



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES

RENATA DE SOUZA SALES

**PROPOSTA DE CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE
REVESTIMENTOS ASFÁLTICOS DE PISTAS DE POUSO E DECOLAGEM
BASEADA EM PARÂMETROS DE ADERÊNCIA**

FORTALEZA

2023

RENATA DE SOUZA SALES

PROPOSTA DE CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE
REVESTIMENTOS ASFÁLTICOS DE PISTAS DE POUSO E DECOLAGEM BASEADO
EM PARÂMETROS DE ADERÊNCIA

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia de Transportes. Área de concentração: Infraestrutura de Transportes.

Orientador: Prof. Dr. Francisco Heber Lacerda de Oliveira.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- S155p Sales, Renata de Souza.
Proposta de classificação da segurança operacional de revestimentos asfálticos de pistas de pouso e decolagem baseada em parâmetros de aderência / Renata de Souza Sales. – 2023.
121 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2023.
Orientação: Prof. Dr. Francisco Heber Lacerda de Oliveira.
1. Segurança. 2. Operações. 3. Revestimentos Asfálticos. 4. Pista de Pouso e Decolagem. 5. Aderência Pneu-Pavimento. I. Título.

CDD 388

RENATA DE SOUZA SALES

PROPOSTA DE CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE
REVESTIMENTOS ASFÁLTICOS DE PISTAS DE POUSO E DECOLAGEM BASEADO
EM PARÂMETROS DE ADERÊNCIA

Dissertação apresentado ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Engenharia de Transportes. Área de concentração: Infraestrutura de Transportes.

Aprovada em: 11/07/2023.

BANCA EXAMINADORA

Prof. Dr. Francisco Heber Lacerda de Oliveira (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Carlos Augusto Uchôa da Silva (Examinador interno)
Universidade Federal do Ceará (UFC)

Profª. Dra. Michelle Andrade (Examinadora externa)
Universidade de Brasília (UNB)

Prof. Dr. Danilo Rinaldi Bisconsini (Examinador externo)
Universidade Tecnológica Federal do Paraná (UTFPR)

Aos meus pais, Ângela e Wagner.

AGRADECIMENTOS

Primeiramente, agradeço aos meus pais, Ângela e Wagner, por sempre acreditarem na minha capacidade e apoiarem minhas decisões. Por não medirem esforços para que eu pudesse estudar e realizar minhas conquistas por meio da educação.

À minha família por sempre ter me incentivado e acreditado em mim, em especial meus irmãos e minha avó Jota.

Ao professor Heber, pela orientação, atenção e paciência (muita) ao longo desses anos, nessa parceria que se deu na graduação e se seguiu até aqui. Agradeço pela confiança no meu trabalho, pela partilha de conhecimento, pelos puxões de orelha e por não soltar minha mão.

Aos amigos que foram suporte nos momentos mais difíceis durante esse percurso, Aldaianny, Beliza, Bruno Mota, Diego, Gabriel, Harley, Lucas Moreira e Mateus Lira. Sem vocês isso não seria possível. Em especial Aldaianny e Beliza, que foram suporte no ambiente que eu chamei de casa nos últimos anos. Ao Mateus Lira que ouviu muitas reclamações e desabafos diários. Um agradecimento especial ao Altanízio, Gustavo e Renato que me auxiliaram bastante no processo de desenvolvimento do trabalho.

Agradeço ao meu namorado por ter me motivado e me ajudado a ter paciência e confiança nesse processo final da dissertação.

Aos demais amigos que não foram citados, mas que me ajudaram mesmo que ao conseguir tirar um sorriso de mim.

À Vanessa, um anjo que tive a oportunidade de encontrar nessa vida e que me ajudou em momentos tão difíceis. Sem você, isso também não seria possível

Ao professor Uchôa, à professora Michelle e ao professor Danilo por terem aceitado participar da banca examinadora. À professora Viviane, que mesmo não estando presente na banca de defesa fez contribuições importantes no processo de qualificação.

À ANAC pelo financiamento do projeto o qual minha linha de pesquisa está inserida, em especial ao Lucius Prado e ao Lucas Travagin, que deram suporte ao projeto nesses dois anos.

“There has always been a rainbow hanging over your head.” (KACEY MUSGRAVES, 2018).

RESUMO

O aumento do número de passageiros no transporte aéreo no Brasil influencia a segurança das operações de pouso e decolagem. Nesse contexto, uma classificação dessa segurança pode possibilitar a gerência das operações aeroportuárias com eficácia, especialmente quando apoiada por ferramentas computacionais. Parâmetros de aderência pneu-pavimento, tais como a macrotextura e o coeficiente de atrito, são informações importantes relacionadas à resistência à derrapagem, que afetam a segurança das operações de pouso e decolagem. No Brasil, a classificação da segurança operacional é realizada de maneira segmentada considerando aspectos específicos das operações aéreas e da infraestrutura aeroportuária. Isso dificulta a identificação de áreas de risco que podem contribuir para a ocorrência de acidentes com as aeronaves. Diante do exposto, o objetivo deste trabalho é classificar a segurança operacional de revestimentos asfálticos de pistas de pouso e decolagem brasileiras, com base nas características de aderência pneu-pavimento. Para isso, utilizou-se a técnica de *Machine Learning Multilayer Perceptron* (MLP), por meio do *software MatLab*. Os dados utilizados na modelagem são provindos de duas pistas de pouso e decolagem brasileiras, com revestimento em Concreto Asfáltico e em Camada Porosa de Atrito (CPA). As informações são referentes ao período de 2014 a 2018 e incluem dados de profundidade de macrotextura, de coeficiente de atrito e de remoção do acúmulo de borracha dos referidos revestimentos. Os resultados indicam que o tipo de revestimento asfáltico deve ser distinguido na modelagem e que a CPA pode proporcionar restrições à segurança das operações de pouso e decolagem, considerando sua utilização com crédito de desempenho. Além disso, observou-se que o coeficiente de atrito é o parâmetro decisivo na classificação da segurança operacional. Foi possível concluir que o modelo provindo do conjunto de dados 2 proporciona uma determinação eficaz dos trechos de pavimento que necessitam de medidas de manutenção para que a segurança operacional de pousos e decolagens seja melhorada. Espera-se que o trabalho possa contribuir para estudos futuros e o aperfeiçoamento do processo de análise da segurança de pousos e decolagens no território nacional.

Palavras-chave: Segurança. Operações. Revestimentos Asfálticos. Pista de Pouso e Decolagem. Aderência Pneu-Pavimento.

ABSTRACT

The increase in the number of passengers carried in Brazil influences the safety of landing and takeoff operations. In this context, the classification of this safety can enable airport operations management effectively, especially when supported by computational tools. The tire-pavement adhesion parameters are important information directly related to skid resistance, which impairs the safety of landing and takeoff operations. In Brazil, the operational classification of safety is carried out in a segmented manner considering specific aspects of airline operations and airport infrastructure. This makes it difficult to identify risk areas that could contribute to aircraft accidents. This paper aims to classify the operational safety of asphalt pavements on Brazilian runways. To this end, the modeling technique Multilayer Perceptron (MLP) was applied using the software MatLab. The data used in the modeling comes from two Brazilian runways, with Asphalt Concrete and Porous Friction Course (PFC). The information is for the period between 2014 and 2018 and includes data on macrotexture depth, friction coefficient, and removal of rubber buildup from the pavement surface. The results indicate that the type of pavement surface should be distinguished in modeling and that PFC can provide restrictions on the safety of landing and takeoff operations, considering its use with performance credit. Furthermore, it was observed that the friction coefficient is the decisive parameter in the classification of operational safety. It was concluded that the model derived from data set 2 provides an effective way of determining which sections of the runway require maintenance measures to improve the operational safety of landings and take-offs. It is hoped that this work can contribute to future studies and the improvement of the analysis process of the safety of landings and takeoffs in the national territory.

Keywords: Safety. Operations. Asphalt Pavements. Runway. Tire-Pavement Adherence.

LISTA DE FIGURAS

Figura 1	– Coeficiente de atrito x taxa de desgaste do pavimento.....	30
Figura 2	– Coeficiente de atrito versus taxa de desgaste do pavimento com presença de lâmina d'água.....	31
Figura 3	– Depósitos de borracha no revestimento da PPD do KIA em Taiwan.....	32
Figura 4	– Ensaio da mancha de areia.....	36
Figura 5	– Análise estatística da profundidade de macrotextura.....	56
Figura 6	– Análise estatística do coeficiente de atrito.....	57
Figura 7	– Relação entre a profundidade de macrotextura, o coeficiente de atrito e a classificação da segurança operacional.....	58
Figura 8	– Relação entre o tipo de revestimento, a classificação da segurança operacional e os parâmetros de aderência.....	59
Figura 9	– Relação entre remoção do acúmulo de borracha, classificação da segurança operacional e parâmetros de aderência.....	60
Figura 10	– Relação entre o coeficiente de atrito e a localização da medição (m).....	61
Figura 11	– Relação entre o coeficiente de atrito e os terços das PPD.....	61
Figura 12	– Relação entre a profundidade de macrotextura e a localização da medição (m).....	62
Figura 13	– Relação entre a profundidade de macrotextura e os terços das PPD.....	63
Figura 14	– Matriz de correlação entre as variáveis do estudo.....	64
Figura 15	– Matrizes de confusão para treinamento, teste e validação (Conjunto 1)...	70
Figura 16	– Matrizes de confusão para treinamento, teste e validação (Conjunto 2)...	72
Figura 17	– Matrizes de confusão para treinamento, teste e validação (Conjunto 3)...	74
Figura 18	– Matrizes de confusão para treinamento, teste e validação (Conjunto 4)...	76
Figura 19	– Curvas ROC para treinamento, teste e validação (Conjunto 1).....	78
Figura 20	– Curvas ROC para treinamento, teste e validação (Conjunto 2).....	79
Figura 21	– Curvas ROC para treinamento, teste e validação (Conjunto 3).....	80
Figura 22	– Curvas ROC para treinamento, teste e validação (Conjunto 4).....	81

LISTA DE TABELAS

Tabela 1	– Estudos de Indicadores de Segurança Operacional.....	24
Tabela 2	– Valores mínimos estabelecidos no Brasil para o coeficiente de atrito.....	34
Tabela 3	– Valores mínimos de coeficiente de atrito estabelecidos pela FAA.....	35
Tabela 4	– Classificação da profundidade de macrotextura segundo a ANAC.....	37
Tabela 5	– Classificação da profundidade de macrotextura segundo a ICAO.....	37
Tabela 6	– Estudos de Aderência Pneu-Pavimento em pistas de pouso e decolagem.....	38
Tabela 7	– Emprego de <i>Machine Learning</i> em problemas de pavimentos.....	45
Tabela 8	– Resumo do banco de dados analisado para as PPD de estudo.....	50
Tabela 9	– Descrição das variáveis utilizadas na análise.....	50
Tabela 10	– Análise estatística da profundidade de macrotextura.....	54
Tabela 11	– Análise estatística do coeficiente de atrito.....	55
Tabela 12	– Proporção dos parâmetros em cada conjunto de dados.....	66
Tabela 13	– Resultado do treinamento do MLP por meio do MatLab.....	66
Tabela 14	– Entropias cruzadas e erros do modelo.....	68
Tabela 15	– Métricas de desempenho (Conjunto 1).....	71
Tabela 16	– Métricas de desempenho (Conjunto 2).....	73
Tabela 17	– Métricas de desempenho (Conjunto 3).....	75
Tabela 18	– Métricas de desempenho (Conjunto 4).....	77
Tabela 19	– Resumo das métricas obtidas para cada conjunto de dados.....	82

LISTA DE ABREVIATURAS

ANAC	Agência Nacional de Aviação Civil
ACN	<i>Aircraft Classification Number</i>
ALD	<i>Actual Landing Distance</i>
ASRS	<i>Aviation Safety Reporting System</i>
AUC	<i>Area Under the ROC Curve</i>
CA	Concreto Asfáltico
CAA	<i>Civil Aviation Authority</i>
CBR	<i>California Bearing Ratio</i>
CENIPA	Centro de Investigação e Prevenção de Acidentes Aeronáuticos
CNN	<i>Convolutional Neural Network (</i>
CPA	Camada Porosa de Atrito
FAA	<i>Federal Aviation Administration</i>
FOD	<i>Foreing Object Damage</i>
ICAO	<i>International Civil Aviation Organization</i>
INFRAERO	Empresa Brasileira de Infraestrutura Aeroportuária
IRI	<i>International Roughness Index</i>
LDA	<i>Landing Distance Available</i>
M&R	Manutenção e Reabilitação
MCDA-C	<i>Methodology Multicriteria Decision Aid – Constructivist</i>
MLP	<i>Multilayer Perceptron</i>
PCI	<i>Pavement Condition Index</i>
PCN	<i>Pavement Classification Number</i>
PPD	Pista de Pouso e Decolagem
RESA	<i>Runway Safety Area</i>
RLD	<i>Required Landing Distance</i>
RMSE	<i>Root Mean Squared Error</i>
RFC	<i>Random Forest Classifier</i>
ROC	<i>Receiver Operating Characteristic Curve</i>
SBFZ	<i>Aeroporto Internacional de Fortaleza</i>
SBRJ	<i>Aeroporto do Rio de Janeiro/Santos Dumont</i>
SFT	<i>Saab Surface Friction Tester</i>

SGPA	Sistemas de Gerência de Pavimentos Aeroportuários
SGS	Sistema de Gestão da Segurança
SMA	<i>Stone Mastic Asphalt</i>
SVC	<i>Support Vector Classifier</i>

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Contextualização.....	13
1.2	Problema de Pesquisa.....	14
1.3	Justificativa.....	15
1.4	Objetivos.....	15
1.5	Estrutura do Trabalho.....	15
2	REVISÃO BIBLIOGRÁFICA.....	17
2.1	Indicadores de segurança operacional.....	17
2.2	Aderência pneu-pavimento.....	29
2.3	<i>Machine Learning</i>.....	40
3	MÉTODO DE PESQUISA.....	47
3.1	Materiais.....	47
3.1.1	Área de estudo.....	47
3.1.2	Coleta e tabulação dos dados.....	48
3.2	Método.....	50
3.2.1	Análise exploratória.....	50
3.2.2	<i>Classificação da segurança operacional</i>.....	51
3.2.3	<i>Modelagem por meio do MatLab</i>.....	52
4	RESULTADOS E DISCUSSÕES.....	54
4.1	Análise exploratória.....	54
4.2	Classificação da segurança operacional.....	65
4.3	Modelagem por meio do <i>MatLab</i>.....	65
5	CONCLUSÕES E RECOMENDAÇÕES.....	83
5.1	Principais conclusões.....	83
5.2	Principais limitações.....	84
5.3	Sugestões para trabalhos futuros.....	85
	REFERÊNCIAS.....	98
	APÊNDICE A - BANCO DE DADOS ANALISADO.....	103

1 INTRODUÇÃO

Este capítulo apresenta uma visão geral sobre o cenário do transporte aéreo e da segurança operacional da infraestrutura aeroportuária no Brasil e a importância do acompanhamento das suas condições para pistas de pouso e decolagem (PPD). Além disso, é apresentada a contextualização do trabalho, bem como o problema de pesquisa, a justificativa do estudo, seus objetivos e sua estrutura.

1.1 Contextualização

Em 2019, o número de passageiros transportados no território nacional obteve um aumento pelo terceiro ano consecutivo, de maneira que atingiu a marca de 951 mil operações e 119,4 milhões de passageiros conforme a Agência Nacional de Aviação Civil (ANAC, 2020). Em 2020, devido à pandemia de covid-19, o cenário do transporte aéreo foi diferente do normalmente observado em todo mundo. Houve uma queda expressiva na quantidade de passageiros transportados, bem como do número de operações aéreas. Segundo ANAC (2021a), o número de voos domésticos e internacionais foi 51% menor que em 2019 e o número de passageiros foi reduzido em 56%.

Em 2021, a retomada pós surgimento da covid-19 começou a ser observada, de maneira que foi observado um aumento de 35% do número de operações e 38% do número de passageiros, em relação a 2020. Foram realizadas 546 mil operações e 62,6 milhões de passageiros foram transportados naquele ano, segundo ANAC (2022).

A movimentação de passageiros transportados no Brasil requer atenção dos operadores de aeródromos e da autoridade de aviação civil quanto à segurança das operações aéreas. As fases de pouso e decolagem são as mais críticas de um voo. De acordo com o Centro de Investigação e Prevenção de Acidentes Aeronáuticos (CENIPA, 2021), cerca de 70% dos acidentes aéreos ocorridos entre 2010 e 2019 nos aeródromos brasileiros foram registrados durante as fases de pouso e decolagem e corrida após pouso. No que diz respeito aos incidentes graves, esse número aumentou para 75% aproximadamente.

Nesse âmbito, segundo Liou *et al.* (2008), favorecer condições aceitáveis de segurança às operações, sobretudo nas etapas de pousos e decolagens, é importante para o êxito do transporte aéreo. A utilização de Sistemas de Gerência de Pavimentos Aeroportuários (SGPA) em aeródromos com grandes quantidades de operações é fundamental para a garantia da segurança operacional. ANAC (2021b) afirma que o SGPA permite ao usuário armazenar

informações sobre a condição do pavimento em um banco de dados por meio dos recursos do sistema, para determinar a solução mais viável economicamente para ações de manutenção e reabilitação (M&R). Além disso, o SGPA pode listar vários elementos essenciais à infraestrutura dos pavimentos aeroportuários que podem ser armazenados para tomada de decisões, como as informações sobre seus inventários, estrutura das camadas, estado de conservação, histórico de M&R, custos e tráfego, dentre outras.

Ademais, ANAC (2021b) determina que os operadores de aeródromos devem estabelecer procedimentos de gerenciamento do risco à segurança operacional, de maneira que se garanta continuamente a redução dos riscos. ANAC (2021b) determina, ainda, que devem ser instituídos pelos operadores de aeródromos requisitos, fontes de dados e recursos a serem utilizados para identificação de riscos.

Nesse contexto, uma importante ferramenta de auxílio ao gerenciamento de risco é a avaliação de desempenho da segurança das operações nos aeroportos. Uma classificação da segurança operacional pode monitorar riscos e auxiliar operadores de aeródromos e autoridades aeronáuticas na tomada de decisões, quanto à melhoria da segurança de pouso e decolagem e de taxiamento (CHEN e LI, 2016). Considerando-se essas operações, tem-se que os revestimentos dos pavimentos aeroportuários, sobretudo das pistas de pouso e decolagem, por serem o primeiro contato da aeronave nos aeroportos, são elementos importantes, pois precisam garantir adequada aderência entre o pneu e o pavimento.

1.2 Problema de Pesquisa

O monitoramento atual das condições de aderência dos pavimentos das pistas de pouso e decolagem (PPD) brasileiros é realizado de forma segmentada, considerando aspectos específicos das operações aéreas e da infraestrutura aeroportuária. Isso dificulta a identificação de áreas de risco que podem contribuir para a ocorrência de acidentes com as aeronaves.

A inadequação do monitoramento pode levar a um agravamento das ocorrências de acidentes aéreos, pois os operadores de aeródromos não podem agir proativamente para melhorar as condições das PPD. Uma solução para o problema é o desenvolvimento de ferramentas de suporte ao gerenciamento da segurança operacional que auxiliem no monitoramento das condições de aderência dos revestimentos dos pavimentos das PPD.

Essas ferramentas devem ser capazes de integrar dados de diferentes fontes, como operações aéreas e infraestrutura aeroportuária. Também devem utilizar técnicas de análise preditiva para identificar áreas de risco. Com a implementação dessas ferramentas, os

operadores de aeródromos poderão identificar áreas de risco de forma mais eficaz e agir proativamente para melhorar as condições das PPD, reduzindo assim o risco de acidentes aéreos.

1.3 Justificativa

A segurança operacional das pistas de pouso e decolagem (PPD) é essencial para o funcionamento eficiente e seguro dos aeroportos. As condições dos revestimentos asfálticos dessas pistas desempenham um papel fundamental na garantia da segurança das operações aeroportuárias, uma vez que impactam diretamente na capacidade de frenagem das aeronaves, no controle direcional durante pousos e decolagens, e na redução do risco de derrapagens.

Esta pesquisa se justifica por contribuir para a segurança de passageiros e tripulantes, uma vez que as condições de aderência dos revestimentos asfálticos têm impacto relevante na ocorrência de acidentes e incidentes. Uma classificação da segurança operacional das pistas torna possível a adoção de medidas proativas para evitar restrições das operações aeroportuárias e falhas que possam comprometer a integridade da aderência pneu-pavimento.

1.4 Objetivos

O objetivo geral desta pesquisa é propor uma classificação da segurança operacional de pistas de pouso e decolagem brasileiras para acompanhamento das condições de resistência à derrapagem dos revestimentos asfálticos. Como objetivos específicos, podem ser listados:

- a) Determinar os principais parâmetros de aderência pneu-pavimento relacionados à segurança das pistas de pouso e decolagem brasileiras;
- b) Modelar a segurança operacional por meio de parâmetros de aderência;
- c) Verificar a qualidade dos modelos propostos, em relação ao atendimento das necessidades de um indicador de segurança operacional;

1.5 Estrutura do Trabalho

O presente trabalho é estruturado em cinco capítulos. Além deste capítulo introdutório, no Capítulo 2 é apresentada a revisão da literatura, contendo informações essenciais acerca de indicadores e classificação da segurança operacional, aderência pneu-

pavimento e *Machine Learning*. O Capítulo 3 descreve o método de pesquisa empregado para a obtenção dos resultados. O Capítulo 4 apresenta os resultados acerca da análise exploratória, da classificação da segurança operacional, e, por fim, dos modelos utilizados. Por fim, no Capítulo 5 são expostas as conclusões obtidas com a realização deste trabalho, além das limitações e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo se discute sobre a importância de indicadores de segurança operacional para o gerenciamento de um aeroporto. Além disso, são apresentados parâmetros de aderência pneu-pavimento, tais como coeficiente de atrito, profundidade de macrotextura e remoção do acúmulo de borracha. Por fim, é exposta uma revisão do estado da arte no que diz respeito ao uso do *Machine Learning* para o estudo de pavimentos e escolha das técnicas de classificação adequadas para o problema estudado.

2.1 Indicadores de segurança operacional

A avaliação da segurança operacional de maneira holística é um tema abordado por Wilke *et al.* (2012), Wilke *et al.* (2014) e Cunha *et al.* (2021). Segundo esse método, a segurança operacional deve ser analisada pelo ponto de vista de todos os envolvidos nas operações de pouso e decolagem. As avaliações foram realizadas por meio de consultas a profissionais da aviação civil, com o uso de formulários. A utilização dessa ferramenta torna a análise simples e minimiza a possibilidade de os consultados não responderem a pesquisa. No entanto, é importante minimizar a complexidade das perguntas e o tempo gasto para respondê-las, e assim obter o máximo de retorno dos consultados.

Wilke *et al.* (2012) propuseram um novo método de taxonomia holística de fatores críticos subjacentes a acidentes e incidentes ocorridos nas áreas de manobra de um aeroporto. Por meio de consulta à literatura e a profissionais da aviação, os autores reuniram um conjunto de fatores críticos à segurança das operações realizadas nas áreas de manobra.

Com a aplicação desse método, Wilke *et al.* (2012) analisaram então a existência de correlação entre as características do aeroporto e as ocorrências de acidentes e incidentes. As características analisadas foram: tráfego, geometria, equipamentos e instalações, sinalização visual, manutenção, regulamentos e aspectos humanos. Como ocorrências, analisou-se excursões, incursões, colisões e *Foreign Object Damage* (FOD).

Por meio da consulta a especialistas pode-se validar a taxonomia obtida por meio das correlações. Wilke *et al.* (2012) concluíram, então, que a segurança operacional relacionada ao pavimento aeroportuário é uma chave para a segurança da aviação, embora as abordagens para analisar e mitigar as ocorrências careçam de integração. A taxonomia obtida pelos autores combina quatro técnicas de pesquisa (revisão de literatura, análise de dados de segurança, levantamento de aeroportos e entrevistas com profissionais), de maneira que os pontos de vista

de todas as partes da aviação envolvidas em ocorrências de segurança operacional do pavimento aeroportuário são consultados.

Uma estrutura para avaliação de risco de forma holística, a fim de integrar todas as partes interessadas no nível de segurança operacional do pavimento aeroportuário, foi a proposta do estudo de Wilke *et al.* (2014). O método utilizado é simples, uma vez que é focado na elaboração e refinamento de um modelo, composto pela estrutura de avaliação. A importância de se obter dados seguros no desenvolvimento da pesquisa, além de aeroportos de média a alta movimentação, de maneira que os dados obtidos fossem suficientes para o estudo, foi algo considerado importante na pesquisa.

Wilke *et al.* (2014) computaram 344 fatores relacionados ao pavimento aeroportuário, a fim de buscar as ocorrências de acidentes e incidentes que pudessem estar relacionadas a essas características. As ocorrências analisadas foram: excursões, incursões, colisões, FOD e colisões com vida selvagem, em um total de 6.300 ocorrências. Foram avaliados fatores relacionados ao controle do tráfego aéreo, à aeronave, às operações do aeródromo, ao ambiente e regulamentos. Não se analisou condições relacionadas ao estado de conservação do pavimento.

