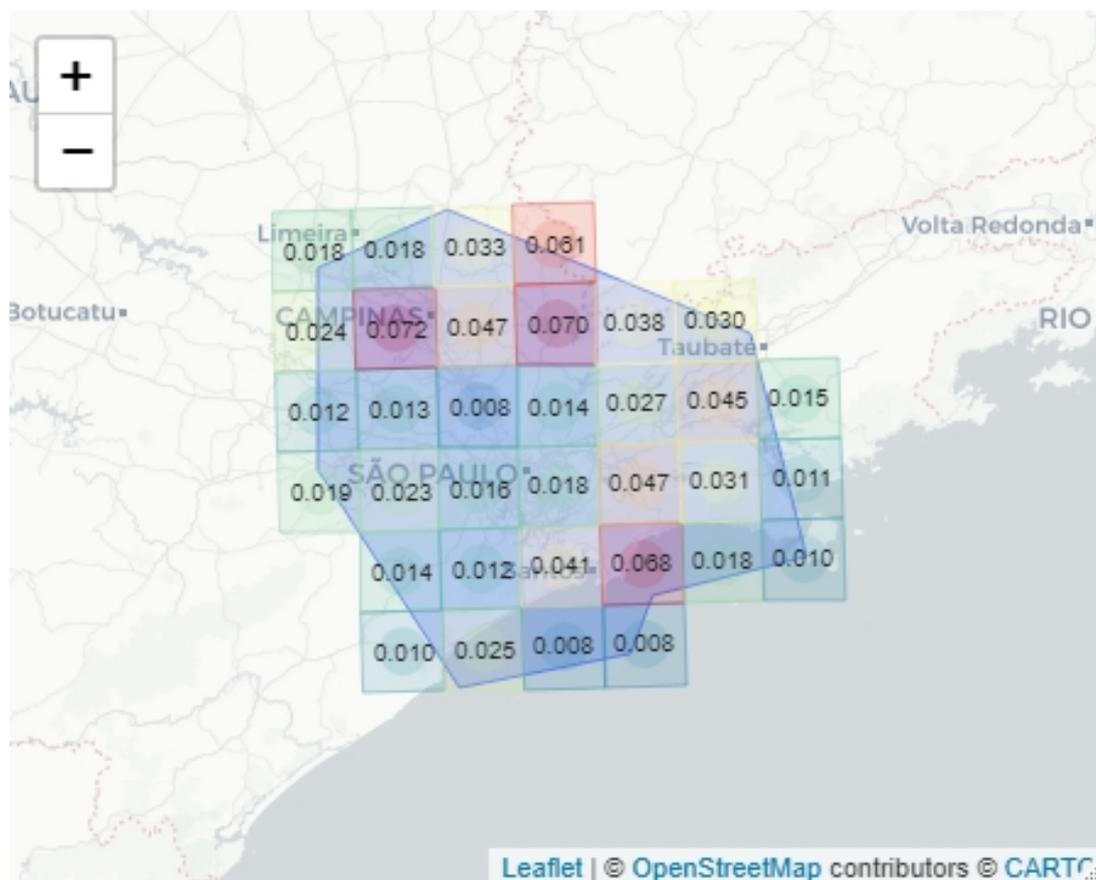


FIGURA 4.22 – Visualização do erro de previsão (RMSE) para as células da TMA-SP na faixa de altitude 17000-20000 pés. Fonte: O Autor

5 Conclusão

O presente trabalho teve por objetivo desenvolver uma abordagem baseada em dados para quantificação e previsão da complexidade do controle de tráfego aéreo na TMA-SP. O estudo baseou-se em dados históricos de trajetória de voo e de meteorologia para os aeroportos de Guarulhos, Congonhas e Viracopos durante o período de dezembro/2019 a fevereiro/2020.

Primeiramente, foi realizado o cálculo de um indicador de complexidade horária para células de espaço aéreo de 20 milhas náuticas x 20 milhas náuticas x 3000 pés na TMA-SP. A partir desta quantificação, desenvolveu-se um modelo preditivo de complexidade usando aprendizado de máquina supervisionado e o método de Florestas Aleatórias.

Observou-se que a complexidade, bem como o erro de previsão, apresenta uma grande variação espacial. Observou-se também que a demanda e a configuração de operação determinada pela direção do vento são os principais fatores que contribuem para o nível de complexidade na TMA-SP. As demais variáveis meteorológicas mostraram menor contribuição, sendo o teto a mais significativa entre elas.