Foi destacado no estudo de Wilke *et al.* (2014) a importância de considerar o ponto de vista de todos os profissionais envolvidos no sistema. O modelo construído permite que os gestores sejam capazes de visualizar fatores não diretamente relacionados com as operações.

Propor um método composto de multicritérios para prever o risco existente em aeroportos, com o auxílio de profissionais da área, foi o objetivo do estudo de Cunha *et al.* (2021). Foi utilizada a ferramenta *Methodology Multicriteria Decision Aid – Constructivist* (MCDA-C) como forma de diminuir a subjetividade existente no desenvolvimento de uma árvore de decisão para avaliação de riscos em aeroportos. Esse método é composto de três etapas: a estruturação do contexto da tomada de decisão, a construção de critérios de avaliação e a análise final dos resultados com proposta de decisão.

A árvore de decisão obtida pelo estudo de Cunha *et al.* (2021) foi composta de 12 elementos que foram organizados em diferentes níveis. Após o julgamento dos profissionais da área sobre os 12 aspectos levantados inicialmente, foram atribuídos pesos para cada um deles. Os autores selecionaram então os 5 principais elementos de análise, considerados os mais representativos, e por fim realizaram uma análise de percepção de risco em 29 aeroportos brasileiros. Os parâmetros avaliados foram *Aircraft Classification Number/Pavement Classification Number* (ACN/PCN), *Pavement Condition Index* (PCI), coeficiente de atrito, *International Roughness Index* (IRI) e profundidade de macrotextura.

Cunha *et al.* (2021) concluíram que uma parte considerável dos recursos direcionados aos aeroportos brasileiros poderia ser aplicada de forma mais racional, pois reduziria a despesa com elementos de baixo risco. Além disso, os autores concluíram que o método utilizado pode ser aplicado como ferramenta para avaliação de riscos em cenários com dados objetivos e subjetivos.

A maior prioridade para a seleção dos dados de segurança é a qualidade, segundo Wilke *et al.* (2015). Isto se deve à relação direta entre a precisão da modelagem estatística e a qualidade dos dados utilizados. Os autores se referem à segurança das operações de pouso e decolagem como um desafio, possível de se superar com a identificação e entendimento dos fatores causais que envolvem a segurança dessas operações. Além disso, a complexidade da infraestrutura do pavimento aeroportuário torna esse sistema vulnerável. No entanto, embora a contribuição dos fatores humanos, práticas operacionais e procedimentos tenham sido amplamente pesquisados, o impacto das características do pavimento tem recebido pouca ou nenhuma atenção.

Com a finalidade de analisar o impacto das características do pavimento aeroportuário na ocorrência de acidentes e incidentes, Wilke *et al.* (2015) propuseram uma estrutura para avaliação integrada de risco das operações realizadas em áreas de manobra (pista de pouso e decolagem e de taxiamento). O método é composto por modelagens estatísticas.

Os dados utilizados no estudo de Wilke *et al.* (2015) foram previamente analisados a fim de conhecer a distribuição a que eles melhor se adequavam e se os valores poderiam ser considerados homogêneos, visto que os dados vieram de países diferentes. Em seguida foram testadas diferentes correlações entre as características do pavimento e os acidentes e incidentes, aquelas que se mostraram significativas tiveram seus dados modelados por regressão logística.

As características analisadas foram: localização do aeroporto, tráfego, geometria do pavimento, equipamentos e instalações, sinalizações visuais, operações de manutenção do pavimento, regulamentos e aspectos humanos. Incursões, excursões e FOD foram as ocorrências analisadas. Wilke *et al.* (2015), então, concluíram que a gravidade das ocorrências pode ser prevista por meio da modelagem estatística das características do pavimento, em particular a geometria do pavimento, mas a previsão das ocorrências não é possível com o uso do método aplicado.

Ao analisar as condições físicas de pavimentos aeroportuários, Mota *et al.* (2016) buscaram priorizar aquelas que tivessem maior influência sobre a segurança das operações de pouso e decolagem, por meio de consulta a profissionais da área. Segundo os entrevistados, o coeficiente de atrito e a profundidade de macrotextura têm, juntos, peso de 48% sobre a

segurança das operações, com 30% e 18% respectivamente. Esse fator coloca as condições de aderência (61%) como as mais importantes no que diz respeito à priorização das atividades de M&R, seguidas pelas condições funcionais (28%) e estruturais do pavimento (11%).

Valdés *et al.* (2011), Benedetto *et al.* (2014), Distefano e Leonardi (2019), Di Mascio *et al.* (2020) e Galagedera *et al.* (2021) desenvolveram um método com o objetivo de minimizar os riscos de excursões em pista. Segundo *Civil Aviation Authority* (CAA, 2021), a *International Civil Aviation Organization* (ICAO) concentra sua atenção no que diz respeito à segurança operacional nas pistas de pouso e decolagem nas excursões em pistas. Essa ocorrência tem como fator de risco a deficiência das condições de aderência pneu-pavimento que sofre influência dos contaminantes presentes na superfície das pistas.

Embora as condições de aderência sejam um fator de atenção para a ocorrência de excursões, a literatura apresenta pouca abordagem dos parâmetros relacionados a essa condição. Galagedera *et al.* (2021) ao avaliar o impacto de diferentes características referentes as pistas de pouso e decolagem sobre a ocorrência de excursões, incluíram o coeficiente de atrito dentre os parâmetros analisados. Os autores concluíram que o coeficiente de atrito pouco influenciava o evento de risco.

No que diz respeito às condições estruturais, Benedetto *et al.* (2014) desenvolveram um método para previsão da deformação de solos, a fim de evitar a formação de afundamentos permanentes no pavimento, o que pode levar a excursões em pista, segundo os autores. Por meio dos resultados, observou-se que uma descrição detalhada das propriedades de resistência do solo é importante na previsão dos afundamentos. No entanto, o trabalho não detalha a que ponto esse tipo de defeito pode desestabilizar os trens de pouso de uma aeronave, de maneira que o foco é apenas o estudo do defeito, não sua correlação com a ocorrência de risco.

Di Mascio *et al.* (2020) analisaram as características geotécnicas por meio do *California Bearing Rating* (CBR) e obtiveram valores inferiores aos indicados pela literatura. Isso sugere maiores danos associados aos eventos de excursão e apontam a necessidade em melhorar a capacidade de carga e conseqüentemente a condição estrutural do pavimento local. Apesar de Di Mascio *et al.* (2020) indicarem limites que precisam ser atendidos pelo CBR para minimizar os efeitos dos riscos de excursão em pistas (entre 15% e 20%) destaca-se que para cenários brasileiros a utilização de CBR para avaliação do suporte de carga é questionado. Isto se deve ao fato de o solo ser comparado a um material padrão utilizado nos EUA que não reflete adequadamente as características apresentadas pela maioria dos solos brasileiros.

Di Mascio *et al.* (2020) avaliaram quantitativamente o risco de excursão em pista por meio de estudo de caso em um aeroporto internacional localizado na Itália. Assim como

Moretti *et al.* (2018), os autores utilizaram métodos e modelos para representar o risco de excursão por meio da probabilidade de ocorrência. Para o estudo, os autores consideraram a definição de uma matriz de risco que consistiu em cinco níveis de probabilidade de risco e gravidade da ocorrência e de critérios de aceitabilidade. Tal método pode ser analisado para verificar a aplicação da criação de modelos e análise de variáveis obtidas para aeroportos brasileiros que possam auxiliar na compreensão das ocorrências de acidentes ou incidentes nacionais.

Distefano e Leonardi (2019) identificaram correspondências entre características relativas à região geográfica, causa potencial do evento, classe da aeronave, natureza do voo e danos à aeronave, que ocorrem em eventos de excursão em pista para as etapas de pouso e decolagem. Os autores perceberam que as excursões de pista com perda total da aeronave são causadas por más condições climáticas e más condições da pista. No Brasil, por exemplo, as condições de pista podem ser um fator de risco para esse tipo de ocorrência, devido às dificuldades em manter os pavimentos com conservação adequada.

As condições da pista consideradas por Distefano e Leonardi (2019) foram: pista molhada, presença de contaminação, FOD e presença de vida selvagem. Enquanto as variáveis climáticas consideradas incluíam: baixa visibilidade, chuva, vento turbulência, entre outros. Apesar de os autores considerarem fatores relacionados às condições da pista, não se verifica a utilização de variáveis relacionadas às condições da estrutura ou superfície do pavimento.

Valdés *et al.* (2011) utilizaram uma abordagem probabilística para modelar o risco de excursões em pista. O método é composto pela coleta de dados históricos de acidentes. Segundo os autores, as informações sobre acidentes devem ser suficientemente detalhadas, confiáveis e consistentes para garantir que as análises subsequentes sejam confiáveis. Além disso, o processo de modelagem foi supervisionado e validado por uma equipe multidisciplinar de profissionais da área.

Além disso, os autores concluíram que, em alguns casos, atender plenamente às exigências da ICAO pode levar a um aumento do risco de acidente. No caso de aterrissagens em excesso no aeroporto estudado por Valdés *et al.* (2011), o aumento do comprimento da pista e da *Runway Safety Area* (RESA) leva a uma redução da distância de aterrissagem disponível e, portanto, a um aumento do risco associado. Dessa forma, percebe-se que é necessário que os operadores de aeródromos investiguem com mais detalhes as peculiaridades que envolvem projetos aeroportuários.

Ayres Jr. *et al.* (2013) desenvolveram modelos para avaliar riscos relacionados à acidentes com aeronaves nos aeroportos e nas suas proximidades e gerenciar a RESA como

uma medida de mitigação de riscos. Isso indica que há amplas possibilidades de se utilizar modelagens estatísticas para o desenvolvimento de modelos de risco à segurança das operações aéreas.

Trucco *et al.* (2015) desenvolveram um modelo probabilístico para a caracterização topológica do risco de acidentes considerando fatores de tráfego e clima. O modelo foi construído a partir do uso de regressão logística e considerou diferentes variáveis para as etapas de pouso e decolagem. Com o estudo, os autores observaram que os fatores relacionados ao clima (presença de gelo, neve e vento cruzado) foram os mais influentes para a ocorrência de acidentes nas etapas de pouso e decolagem.

Destaca-se que para aplicação do modelo obtido por Trucco *et al.* (2015) em território brasileiro, de clima tropical, outros fatores climáticos que não a presença de gelo ou neve nas pistas devem ser considerados. Em concordância ao obtido por Trucco *et al.* (2015), Distefano e Leonardi (2019) observaram que a causa mais comum de excursão em pista durante o pouso são as condições climáticas.

Desenvolver um método para estimar um Indicador Individual de Desempenho e um Indicador Geral de Desempenho com base em condições latentes foi o objetivo do estudo de Cardoso *et al.* (2008). O estudo iniciou com a identificação de indicadores de desempenho a serem medidos em um aeroporto. Foram estabelecidas características essenciais aos indicadores que se pretendia observar. Esses indicadores foram enviados a profissionais da aviação sul-americana para que fossem validados e listados ordem de prioridade. Por fim, estabelecidos os pesos a cada indicador individual, foi estabelecido o indicador geral por meio de uma equação desenvolvida pelos autores. Foram identificados 27 indicadores individuais de desempenho no estudo de Cardoso *et al.* (2008). Os indicadores com maior influência foram: incursões na pista, incidentes na PPD, vida selvagem e FOD na PPD.

Soncim *et al.* (2019) desenvolveram modelos de Lógica Fuzzy para a avaliação do desempenho do pavimento asfáltico. O conjunto de variáveis independentes utilizado neste estudo consistia na idade do pavimento e na carga equivalente a um eixo de 80 kN (N). O conjunto de variáveis dependentes foi composto pelo *International Roughness Index* (IRI) e pelo PCI.

Os modelos do estudo de Soncim *et al.* (2019) foram construídos com o auxílio de especialistas em gestão de pavimentos, que foram consultados por meio de formulários. Os especialistas deveriam relacionar valores de cada parâmetro as classificações, além de sua pertinência, ou seja, quão um valor pode se encaixar dentro de uma categoria, em uma escala composta por 0, 0,25, 0,50, 0,75 e 1, em que: 0 significa que o valor não pode ser enquadrado

dentro de uma categoria e 1 que ele pode ser totalmente enquadrado.

Por meio dos modelos construídos por Soncim *et al.* (2019) foi possível prever os valores de IRI e de PCI, com coeficientes de correlação de 0,71 e 0,70, respectivamente. Este estudo mostrou que a Lógica *Fuzzy* pode ser usada para modelar variáveis relacionadas à deterioração do pavimento flexível, com base no conhecimento de especialistas em gestão de pavimentos, além de ser uma ferramenta alternativa, quando não há dados históricos de um determinado trecho de rodovia.

A Tabela 1 apresenta de forma resumida as informações extraídas dos estudos citados neste capítulo. Nela são apresentados os objetivos, método adotado na pesquisa, parâmetros avaliados e principais conclusões.

Tabela 1 – Estudos de Indicadores de Segurança Operacional

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
Holistic Approach to Airport Surface Safety (WILKE <i>et al.</i> , 2012)	Propor uma abordagem para questões de segurança do pavimento aeroportuária, com a identificação de fatores do pavimento relacionados com incidentes e acidentes.	Foi analisada a correlação entre diversas variáveis relacionadas às pistas de pouso e decolagem e os fatores críticos. Realizaram-se também entrevistas com profissionais para que houvesse auxílio na análise dos dados.	Incurção, excursão e FOD.	A segurança operacional relacionada ao pavimento aeroportuária é uma chave para a segurança da aviação.
Airport surface operations: A holistic framework for operations modeling and risk management (WILKE <i>et al.</i> , 2014)	Desenvolver uma ferramenta que determine os fatores que causam falha nas operações aéreas, além de avaliar a arquitetura do aeroporto em termos de segurança.	A ferramenta foi desenvolvida em quatro etapas: (i) criação do modelo; (ii) análise dos fatores causais para acidentes/incidentes nas pistas do aeroporto; (iii) refinamento do modelo do processo e (IV) desenvolvimento da ferramenta de cenário macroscópico. Foram avaliados 58 aeroportos.	Excursões, incurções, colisões, acidentes com vida selvagem e <i>Foreign Object Damage</i> (FOD).	Foi destacada a importância de considerar o ponto de vista de todos os profissionais envolvidos no sistema. O modelo construído permite que os gestores sejam capazes de visualizar fatores não diretamente relacionados com as operações.
RISK assessment in airport maintenance runway condition using MCDA-C (CUNHA <i>et al.</i> , 2021)	Propor um método composto de multicritérios para prever o risco existente em aeroportos, com o auxílio de profissionais da área.	Foi utilizada a ferramenta MCDA-C. A árvore de decisão obtida pelo estudo foi composta de 12 elementos que foram organizados em diferentes níveis. Após o julgamento dos profissionais da área sobre os aspectos levantados inicialmente, foram atribuídos pesos para cada um deles.	ACN/PCN, PCI, coeficiente de atrito, IRI e profundidade de macrotextura.	Os autores concluíram que uma parte dos recursos direcionados aos aeroportos brasileiros poderiam ser redirecionados a uma aplicação racional, pois reduziria a despesa com elementos de baixo risco.
The impact of airport characteristics on airport surface accidents and incidents (WILKE <i>et al.</i> , 2015)	Propor uma estrutura para uma avaliação de risco integrada das operações de superfície aeroportuária e analisar o impacto das características do aeroporto na ocorrência de acidentes e incidentes em pistas e suas causas na América do Norte, Europa e Oceania.	Foi realizada uma análise estatística, por meio de regressão, com a finalidade de averiguar a correlação entre as características dos aeroportos e os incidentes e acidentes.	Incurções, excursões e FOD.	O estudo constatou que a gravidade das ocorrências pode ser prevista. Além disso, provou pela primeira vez que existe uma relação entre as características do aeroporto e as ocorrências de segurança.

Tabela 1 – Estudos de Indicadores de Segurança Operacional

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
Verificação multicritério das condições físicas para a segurança operacional aeroportuária (MOTA <i>et al.</i> , 2016)	Analisar a influência das condições de aderência, estruturais e funcionais sobre a segurança operacional aeroportuária.	O trabalho foi realizado por meio da MAH. Com o uso de formulários, profissionais da área avaliaram cada critério, designando um peso para cada, conforme a importância na segurança das operações aeroportuárias. Utilizou-se o software <i>Expert Choice</i> para a combinação das respostas, gerando um peso para cada critério.	ACN, PCN, PCI, IRI, macrotextura e coeficiente de atrito.	O coeficiente de atrito e a macrotextura foram, segundo os profissionais entrevistados, as condições que mais influenciam na segurança das operações aeroportuárias.
The development of probabilistic models to estimate accident risk (due to runway overrun and landing undershoot) applicable to the design and construction of runway safety areas (VALDÉS <i>et al.</i> , 2011)	Desenvolver um método sistemático e prático que permita às organizações envolvidas no projeto e gestão de aeroportos avaliar o nível de risco de um determinado aeroporto com base em normas para RESAs.	O método seguiu os passos: a) coleta de dados históricos sobre acidentes representativos; b) desenvolvimento de um modelo de dados para classificação e descrição de acidentes; c) formalização desse modelo em um banco de dados.	Dados de acidentes do tipo <i>overrun</i> e <i>undershoot</i> .	O modelo oferece a possibilidade de comparar os riscos associados a diferentes configurações de pistas e comparação de suas vantagens e desvantagens. Com base nesta aplicação, percebeu-se que, em alguns casos, atender às exigências da ICAO e seguir suas recomendações pode levar a um aumento do risco de acidente. Os resultados das estimativas de risco são maiores no caso de <i>overrun</i> pois esse tipo de acidente tem maior probabilidade de ser fatal.
Evaluation of the impact of runway characteristics on veer-off risk at rapid exit taxiways (GALAGEDERA <i>et al.</i> , 2021)	Propor um método para avaliar os riscos de <i>veer-off</i> sob diferentes condições operacionais e de design nas saídas rápidas das pistas	Utiliza-se princípios de estabilidade lateral da engrenagem nasal. Um modelo determinístico é derivado para o raio de giro da mesma. Supõe-se que as variações causais induzidas pelas condições operacionais fariam a aeronave desviar da trajetória da linha central da <i>taxiway</i> . Desvios excessivos são a base para potenciais eventos de excursão	Fatores operacionais e de design da aeronave, desaceleração e velocidade.	Um dos maiores desafios superados pela abordagem do estudo é a falta de dados operacionais relacionados a incidentes de <i>veer-off</i> relacionados à saída rápida. Os riscos de desvio de aeronaves aumentam significativamente em velocidades de saída mais altas e desacelerações mais baixas.

Tabela 1 – Estudos de Indicadores de Segurança Operacional

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
<p>Aircraft runway excursion features: a multiple correspondence analysis (DISTEFANO <i>et al.</i>, 2019)</p>	<p>Identificar a correspondência entre características pertencentes a diferentes aspectos que ocorrem em eventos de excursão de pista, distinguindo entre as fases de decolagem e pouso.</p>	<p>Aplicação de análise de correspondência múltipla (MCA) para definir a correspondência entre as características das excursões de pista e variáveis que podem afetar sua ocorrência.</p>	<p>Região geográfica, causa potencial (defeitos no sistema da aeronave, erro humano, condições climáticas, condições da pista, desconhecido), classe da aeronave, natureza do voo, danos a aeronave.</p>	<p>As consequências de um acidente de excursão na pista são danos substanciais à aeronave; as causas potenciais variam de acordo com a classe da aeronave e a região geográfica. As excursões de pista com perda total da aeronave são causadas por más condições climáticas e más condições da pista, tanto durante a decolagem quanto para o pouso.</p>
<p>Runway Veer-Off Risk Analysis: An International Airport Case Study (DI MASCIO <i>et al.</i>, 2020)</p>	<p>Avaliar de forma quantitativa os riscos de <i>veer-off</i> da pista de decolagem em um aeroporto.</p>	<p>Criação de um conjunto estruturado de métodos e modelos para representar o risco por meio da probabilidade de ocorrência e a gravidade do dano.</p>	<p>Vento, tráfego, operações de decolagem e pouso, presença de edifícios no interior do recinto aeroportuário e as características geotécnicas das áreas da faixa.</p>	<p>Observou-se o que em muitos casos, o risco calculado excede o nível máximo de risco permitido e exige a adoção de medidas. O método apresentado pelos autores pode ser uma ferramenta válida para os operadores de aeródromos gerirem os desvios registrados nas infraestruturas aeroportuárias.</p>
<p>Improving safety of runway overrun through the correct numerical evaluation of rutting in Cleared and Graded Areas (BENEDETTO <i>et al.</i>, 2014)</p>	<p>Desenvolver um método alternativo para prever deformações devido à ultrapassagem das aeronaves.</p>	<p>Os experimentos foram projetados para verificar a eficácia do modelo de interação pneu-solo. Os efeitos da carga exercida pela engrenagem principal sobre o <i>Cleared and Graded Area</i> durante a ultrapassagem foram simulados. Mediu-se o afundamento e as propriedades mecânicas do material envolvido nos processos de ultrapassagem do veículo. Os testes foram realizados em diferentes velocidades iniciais de ultrapassagem até a parada do veículo.</p>	<p>CBR, deformações e afundamentos de trilha de roda.</p>	<p>Os resultados demonstraram que uma descrição mais detalhada das propriedades de resistência do solo desempenha um papel profundamente importante na previsão das deformações. Com o uso de valores discretizados de CBR, os dados experimentais foram ajustados de forma mais adequada.</p>

Tabela 1 – Estudos de Indicadores de Segurança Operacional

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
Topological risk mapping of runway overruns: A probabilistic approach (TRUCCO <i>et al.</i> , 2015)	Desenvolver um modelo de caracterização topológica do risco de <i>overruns</i> em pistas, tendo em consideração um vasto conjunto de fatores incertos, tanto relacionados com o tráfego e condições climáticas.	Criação de modelos probabilísticos capazes de realizar a quantificação da importância de cada fator considerado na análise e a forma como influencia na probabilidade final de acidente	Condições meteorológicas e tráfego a que a pista está sujeita	O método proposto apresenta técnica independente de julgamentos qualitativos comumente observados em avaliações de riscos. O método permite uma melhor quantificação da probabilidade de acidentes para cada área topológica do aeroporto permitindo um planeamento mais detalhado das RESAs.
Modelling the location and consequences of aircraft accidents (AYRES JR, <i>et al.</i> , 2013)	Desenvolver um método de avaliação dos riscos aeroportuários destinada a avaliar aqueles relacionados com acidentes aéreos nos aeroportos e na sua proximidade e a gerir as RESAs como medida de mitigação de riscos.	Com banco de dados de acidentes foram desenvolvidos modelos de frequência de ocorrências, identificando-se quais fatores são contribuintes. Comparou-se esses casos com aqueles contidos em um banco de dados em que não foram registrados acidentes, mas com a presença dos mesmos fatores causais analisados anteriormente.	<i>Overrun, veer-off e undershoot.</i>	Os modelos de localização poderiam ser melhorados se fosse dada maior atenção à causalidade, mas existem dificuldades de dados, por exemplo, sobre as influências meteorológicas na distância.
Methodology to Estimate Individual and Overall Performance Indicators for Airport Safety Management Systems (SMS) (CARDOSO, <i>et al.</i> , 2008)	Desenvolver um método para estimar um Indicador Individual de Desempenho e um Indicador Geral de Desempenho com base em condições latentes.	Foram estabelecidas características essenciais aos indicadores que se pretendia observar. Esses indicadores foram enviados a profissionais da aviação para que fossem validados e indicados ordem de prioridade. Por fim, estabelecidos os pesos a cada indicador individual, foi estabelecido o indicador geral por meio de uma equação desenvolvida pelos autores.	Foram identificados 27 indicadores individuais de desempenho, entre eles: incursões, FOD e, presença de vida selvagem	Os indicadores elencados como possuindo maior influência foram: incursões na pista, incidentes na PPD, vida selvagem/ataque de pássaros as aeronaves e FOD na PPD.

Tabela 1 – Estudos de Indicadores de Segurança Operacional

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
<p>Development of fuzzy models for asphalt pavement performance (SONCIM, <i>et al.</i>, 2019)</p>	<p>Desenvolver modelos de Lógica <i>Fuzzy</i> para a avaliação do desempenho do pavimento asfáltico.</p>	<p>Os modelos do estudo foram construídos com o auxílio de especialistas em gestão de pavimentos, que foram consultados por meio de formulários.</p>	<p>Idade do pavimento, tráfego, IRI e PCI.</p>	<p>Foi possível prever os valores de IRI e de PCI. Este estudo mostrou que a Lógica <i>Fuzzy</i> pode ser usada para modelar variáveis relacionadas à deterioração do pavimento flexível, com base no conhecimento de especialistas em gestão de pavimentos, além de ser uma ferramenta alternativa, quando não há dados históricos de um determinado trecho de rodovia.</p>

Fonte: Elaborado pela autora (2023)

2.2 Aderência pneu-pavimento

Zheng *et al.* (2018) desenvolveram um estudo com o objetivo de determinar as características que afetam a aderência pneu-pavimento. Para isso, foram analisados três tipos de revestimento asfáltico: Camada Porosa de Atrito (CPA), Concreto Asfáltico (CA) e *Stone Mastic Asphalt* (SMA). Por meio de modelos de elementos finitos, os autores caracterizaram a ocorrência da hidroplanagem.

Verificou-se que a aderência pneu-pavimento diminui com o aumento da velocidade do veículo em todas as condições. No entanto, foi observado que o pavimento de CPA tem uma maior aderência mesmo na presença de película de água e em condições com altas velocidades. O pavimento de CA apresentou a pior condição, com redução de 15,4% da aderência em um evento de hidroplanagem, enquanto o SMA apresentou 11,8% e a CPA 9,7% (ZHENG *et al.*, 2018).

O CA apresentou pior desempenho da aderência pneu-pavimento ao se considerar apenas o aumento da velocidade, de maneira que foi o revestimento com maior decréscimo nessa condição. Além disso, o estudo demonstrou que, na presença de lâmina d'água, a aderência pneu-pavimento aumenta com uma maior profundidade de macrotextura. Isso indica que a CPA também apresenta melhor desempenho no que diz respeito a esse parâmetro, visto que é o revestimento com maiores profundidades de macrotextura (ZHENG *et al.*, 2018).

Yager, em 1962, desenvolveu a técnica que consiste na execução de ranhuras por fresagem no revestimento asfáltico, de profundidade, largura, espaçamento e forma uniformes. A fresagem é feita no sentido transversal do eixo de pistas de pouso e decolagem em aeroportos, com o objetivo de diminuir a distância de frenagem na presença de chuvas (PEREIRA, 2010). Essa técnica, denominada de *grooving* surgiu a partir da preocupação com a hidroplanagem, que consiste na perda de contato dos pneus das aeronaves com o pavimento devido à existência de lâmina d'água sobre o pavimento (HORNE e TAYLOR, 1965).

Sales *et al.* (2022) avaliaram três revestimentos distintos, com o objetivo de verificar a existência de correlação entre a prática de remoção de acúmulo de borracha e a melhoria da aderência pneu-pavimento. Os autores estudaram a CPA, o CA e o *grooving*, presentes em três aeroportos brasileiros, que tiveram profundidade de macrotextura e coeficiente de atrito analisados por meio de testes estatísticos.

Observou-se que a remoção do acúmulo de borracha é um processo de manutenção eficiente nos aeroportos, uma vez que possibilita que os níveis mínimos exigidos pelos regulamentos para profundidade de macrotextura e coeficiente de atrito sejam mantidos.


Percebeu-se que a remoção do acúmulo de borracha proporciona reações diferentes em cada tipo de revestimento. No entanto, o processo não garante aumentos significativos a longo prazo. Dessa forma, esse procedimento não deve ser a única ferramenta de manutenção das pistas de pouso e decolagem (SALES *et al.*, 2022).

Tendo em vista que a textura do pavimento é diretamente ligada ao coeficiente de atrito, sua deterioração é um fator crítico para a segurança das operações de pouso e decolagem, especialmente em pavimentos com presença de lâmina d'água. A fim de estudar os efeitos dessa deterioração, Zhu *et al.* (2021) avaliaram três tipos de revestimentos asfálticos: CPA, CA e *Stone Mastic Asphalt* (SMA). Para esse fim, os autores desenvolveram um algoritmo que simula o desgaste do revestimento com o uso de elementos finitos. O modelo de hidropilanagem desenvolvido apresenta quatro submodelos: modelo para os pneus, pista de pouso e decolagem, interação pneu-pavimento e película d'água.

Como resultado, Zhu *et al.* (2021) inicialmente observaram que o coeficiente de atrito diminui consideravelmente nos três tipos de pavimentos analisados a partir de taxa de desgaste igual a 30. Por meio da Figura 1, pode-se observar que a CPA foi o revestimento que apresentou o melhor comportamento diante do aumento do desgaste, mas que todos os pavimentos demonstraram situação crítica diante a um desgaste maior que 40. A Equação 1 apresenta o cálculo da taxa de desgaste.

$$\text{Taxa de Desgaste} = \frac{\text{Velocidade}_{\text{aeronave}} - \text{Velocidade}_{\text{pneu}}}{\text{Velocidade}_{\text{aeronave}}} \times 100 \quad (1)$$

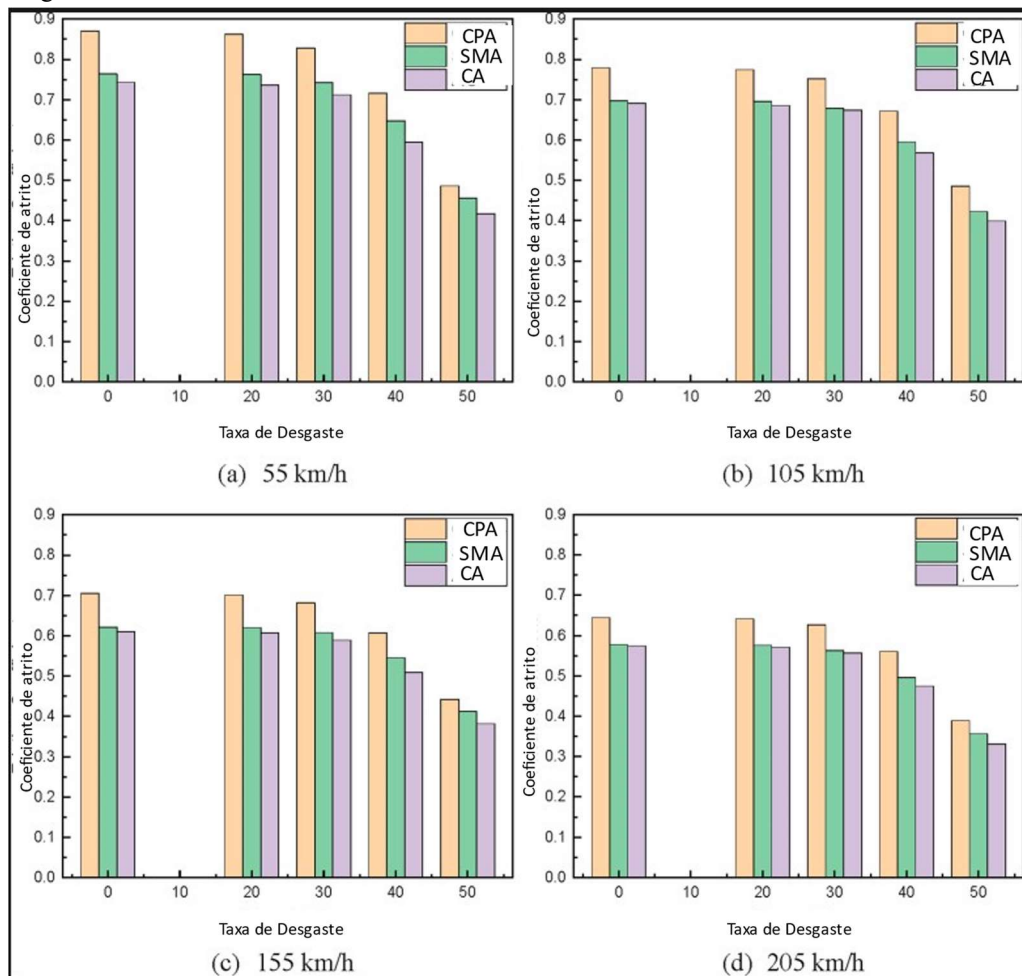
Figura 1 – Coeficiente de atrito x taxa de desgaste do pavimento



Fonte: Adaptado de Zhu *et al.* (2021)

A Figura 2 apresenta os resultados obtidos em pavimentos com presença de lâmina d'água. Por meio dela pode-se perceber que as diferenças de coeficiente de atrito entre os tipos de revestimento diminuem em relação a um pavimento seco.


Figura 2 – Coeficiente de atrito *versus* taxa de desgaste do pavimento com presença de lâmina d'água



Fonte: Adaptado de Zhu *et al.* (2021)

A presença de contaminantes em revestimentos de pistas de pouso e decolagem também foi assunto do estudo de Chen *et al.* (2013). Por meio de análises macro e microscópicas os autores avaliaram o pavimento do *Kaohsiung International Airport* (KIA) em Taiwan. A Figura 3 apresenta um importante resultado deste estudo, as espessuras dos depósitos de borracha, que tem suas camadas representadas pelos números ímpares, em vermelho, enquanto os pares são de revestimento asfáltico.

Figura 3 – Depósitos de borracha no revestimento da PPD do KIA em Taiwan



Fonte: Adaptado de Chen *et al.* (2013)

Os resultados do estudo de Chen *et al.* (2013) indicaram que a borracha em um revestimento promove o aumento da espessura cerca de $0,05 \mu\text{m}$ a cada pouso de aeronave. Chen *et al.* (2013) observaram que as camadas mais profundas de borracha, depositadas há mais tempo, apresentaram maior rigidez, o que dificulta sua remoção.

Além disso, Chen *et al.* (2013) observaram que, nas regiões de toque das aeronaves durante o pouso, os valores de coeficiente de atrito estavam abaixo do mínimo permitido. No que diz respeito a profundidade de macrotextura, os autores concluíram que pequenas mudanças nesse parâmetro já influenciam no coeficiente de atrito, de maneira que os dois estão diretamente relacionados. Por fim, conclui-se que um aumento de $0,4 \text{ mm}$ na espessura de depósito de borracha impacta em um decréscimo de $0,2$ no coeficiente de atrito mensurado pelo *Saab Surface Friction Tester* (SFT).

O processo de remoção do acúmulo de borracha dos revestimentos aeroportuários é a principal atividade de manutenção que ocorre nas pistas de pouso e decolagem brasileiras. No entanto, o estudo desenvolvido por Rodrigues Filho (2006) demonstrou que o processo realizado por meio de hidrojateamento reduz significativamente o coeficiente de atrito em uma pista, além de acelerar o processo de perda de finos e desagregação do revestimento.

A profundidade de macrotextura é um fator de relativa importância para a segurança operacional das pistas de pouso e decolagem. Segundo Rodrigues Filho (2006), a profundidade de profundidade de macrotextura é essencial à adequada drenagem de um pavimento aeroportuário. O autor observou que, em revestimentos com alto teor de contaminação por

acúmulo de borracha, a profundidade de macrotextura apresenta redução em seus valores.

Silva (2008) observou que a execução de *grooving* em uma pista de pouso e decolagem proporciona melhorias significantes na aderência pneu-pavimento, devido a capacidade drenante desse tipo de revestimento. No entanto, o emborrachamento da superfície da pista compromete a segurança das operações, de maneira que se comprovou por meio de análises estatísticas que o processo de remoção do acúmulo de borracha por meio de hidrojateamento proporciona melhorias significativas na profundidade de macrotextura do revestimento e conseqüentemente na drenabilidade. O autor observou que a aderência apresentou condição três vezes superior após a remoção do acúmulo de borracha.

Alecrim *et al.* (2022) estudaram vias urbanas brasileiras com o objetivo de avaliar o desempenho acústico do revestimento em Camada Porosa de Atrito (CPA) quando utilizado nesse tipo de pavimento. Em suas conclusões, os autores observaram que ao longo de 2,5 anos de uso, esses pavimentos passaram de classificação de profundidade de macrotextura aberta ($0,80 \leq \text{Profundidade} \leq 1,20 \text{ mm}$) ou muito aberta ($\text{Profundidade} > 1,20 \text{ mm}$) para média ($0,40 \leq \text{Profundidade} \leq 0,80 \text{ mm}$). Esse fato indicou que a CPA em ambientes urbanos, com grande solicitação de tráfego, e em locais secos (pouca precipitação) pode estar sendo colmatada, ou seja, os vazios estão sendo preenchidos por contaminantes.

A CPA tem desvantagens que causam resistência no processo de decisão sobre seu uso como revestimento. Essa mistura tem menor durabilidade, pois o processo de perda de agregados na superfície se dá com maior rapidez que em outros tipos de revestimentos. Além disso, no que diz respeito à sua funcionalidade, seus vazios proporcionam o depósito de sedimentos, que leva a colmatação do revestimento, com sua funcionabilidade no que diz respeito à drenagem, diminuída. Dessa forma, a CPA se caracteriza como uma mistura de maior custo e menor vida útil. Mesmo após passar por processos de manutenção, a CPA tem apenas 69% de sua permeabilidade inicial restaurada (HERNANDEZ-SAENZ *et al.*, 2016).

ANAC (2020) regulamenta sobre o uso de créditos de desempenho por aeródromos que possuam revestimentos antiderrapantes, *grooving* ou CPA. Esse benefício consiste na possibilidade de aeródromos que possuem esses revestimentos, operar em pistas com condições molhadas, sem a necessidade de aplicação da margem de segurança adotada de 15% para a *Required Landing Distance* (RLD), que se trata da distância requerida para pousar e frear uma aeronave até a parada total. Usualmente, em pistas secas, esse parâmetro consiste na multiplicação da *Actual Landing Distance* (ALD) por 1,67. A ALD consiste na distância necessária para pousar e frear a aeronave até a parada total, após cruzar a cabeceira da pista a 50 pés. Além disso, a ALD deve ser limitada a 60% da *Landing Distance Available* (LDA), que

se trata do comprimento de pista de pouso e decolagem declarado, disponível para pouso.

Dessa forma, segundo a ANAC (2020), pistas de pouso e decolagem com comprimentos menores se beneficiam de revestimentos compostos de *grooving* e CPA, uma vez que, com essa composição, aeroportos podem operar com aeronaves maiores em condições em que o pavimento esteja molhado. Para tanto, é imprescindível que tais pavimentos se mantenham em condições adequadas no que diz respeito às questões de aderência pneu-pavimento.

No que diz respeito aos parâmetros de aderência, o valor do coeficiente de atrito consiste na média aritmética dos valores obtidos a cada 100 m, no mesmo lado e distância, tendo como referência o eixo de uma PPD (ANAC, 2021b). As medições devem resultar nos valores mínimos estabelecidos pelo regulamento brasileiro, apresentados na Tabela 2, conforme o tipo de equipamento utilizado na medição (coluna [1]), e algumas condições (colunas [2] a [5]).

Tabela 2 – Valores mínimos estabelecidos no Brasil para o coeficiente de atrito

Equipamento [1]	Pneu		Velocidade do ensaio (km/h) [4]	Profundidade da lâmina d'água simulada (mm) [5]	Coeficiente de atrito	
	Tipo [2]	Pressão (kPa) [3]			Nível de manutenção [6]	Nível mínimo [7]
<i>Mu-meter</i>	A	70	65	1,0	0,52	0,42
	A	70	95	1,0	0,38	0,26
<i>Skiddometer</i>	B	210	65	1,0	0,60	0,50
	B	210	95	1,0	0,47	0,34
<i>Surface Friction Tester Vehicle</i>	B	210	65	1,0	0,60	0,50
	B	210	95	1,0	0,47	0,34
<i>Runway Friction Tester Vehicle</i>	B	210	65	1,0	0,60	0,50
	B	210	95	1,0	0,54	0,41
<i>Tatra</i>	B	210	65	1,0	0,57	0,48
	B	210	95	1,0	0,52	0,42
<i>Grip Tester</i>	C	140	65	1,0	0,53	0,43
	C	140	95	1,0	0,36	0,24

Fonte: ANAC (2021b).

Na ocorrência de valores de coeficiente de atrito inferiores ao mínimo de manutenção, o operador de aeródromo deve informar à ANAC os procedimentos que serão praticados para o reestabelecimento à nível de manutenção. Essas ações geralmente se iniciam pela retexturização do revestimento por meio do processo de remoção do acúmulo de borracha acumulada. Em caso de valores inferiores ao nível mínimo, a ANAC solicita que o operador do aeródromo adote ações a fim de manter a segurança operacional, por meio de gerenciamento do risco à segurança operacional. Essas ações devem ser tomadas para que os perigos e riscos presentes sejam identificados, analisados e priorizados até serem minimizados (ANAC, 2014; 2021b).

Segundo a *Federal Aviation Administration* (FAA, 2007) a resistência à derrapagem de uma PPD se deteriora devido a fatores como desgaste mecânico, polimento da textura do pavimento provocada pelos pneus das aeronaves e presença de contaminantes, principalmente de borracha, além do tipo de revestimento utilizado no pavimento. Dessa forma, o operador de aeródromo deve mensurar o coeficiente de atrito com frequência, no mínimo, anual. Tal frequência deve ser diminuída de acordo com o mix de aeronaves que realizam operações no aeródromo.

A Tabela 3 apresenta os valores de coeficiente de atrito estabelecidos pela FAA (2007). Quando o valor médio do coeficiente de atrito está abaixo do valor referente à manutenção, mas acima do mínimo, não são necessárias ações corretivas. Essa classificação indica que o atrito do pavimento está em estado de deterioração, mas ainda aceitável. Para valores de coeficiente de atrito abaixo do mínimo, ações de manutenção devem ser tomadas com urgência, além de investigações pelas causas dos valores baixos.

Tabela 3 – Valores mínimos de coeficiente de atrito estabelecidos pela FAA

Equipamento [1]	Velocidade do ensaio (km/h) [2]	Coeficiente de atrito		
		Nível mínimo [3]	Nível de manutenção [4]	Nível de implantação [4]
<i>Mu-meter</i>	65	0,42	0,52	0,72
	95	0,26	0,38	0,66
<i>Dynatest Consulting, Inc. Runway Friction Tester</i>	65	0,50	0,60	0,82
	95	0,41	0,54	0,72
<i>Airport Equipment Co. Skiddometer</i>	65	0,50	0,60	0,82
	95	0,34	0,47	0,74
<i>Airport Surface Friction Tester</i>	65	0,50	0,60	0,82
	95	0,34	0,47	0,74
<i>Airport Technology USA Safegate Friction Tester</i>	65	0,50	0,60	0,82
	95	0,34	0,47	0,74
<i>Findlay, Irvine, Ltd. Griptestter Friction Meter</i>	65	0,43	0,53	0,74
	95	0,24	0,36	0,64
<i>Tatra Friction Tester</i>	65	0,48	0,57	0,76
	95	0,42	0,52	0,67
<i>Norsemeter RUNAR (operated at fixed 16% slip)</i>	65	0,45	0,52	0,69
	95	0,32	0,42	0,63

Fonte: Adaptado de FAA (2007).

A profundidade da macrotextura do revestimento deve ser determinada por meio do ensaio da mancha de areia, de acordo com ANAC (2021b). O ensaio consiste na determinação da profundidade de areia na superfície de um pavimento por meio do preenchimento dos vazios da textura superficial com um volume de 25.000 mm³ de uma areia padronizada. A areia é espalhada em uma superfície limpa inicialmente, em movimentos circulares, até que não seja mais possível espalhar o material e tenha-se obtido uma mancha no formato aproximado de um

círculo. É necessária a utilização de um anteparo de madeira, de maneira que não haja influência do vento sobre o ensaio. O procedimento é ilustrado na Figura 4.

Figura 4 – Ensaio da mancha de areia



Fonte: Sousa e Oliveira (2019).

Por fim, deve-se realizar a medida do diâmetro do círculo, quatro vezes em direções diferentes e calculada a média. Dessa forma, tendo-se o conhecimento do volume de areia e do diâmetro do círculo, é possível obter a altura da mancha de areia na superfície do pavimento.

A profundidade média da macrotextura deve-se manter acima de 0,60 mm em uma PPD, no entanto essa classificação é diferente para revestimentos constituídos de CPA, cuja profundidade média da macrotextura deve ser no mínimo 1,20 mm, de acordo com a classificação Muito Aberta da macrotextura (ANAC, 2021b).

A profundidade da macrotextura do revestimento deve ser mensurada em toda extensão de operações de pouso e decolagens, em áreas do revestimento em que não haja *grooving*, distanciando-se 3 m do eixo da PPD. Além disso, deve-se alternar a cada 100 m entre direita e esquerda e três medições, no mínimo, devem ser realizadas em cada área. Em seguida, calcula-se a média da profundidade de macrotextura, que deve ser classificada conforme a Tabela 4 (ANAC, 2021b).

Tabela 4 – Classificação da profundidade de macrotextura segundo a ANAC

Profundidade - P (mm)	Classificação
$P < 0,2$	Muito fechada
$0,2 < P < 0,4$	Fechada
$0,4 < P < 0,8$	Média
$0,8 < P < 1,2$	Aberta
$P > 1,2$	Muito aberta

Fonte: ANAC (2021b).

Ações devem ser tomadas pelo operador do aeródromo em caso de profundidade de macrotextura inferior ao nível mínimo de 0,60 mm. Deve-se avaliar se a profundidade média de água excede 3 mm em uma região de 150 m de comprimento por 12 m de largura localizada no centro da PPD, e ainda garantir que a PPD tenha drenagem suficiente para não acumular água acima do que é permitido. (ANAC, 2021b).

Segundo ICAO (2022), a profundidade de macrotextura pode ter sua profundidade diminuída devido ao acúmulo de borracha no pavimento. A Tabela 5 apresenta as profundidades de macrotextura definidas pela ICAO (2022), que recomenda que os valores estejam no mínimo entre as classes B e C.

Tabela 5 – Classificação da profundidade de macrotextura segundo a ICAO

Classe	Valores (mm)
A	0,10 – 0,14
B	0,15 – 0,24
C	0,25 – 0,50
D	0,51 – 1,00
E	1,00 – 2,54

Fonte: ICAO (2022).

A Tabela 6 apresenta de forma resumida as informações extraídas dos estudos citados neste capítulo. Nela são apresentados os objetivos, método adotado na pesquisa, parâmetros avaliados e principais conclusões.

Tabela 6 – Estudos de Aderência Pneu-Pavimento em pistas de pouso e decolagem.

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
Macroscopic and Microscopic Evaluation of Surface Friction of Airport Pavements (CHEN <i>et al.</i> , 2013)	Avaliar o efeito microscópico e macroscópico dos depósitos de borracha sobre as características de aderência dos pavimentos de PPD.	O Pêndulo Britânico e o método da mancha de areia foram realizados regularmente no local durante um período de 24 meses. Um microscópio óptico e um microscópio electrónico de varrimento foram utilizados para a avaliação microscópica de depósitos de borracha retirados da pista.	Coefficiente de atrito e textura do pavimento.	A borracha em um revestimento promove o aumento da espessura de 0,05 μm a cada pouso de aeronave. Nas regiões de toque das aeronaves durante o pouso, os valores de coeficiente de atrito estavam abaixo do mínimo permitido. Pequenas mudanças na macrotextura já influenciam no coeficiente de atrito.
Características de aderência de revestimentos asfálticos aeroportuários. Estudo de caso do aeroporto internacional de São Paulo/Congonhas (RODRIGUES FILHO, 2006)	Caracterizar o comportamento da aderência pneu-pavimento em função do tráfego e das práticas de manutenção de pavimentos de PPD.	Foram realizados levantamentos visuais da PPD, bem como acompanhamentos dos serviços de remoção de borracha, medições de coeficiente de atrito e profundidade de macrotextura.	Coefficiente de atrito e Profundidade de Macrotextura	Em revestimentos com alto teor de contaminação por acúmulo de borracha, a macrotextura apresenta redução em seus valores
Performance of tire-asphalt pavement adherence according to rubber removal on runways (SALES <i>et al.</i> , 2022)	Analisar o desempenho da aderência pneu-pavimento aeroportuário com revestimentos distintos- CA, <i>Grooving</i> e CPA- a partir da influência dos processos de remoção de borracha acumulada.	Estudou-se a CPA, o CA e o <i>grooving</i> , presentes em três aeroportos brasileiros, que tiveram profundidade de macrotextura e coeficiente de atrito analisados por meio de testes estatísticos.	Remoção de Borracha, coeficiente de atrito e profundidade de macrotextura	Observou-se que a remoção do acúmulo de borracha é um processo de manutenção eficiente. No entanto, o processo não garante aumentos significativos a longo prazo. Dessa forma, esse procedimento não deve ser a única ferramenta de manutenção das pistas de pouso e decolagem
Adhesion characteristics of tire-asphalt pavement interface based on a proposed tire hydroplaning model (ZHENG <i>et al.</i> , 2021)	Determinar as características de aderência pneu-pavimento	Por meio de modelos de elementos finitos, os autores caracterizaram a ocorrência da hidroplanagem.	Velocidade, profundidade de macrotextura, aderência e película de água.	Verificou-se que a aderência pneu-pavimento diminui com o aumento da velocidade do veículo em todas as condições. No entanto, foi observado que o pavimento de CPA tem uma maior aderência mesmo na presença de película de água e em condições com altas velocidades.

Tabela 6 – Estudos de Aderência Pneu-Pavimento em pistas de pouso e decolagem.