Como sugestão para possíveis trabalhos futuros, recomenda-se o desenvolvimento de modelos de previsão individuais para as diferentes células, bem como o uso de outros métodos de aprendizado de máquina supervisionado, de forma a mitigar os impactos da variação espacial da complexidade na TMA-SP e aperfeiçoar o desempenho preditivo. Por fim, sugere-se o uso das estimativas de complexidade geradas pelo modelo preditivo em uma abordagem de configuração dinâmica de setor para avaliação de potenciais benefícios no gerenciamento da capacidade do espaço aéreo.

Referências

AEROIN. **Aeroportos de São Paulo estarão superlotados já em 2022, revela projeção.** 2019. Available from Internet: <<https://www.aeroin.net/aeroportos-sao-paulo-estarao-superlotados-2022/>>. Acesso em: 04 nov. 2020.

DURAND, N.; GIANAZZA, D.; GOTTELAND, J.-B.; ALLIOT, J.-M. **Metaheuristics for Air Traffic Management**. 1. ed. [S.l.]: Wiley, 2016. (Computer Engineering: Metaheuristics Set, v. 2). ISBN 978-1-84821-810-9,1848218109.

FLIGHTRADAR24. **FlightFadar24 - Live Air Traffic**. 2019–2020. Available from Internet: <<https://www.flightradar24.com/>>. Acesso em: 30 nov. 2019 a 4 mar. 2020.

GARCIA, M. **Airlines Expect Slow Return To Growth, With Demand Down 41% In 2021**. 2020. Available from Internet: <<https://www.forbes.com/sites/marisagarcia/2020/05/13/airlines-project-slow-return-to-growth-with-demand-up-to-41-lower-than-expected-in-2021/?sh=117904ec6c19>>. Acesso em: 04 nov. 2020.

HERZMANN, D. **Iowa Environmental Mesonet**. 2020. Available from Internet: <https://mesonet.agron.iastate.edu/request/download.phtml?network=BR_ASOS>. Acesso em: 04 nov. 2020.

HUGHES, W. J. **Dynamic Density – A Review of Proposed Variables**. [S.l.], 2000.

IATA. **IATA Forecast Predicts 8.2 billion Air Travelers in 2037**. 2018. Available from Internet: <<https://www.iata.org/en/pressroom/pr/2018-10-24-02/>>. Acesso em: 04 nov. 2020.

IBGE. **Áreas Territoriais**. 2019. Available from Internet: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/15761-areas-dos-municipios.html?#t=sobre>>. Acesso em: 4 nov. 2020.

ICAO. **Manual on Air Traffic Management System Requirement**: Doc 9882 an/467. [S.l.], 2008.

ICAO. **The World of Air Transport in 2014**. 2014. Available from Internet: <<https://www.icao.int/annual-report-2014/Pages/the-world-of-air-transport-in-2014.aspx>>. Acesso em: 04 nov. 2020.

MAJUMDAR, A.; OCHIENG, W. Y. Factors affecting air traffic controller workload: Multivariate analysis based on simulation modeling of controller workload.

Transportation Research Record, SAGE Publications Sage CA: Los Angeles, CA, v. 1788, n. 1, p. 58–69, 2002.

MALICKI, P. **O impacto do coronavírus no setor de aviação no Brasil**. 2020. Available from Internet: <<https://www.flyflapper.com/stories/pt-br/o-impacto-do-coronavirus-no-setor-de-aviacao-no-brasil/>>. Acesso em: 04 nov. 2020.

MOGFORD, R. H.; GUTTMAN, J.; MORROW, S.; KOPARDEKAR, P. **The Complexity Construct in Air Traffic Control: A Review and Synthesis of the Literature**. [S.l.], 1995.

MTPA. **PAN 2018 - Plano Aeroviário Nacional**. 2018. Available from Internet: <https://www.gov.br/infraestrutura/pt-br/centrais-de-conteudo/pan2018_ebook.pdf>. Acesso em: 04 nov. 2020.

SABHNANI, G.; YOUSEFI, A.; MITCHELL, J. S. Flow conforming operational airspace sector design. In: **10th AIAA Aviation Technology, Integration, and Operations (ATIO) Conference**. [S.l.: s.n.], 2010. p. 9377.

WELCH, J. D.; ANDREWS, J. W.; MARTIN, B. D.; SRIDHAR, B. Macroscopic workload model for estimating en route sector capacity. 2007.

WRIGHT, M. N.; DANKOWSKI, T.; ZIEGLER, A. Unbiased split variable selection for random survival forests using maximally selected rank statistics. **Statistics in medicine**, Wiley Online Library, v. 36, n. 8, p. 1272–1284, 2017.