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
<p>Effects of surface texture deterioration and wet surface conditions on asphalt runway skid resistance (ZHU <i>et al.</i>, 2021)</p>	<p>Estudar os efeitos da deterioração da textura do pavimento.</p>	<p>Avaliação de três tipos de revestimentos asfálticos: CPA, CA e SMA. Foi desenvolvido um algoritmo que simula o desgaste do revestimento com o uso de elementos finitos. O modelo de hidroplanagem desenvolvido apresenta quatro submodelos: modelo para os pneus, pista de pouso e decolagem, interação pneu-pavimento e película d'água.</p>	<p>Coefficiente de atrito, taxa de desgaste, velocidade e película de água.</p>	<p>O coeficiente de atrito diminui consideravelmente nos três tipos de pavimentos analisados a partir de taxa de desgaste igual a 30</p>

Fonte: Elaborado pela autora (2023)

2.3 Machine Learning

O aprendizado de máquina (*Machine Learning*) é uma área de conhecimento em que é dado ao computador a habilidade de aprendizado sem a necessidade de uma programação muito robusta. Dessa forma, o *Machine Learning* é utilizado para ensinar máquinas a processar dados de forma mais eficiente, sendo um auxílio na extração de informação de dados complexos. Nesse âmbito, existe uma série de algoritmos que podem ser utilizados na solução de problemas, a escolha do melhor entre eles deve ser feita de acordo com o estudo do tipo do problema (MAHESH, 2020).

Uma das aplicações comumente utilizadas dentro do *Machine Learning* é a classificação. O objetivo da classificação é dividir os dados analisados em classes e denominar rótulos para cada uma (SINGH *et al.*, 2016).

Segundo Zhang e Mahadevan (2019) o aprendizado profundo (*deep learning*) é eficiente no que diz respeito aos dados categóricos, devido a sua capacidade de identificar a relação altamente complexa entre características contextuais de eventos e suas consequências. Isso pois o *deep learning* tem capacidade de estabelecer uma representação densa das características, o que o torna eficaz no aprendizado de complexidades a partir dos dados brutos.

Visando auxiliar operadores de aeródromos e agências reguladoras em suas tomadas de decisão no que diz respeito à conservação dos pavimentos aeroportuários, Quariguasi *et al.* (2021) desenvolveram um modelo de previsão do coeficiente de atrito medido numa PPD, por meio de Redes Neurais Artificiais (RNA). O trabalho foi desenvolvido por meio do uso dos seguintes parâmetros: coeficiente de atrito, remoção de borracha, número de operações (pousos e descolagens), umidade relativa e idade da pista.

O estudo de Quariguasi *et al.* (2021) resultou em um modelo com 77,5% de coeficiente de determinação. Dessa forma, a ferramenta pode auxiliar na tomada de decisão quanto à realização de medições de coeficiente de atrito, com subjetividade da avaliação reduzida.

Devido à deficiência de métodos de identificação de trincas em pavimentos rodoviários, Praticò *et al.* (2020) desenvolveram um algoritmo de aprendizagem supervisionada para a identificação e classificação dessas trincas. Diferentes classificadores de *machine learning* foram utilizados: *Multilayer Perceptron* (MLP), *Convolutional Neural Network* (CNN), *Random Forest Classifier* (RFC) e *Support Vector Classifier* (SVC).

Praticò *et al.* (2020) utilizaram um banco de dados que consistiu nas respostas acústicas dos pavimentos rodoviários às cargas induzidas por veículos. Os resultados mostraram

a possibilidade de associar uma característica vibro-acústica específica a um pavimento rodoviário por meio de *machine learning*. Os classificadores foram avaliados em termos da precisão de modelos derivados de matrizes de confusão. O MLP e a CNN foram capazes de classificar conjuntos de dados com precisões que variaram de 83% a 95,4%. O RFC apresentou precisão de 91,0% e o SVM 99,1%. Por meio desses resultados, os autores esperam aplicar o método no monitoramento da saúde estrutural de pavimentos rodoviários, além de pontes e edifícios.

Praticò *et al.* (2020) utilizaram o MLP como uma abordagem básica de classificação, pois permite obter bons resultados com conjuntos de dados com tamanho superior a 800, e porque ele é capaz de minimizar o uso de sinais no processo de treinamento, com um número menor de *epochs*. O *Random Forest* foi utilizado como uma alternativa às Redes Neurais Artificiais, pois esse modelo pode produzir resultados comparáveis ao MLP.

Rababaah *et al.* (2005) compararam três abordagens diferentes para a classificação de defeitos em pavimentos asfálticos, com uma abordagem composta de pré-processamento de imagens, detecção, representação e classificação de trincas. Foram comparados o *genetic algorithms*, *multilayer perceptrons* e *selforganizing maps*. Os dois primeiros são algoritmos supervisionados e o último não supervisionado.

Os resultados obtidos no estudo de Rababaah *et al.* (2005) mostraram que a técnica mais efetiva foi o MLP, apresentando uma precisão de 98,6%. Em comparação com abordagens anteriores, o estudo obteve maior precisão e utilizou um número menor de nós de camada oculta, o que deve melhorar o desempenho em tempo real.

Gajewski e Sadowski (2014) desenvolveram um estudo com o objetivo de avaliar a sensibilidade da análise de propagação de trincas em revestimentos asfálticos, além de analisar o efeito de parâmetros no processo de formação de trincas. Para tanto, foram combinadas as aplicações de redes neurais e o método de elementos finitos.

O MLP foi utilizado por Gajewski e Sadowski (2014) por ser uma rede neural de camada múltipla que possui um algoritmo de aprendizado relativamente simples e eficaz, conhecido como o método de propagação do erro retroativo. É capaz de aproximar mapeamentos complexos e amplamente aplicado em problemas de classificação e previsão, ou controle automático. Além disso, o MLP possui um tempo de resposta curto, o que permite a aplicação da rede em tarefas em que a resposta em tempo real é necessária. No estudo em questão, o MLP foi melhor em lidar com a tarefa de classificação, com uma qualidade de aprendizado de mais de 94%, enquanto o modelo *Radial Basis Function*, a outra rede neural aplicada, obteve resultado de 65% para o mesmo conjunto de dados de aprendizado.

No que diz respeito ao uso do *Falling Weight Deflectometer* (FWD) na medição da deflexão em pavimentos flexíveis para a caracterização da integridade estrutural, é necessária uma retroanálise das propriedades mecânicas do pavimento. Isso é normalmente realizado com o uso de uma ferramenta de cálculo retroativo que abranja um modelo de resposta de pavimento avançado e um algoritmo de otimização. Por outro lado, tal problema também pode ser resolvido por um sistema adaptativo usando um algoritmo de aprendizado supervisionado. Nesse âmbito, Göktepe *et al.* (2005) compararam dois métodos baseados em inteligência artificial, *Multilayer Perceptron* (MLP) e *Adaptive Neuro-Fuzzy System* (ANFIS).

Os resultados do estudo de Göktepe *et al.* (2005) mostraram que ambas as técnicas são válidas e o desempenho dos métodos de inteligência artificial para problemas de retroanálise de pavimentos é sensível à qualidade e quantidade dos dados de treinamento. As técnicas de mapeamento não lineares supervisionado baseadas em inteligência artificial chegaram à resultados precisos de retroanálise e habilidades de análise de pavimentos em tempo real.

Göktepe *et al.* (2005) concluíram que o MLP é a melhor escolha se houver quantidade suficiente de dados para caracterizar o comportamento do alvo de estudo e, caso contrário, o ANFIS deve ser preferido devido à sua capacidade de lógica *fuzzy* que gerencia a incerteza. Além disso, o método ANFIS pode ser empregada em problemas de retroanálise que envolvem dados incompletos e os resultados são obtidos mais rapidamente, tornando-a adequada para cálculos em tempo real.

Nitsche *et al.* (2012) desenvolveram um estudo com o objetivo de estimar o perfil longitudinal ponderado de uma rodovia. Para tanto, foram comparados três modelos de aprendizado de máquina: *Multilayer Perceptron* (MLP), o *Support Vector Machine* (SVM) e o *Random Forest*. Os dados utilizados consistiram em uma base com informações coletadas de sensores disponíveis em veículos de passageiros comuns, como acelerômetros e velocidade das rodas. Por meio do treinamento desses modelos com dados de simulação e medições reais, o estudo visou identificar os pontos fortes e fracos de cada modelo para o propósito específico de estimar o IRI do pavimento.

Os resultados do estudo de Nitsche *et al.* (2012) indicaram que o método proposto permitiu o monitoramento da rede viária, com o uso de carros de passageiros convencionais. Isso pode ser considerado como um complemento prático às medições mais comuns com dispositivos móveis de custo elevado. O modelo que obteve os melhores resultados foi o SVM, considerando que as diferenças encontradas entre o desempenho dos modelos foram relativamente similares.

Embora o MLP tenha desvantagens, como ser um modelo "caixa-preta" e a dificuldade de escolher propriedades de rede adequadas (camadas ocultas, funções de transferência), sua vantagem de aproximar qualquer função com precisão arbitrária fez com que fosse adequado para estimar o IRI. No entanto, quando se reduz o número de recursos para tornar o modelo mais estável, o *Random Forest* e o SVM são mais estáveis do que o MLP (NITSCHE *et al.*, 2012).

As métricas de avaliação dos classificadores são medidas de desempenho dos modelos que auxiliam no processo de escolha da melhor ferramenta de *Machine Learning* a ser utilizada (HOSSIN e SULAIMAN, 2015). A seguir são descritas as principais métricas utilizadas na avaliação de desempenho dos modelos.

- a) Acurácia: indica dentre todas as classificações realizadas, quantas o modelo classificou corretamente. É uma boa indicação geral de como o modelo performou. A Equação 2 apresenta como é realizado o cálculo da acurácia.

$$\text{Acurácia} = \frac{\text{Verdadeiros Positivos} + \text{Verdadeiro Negativos}}{\text{V. Positivos} + \text{. Negativos} + \text{Falsos Positivos} + \text{Fals Negativos}} \quad (2)$$

- b) Precisão: é a proporção de acertos dentre todas as classificações de classe Positivo que o modelo fez. Pode ser usada em uma situação em que os Falsos Positivos são considerados mais prejudiciais que os Falsos Negativos. A Equação 3 apresenta como é realizado o cálculo da precisão.

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}} \quad (3)$$

- c) Sensibilidade: dentre todas as situações de classe Positivo como valor esperado, quantas o modelo acertou. Pode ser usada em uma situação em que os Falsos Negativos são considerados mais prejudiciais que os Falsos Positivos. A Equação 4 apresenta como é realizado o cálculo da sensibilidade.

$$\text{Sensibilidade} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Fa Negativos}} \quad (4)$$

- d) Especificidade: é a taxa de falso positivo: Esse indicador é importante para o cálculo da curva ROC, explicado a seguir. A Equação 5 apresenta como é realizado o cálculo da dessa taxa.

$$\text{Especificidade} = \frac{\text{Falsos Positivos}}{\text{Verdadeiros Negativos} + \text{Falsos Positivos}} \quad (5)$$

- e) F1-Score: média harmônica entre precisão e sensibilidade. É uma maneira de observar somente uma métrica ao invés de duas (precisão e sensibilidade) em alguma situação. Quando se tem um F1-Score pequeno, é um indicativo de que a precisão ou a sensibilidade estão baixos. A Equação 6 apresenta como é realizado o cálculo do F1-Score.

$$\text{F1-Score} = \frac{2 \times \text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilid}} \quad (6)$$

- f) *Receiver Operating Characteristic Curve* (ROC): A curva ROC demonstra o desempenho de um modelo classificador binário, por meio dos parâmetros Sensibilidade e Especificidade. O modelo perfeito apresenta Sensibilidade de 100% e Taxa de Falso Positivo igual a 0.
- g) *Area Under the ROC Curve* (AUC): É um parâmetro que simplifica a análise da ROC. O valor do AUC varia de 0 até 1,0 e o limiar entre classes é 0,5. Quanto maior o AUC, melhor. Uma vantagem desta métrica é que ela não é sensível ao desbalanço de classes, como ocorre com a acurácia.

No que diz respeito ao processo de construção do banco de dados que será utilizado nos modelos, esse é um passo importante, pois problemas nessa etapa podem interferir no resultado das modelagens. O viés de amostragem é um problema de ocorrência sobre o banco de dados ocasionado por informações diferentes das que serão enfrentadas pelo algoritmo na realidade. Isso ocorre quando o treinamento do modelo é realizado com informações que não contemplam todas as características necessárias à classificação. Esse erro permite que haja subdimensionamentos ou sobredimensionamentos, o que pode ser evitado com um processo cauteloso de amostragem (PANZERI *et al.*, 2007).

A Tabela 7 apresenta de forma resumida as informações extraídas dos estudos citados neste capítulo. Nela são apresentados os objetivos, método adotado na pesquisa, parâmetros avaliados e principais conclusões.

Tabela 7 – Emprego de *Machine Learning* em problemas de pavimentos

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
Ensemble machine learning models for aviation incident risk prediction (ZHANG e MAHADEVAN, 2019)	Prever a severidade de eventos de risco.	<i>Deep learning e support vector machine</i>	Incidentes e acidentes ocorridos entre janeiro de 2006 e dezembro de 2017 provindos do banco de dados da <i>Aviation Safety Reporting System</i> (ASRS).	Por meio das previsões dos dois modelos de aprendizagem da máquina quantificou-se o risco associado com a consequência de cada incidente, utilizando os modelos fundidos. Os resultados demonstram que o modelo híbrido desenvolvido supera o desempenho dos modelos individuais.
A prediction model of the coefficient of friction for runway using artificial neural network (QUARIGUASI <i>et al.</i> , 2021)	Auxiliar operadores de aeródromos e agências reguladoras em suas tomadas de decisão no que diz respeito à conservação dos pavimentos aeroportuários	Redes Neurais Artificiais (RNA)	Coefficiente de atrito, remoção de borracha, número de operações (pousos e descolagens), umidade relativa e idade da pista	A ferramenta proporciona uma avaliação com subjetividade reduzida.
Detection and Monitoring of Bottom-Up Cracks in Road Pavement Using a Machine-Learning Approach (PRATICO <i>et al.</i> , 2020)	Identificar e caracterizar fissuras ocultas em pavimentos rodoviários	<i>Multilayer Perceptron</i> (MLP), <i>Convolutional Neural Network</i> (CNN), <i>Random Forest Classifier</i> (RFC) e <i>Support Vector Classifier</i> (SVC).	Respostas acústicas dos pavimentos rodoviários às cargas induzidas por veículos	O método pode ser aplicado no monitoramento da saúde estrutural de pavimentos rodoviários, além de pontes e edifícios.
Asphalt Pavement Crack Classification: A Comparison of GA, MLP, and SOM (RABABAAH <i>et al.</i> , 2005)	Classificar automaticamente trincas em pavimentos asfálticos	<i>Genetic algorithms, multilayer perceptrons e selforganizing maps</i>	Trincas do pavimento	O MLP apresentou 98,6% de previsão, com classificação mais eficaz em todos os classificadores estudados.
Sensitivity analysis of crack propagation in pavement bituminous layered structures using a hybrid system integrating Artificial Neural Networks and Finite Element Method (GAJEWSKI e SADOWSKI, 2014)	Avaliar a sensibilidade da análise de propagação de trincas em revestimentos asfálticos, além de analisar o efeito de parâmetros no processo de trincas.	<i>Radial Basis Function</i> (RBF) e <i>Multilayer Perceptron</i> atrelados a um modelo de elementos finitos	Os valores de espessura da camada betuminosa, bem como diferentes modos de carga e os módulos de elasticidade dos materiais das camadas foram alterados durante as simulações numéricas em uma ampla faixa	A aplicação de um sistema híbrido de ANNs e FEM para avaliar o comportamento de pavimentos de estradas mostrou-se funcional.

Tabela 7 – Emprego de *Machine Learning* em problemas de pavimentos

Trabalho	Objetivo do estudo	Método utilizado	Parâmetros avaliados	Principais conclusões
Comparison of multilayer perceptron and adaptive neuro-fuzzy system on backcalculating the mechanical properties of flexible pavements (GÖKTEPE <i>et al.</i> , 2019)	Calcular as propriedades mecânicas de pavimentos flexíveis usando testes não destrutivos	<i>Multilayer Perceptron e Adaptive Neuro-Fuzzy System</i>	Parâmetros mecânicos das camadas de pavimentos flexíveis por meio de técnicas de teste não destrutivas, com o uso do <i>Falling Weight Deflectometer</i> (FWD)	Os métodos de retroanálise adaptativas, MLP e ANFIS, fornecem resultados precisos em comparação com os métodos clássicos, e os resultados são obtidos mais rapidamente. O MLP é a melhor escolha se houver quantidade suficiente de dados para caracterizar o comportamento desejado. Caso contrário, ANFIS deve ser preferido devido à sua capacidade de lógica <i>fuzzy</i> para lidar com a incerteza.
Comparison of machine learning methods for evaluating pavement roughness based on vehicle response (NITSCHKE <i>et al.</i> , 2014)	Estimar o IRI de uma rodovia com base em dados coletados de sensores disponíveis em veículos de passageiros comuns, como acelerômetros e velocidade das rodas	<i>Multilayer perceptron, Support Vector Machine e Random Forest.</i>	Além do IRI, o estudo avaliou o perfil longitudinal ponderado para avaliar a aspereza do pavimento, além de dados de acelerômetro e velocidade da roda, coletados de sensores comuns em veículos.	Embora o MLP tenha desvantagens, sua vantagem de aproximar qualquer função com precisão arbitrária faz com que seja adequado para estimar o IRI. No entanto, quando se reduz o número de recursos para tornar o modelo mais estável, o <i>Random Forest</i> e o SVM são mais estáveis do que o MLP

Fonte: Elaborado pela autora (2023)

3 MÉTODO DE PESQUISA

Neste capítulo, são detalhados os materiais utilizados nesta pesquisa e o método seguido para a obtenção dos resultados.

3.1 Materiais

Os materiais utilizados nesta pesquisa consistem nos dados referentes a duas pistas de pouso e decolagem brasileiras. Tais informações são oriundas de relatórios técnicos fornecidos pela Superintendência de Infraestrutura Aeroportuária da Agência Nacional de Aviação Civil (SIA/ANAC) e elaborados pelos respectivos operadores de aeródromos, detalhados a seguir.

Além disso, foram utilizados o *software MatLab* R2023a em sua versão acadêmica, com licença obtida por meio da Universidade Federal do Ceará (UFC). Também foi utilizado o *Jupyter Notebook*, aplicativo pertencente ao *software Anaconda3* (versão 2021.05) compatível com *Python* 3.8.8, cuja licença é aberta.

O método utilizado na elaboração da base de dados empregada nas modelagens deste estudo é detalhado em seguida. Foi determinada a área de estudo e os dados coletados para posterior tabulação, com período de análise entre 2014 e 2018.

3.1.1 Área de estudo

Para a área de estudo, foram escolhidos o Aeroporto Internacional de Fortaleza (SBFZ), no estado do Ceará, e o Aeroporto Santos Dumont (SBRJ), no estado do Rio de Janeiro. Essa decisão se baseou no fato de serem aeroportos com revestimentos asfálticos distintos e por apresentarem medições constantes de coeficiente de atrito, profundidade de macrotextura e remoção de borracha.

O Aeroporto Internacional de Fortaleza possui código E da aeronave crítica de projeto, cuja envergadura está entre 52 m e 65 m. A pista de pouso e decolagem (PPD) do SBFZ apresenta geometria de 2.755 m de comprimento e 45 m de largura, com revestimento de Concreto Asfáltico (CA), classificado como flexível (FRAPORT, 2018).

A denominação das cabeceiras da PPD do SBFZ, segundo ICAO (2004), é 13 e 31, sendo a cabeceira predominante para pousos designada como 13. A média de pousos diários no ano de 2017 na cabeceira 13 foi de 70, enquanto da cabeceira 31 apenas 1 (FRAPORT, 2018).

As medições de coeficiente atrito na PPD do SBFZ foram realizadas pelo equipamento *Grip Tester* a uma velocidade de 65 km/h. Essas medições ocorreram a 3 m e a 6 m do eixo da PPD, devido ao seu código de operações (ANAC, 2021b). As medições da profundidade de macrotextura foram realizadas por meio do ensaio de mancha de areia (ANAC, 2021b).

O Aeroporto Santos Dumont tem classificação C da aeronave crítica de projeto, com envergadura entre 24 m e 36 m. Possui duas PPD: a principal tem geometria com 1.323 m de comprimento e 42 m de largura e a auxiliar com 1.260 m de comprimento e 30 m de largura. O revestimento da PPD principal, utilizada neste estudo, é constituído de uma camada de rolamento em Camada Porosa de Atrito (CPA) em toda sua extensão (INFRAERO, 2018; INFRAERO, 2019).

As cabeceiras da PPD do SBRJ apresentam denominação 02 e 20. Como o aeroporto possui duas PPD, é necessário diferenciá-lo por meio da classificação R (*right* – direita) e L (*left* – esquerda); dessa forma, o SBRJ possui como cabeceiras, 02L, 20L, 02R e 20R. Em 2017, o SBRJ apresentou média diária de 90 operações de pouso e decolagem na cabeceira principal, 20L, e 43 na secundária, 02R. (ICAO, 2004; INFRAERO, 2019).

As medições de coeficiente de atrito na PPD do SBRJ também foram realizadas pelo equipamento *Grip Tester* a uma velocidade de 65 km/h. Assim como no SBFZ, as medições da profundidade de macrotextura também foram realizadas por meio do ensaio de mancha de areia.

De acordo com o publicado pela INFRAERO (2019), o Aeroporto Santos Dumont passou por um mês de obras, em agosto de 2019. O objetivo da reforma foi a execução de um novo revestimento de CPA, visto que a última vez que a sua PPD principal passou por obras de reabilitação foi em 2009. Portanto, o revestimento de CPA do SBRJ analisado neste estudo possuía idade variando de 5 a 9 anos durante o período estudado (2014-2018).

3.1.2 Coleta e tabulação dos dados

Os dados de coeficiente de atrito e de profundidade de macrotextura foram coletados por meio de solicitação junto à SIA/ANAC. Os dados, obtidos entre os anos de 2014 e 2018, foram recebidos por meio de relatórios técnicos de coeficiente de atrito e profundidade de macrotextura elaborados pelos respectivos operadores de aeródromos: FRAPORT para o Aeroporto SBFZ e INFRAERO para o Aeroporto SBRJ.

Foram analisados dados provindos de 21 relatórios de profundidade de

macrotextura e 27 relatórios de coeficiente de atrito do SBFZ. No que diz respeito ao SBRJ, a análise foi realizada por meio de 21 relatórios de profundidade de macrotextura e 49 relatórios de coeficiente de atrito.

Visto que o banco de dados foi limitado pela quantidade de informações de profundidade de macrotextura, que existem em menor número, os valores desse parâmetro foram relacionados aos de coeficiente de atrito. Para tanto, assumiu-se a premissa de intervalo máximo de um mês entre as medições.

Partiu-se da premissa de existência de dois dados de coeficiente de atrito e profundidade de macrotextura que não foram medidos no mesmo dia, mas com medições de, no máximo, 30 dias entre os parâmetros, que poderiam ser considerados pertencentes a uma mesma amostra de valores de aderência pneu-pavimento. Dessa forma, as variáveis coeficiente de atrito e profundidade de macrotextura são variáveis denominadas quantitativas e contínuas. A variável localização na PPD é também quantitativa, porém discreta, de maneira que só são permitidos valores a cada 100 m.

A remoção do acúmulo de borracha tem sua ocorrência descrita nos relatórios de medição de coeficiente de atrito e de profundidade de macrotextura. É uma variável binária, em que os dados consistem em sim ou não para sua realização. Determinou-se, portanto, que as informações para esse parâmetro seriam organizadas de maneira que o algarismo 0 representa a realização do procedimento e 1 a não realização. Os terços da PPD foram representados de maneira que 1 é referente ao primeiro terço, 2 ao segundo e 3 ao terceiro.

No que diz respeito aos tipos de revestimentos asfálticos analisados, a variável binária funcionou de maneira que 0 indica CA e 1 CPA. Essa classificação foi necessária devido à diferença entre os valores da profundidade de macrotextura para CA e para CPA, de maneira que a profundidade de macrotextura da CPA é maior, por ser um revestimento poroso.

A base de dados reunida para este trabalho contabilizou 460 amostras referentes ao revestimento de CPA e 786 referentes ao revestimento de CA. No entanto, foram contabilizadas oito amostras em que a variável coeficiente de atrito apresentou valores iguais a zero, que foram considerados *outliers* e retirados da base de dados. Dessa forma, a base contabilizou, no total, 1.238 amostras. A Tabela 8 apresenta um resumo do banco de dados analisado e o Apêndice A apresenta o banco de dados completo. Os títulos de ambos (tabela e apêndice) apresentam direcionamento a um *link* em que o banco de dados completo pode ser acessado. A Tabela 9 apresenta a descrição das variáveis utilizadas neste trabalho.

Tabela 8 – Resumo do banco de dados analisado para as PPD de estudo

ID	Coefficiente de Atrito	Profundidade de Macrot textura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Revestimento
0	0,64	0,62	1	1	100	0
1	0,76	0,69	1	1	100	0
2	0,64	0,62	1	1	100	0
3	0,62	0,79	0	1	100	0
4	0,78	0,88	1	1	100	0
5	0,67	0,63	1	1	100	0

Fonte: Elaborado pela autora (2023)

Tabela 9 – Descrição das variáveis utilizadas na análise

Tipo de Revestimento	
Classe	Correspondência
0	Concreto Asfáltico
1	Camada Porosa de Atrito
Ocorrência de Remoção de Borracha	
Classe	Correspondência
0	Sim
1	Não
Terço da Pista	
Classe	Correspondência
1	Primeiro
2	Segundo
3	Terceiro

Fonte: Elaborado pela autora (2023)

3.2 Método

O procedimento da pesquisa foi seguido em quatro etapas que são descritas na sequência, a saber: (i) análise exploratória, (ii) classificação da segurança operacional e (iii) modelagem por meio do *MatLab*.

3.2.1 Análise exploratória

Foram avaliados os parâmetros estatísticos de média, mediana, desvio padrão, valor máximo, valor mínimo e coeficiente de variação, para compreender os dados tratados neste estudo. Além disso, na análise exploratória foram avaliadas relações entre as variáveis do banco de dados. Quatro relações foram investigadas por meio do *Jupyter Notebook*, quais sejam:

- a) profundidade de macrotextura, coeficiente de atrito e a classificação da segurança;

- b) tipo do revestimento, classificação da segurança, coeficiente de atrito e profundidade de macrotextura;
- c) remoção do acúmulo de borracha, classificação da segurança operacional, coeficiente de atrito e profundidade de macrotextura;
- d) local da medição e os valores de coeficiente de atrito e profundidade de macrotextura.

3.2.2 Classificação da segurança operacional

Para as modelagens supervisionadas realizadas neste estudo, fez-se necessário uma classificação prévia dos dados quanto à segurança das operações de pousos e decolagens. Na elaboração dessa classificação foram utilizadas premissas que estão de acordo com ANAC (2021b). Tal consideração diz respeito aos valores mínimos aceitáveis para coeficiente de atrito e profundidade de macrotextura.

Na classificação da segurança operacional para o revestimento da CPA foi assumida a seguinte regra: se o revestimento contivesse uma profundidade de macrotextura menor que 1,20 mm ou um coeficiente de atrito menor que 0,65, ele seria considerado com uma segurança operacional não adequada; caso contrário, a segurança operacional seria classificada como adequada. Dessa forma, as duas condições, para profundidade de macrotextura e coeficiente de atrito, precisam ser atendidas para que o revestimento asfáltico seja considerado seguro operacionalmente do ponto de vista da aderência pneu-pavimento.

Embora a ANAC (2023) determine que o coeficiente de atrito deve estar com valor de, pelo menos 0,53, essa recomendação não foi seguida neste trabalho, pois, o seu objetivo vai além de classificar a situação dos parâmetros de aderência de acordo com a regulamentação. A classificação desse parâmetro é baseada em questões de segurança das operações de pouso e decolagem, portanto, entende-se que para o pavimento ter uma condição suficiente de segurança, ele precisa manter uma certa margem em relação aos valores determinados pela regulamentação vigente.

Além disso, os valores adotados para a classificação foram determinados de maneira que as amostras se dividissem o mais próximo possível em 50% para segurança não adequada e 50% para segurança adequada. Isso proporciona que o algoritmo não seja tendenciado para nenhuma das duas classificações.

Para o revestimento de CA, a regra utilizada foi de profundidade de macrotextura menor que 0,80 mm ou coeficiente de atrito menor que 0,70, segurança operacional não

adequada, caso contrário, a segurança operacional seria classificada como adequada. Novamente, as premissas detalhadas no parágrafo anterior foram seguidas. Ressalta-se que o recomendado é que o pavimento de CPA apresente profundidade de macrotextura de pelo menos 1,20 mm. A classificação binária (adequada e não adequada) foi necessária devido à quantidade de dados, insuficiente para uma classificação com maior número de classes.

3.2.3 Modelagem por meio do MatLab

A seguir, é descrito o método utilizado para a modelagem utilizando o MatLab.

3.2.3.1 Pré-processamento de Dados

Os dados foram importados de um arquivo CSV contendo as seguintes informações sobre as pistas de pouso e decolagem: tipo de revestimento, remoção de borracha e terço da pista. Tais dados foram selecionadas e utilizadas como dados de entrada, enquanto a classificação da segurança operacional foi designada como dados de saída. A amostra de dados foi dividida aleatoriamente em quatro conjuntos de dados de igual tamanho para análise robusta, contendo cada um 309 observações.

Foram aplicadas funções de pré-processamento aos dados de entrada, sendo elas:

- a) *removeconstantrows*: remoção de linhas com valores constantes para evitar redundâncias.
- b) *mapminmax*: normalização dos dados para o intervalo $[0,1]$, melhorando a convergência durante o treinamento.

Além disso, os dados foram divididos em conjuntos de treinamento (70%), validação (15%), e teste (15%) utilizando o método de divisão randômica. Foi escolhida a função de desempenho do tipo entropia cruzada (*crossentropy*), que é apropriada para problemas de classificação.

3.2.3.2 Configuração da Rede Neural

Foi utilizada uma Rede Neural do tipo *Pattern Recognition Network* com uma camada oculta composta por dois neurônios nos quatro modelos. Dado o tamanho relativamente pequeno do conjunto de dados (309 observações) utilizou-se de regras heurísticas na definição do número de neurônios, aplicando-se a regra da raiz quadrada do número de dados de entrada

(neste caso três), o que resultou na escolha de dois neurônios. O algoritmo escolhido para o treinamento foi o *Scaled Conjugate Gradient Backpropagation (trainlm)*, devido ao seu equilíbrio entre eficiência computacional e desempenho em problemas desafiadores.

3.2.3.3 *Treinamento da Rede*

Utilizou-se o método *trainlm (Scaled Conjugate Gradient Backpropagation)* para o treinamento da rede neural. Os pesos da rede foram inicializados aleatoriamente. Os dados de entrada foram propagados pela rede, camada por camada, até que a saída fosse obtida. A saída prevista foi comparada com a saída real para calcular o erro.

O algoritmo *Backward Pass (Backpropagation)* calculou o gradiente da função de custo em relação aos pesos da rede. Os pesos foram ajustados proporcionalmente à magnitude do gradiente, reduzindo o erro.

O algoritmo utilizou um método de gradiente descendente para atualizar os pesos. A taxa de aprendizado controlou o tamanho dos passos durante a atualização. A propagação camada por camada, com obtenção e comparação da saída e a atualização dos pesos foram repetidos iterativamente até que a convergência fosse alcançada ou um número máximo de iterações fosse atingido.

A modelagem se beneficia do *Scaled Conjugate Gradient Backpropagation (LVM)*, incorporando suas características de gradiente conjugado, adaptação dinâmica da taxa de aprendizado e eficiência em termos de memória. Esses elementos tornam o treinamento da rede neural mais eficiente e adaptável a diferentes cenários, contribuindo para um modelo mais robusto e eficaz.

3.2.3.4 *Avaliação de Desempenho*

Após o treinamento, a rede foi testada utilizando os dados de entrada para avaliação do desempenho. As métricas de desempenho incluíram análise de erros percentuais, matriz de confusão e curva ROC.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os resultados e suas respectivas discussões, divididas entre a análise exploratória, a classificação da segurança operacional e as modelagens.

4.1 Análise exploratória

Pela análise dos dados estudados nesta pesquisa, verificou-se que a média do coeficiente de atrito na base de dados composta de Concreto Asfáltico (CA) é igual a 0,78, enquanto a média da profundidade de macrotextura é igual a 0,96 mm. A realização da remoção do acúmulo de borracha foi contabilizada 181 vezes e a não realização, 597. No que diz respeito ao revestimento em Camada Porosa de Atrito (CPA), a média do coeficiente de atrito é igual a 0,66, enquanto a média da profundidade de macrotextura é igual a 1,38 mm. A realização da remoção do acúmulo de borracha foi contabilizada 40 vezes e a não realização 420.

Em relação à profundidade de macrotextura (Tabela 10) pode-se observar que a média da CPA é 43,8% maior que a do CA. Além disso, a CPA apresentou desvio padrão e, por consequência, coeficiente de variação menor que a do CA. Essa diferença entre os dois conjuntos resultou em desvio padrão e coeficiente de variação elevados ao se analisar os dados de CPA e CA em conjunto. Esse fator é devido a dois aspectos: (i) a dispersão elevada dos dados de CA, com coeficiente de variação de, aproximadamente, duas vezes o da CPA, e (ii) aos maiores valores de profundidade de macrotextura da CPA.

Tabela 10 – Análise estatística da profundidade de macrotextura

Parâmetro	CA	CPA	Conjunto (CA + CPA)
Média (mm)	0,96	1,38	1,11
Desvio Padrão (mm)	0,20	0,13	0,27
Mediana (mm)	0,93	1,39	1,11
Mínimo (mm)	0,39	1,16	0,39
Máximo (mm)	1,55	1,65	1,65
Coeficiente de Variação (%)	21,4	9,7	24,6

Fonte: Elaborado pela autora (2023)

Além disso, percebe-se que, embora, o revestimento de CPA tenha como característica uma profundidade de macrotextura mais aberta (maior que 1,20 mm), sua média foi apenas 30% superior à média do CA. Esse fator é mais relevante ao se analisar os valores máximos e mínimos: o máximo de CPA é bem próximo que o do CA, embora os mínimos apresentem 0,77 mm de diferença. Além disso, o desvio padrão da CPA é de 0,13 mm, o que indica que os valores do conjunto de dados são bem próximos da média. A Figura 5 apresenta

essa análise em gráficos dos resultados.

Em relação ao coeficiente de atrito (Tabela 11), pode-se observar que a média do CA é 18,2% maior que a da CPA, que apresentou desvio padrão e, por consequência, coeficiente de variação menor que a do CA. Essa diferença entre os dois conjuntos resultou em desvio padrão e coeficiente de variação elevados ao se analisar os dados de CPA e CA em conjunto. Esse fator é devido a dois aspectos: (i) a dispersão elevada dos dados de CA, com coeficiente de variação cerca de duas vezes o da CPA e (ii) aos maiores valores de coeficiente de atrito do CA.

Tabela 11 – Análise estatística do coeficiente de atrito


Parâmetro	CA	CPA	Conjunto (CA + CPA)
Média	0,78	0,66	0,74
Desvio Padrão	0,13	0,06	0,12
Mediana	0,77	0,66	0,71
Mínimo	0,48	0,57	0,48
Máximo	1,19	0,86	1,19
Coeficiente de Variação (%)	16,3	9,3	16,7

Fonte: Elaborado pela autora (2023)

Pode-se observar, ainda pela Tabela 11, que o coeficiente de atrito do revestimento da CPA está próximo do valor mínimo de manutenção (0,53) com uma média de 0,66 que não apresenta grande variação, como indicam o desvio padrão (0,06) e o coeficiente de variação (9,3%). Embora a profundidade de macrotextura da CPA tenha se mostrado maior que a do CA, o coeficiente de atrito da CPA apresentou desempenho menor. Esse fator, junto aos resultados obtidos para a profundidade de macrotextura indicam que o revestimento de CPA analisado apresenta características muito próximas ao do pavimento de CA.

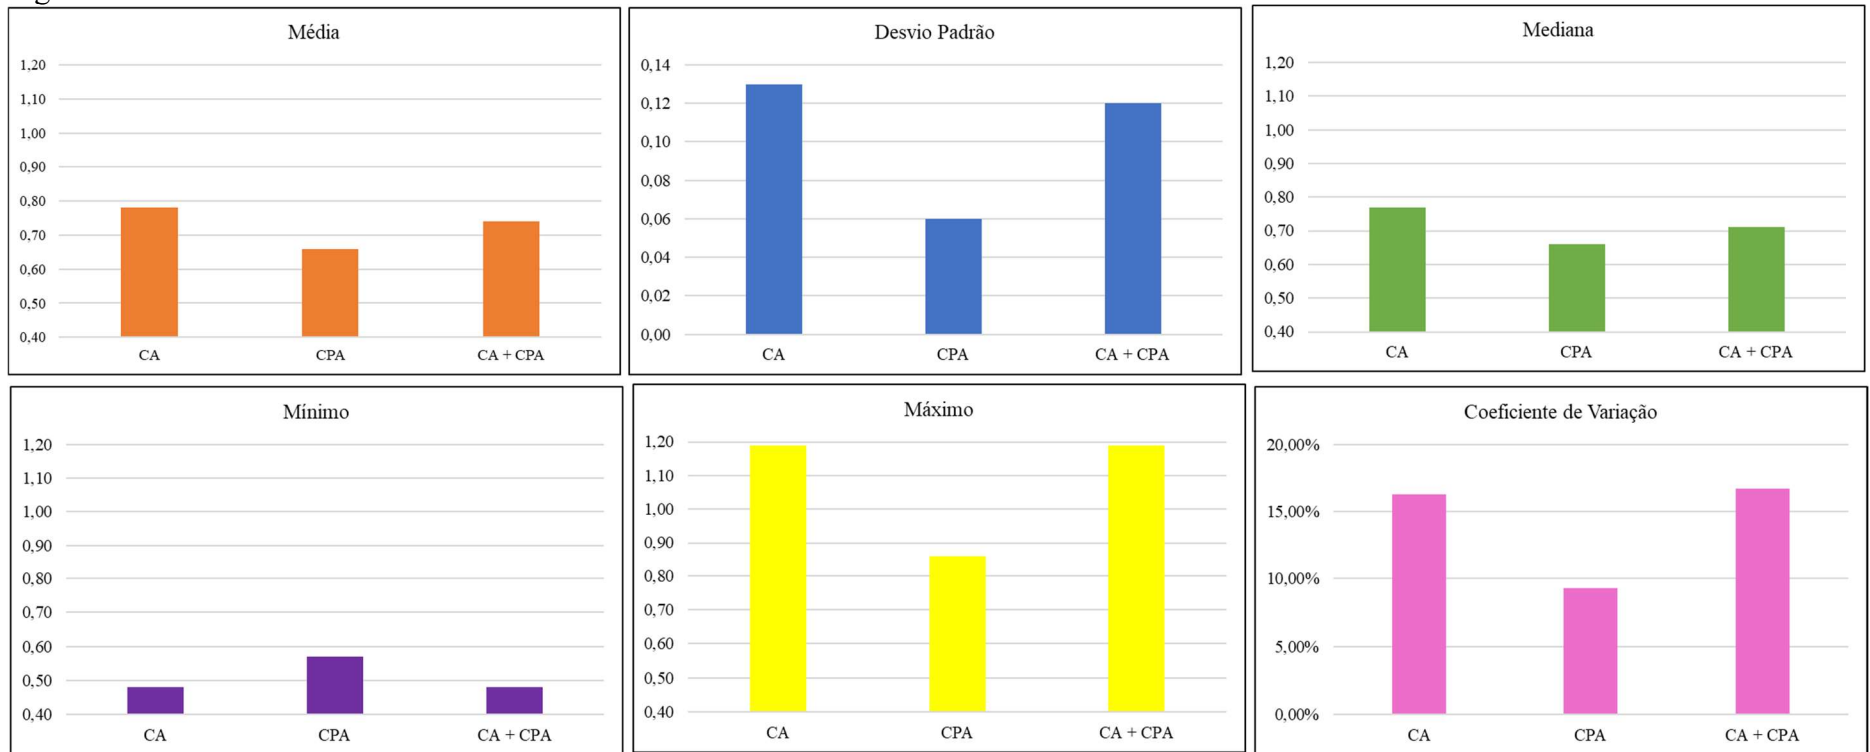
Isso levanta a hipótese de que o revestimento drenante em questão poderia não estar mais gerando os benefícios esperados de um revestimento de CPA como uma mistura asfáltica não convencional para pistas de pouso e decolagem. Tal fato pode ser justificado devido à idade do pavimento, que teve sua última restauração ainda em 2009, de forma que quando analisado neste estudo, já estava no fim de sua vida útil (cerca de 10 anos). A Figura 6 apresenta a análise gráfica dos resultados.

Figura 5 – Análise estatística da profundidade de macrotextura



Fonte: Elaborado pela autora (2023)

Figura 6 – Análise estatística do coeficiente de atrito




Fonte: Elaborado pela autora (2023)

Dessa forma, percebe-se que é necessário o desenvolvimento de um parâmetro que diferencie o tipo do revestimento, já que o CA e a CPA devem possuir atuações distintas em revestimentos de pistas de pouso e decolagem, sobretudo quando se opera com o crédito de desempenho (no caso a CPA). A análise do conjunto mostrou-se inviável, pois, utilizar uma classificação que se adeque aos dois parâmetros subdimensionaria um dos revestimentos. Diante do exposto, justifica-se a inserção de uma variável binária para o tipo do revestimento, além de classificações diferentes para cada um deles.

Foram analisadas algumas relações entre as variáveis em busca de obter um conjunto adequado para a modelagem. A primeira relação analisada foi entre a profundidade de macrotextura, o coeficiente de atrito e a classificação da segurança operacional (Figura 7).

Figura 7 – Relação entre a profundidade de macrotextura, o coeficiente de atrito e a classificação da segurança operacional



Fonte: Elaborado pela autora (2023)


Observou-se na Figura 7 a existência de relação entre a classificação, a profundidade de macrotextura e o coeficiente de atrito. Percebe-se que, para um trecho da pista ter classificação adequada de segurança operacional, é necessário, no mínimo, coeficiente de atrito de 0,65 (valor estabelecido para a CPA). No entanto, existem poucos trechos com coeficiente de atrito abaixo de 0,70 com classificação adequada (categoria do CA), de maneira que é perceptível uma divisão entre as classes no ponto de coeficiente de atrito igual a 0,70.

No que diz respeito à profundidade de macrotextura, observa-se que não existem

trechos classificados como segurança operacional não adequada, com valores abaixo de 0,80 mm (valor estabelecido pelo CA), de maneira que é perceptível uma separação entre as duas classes nesse valor. Essa separação indica que, neste estudo, a classificação atribuída ao CA pode ser suficiente para classificar também a CPA. Desse modo, para a segurança operacional classificada como não adequada, o coeficiente de atrito foi um limitante para revestimentos em CPA e a profundidade de macrotextura foi o limitante para classificação de segurança operacional não adequada nos trechos constituídos de CA.

Em seguida, verificou-se a relação entre o tipo do revestimento, a classificação da segurança operacional, o coeficiente de atrito e a profundidade de macrotextura. Esses resultados são apresentados na Figura 8.

Figura 8 – Relação entre o tipo de revestimento, a classificação da segurança operacional e os parâmetros de aderência




Fonte: Elaborado pela autora (2023)

Pode-se observar pela Figura 8 que os valores relacionados à CPA se encontram de maneira mais isolada na parte superior do gráfico, em que se concentram os dados com maiores profundidades de macrotextura, ou seja, maior que 1,20 mm. No entanto, também são encontrados nessa região de macrotextura dados correspondentes ao revestimento de CA, o que indica a semelhança entre os revestimentos nesse quesito. Além disso, nota-se que essa área é concentrada em uma região de menores coeficientes de atrito, entre 0,55 e 0,70, estendendo-se pouco além desse limite. Dessa forma, na área que vai além do limite de 0,70 concentram-se as

informações referentes ao CA, revestimento com melhores condições de coeficiente de atrito que a CPA, devido ao desgaste do revestimento poroso.

A outra relação analisada foi entre a remoção do acúmulo de borracha, a classificação da segurança operacional, o coeficiente de atrito e a profundidade de macrotextura. Entretanto, não foi possível observar nenhum padrão entre essas variáveis com o processo de remoção do acúmulo de borracha. Percebe-se pela distribuição (Figura 9) que a informação da remoção do acúmulo de borracha encontra-se dispersa na área do gráfico, o que indica que não existe correlação entre a remoção de borracha e a classificação adotada neste estudo.


Figura 9 – Relação entre remoção do acúmulo de borracha, classificação da segurança operacional e parâmetros de aderência



Fonte: Elaborado pela autora (2023)

Foi analisada a relação entre o coeficiente de atrito e a localização da medição nas PPD em estudo (CPA e CA). A Figura 10 demonstra o resultado dessa avaliação, em que é possível observar valores menores de coeficiente de atrito nos primeiros 1.100 m de ambas as PPD, com uma inclinação negativa no gráfico a partir desse ponto até os 1.900 m. Ressalta-se que as operações de pouso e decolagem que proporcionam maior desgaste dos revestimentos são concentradas no primeiro terço da PPD, correspondente à zona de toque das aeronaves durante pousos, em que esses valores menores são observados. Além disso, na decolagem, os esforços proporcionados pelos pneus das aeronaves promovem o desgaste dos revestimentos no primeiro terço da PPD.


Figura 10 – Relação entre o coeficiente de atrito e a localização da medição (m)



Fonte: Elaborado pela autora (2023)

A Figura 11 apresenta os resultados dos terços de forma geral, em que é possível verificar que, em média, o primeiro terço apresenta valores menores que os demais. No entanto, a variação percentual entre as medições de coeficiente de atrito é pequena: do primeiro terço para o segundo e último terços é de 4,3% e 6,4%, respectivamente.


Figura 11 – Relação entre o coeficiente de atrito e os terços das PPD



Fonte: Elaborado pela autora (2023)

A análise da relação entre a profundidade de macrotextura e a localização da medição é apresentada na Figura 12 para o conjunto de revestimentos (CA + CPA). Observa-se que a relação é contrária à do coeficiente de atrito, com valores maiores nos primeiros 1.000 metros de pista. O desgaste do revestimento proporcionado pelas operações de pouso e decolagem associado ao processo periódico de remoção do acúmulo de borracha, podem proporcionar uma macrotextura mais aberta, devido aos materiais finos que são desprendidos do revestimento e, também, a maior exposição do agregado da mistura asfáltica.


Figura 12 – Relação entre a profundidade de macrotextura e a localização da medição (m)



Fonte: Elaborado pela autora (2023)

A Figura 13 apresenta os resultados dos terços das PPD, em que é possível verificar que, em média, o primeiro terço apresenta valores maiores que o último, e próximos do segundo. Em termos de variação percentual do primeiro terço para o segundo e último terços, os resultados são de 1,1% e 11,7%, respectivamente.

Figura 13 – Relação entre a profundidade de macrotextura e os terços das PPD



Fonte: Elaborado pela autora (2023)


Por fim, realizou-se uma matriz de correlação (Figura 14) a fim de elaborar hipóteses para análise. Foram utilizados todos os parâmetros disponíveis do estudo: coeficiente de atrito, profundidade de macrotextura, localização das medições (em metros e terço da PPD), realização de remoção do acúmulo de borracha e classificação da segurança operacional.

Os resultados mostrados na Figura 14 demonstram que as variáveis localização da medição e terço da pista apresentam forte correlação (0,86), pois elas medem o mesmo atributo. O coeficiente de atrito tem correlação com a classificação da segurança operacional (0,54), enquanto a profundidade de macrotextura tem fraca correlação com a classificação (0,03). Isso mostra que o coeficiente de atrito foi um limitador da classificação da segurança operacional para os revestimentos asfálticos analisados, de maneira que foram observados mais valores abaixo do limiar para coeficiente de atrito do que para a profundidade de macrotextura.

Outra variável com correlação observada com a classificação da segurança operacional foi o tipo de revestimento (-0,22). Esse valor indica que a pista de pouso e decolagem com revestimento em CPA analisada neste estudo pode não apresentar condições adequadas de segurança, sobretudo no contexto do crédito de desempenho (ANAC, 2020) devido à correlação negativa com o classificador. Isso pode ser relacionado ao fato de que a CPA tende a se desgastar mais rapidamente com o tempo e permite maior acúmulo de borracha devido à profundidade de macrotextura mais aberta, quando comparada ao revestimento em

CA. Como abordado por Alecrim *et al.* (2022) e Hernandez-Saenz *et al.* (2016), a colmatagem dos vazios da CPA prejudica sua vida de serviço, tornando-o ineficaz quando se trata da sua drenabilidade. Esse fator é crítico para o crédito de desempenho, em que pistas de pouso e decolagem podem operar na condição molhada sem o fator de segurança que é requisito usual.

Figura 14 – Matriz de correlação entre as variáveis do estudo



Fonte: Elaborado pela autora (2023)

Ressalta-se que o revestimento em CPA do Aeroporto Santos Dumont, objeto deste estudo, passou pela última restauração em 2009. Assim, os dados analisados dizem respeito ao período de 2014 a 2018, em que o revestimento apresentava de 5 a 9 anos de uso. Além disso, a quantidade de dados relativos ao revestimento de CPA é inferior aos dados de CA: o primeiro corresponde a 37,2% do total de dados, enquanto o segundo, 62,8%. Essa desproporção pode ter gerado algum subdimensionamento no modelo analisado.

A localização da medição apresentou correlação de 0,16, o que indica que essa variável apresenta fraca relação com a segurança operacional. Por fim, a correlação entre a ocorrência de remoção do acúmulo de borracha e a classificação da segurança operacional

apresentou fraca correlação de 0,04. Esse valor indica que a remoção do acúmulo de borracha tem pouca influência sobre a segurança operacional, retratada neste estudo.

Novamente, ressalta-se a desproporção entre os dados analisados, de maneira que a proporção de ocorrências de remoção de borracha foi 17,9% enquanto a não ocorrência foi 82,2%. Essa desproporção dos dados prejudica a análise estatística, além de levantar a hipótese de subnotificações das ocorrências de remoção do acúmulo de borracha. Os dados analisados neste estudo indicam que as condições de aderência atenderam aos valores normatizados, patamar alcançado com adequada frequência de manutenções do revestimento asfáltico, dentre elas, a remoção de borracha.

4.2 Classificação da segurança operacional

A classificação da segurança operacional apresentou os resultados que são detalhados no Apêndice A. Foram contabilizados 574 dados com classificação de segurança operacional não adequada (46,4%) e 664 dados como segurança operacional adequada (53,6 %).

Observa-se que a classificação apresentou resultados balanceados entre os dois rótulos (não adequado e adequado) com variação percentual entre as duas classificações de 7,2%. Esse equilíbrio é considerado ideal para a realização de modelagens, de maneira que possibilita uma análise sem tendências para algum dos rótulos.

4.3 Modelagem por meio do *MatLab*

A Tabela 12 apresenta as proporções da classificação de segurança adequada e segurança não adequada em cada um dos quatro conjuntos de dados analisado. Além disso pode ser vista a proporção de cada um dos parâmetros analisados. Por meio dela, pode-se perceber que nenhum dos parâmetros apresentou proporção com diferença significativa do total de observações, de maneira que todos os resultados estão bem próximos. Isso indica que a divisão aleatória dos quatro conjuntos não possibilitará qualquer diferença de resultado que possa ser explicada por diferenças entre os conjuntos estudados.

Tabela 12 – Proporção dos parâmetros em cada conjunto de dados

Conjunto de Dados	Segurança Adequada	Segurança Não Adequada	CA	CPA	1º Terço	2º Terço	3º Terço
1	55%	45%	63%	37%	43%	33%	24%
2	49%	51%	60%	40%	44%	38%	17%
3	54%	46%	63%	37%	41%	41%	18%
4	57%	43%	66%	34%	45%	36%	20%
Total	54%	46%	63%	37%	43%	37%	20%

Fonte: Elaborado pela autora (2023)

A Tabela 13 apresenta os resultados obtidos por meio do MatLab no treinamento do modelo MLP. Esses resultados indicam que o treinamento foi monitorado e controlado por vários critérios, sendo eles: épocas, desempenho, gradientes e validações

Tabela 13 – Resultado do treinamento do MLP por meio do *MatLab*

Conjunto de Dados 1			
Parâmetro	Valor Inicial	Valor de parada	Critério de Parada
Épocas	0	10	1000
Tempo decorrido	-	00:00:02	-
Desempenho	1,22	0,646	0
Gradiente	0,537	0,00608	1,00E-06
Verificações	0	6	6
Conjunto de Dados 2			
Parâmetro	Valor Inicial	Valor de parada	Critério de Parada
Épocas	0	7	1000
Tempo decorrido	-	00:00:00	-
Desempenho	0,773	0,641	0
Gradiente	0,259	0,0124	1,00E-06
Verificações	0	6	6
Conjunto de Dados 3			
Parâmetro	Valor Inicial	Valor de parada	Critério de Parada
Épocas	0	13	1000
Tempo decorrido	-	00:00:00	-
Desempenho	0,788	0,634	0
Gradiente	0,202	0,0114	1,00E-06
Verificações	0	6	6
Conjunto de Dados 4			
Parâmetro	Valor Inicial	Valor de parada	Critério de Parada
Épocas	0	11	1000
Tempo decorrido	-	00:00:00	-
Desempenho	1,38	0,651	0
Gradiente	0,711	0,0393	1,00E-06
Verificações	0	6	6

Fonte: Elaborado pela autora (2023)

As épocas referem-se ao número de vezes que todo o conjunto de dados de treinamento foi apresentado à rede. O critério de parada é baseado performance da rede e foi estabelecido como 1000, no entanto o treinamento encerrou após 10, 7, 13 e 11 épocas, respectivamente, para cada um dos conjuntos de dados analisados.

O tempo decorrido para completar o treinamento da rede foi de 2 segundos para o primeiro conjunto e 0 para os demais. O tempo relativamente curto sugere que o treinamento foi eficiente.

Em todos os conjuntos observou-se a diminuição dos valores de desempenho ao fim do treinamento. Isso indica que a rede melhorou seu desempenho durante a tarefa de treinamento. Essa diminuição foi mais relevante nos conjuntos 1 e 4, com reduções de 47% e 53%, respectivamente, enquanto os conjuntos 2 e 3 apresentaram 17% e 20%.

Os gradientes são valores que indicam a inclinação da curva da função de custo em relação aos pesos da rede. Um gradiente menor sugere que a rede está se aproximando de um mínimo local. Os gradientes diminuíram ao longo do treinamento, de maneira que o conjunto 1 apresentou maior porcentagem, de 99%, enquanto os conjuntos 2, 3 e 4 apresentaram 95%, 94% e 94%, respectivamente. A diminuição dos valores de desempenho e de gradiente indicam uma convergência adequada da rede para a tarefa de classificação em questão.

O treinamento foi interrompido após as 6 validações predefinidas. Esse foi o critério de parada atendido para os quatro conjuntos de dados, o que indica que os demais parâmetros, anteriormente descritos, se referem ao atingido após esse número de validações.

A Tabela 14 apresenta os resultados referentes às entropias cruzadas e aos erros obtidos pelo modelo.

Tabela 14 – Entropias cruzadas e erros do modelo

Conjunto de dados 1			
	Observações	Entropia cruzada	Erro
Treinamento	217	0,6521	0,3687
Validação	46	0,7462	0,5217
Teste	46	0,7493	0,5217
Desvio padrão		0,0552	0,0883
Conjunto de dados 2			
	Observações	Entropia cruzada	Erro
Treinamento	217	0,6996	0,4424
Validação	46	0,6496	0,3913
Teste	46	0,6332	0,3043
Desvio padrão		0,0346	0,0698
Conjunto de dados 3			
	Observações	Entropia cruzada	Erro
Treinamento	217	0,6382	0,3594
Validação	46	0,6530	0,3261
Teste	46	0,6037	0,3261
Desvio padrão		0,0253	0,0192
Conjunto de dados 4			
	Observações	Entropia cruzada	Erro
Treinamento	217	0,6653	0,3963
Validação	46	0,6593	0,3478
Teste	46	0,6201	0,3043
Desvio padrão		0,0245	0,0460

Fonte: Elaborado pela autora (2023)

A entropia cruzada é uma medida de quão bem o modelo se saiu na tarefa de classificação. Um valor mais baixo indica melhor desempenho. Os valores obtidos no treinamento sugerem uma boa adequação do modelo aos dados de treinamento.

O erro indica a média dos erros de classificação no conjunto de treinamento. Foram obtidos valores baixos em todos os conjuntos, o que é o desejado, pois representa menor discrepância entre as saídas reais e as saídas previstas pelo modelo.

O valor de entropia cruzada para o conjunto de validação indica como o modelo está generalizando para dados não vistos durante o treinamento. Um valor mais alto do que o obtido no treinamento pode indicar algum grau de *overfitting* (sobreajuste), ou seja, o modelo pode estar muito ajustado aos dados de treinamento específicos. Isso foi observado nos conjuntos de dados 1 e 3.

Novamente, um valor mais baixo é desejado para o erro médio, e a comparação com o erro de treinamento pode indicar a capacidade de generalização do modelo. O conjunto 1 foi

o que apresentou maior diferença nesse aspecto.

A entropia cruzada para o conjunto de teste é uma medida adicional da performance do modelo em dados não vistos anteriormente. Um valor comparável ao conjunto de validação sugere que o modelo está se comportando consistentemente em conjuntos de dados diferentes.

A consistência do erro médio com os resultados de treinamento e validação é importante para garantir que o modelo seja robusto e capaz de generalizar para novos dados. Diferenças significativas entre os resultados de treinamento e validação podem indicar *overfitting*, enquanto uma boa concordância sugere um modelo robusto. Dessa forma, os desvios padrões sugerem que o conjunto de dados 4 foi o que obteve melhor desempenho, pois apresentou menores valores para desvios de entropia e erro e o valor de entropia de treinamento não foi superado pelos demais.

A Figura 15, Figura 16, Figura 17 e Figura 18 apresentam as matrizes de confusão para treinamento, teste e validação dos quatro conjuntos de dados analisados. Por meio delas, pode-se verificar as seguintes taxas:

- a) Verdadeiro positivo: ocorre quando no conjunto real, a classe em questão foi prevista corretamente.
- b) Falso positivo: ocorre quando no conjunto real, a classe em questão foi prevista incorretamente.
- c) Falso verdadeiro: ocorre quando no conjunto real, a classe que não está em questão foi prevista corretamente.
- d) Falso negativo: ocorre quando no conjunto real, a classe que não está em questão foi prevista incorretamente.

Figura 15 – Matrizes de confusão para treinamento, teste e validação (Conjunto 1)

		Training Confusion Matrix			Test Confusion Matrix		
Output Class	0	44 20.3%	32 14.7%	57.9% 42.1%	6 13.0%	4 8.7%	60.0% 40.0%
	1	48 22.1%	93 42.9%	66.0% 34.0%	20 43.5%	16 34.8%	44.4% 55.6%
		47.8% 52.2%	74.4% 25.6%	63.1% 36.9%	23.1% 76.9%	80.0% 20.0%	47.8% 52.2%
		Target Class			Target Class		
		0	1		0	1	
		Validation Confusion Matrix			All Confusion Matrix		
Output Class	0	5 10.9%	8 17.4%	38.5% 61.5%	55 17.8%	44 14.2%	55.6% 44.4%
	1	16 34.8%	17 37.0%	51.5% 48.5%	84 27.2%	126 40.8%	60.0% 40.0%
		23.8% 76.2%	68.0% 32.0%	47.8% 52.2%	39.6% 60.4%	74.1% 25.9%	58.6% 41.4%
		Target Class			Target Class		
		0	1		0	1	

Fonte: Elaborado pela autora (2023)

A Figura 15 indica que as taxas de verdadeiro positivo foram 20,3%, 13,0% e 10,9% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 17,8%. Isso representa que o fator segurança não adequada foi previsto corretamente 55 vezes no conjunto de dados analisados.

As taxas de falso positivo foram 14,7%, 8,7% e 17,4% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 14,2%. Isso indica que o fator segurança não adequada foi previsto incorretamente (como segurança adequada) 44 vezes no conjunto de dados analisados.

As taxas de falso negativo foram 22,1%, 43,5% e 34,8% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 27,2%. Isso indica que o fator segurança adequada foi previsto incorretamente (como segurança inadequada) 84 vezes no conjunto de dados analisados.

As taxas de falso verdadeiro foram 42,9%, 34,8% e 37,0% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 40,8%. Isso indica que o fator segurança adequada foi previsto corretamente 126 vezes no conjunto de dados analisados. Dessa forma, pode-se calcular as métricas de desempenho acurácia, sensibilidade, precisão e F1-score, como apresentado na Tabela 15.

Tabela 15 – Métricas de desempenho (Conjunto 1)

Treinamento			
Acurácia	Sensibilidade	Precisão	F1-score
63,2%	47,9%	58,0%	52,5%
Teste			
Acurácia	Sensibilidade	Precisão	F1-score
47,8%	23,0%	59,9%	33,2%
Validação			
Acurácia	Sensibilidade	Precisão	F1-score
47,9%	23,9%	38,5%	29,5%
Geral			
Acurácia	Sensibilidade	Precisão	F1-score
58,6%	39,6%	55,6%	46,2%

Fonte: Elaborado pela autora (2023)

A acurácia representa a proporção de instâncias classificadas corretamente em relação ao total de instâncias. Neste caso, o modelo acertou aproximadamente 58,6% das previsões. Dessa forma, pode-se perceber que a acurácia do modelo é moderada, pois tem desempenho melhor do que uma classificação aleatória.

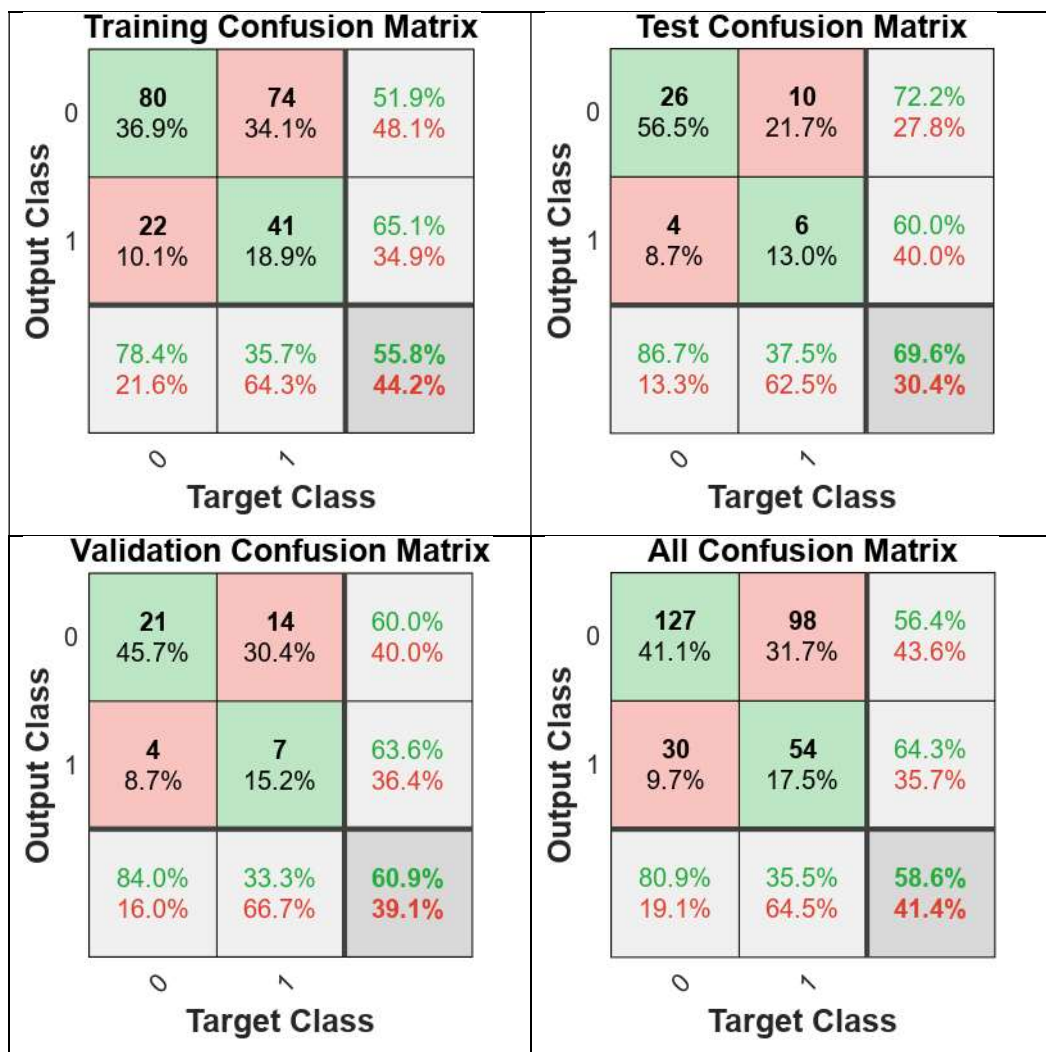
A sensibilidade representa a proporção de segurança não adequada que foram corretamente identificadas pelo modelo. Aqui, o modelo identificou corretamente cerca de 39,6% dos trechos de pista com segurança não adequada, o que é considerado um resultado crítico, pois a segurança adequada não pode ser confundida com adequada, visto que isso leva a medidas de manutenção que não serão realizadas devido à falsa classificação, que nesse caso representam 60,4% do total de trechos analisados.

A precisão representa a proporção de segurança não adequada classificadas como positivas pelo modelo que eram realmente positivas. Cerca de 55,6% das instâncias classificadas como positivas pelo modelo eram realmente positivas. Isso indica que 44,4% das instâncias classificadas como segurança não adequada, eram na verdade segurança adequada, o que pode levar a medidas serem tomadas quando não são necessárias, o que leva a desperdício de recursos financeiros, mas que não gera prejuízo à segurança operacional.

O F1-Score é uma métrica que considera tanto a precisão quanto a sensibilidade. É uma média harmônica entre essas duas métricas. Nesse caso, o F1-Score resultou em 46,2% o que indica um desequilíbrio entre precisão e sensibilidade.

Além disso, o desempenho no conjunto de teste e validação é crucial para avaliar a capacidade de generalização do modelo para dados não vistos durante o treinamento. Neste caso, esses conjuntos não tiveram bom desempenho, com exceção da precisão do conjunto de teste, que resultou em 59,9%.

Figura 16 – Matrizes de confusão para treinamento, teste e validação (Conjunto 2)



Fonte: Elaborado pela autora (2023)

A Figura 16 indica que as taxas de verdadeiro positivo foram 36,9%, 56,5% e 45,7% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 41,1%. Isso representa que o fator segurança não adequada foi previsto corretamente 127 vezes no conjunto de dados analisados.

As taxas de falso positivo foram 34,1%, 21,7% e 30,4% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 31,7%. Isso indica que o fator segurança não adequada foi previsto incorretamente (como segurança adequada) 98 vezes no conjunto de dados analisados.

As taxas de falso negativo foram 10,1%, 8,7% e 8,7% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 9,7%. Isso indica que o fator segurança adequada foi previsto incorretamente (como segurança inadequada) 30 vezes no conjunto de dados analisados.

As taxas de falso verdadeiro foram 18,9%, 13,0% e 15,2% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 17,5%. Isso indica que o fator segurança adequada foi previsto corretamente 54 vezes no conjunto de dados analisados. Dessa forma, pode-se calcular as métricas de desempenho acurácia, sensibilidade, precisão e F1-score, como apresentado na Tabela 16.

Tabela 16 – Métricas de desempenho (Conjunto 2)

Treinamento			
Acurácia	Sensibilidade	Precisão	F1-score
55,8%	78,5%	52,0%	62,5%
Teste			
Acurácia	Sensibilidade	Precisão	F1-score
69,6%	86,7%	72,3%	78,8%
Validação			
Acurácia	Sensibilidade	Precisão	F1-score
60,9%	84,0%	60,1%	70,0%
Geral			
Acurácia	Sensibilidade	Precisão	F1-score
58,6%	80,9%	56,5%	66,5%

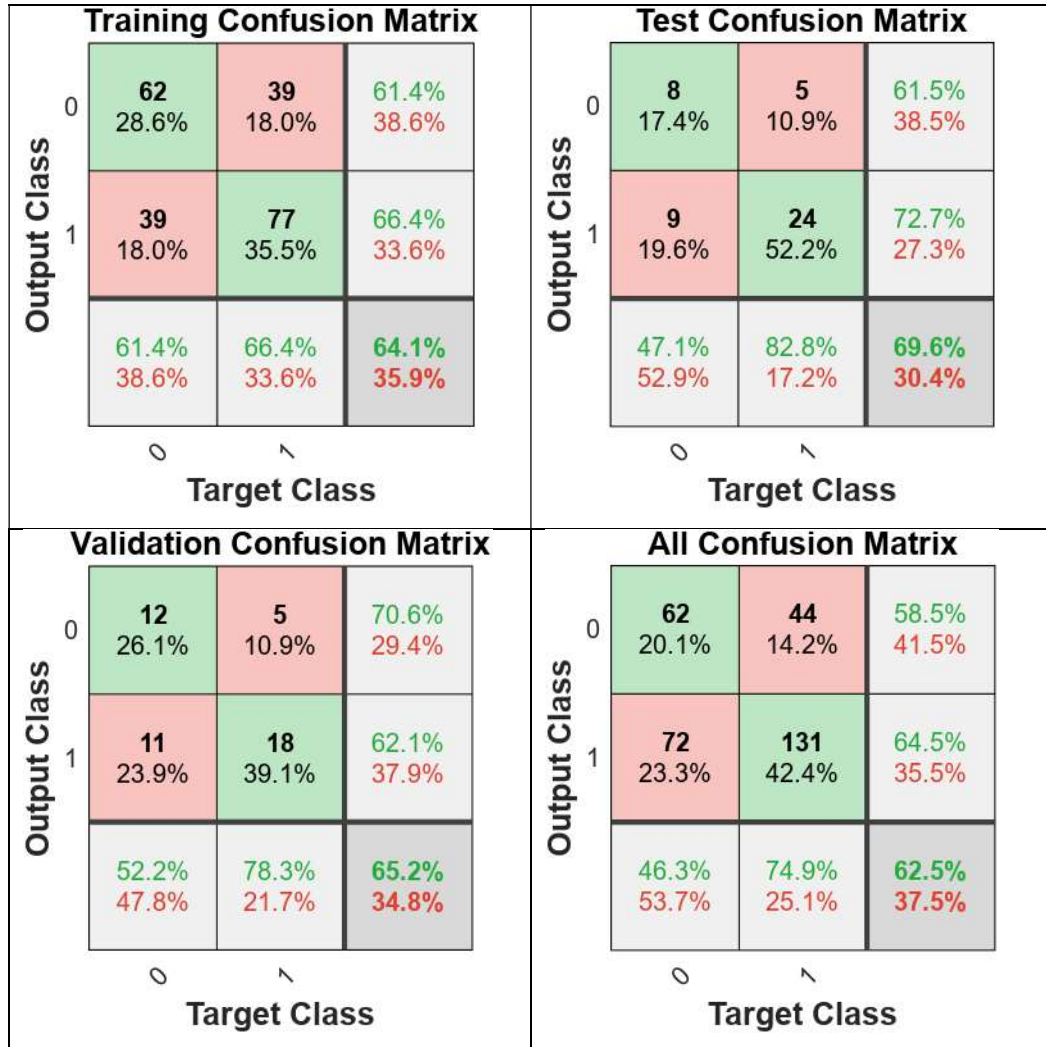
Fonte: Elaborado pela autora (2023)

Neste caso, o modelo acertou aproximadamente 58,6% das previsões. Dessa forma, pode-se perceber que a acurácia do modelo é moderada, pois tem desempenho melhor do que uma classificação aleatória.

Para este conjunto de dados o modelo identificou corretamente cerca de 80,9% dos trechos de pista com segurança não adequada, o que é considerado um resultado bom, pois permite que recursos sejam destinados adequadamente aos trechos que necessitam de manutenções para terem a segurança melhorada. Cerca de 56,5% das instâncias classificadas como positivas pelo modelo eram realmente positivas, resultado parecido com o obtido

anteriormente para o conjunto 1. Nesse caso, o F1-Score resultou em 66,5% o que indica um equilíbrio entre precisão e sensibilidade que pode ser considerado adequado. Por fim, o desempenho no conjunto de teste e validação obtiveram resultados bons, quando comparado ao conjunto 1.

Figura 17 – Matrizes de confusão para treinamento, teste e validação (Conjunto 3)



Fonte: Elaborado pela autora (2023)

A Figura 17 indica que as taxas de verdadeiro positivo foram 28,6%, 17,4% e 26,1% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 20,1%. Isso representa que o fator segurança não adequada foi previsto corretamente 62 vezes no conjunto de dados analisados.

As taxas de falso positivo foram 18,0%, 10,9% e 10,9% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 14,2%. Isso indica que o fator segurança não adequada foi previsto incorretamente (como segurança adequada) 44 vezes no

conjunto de dados analisados.

As taxas de falso negativo foram 18,0%, 19,6% e 23,9% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 23,3%. Isso indica que o fator segurança adequada foi previsto incorretamente (como segurança inadequada) 72 vezes no conjunto de dados analisados.

As taxas de falso verdadeiro foram 35,5%, 52,2% e 39,1% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 42,4%. Isso indica que o fator segurança adequada foi previsto corretamente 131 vezes no conjunto de dados analisados. Dessa forma, pode-se calcular as métricas de desempenho acurácia, sensibilidade, precisão e F1-score, como apresentado na Tabela 17.

Tabela 17 – Métricas de desempenho (Conjunto 3)

Treinamento			
Acurácia	Sensibilidade	Precisão	F1-score
64,0%	61,4%	61,4%	61,4%
Teste			
Acurácia	Sensibilidade	Precisão	F1-score
69,5%	47,0%	61,5%	53,3%
Validação			
Acurácia	Sensibilidade	Precisão	F1-score
65,2%	52,2%	70,5%	60,0%
Geral			
Acurácia	Sensibilidade	Precisão	F1-score
62,5%	46,3%	58,6%	51,7%

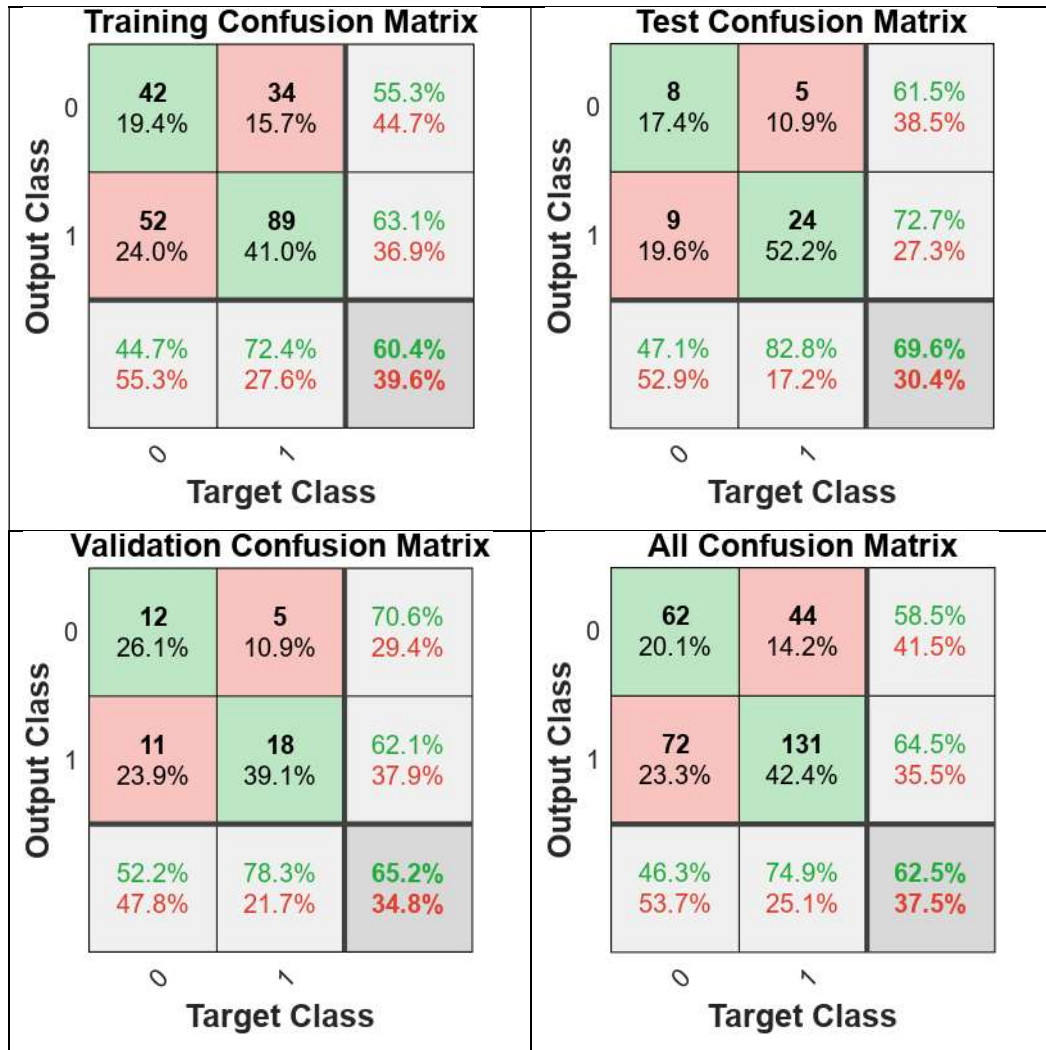
Fonte: Elaborado pela autora (2023)

Neste caso, o modelo acertou aproximadamente 62,5% das previsões. Dessa forma, pode-se perceber que a acurácia do modelo é moderada, pois tem desempenho melhor do que uma classificação aleatória.

Para este conjunto de dados o modelo identificou corretamente cerca de 46,3% dos trechos de pista com segurança não adequada, o que é considerado um resultado crítico, pois não permite a identificação correta dos trechos que necessitam de manutenções para terem a segurança melhorada. Cerca de 58,6% das instâncias classificadas como positivas pelo modelo eram realmente positivas, resultado parecido com o obtido anteriormente para os conjuntos 1 e 2. Nesse caso, o F1-Score resultou em 51,7% o que o indica um equilíbrio entre precisão e sensibilidade que pode ser considerado adequado. Por fim, o desempenho no conjunto de teste e validação obtiveram resultados bons, quando comparado ao conjunto 1, mas piores que o

conjunto 2, principalmente no que diz respeito à sensibilidade, métrica que pode ser considerada crítica neste estudo.

Figura 18 – Matrizes de confusão para treinamento, teste e validação (Conjunto 4)



Fonte: Elaborado pela autora (2023)

A Figura 18 indica que as taxas de verdadeiro positivo foram 19,4%, 17,4% e 26,1% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 20,1%. Isso representa que o fator segurança não adequada foi previsto corretamente 62 vezes no conjunto de dados analisados.

As taxas de falso positivo foram 15,7%, 10,9% e 10,9% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 14,2%. Isso indica que o fator segurança não adequada foi previsto incorretamente (como segurança adequada) 44 vezes no conjunto de dados analisados.

As taxas de falso negativo foram 24,0%, 19,6% e 23,9% para treinamento, teste e

validação, respectivamente, e que de forma geral essa taxa foi de 23,3%. Isso indica que o fator segurança adequada foi previsto incorretamente (como segurança inadequada) 72 vezes no conjunto de dados analisados.

As taxas de falso verdadeiro foram 41,0%, 52,2% e 39,1% para treinamento, teste e validação, respectivamente, e que de forma geral essa taxa foi de 42,4%. Isso indica que o fator segurança adequada foi previsto corretamente 131 vezes no conjunto de dados analisados. Dessa forma, pode-se calcular as métricas de desempenho acurácia, sensibilidade, precisão e F1-score, como apresentado na Tabela 18.

Tabela 18 – Métricas de desempenho (Conjunto 4)

Treinamento			
Acurácia	Sensibilidade	Precisão	F1-score
60,3%	44,7%	55,3%	49,4%
Teste			
Acurácia	Sensibilidade	Precisão	F1-score
69,5%	47,0%	61,5%	53,3%
Validação			
Acurácia	Sensibilidade	Precisão	F1-score
65,2%	52,2%	70,5%	60,0%
Geral			
Acurácia	Sensibilidade	Precisão	F1-score
62,5%	46,3%	58,6%	51,7%

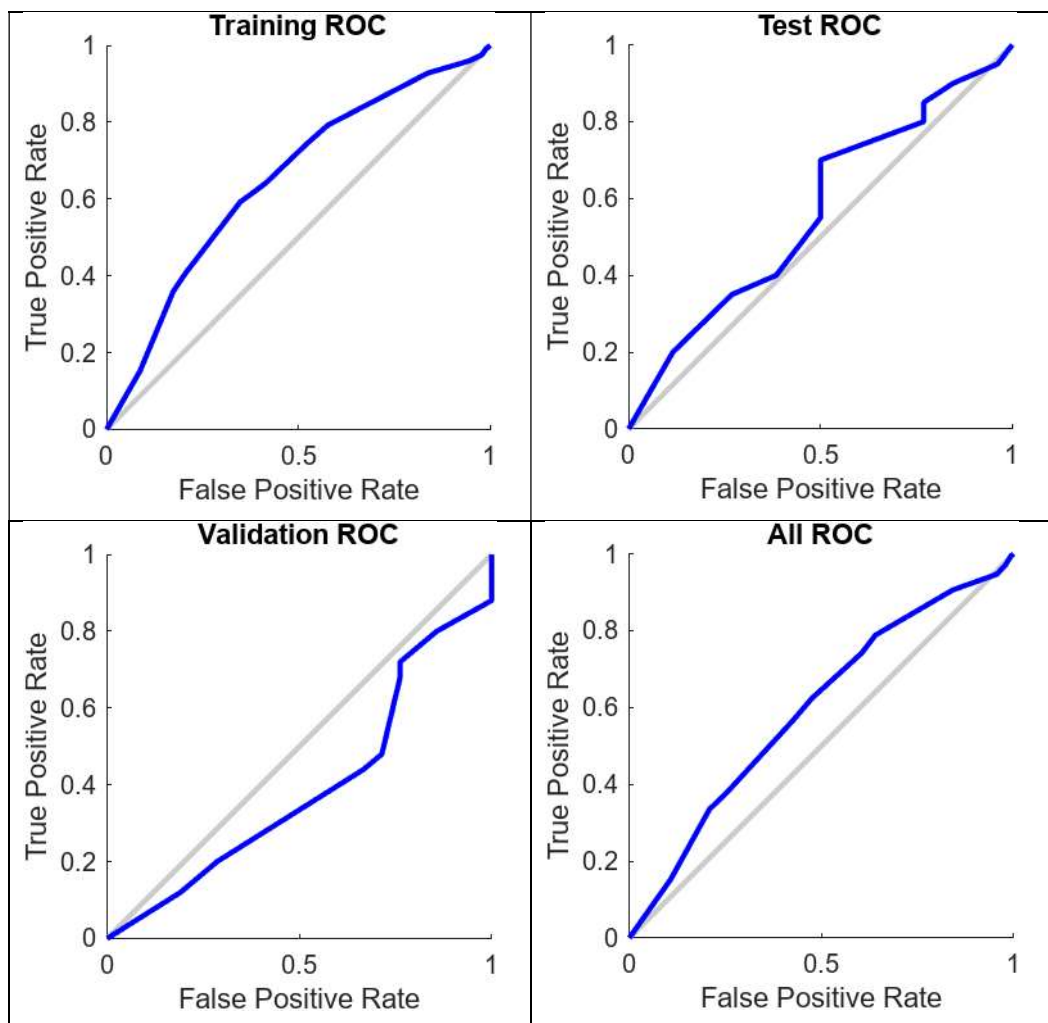
Fonte: Elaborado pela autora (2023)

Neste caso, o modelo acertou aproximadamente 62,5% das previsões. Dessa forma, pode-se perceber que a acurácia do modelo é moderada, pois tem desempenho melhor do que uma classificação aleatória.

Para este conjunto de dados o modelo identificou corretamente cerca de 46,3% dos trechos de pista com segurança não adequada, o que é considerado um resultado crítico, pois não permite a identificação correta dos trechos que necessitam de manutenções para terem a segurança melhorada. Cerca de 58,6% das instâncias classificadas como positivas pelo modelo eram realmente positivas, resultado parecido com o obtido anteriormente para os conjuntos 1 e 2. Nesse caso, o F1-Score resultou em 51,7% o que indica um equilíbrio entre precisão e sensibilidade que pode ser considerado adequado. Por fim, o desempenho no conjunto de teste e validação obtiveram resultados bons, quando comparado ao conjunto 1, mas piores que o conjunto 2, principalmente no que diz respeito à sensibilidade, métrica que pode ser considerada crítica neste estudo.

As Figura 19, Figura 20, Figura 21 e Figura 22 apresentam as curvas ROC para treinamento, teste e validação para os quatro conjuntos de dados. Por meio da Figura 19, pode-se observar que a curva ROC de validação do conjunto 1 está na área sob a metade do gráfico, o que indica AUC abaixo de 0,50 o que indica que mais da metade das previsões de validação foram incorretas. Além disso, percebe-se que as demais área sob a curva ROC são pouco maiores que 0,50.

Figura 19 – Curvas ROC para treinamento, teste e validação (Conjunto 1)




Fonte: Elaborado pela autora (2023)

Por meio da Figura 20 pode-se observar que as áreas sob a curva ROC são visualmente maiores para o conjunto 2 em relação ao conjunto 1. O mesmo pode ser observado nas Figura 21 e Figura 22, com destaque para o conjunto 3 que apresenta a maior área em todas as curvas, o que sugere que para este conjunto de dados o algoritmo obteve maior número de

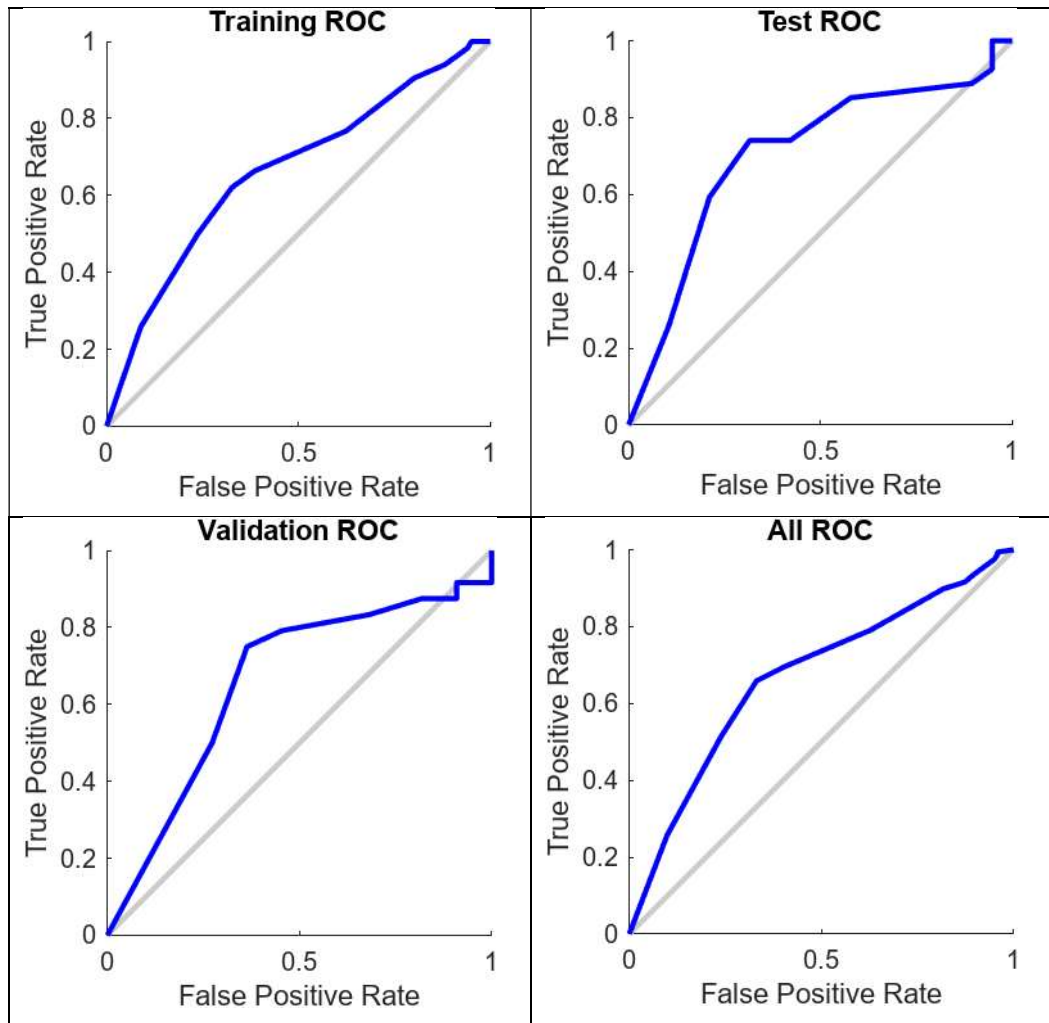
acertos na classificação.

Figura 20 – Curvas ROC para treinamento, teste e validação (Conjunto 2)



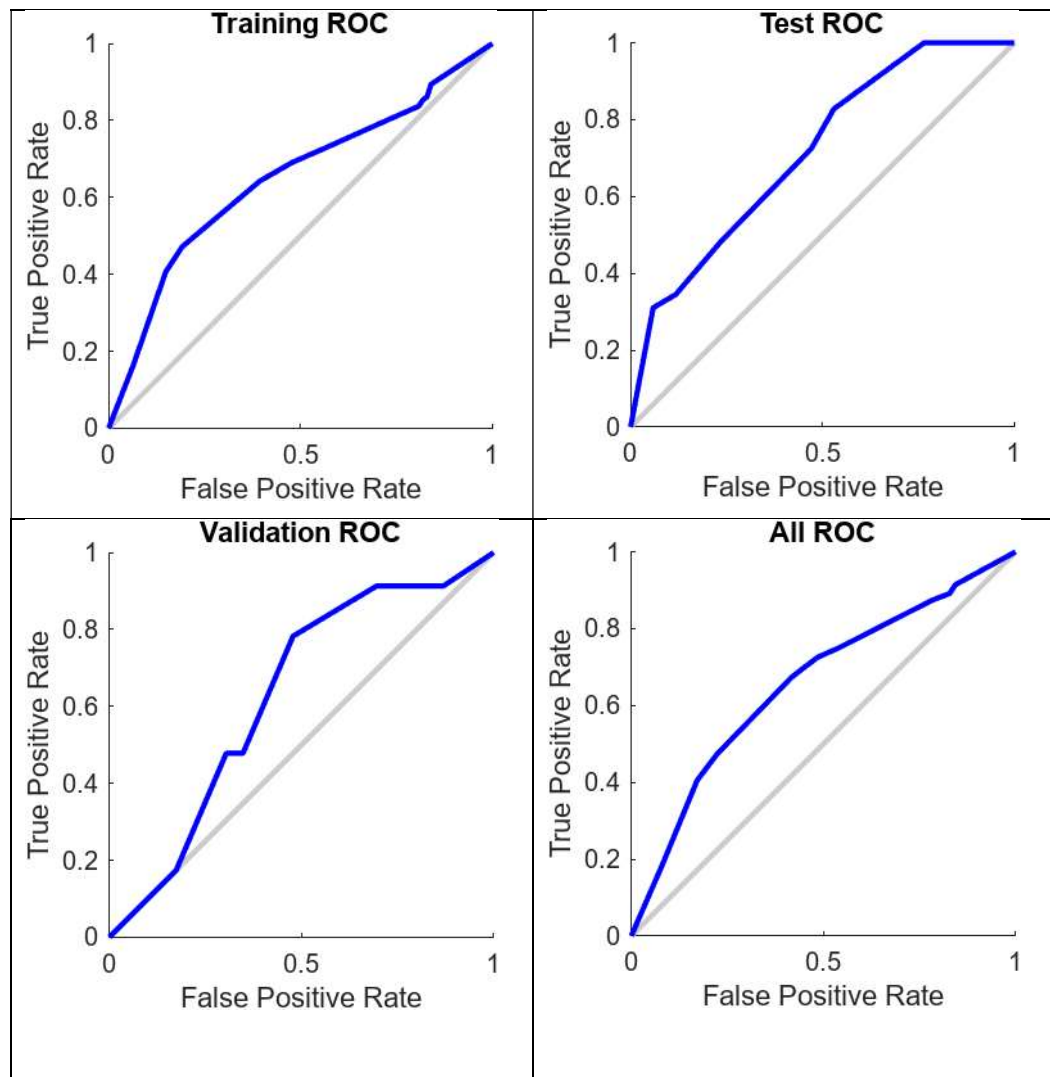
Fonte: Elaborado pela autora (2023)

Figura 21 – Curvas ROC para treinamento, teste e validação (Conjunto 3)



Fonte: Elaborado pela autora (2023)

Figura 22 – Curvas ROC para treinamento, teste e validação (Conjunto 4)



Fonte: Elaborado pela autora (2023)

Por fim, por meio da Tabela 19 pode-se observar de forma geral os resultados das métricas obtidas para cada um dos modelos criados. Em destaque estão as métricas mais relevantes. Pode-se verificar que o modelo criado por meio do conjunto de dados 3 foi o que obteve resultados mais relevantes em todas as etapas. No entanto, ao se considerar o parâmetro sensibilidade como mais relevante na decisão do melhor modelo, pois este parâmetro está relacionado a eficácia da classificação de segurança não adequada pode-se determinar que o modelo 2 apresentou os melhores resultados.

Tabela 19 – Resumo das métricas obtidas para cada conjunto de dados

Treinamento				
	Acurácia	Sensibilidade	Precisão	F1-score
Conjunto 1	63,2%	47,9%	58,0%	52,5%
Conjunto 2	55,8%	78,5%	52,0%	62,5%
Conjunto 3	64,0%	61,4%	61,4%	61,4%
Conjunto 4	60,3%	44,7%	55,3%	49,4%
Teste				
	Acurácia	Sensibilidade	Precisão	F1-score
Conjunto 1	47,8%	23,0%	59,9%	33,2%
Conjunto 2	69,6%	86,7%	72,3%	78,8%
Conjunto 3	69,5%	47,0%	61,5%	53,3%
Conjunto 4	69,5%	47,0%	61,5%	53,3%
Validação				
	Acurácia	Sensibilidade	Precisão	F1-score
Conjunto 1	47,9%	23,9%	38,5%	29,5%
Conjunto 2	60,9%	84,0%	60,1%	70,0%
Conjunto 3	65,2%	52,2%	70,5%	60,0%
Conjunto 4	65,2%	52,2%	70,5%	60,0%
Geral				
	Acurácia	Sensibilidade	Precisão	F1-score
Conjunto 1	58,6%	39,6%	55,6%	46,2%
Conjunto 2	58,6%	80,9%	56,5%	66,5%
Conjunto 3	62,5%	46,3%	58,6%	51,7%
Conjunto 4	62,5%	46,3%	58,6%	51,7%

Fonte: Elaborado pela autora (2023)

5 CONCLUSÕES E RECOMENDAÇÕES

Neste capítulo são descritas as principais conclusões deste estudo, bem como suas limitações e sugestões para trabalhos futuros.

5.1 Principais conclusões

Constatou-se, por meio da análise exploratória, que quanto menor a distância em relação à cabeceira, menos seguras serão as operações de pouso e decolagem. Portanto, é necessário maior acompanhamento nos trechos iniciais das pistas de pouso e decolagem de forma a resistir à derrapagem.

No que diz respeito à aderência pneu-pavimento, identificou-se que o coeficiente de atrito foi o limitador da classificação de segurança operacional não adequada. Para atender à classificação adequada, considerou-se que o coeficiente de atrito e a profundidade de macrotextura necessitam estar acima dos valores propostos nesta pesquisa, diferentes daqueles vigentes na regulamentação brasileira de aviação civil. Para a classificação adequada, os trechos de revestimento que não atenderam a segurança adequada apresentaram apenas coeficiente de atrito abaixo do mínimo. Isso é um indicador de que os operadores de aeródromos devem concentrar mais esforços na avaliação desse parâmetro para garantir que os revestimentos asfálticos possuam condições de aderência pneu-pavimento adequadas.

Além disso, verificou-se que o revestimento de Camada Porosa de Atrito (CPA) analisado neste trabalho possui classificação de segurança não adequada. Essa conclusão pode ser explicada pela vida útil desse tipo de mistura, que é prejudicada pela colmatação de seus vazios, além do desgaste de sua textura devido ao acúmulo de borracha. Constatou-se que a CPA em análise apresenta comportamento muito próximo ao do CA, de maneira que o revestimento nas condições analisadas não proporciona vantagens em termos de segurança operacional, quando analisado sob o aspecto do crédito de desempenho. Um fator determinante para essa conclusão é a idade do revestimento de CPA analisado, que chegou a 9 anos no período estudado.

Por meio das análises dos modelos desenvolvidos, observou-se que os resultados obtidos pelos modelos construídos pelo MatLab mostraram-se bons. É possível concluir que, por meio da análise de todos os parâmetros avaliados, o conjunto de dados 2 resultou no modelo mais eficiente. Isto pois apresentou acurácia e precisão maiores que 50%, o que mostra que o modelo é mais eficiente que uma classificação aleatória, além de que apresentou F1-score acima

de 60%, o que indica equilíbrio entre sensibilidade e precisão.

Além disso, o fator que foi mais relevante para essa conclusão foi a sensibilidade obtido por esse modelo, o que apresentou maior resultado entre os demais, com valor acima de 80%, o que indica que o modelo é eficaz na determinação dos trechos de pavimento que apresentam segurança não adequada. Tal classificação é crítica para o estudo em questão, visto que por meio dela pode-se destinar recursos de maneira correta para os trechos em que é necessário melhorar a segurança das operações de pouso e decolagem. Além disso, o modelo também apresentou bons resultados de gradiente e desempenho, bem como de entropia cruzada e erro, embora não tenham sido os melhores em comparação aos demais conjuntos.

Por fim, foi possível constatar, que o modelo provindo do conjunto de dados 2 se mostrou promissor na classificação da segurança operacional. Por meio dele, é possível determinar de forma eficiente os trechos de pavimento que necessitam de medidas de manutenção para que sua segurança operacional de pousos e decolagens seja melhorada.

5.2 Principais limitações

O processo de classificação por meio de *Machine Learning* exige um banco de dados extenso para que as análises resultem em modelos confiáveis. Dessa forma, a maior limitação deste estudo diz respeito à quantidade de dados, obtida para o desenvolvimento das análises.

As medições de coeficiente de atrito e profundidade de macrotextura ocorrem em frequências diferentes, de maneira que a medição da profundidade de macrotextura é realizada com menor constâncias que o coeficiente de atrito. Esse fato resulta em uma segunda limitação, os dados de coeficiente de atrito e profundidade de macrotextura não podem ser pareados de acordo com as datas de medição (mesmo dia). Para que fosse possível a realização do presente estudo, foi necessário parear dados de coeficiente de atrito e de profundidade de macrotextura com dias de intervalo entre as medições. Considerou-se a hipótese de que medições realizadas em um mesmo mês poderiam ser agrupadas e consideradas como pertencentes à mesmas condições do revestimento.

Além disso, ressalta-se que foram utilizados apenas os parâmetros de coeficiente de atrito e de profundidade de macrotextura para avaliação da segurança operacional de revestimentos asfálticos pelo fato de que, esses são os parâmetros mais mensurados nas pistas de pouso e decolagem brasileiras. Outros parâmetros como *International Roughness Index* (IRI) e *Pavement Condition Index* (PCI) poderiam ser incrementados à análise, porém, a execução

dessas medições é realizada com frequência ainda menor quando comparados aos de aderência pneu-pavimento nas pistas brasileiras, sobretudo no período de análise desta pesquisa, o que inviabilizaria a utilização desses dados nas modelagens.

Portanto, devido às limitações da quantidade de dados e, principalmente, ao número de parâmetros com a possibilidade de serem estudados, este estudo se limitou a classificar a segurança operacional de revestimentos asfálticos. Para que fosse possível a elaboração de um indicador de segurança operacional para os pavimentos, faz-se necessário um banco mais robusto de dados, o que não foi praticável neste estudo.

5.3 Sugestões para trabalhos futuros

Tendo em vista o método de pesquisa adotado neste trabalho, os resultados e as conclusões obtidas, sugere-se para o desenvolvimento de trabalhos futuros:

- a) Incluir um maior número de pistas de pouso e decolagem, compostas de diferentes tipos de revestimentos (asfálticos e de concreto-cimento);
- b) Considerar número de operações e condições climáticas nas modelagens para verificar se os algoritmos têm suas métricas de avaliação melhoradas;
- c) Avaliar a segurança operacional de revestimentos de pistas de pouso e decolagens considerando coeficiente de atrito e profundidade de macrotextura separados, em indicadores distintos. Dessa forma, não será necessário a utilização de premissas de agrupamento das variáveis e pode-se verificar se os indicadores apresentam métricas melhoradas;
- d) Comparar o revestimento de CPA da pista de pouso e decolagem do SBRJ antes do processo de restauração e depois da reforma, ocorrida em 2019. Isso pode auxiliar no entendimento da vida útil desse tipo de revestimento e sua efetiva explicação para o crédito de desempenho;
- e) Analisar ferramentas estatísticas, por meio de testes de hipóteses, se o pavimento de CPA nas condições estudadas pode ser considerado como revestimento de CA, no que diz respeito aos parâmetros de aderência. Essa análise também pode auxiliar na compreensão da vida útil do pavimento em questão.

REFERÊNCIAS

- ALECRIM, C. M. C.; CASTELO BRANCO, V. T. F.; PEIXOTO, N. G. D. M.; ALVES, A.; PINHEIRO, G. M. Avaliação do desempenho acústico e das características de superfície de camada porosa de atrito em meio urbano. **Transportes**, v. 30 n. 1, 2022. DOI: <https://doi.org/10.14295/transportes.v30i1.2581>.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (Brasil). Anuário do Transporte Aéreo 2020. Brasília, DF, 166 p, 2021a.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (Brasil). Anuário do Transporte Aéreo 2021. Brasília, DF, 16 p, 2022.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (Brasil). Guia para elaboração de Manual de Gerenciamento da Segurança Operacional (MGSO) Aeródromos Classe I e II. Brasília: ANAC, 53 p, 2014.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (Brasil). INSTRUÇÃO SUPLEMENTAR – IS Nº 91-009 Revisão A. Brasília, DF, 8 p, 2020.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (Brasil). Aeródromos - Operação, manutenção e resposta à emergência. Regulamento Brasileiro de Aviação Civil - RBAC Número 153, emenda número 05. Brasília, DF, 2023.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR 16504 – Misturas asfálticas – Determinação da profundidade média da macrotextura superficial de pavimentos asfálticos por volumetria – Método da mancha de areia. Rio de Janeiro: ABNT, 2016.
- AYRES JR, M.; SHIRAZI, H.; CARVALHO, R.; HALL, J.; SPEIR, R.; ARAMBULA, E.; DAVID, R.; GADZINSKI, J.; CAVES, R.; WONG, D.; PITFIELD, D. Modelling the location and consequences of aircraft accidents. **Safety Science**, v. 51, n. 1, p. 178-186, 2013. DOI: <https://doi.org/10.1016/j.ssci.2012.05.012>.
- BENEDETTO, A.; D'AMICO, F.; TOSTI, F. Improving safety of runway overrun through the correct numerical evaluation of rutting in Cleared and Graded Areas. **Safety Science**, v. 62, p. 326-338, 2014. DOI: <https://doi.org/10.1016/j.ssci.2013.09.008>.
- CIVIL AVIATION AUTHORITY (United Kingdom). New contaminated runway reporting system. Disponível em: <https://www.caa.co.uk/Commercial-industry/Airports/Safety/New-contaminated-runway-reporting-system/>. Acesso em: 26 out. 2021, 2021.
- CARDOSO, S. H.; MAURINO, D.; FERNANDEZ, J. Methodology to estimate individual and overall performance indicators for airport safety management systems. **Transportation Research Board 87th Annual Meeting**. 2008.
- Centro de Investigação e Prevenção de Acidentes Aeronáuticos. Aeródromos: Sumário Estatístico 2010-2019. Brasília, DF, 82 p, 2021.
- CHEN, Jian-Shiuh; CHEN, Shih-Fan; LIAO, Min-Chih. Macroscopic and Microscopic Evaluation of Surface Friction of Airport Pavements. **International Journal of Pavement Research & Technology**, v. 6, n. 5, 2013. DOI: [https://doi.org/10.6135/ijprt.org.tw/2013.6\(5\).588](https://doi.org/10.6135/ijprt.org.tw/2013.6(5).588).

CHEN, W.; LI, J. Safety performance monitoring and measurement of civil aviation unit. **Journal of Air Transport Management**, v. 57, p. 228-233, 2016. DOI: <https://doi.org/10.1016/j.jairtraman.2016.08.015>.

CUNHA, D. A.; ANDRADE, M.; PRADO, L. A.; L.; SANTANA, L. O.; SILVA, M. P. G. RISK assessment in airport maintenance runway condition using MCDA-C. **Journal of Air Transport Management**, v. 90, p. 101948, 2021. DOI: <https://doi.org/10.1016/j.jairtraman.2020.101948>.

DI MASCIO, P.; COSCIOTTI, M.; FUSCO, R.; MORETTI, L. Runway veer-off risk analysis: An international airport case study. **Sustainability**, v. 12, n. 22, p. 9360, 2020. DOI: <https://doi.org/10.3390/su12229360>.

DISTEFANO, N.; LEONARDI, S. Aircraft runway excursion features: a multiple correspondence analysis. **Aircraft Engineering and Aerospace Technology**, 2019.

FEDERAL AVIATION ADMINISTRATION (USA). Advisory circular 150/5320-12, Measurement, Construction & Maintenance of Skid Resistant Airport Pavement Surface. 2007.

FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Machine learning**, v. 29, n. 2, p. 131-163, 1997.

GAJEWSKI, J.; SADOWSKI, T. Sensitivity analysis of crack propagation in pavement bituminous layered structures using a hybrid system integrating Artificial Neural Networks and Finite Element Method. **Computational Materials Science**, v. 82, p. 114-117, 2014. DOI: <https://doi.org/10.1016/j.commatsci.2013.09.025>.

GALAGEDERA, S.; PASINDU, H. R.; ADIKARIWATTAGE, V. Evaluation of the impact of runway characteristics on veer-off risk at rapid exit taxiways. **Transportation research interdisciplinary perspectives**, v. 12, p. 100480, 2021. DOI: <https://doi.org/10.1016/j.trip.2021.100480>.

GÉRON, A. Hands-On Machine Learning with Scikit-Learn, Keras, and Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems. **O'Reilly Media**. v 1. 856 p, 2019.

GÖKTEPE, A B.; EMINE, A. Ğ. A. R.; LAV, A. H. Comparison of multilayer perceptron and adaptive neuro-fuzzy system on backcalculating the mechanical properties of flexible pavements. **ITU ARI Bulletin of Istanbul Technical University**, v. 54, n. 03, p. 65-77, 2005.

HERNANDEZ-SAENZ, M. A.; CARO, S.; ARÁMBULA-MERCADO, E.; MARTIN, A. E. Mix design, performance and maintenance of Permeable Friction Courses (PFC) in the United States: State of the Art. **Construction and Building Materials**, v. 111, p. 358-367, 2016. DOI: <https://doi.org/10.1016/j.conbuildmat.2016.02.053>.

HORNE, W.; TAYLOR, G., Recent Research on Ways to Improve Tire Traction on Water, Slush or Ice. **Proc. AIAA Aircraft Design and Technology Meeting**, Los Angeles, Calif., 1965, 45 pp.

HOSSIN, M.; SULAIMAN, Md N. A review on evaluation metrics for data classification evaluations. **International journal of data mining & knowledge management process**, v.

5, n. 2, p. 1, 2015. DOI:10.5121/ijdkp.2015.5201.

International Civil Aviation Organization (CANADÁ). ANNEX 14. Annex 14—Aerodromes—Volume I—Aerodromes Design and Operations. 2022.

International Civil Aviation Organization (CANADÁ). Manual on the regulation of international air transport. Montreal, Canada, 2004.

INFRAERO. CARACTERÍSTICAS. Disponível em: <<https://www4.infraero.gov.br/aeroportos/aeroporto-do-rio-de-janeiro-santos-dumont/sobre-o-aeroporto/caracteristicas/>>. Acesso em: 23 set. 2019, 2019.

FRAPORT. Relatório Técnico n° 001/2018/SBFZ. Brasília, DF, 6 p, 2018.

INFRAERO. Relatório Técnico: RTa/SBRJ-004/2018-PPD-02R/20L R(0). Brasília, DF, 11 p, 2018.

INFRAERO. Santos Dumont terá pista principal reformada entre agosto e setembro. Disponível em: <https://www4.infraero.gov.br/noticias/santos-dumont-tera-pista-principal-reformada-entre-agosto-e-setembro/>. Acesso em: 13 mar. 2023. 2019.

LEINBAUM, D. G.; DIETZ, K.; GAIL, M.; KLEIN, M.; KLEIN, M. Logistic regression. New York: Springer-Verlag, 2002.

LIU, J. JH; YEN, L.; TZENG, Gwo-Hshiung. Building an effective safety management system for airlines. **Journal of Air Transport Management**, v. 14, n. 1, p. 20-26, 2008. DOI: <https://doi.org/10.1016/j.jairtraman.2007.10.002>.

MAHESH, B. Machine learning algorithms-a review. **International Journal of Science and Research**, v. 9, p. 381-386, 2020. DOI:10.21275/ART20203995.

MORETTI, L.; DI MASCIO, P.; NICHELE, S.; COKORIOLO, O. Runway veer-off accidents: Quantitative risk assessment and risk reduction measures. **Safety Science**, v. 104, p. 157-163, 2018. DOI: <https://doi.org/10.1016/j.ssci.2018.01.010>.

MOTA, Í. P. D. H.; OLIVEIRA, F. H. L. e AGUIAR, M. F. P. Verificação multicritério das condições físicas para a segurança operacional aeroportuária. **Transportes**, v. 24, n. 2, p. 21–26, 2016. DOI: 10.14295/transportes.v24i2.1033. Disponível em: <https://www.revistatransportes.org.br/anpet/article/view/1033>. Acesso em: 29 mai. 2021.

NITSCHKE, P.; STÜTZ, R.; KAMMER, M.; MAURER, P. Comparison of machine learning methods for evaluating pavement roughness based on vehicle response. **Journal of Computing in Civil Engineering**, v. 28, n. 4, p. 04014015, 2014. DOI:10.1061/(ASCE)CP.1943-5487.0000285.

PANZERI, S.; SENATORE, R.; MONTEMURRO, M. A.; PETERSEN, R. S. Correcting for the sampling bias problem in spike train information measures. **Journal of neurophysiology**, v. 98, n. 3, p. 1064-1072, 2007. DOI: 10.1152/jn.00559.2007.

PEREIRA, C. A. Análise da aderência pneu-pavimento em rodovias do Estado de Pernambuco e da Paraíba com elevado índice de acidentes. 2010. Tese (doutorado em Engenharia Civil) Universidade Federal de Pernambuco, Departamento de Engenharia Civil,

Recife, 2010.

PRATICÒ, F. G.; FEDELE, R.; NAUMOV, V.; SAUER. Detection and monitoring of bottom-up cracks in road pavement using a machine-learning approach. **Algorithms**, v. 13, n. 4, p. 81, 2020. DOI:10.3390/a13040081.

QUARIGUASI, J. B. F.; OLIVEIRA, F. H. L.; REIS, S. D. S. A prediction model of the coefficient of friction for runway using artificial neural network. **Transportes**, vol. 29, n. 2, 2021. DOI: 10.14295/transportes.v29i2.2401

RABABAAH, H.; VRAJITORU, D.; WOLFER, J. Asphalt pavement crack classification: a comparison of GA, MLP, and SOM. **Proceedings of Genetic and Evolutionary Computation Conference, Late-Breaking Paper**. 2005.

RODRIGUES FILHO, O. S. Características de aderência de revestimentos asfálticos aeroportuários. Estudo de caso do aeroporto internacional de São Paulo/Congonhas. Dissertação (mestrado em Engenharia de Transportes) – Universidade de São Paulo, Escola Politécnica, Engenharia de Transportes, São Paulo, 2006.

SALES, R.S; OLIVEIRA, F.H.L. e PRADO L. A. Performance of tire-asphalt pavement adherence according to rubber removal on runways. **International Journal of Pavement Engineering**, v. 23, n. 10, p. 3566-3576, 2022. DOI: 10.1080/10298436.2021.1907577

SILVA, João Paulo Souza. Aderência pneu-pavimento em revestimentos asfálticos aeroportuários. Dissertação (mestrado em Geotecnia) – Universidade de Brasília, Faculdade de Tecnologia, Departamento de Engenharia Civil e Ambiental, Brasília, 2008.

SINGH, A.; THAKUR, N.; SHARMA, A. A review of supervised machine learning algorithms. **3rd International Conference on Computing for Sustainable Global Development (INDIACom)**. Ieee, p. 1310-1315, 2016.

SONCIM, S. P.; DE OLIVEIRA, I. C. S.; SANTOS, F. B. Development of fuzzy models for asphalt pavement performance. **Acta Scientiarum Technology**, v. 41, p. e35626-e35626, 2019. DOI: 10.4025/actascitechnol.v41i1.35626.

SOUSA, E. S.; OLIVEIRA, F. H. L. Verificação do parâmetro de macrotextura de pavimentos em serviço por meio da análise digital de imagens. **Revista Tecnologia**, v. 40, n. 2, 2019. DOI: <https://doi.org/10.5020/23180730.2019.8595>.

TRUCCO, P.; DE AMBROGGI, M.; LEVA, M. C. Topological risk mapping of runway overruns: A probabilistic approach. **Reliability Engineering & System Safety**, v. 142, p. 433-443, 2015. DOI: <https://doi.org/10.1016/j.ress.2015.06.006>.

VALDÉS, R. M. A.; COMENDADOR, F. G.; GORDÚN, L. M.; NIETO, F. J. S. The development of probabilistic models to estimate accident risk (due to runway overrun and landing undershoot) applicable to the design and construction of runway safety areas. **Safety Science**, v. 49, n. 5, p. 633-650, 2011. DOI: <https://doi.org/10.1016/j.ssci.2010.09.020>.

WILKE, S.; MAJUMDAR, A.; OCHIENG, W.Y. Airport surface operations: A holistic framework for operations modeling and risk management. **Safety Science**, v. 63, p. 18-33, 2014. DOI: <https://doi.org/10.1016/j.ssci.2013.10.015>.

WILKE, S.; MAJUMDAR, A.; OCHIENG, W.Y. Holistic approach to airport surface safety. **Transportation Research Record**, v. 2300, n. 1, p. 1-12, 2012. DOI: <https://doi.org/10.3141/2300>.

WILKE, S.; MAJUMDAR, A.; OCHIENG, W.Y. The impact of airport characteristics on airport surface accidents and incidents. **Journal of Safety Research**, v. 53, p. 63-75, 2015. DOI: <https://doi.org/10.1016/j.jsr.2015.03.006>.

ZHANG, X.; MAHADEVAN, S. Ensemble machine learning models for aviation incident risk prediction. **Decision Support Systems**, v. 116, p. 48-63, 2019. DOI: <https://doi.org/10.1016/j.dss.2018.10.009>.

ZHENG, B.; HUANG, X.; ZHANG, W.; ZHAO, R.; ZHU, S. Adhesion characteristics of tire-asphalt pavement interface based on a proposed tire hydroplaning model. **Advances in Materials Science and Engineering**, v. 2018, 2018. DOI: [10.1155/2018/5916180](https://doi.org/10.1155/2018/5916180).

ZHU, X.; YANG, Y.; ZHAO, H.; JELAGIN, D.; CHEN, F.; GILABERT, F. A. e GUARIN, A. Effects of surface texture deterioration and wet surface conditions on asphalt runway skid resistance. **Tribology International**, v. 153, p. 106589, 2021. DOI: [0.1016/j.triboint.2020.106589](https://doi.org/10.1016/j.triboint.2020.106589)

APÊNDICE A - BANCO DE DADOS ANALISADO

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
0	0,64	0,62	1	1	100	0	0
1	0,76	0,69	1	1	100	0	0
2	0,64	0,62	1	1	100	0	0
3	0,62	0,79	0	1	100	0	0
4	0,78	0,88	1	1	100	1	0
5	0,67	0,63	1	1	100	0	0
6	0,7	0,67	1	1	100	0	0
7	0,79	0,71	1	1	100	0	0
8	0,63	0,82	1	1	100	0	0
9	0,65	0,78	1	1	100	0	0
10	0,65	1,06	0	1	100	0	0
11	0,86	0,85	1	1	100	1	0
12	0,78	0,78	1	1	100	0	0
13	0,59	0,69	1	1	100	0	0
14	0,68	0,77	0	1	100	0	0
15	0,54	0,92	0	1	100	0	0
16	0,56	1,18	1	1	100	0	0
17	0,65	0,62	1	1	100	0	0
18	0,84	0,69	1	1	100	0	0
19	0,63	0,62	1	1	100	0	0
20	0,52	0,79	0	1	100	0	0
21	0,63	0,88	1	1	100	0	0
22	0,64	0,63	1	1	100	0	0
23	0,67	0,67	1	1	100	0	0
24	0,72	0,71	1	1	100	0	0
25	0,64	0,82	1	1	100	0	0
26	0,64	0,78	1	1	100	0	0
27	0,56	1,06	0	1	100	0	0
28	0,99	0,85	1	1	100	1	0
29	0,65	0,78	1	1	100	0	0
30	0,65	0,69	1	1	100	0	0
31	0,58	0,77	0	1	100	0	0
32	0,64	0,92	0	1	100	0	0
33	0,61	1,18	1	1	100	0	0
34	0,66	0,64	1	1	200	0	0
35	0,74	0,81	1	1	200	1	0
36	0,7	0,74	1	1	200	0	0
37	0,73	0,92	0	1	200	1	0
38	0,74	1	1	1	200	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
39	0,73	0,72	1	1	200	0	0
40	0,78	0,72	1	1	200	0	0
41	0,89	1,03	1	1	200	1	0
42	0,74	1,15	1	1	200	1	0
43	0,73	0,87	1	1	200	1	0
44	0,73	1,5	0	1	200	1	0
45	1,11	1,1	1	1	200	1	0
46	0,74	0,93	1	1	200	1	0
47	0,72	1,14	1	1	200	1	0
48	0,69	1,14	0	1	200	0	0
49	0,54	1,09	0	1	200	0	0
50	0,62	1,17	0	1	200	0	0
51	0,72	0,64	1	1	200	0	0
52	0,87	0,81	1	1	200	1	0
53	0,74	0,74	1	1	200	0	0
54	0,57	0,92	0	1	200	0	0
55	0,71	1	1	1	200	1	0
56	0,74	0,72	1	1	200	0	0
57	0,78	0,72	1	1	200	0	0
58	0,82	1,03	1	1	200	1	0
59	0,77	1,15	1	1	200	1	0
60	0,76	0,87	1	1	200	1	0
61	0,71	1,5	0	1	200	1	0
62	1,13	1,1	1	1	200	1	0
63	0,64	0,93	1	1	200	0	0
64	0,7	1,14	1	1	200	1	0
65	0,61	1,14	0	1	200	0	0
66	0,55	1,09	0	1	200	0	0
67	0,61	1,17	1	1	200	0	0
68	0,63	0,81	1	1	300	0	0
69	0,76	1,09	1	1	300	1	0
70	0,69	0,96	1	1	300	0	0
71	0,68	1,06	0	1	300	0	0
72	0,74	1,11	1	1	300	1	0
73	0,79	0,9	1	1	300	1	0
74	0,78	0,76	1	1	300	0	0
75	0,91	0,91	1	1	300	1	0
76	0,81	1,1	1	1	300	1	0
77	0,73	0,95	1	1	300	1	0
78	0,71	1,07	0	1	300	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
79	1,1	1,05	1	1	300	1	0
80	0,76	1,25	1	1	300	1	0
81	0,66	1	1	1	300	0	0
82	0,73	0,85	0	1	300	1	0
83	0,61	1,11	0	1	300	0	0
84	0,63	1,22	1	1	300	0	0
85	0,67	0,81	1	1	300	0	0
86	0,72	1,09	1	1	300	1	0
87	0,7	0,96	1	1	300	1	0
88	0,53	1,06	0	1	300	0	0
89	0,68	1,11	1	1	300	0	0
90	0,86	0,9	1	1	300	1	0
91	0,88	0,76	1	1	300	0	0
92	0,88	0,91	1	1	300	1	0
93	0,84	1,1	1	1	300	1	0
94	0,75	0,95	1	1	300	1	0
95	0,75	1,07	0	1	300	1	0
96	1,12	1,05	1	1	300	1	0
97	0,81	1,25	1	1	300	1	0
98	0,72	1	1	1	300	1	0
99	0,7	0,85	0	1	300	1	0
100	0,63	1,11	0	1	300	0	0
101	0,72	1,22	1	1	300	1	0
102	0,67	0,82	1	1	400	0	0
103	0,6	0,81	1	1	400	0	0
104	0,52	0,49	1	1	400	0	0
105	0,61	0,88	0	1	400	0	0
106	0,79	1,44	1	1	400	1	0
107	0,81	1,33	1	1	400	1	0
108	0,82	1,25	1	1	400	1	0
109	0,78	1,24	1	1	400	1	0
110	0,73	1,52	1	1	400	1	0
111	0,72	1,3	1	1	400	1	0
112	0,56	1,29	0	1	400	0	0
113	0,93	1,3	1	1	400	1	0
114	0,7	1,14	1	1	400	1	0
115	0,71	1,52	1	1	400	1	0
116	0,54	1,55	0	1	400	0	0
117	0,64	1,42	0	1	400	0	0
118	0,53	1,36	1	1	400	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
119	0,64	0,82	1	1	400	0	0
120	0,71	0,81	1	1	400	1	0
121	0,6	0,49	1	1	400	0	0
122	0,58	0,88	0	1	400	0	0
123	0,65	1,44	1	1	400	0	0
124	0,96	1,33	1	1	400	1	0
125	0,82	1,25	1	1	400	1	0
126	0,73	1,24	1	1	400	1	0
127	0,78	1,52	1	1	400	1	0
128	0,76	1,3	1	1	400	1	0
129	0,71	1,29	0	1	400	1	0
130	1,02	1,3	1	1	400	1	0
131	0,81	1,14	1	1	400	1	0
132	0,72	1,52	1	1	400	1	0
133	0,71	1,55	0	1	400	1	0
134	0,61	1,42	0	1	400	0	0
135	0,77	1,36	1	1	400	1	0
136	0,75	0,75	1	1	500	0	0
137	0,64	0,74	1	1	500	0	0
138	0,51	0,39	1	1	500	0	0
139	0,62	1	0	1	500	0	0
140	0,8	0,82	1	1	500	1	0
141	0,76	0,99	1	1	500	1	0
142	0,85	1,21	1	1	500	1	0
143	0,83	1,09	1	1	500	1	0
144	0,77	0,86	1	1	500	1	0
145	0,81	1,03	1	1	500	1	0
146	0,55	1,1	0	1	500	0	0
147	0,95	0,81	1	1	500	1	0
148	0,68	0,99	1	1	500	0	0
149	0,78	0,72	1	1	500	0	0
150	0,6	0,82	0	1	500	0	0
151	0,7	0,94	0	1	500	1	0
152	0,52	0,97	1	1	500	0	0
153	0,75	0,75	1	1	500	0	0
154	0,85	0,74	1	1	500	0	0
155	0,48	0,39	1	1	500	0	0
156	0,63	1	0	1	500	0	0
157	0,61	0,82	1	1	500	0	0
158	0,93	0,99	1	1	500	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
159	0,82	1,21	1	1	500	1	0
160	0,72	1,09	1	1	500	1	0
161	0,91	0,86	1	1	500	1	0
162	0,69	1,03	1	1	500	0	0
163	0,54	1,1	0	1	500	0	0
164	1,02	0,81	1	1	500	1	0
165	0,76	0,99	1	1	500	1	0
166	0,78	0,72	1	1	500	0	0
167	0,67	0,82	0	1	500	0	0
168	0,7	0,94	0	1	500	1	0
169	0,72	0,97	1	1	500	1	0
170	0,75	0,6	1	1	600	0	0
171	0,7	0,94	1	1	600	1	0
172	0,56	0,59	1	1	600	0	0
173	0,72	0,99	0	1	600	1	0
174	0,87	0,79	1	1	600	0	0
175	0,76	0,93	1	1	600	1	0
176	0,84	1,09	1	1	600	1	0
177	0,82	1,22	1	1	600	1	0
178	0,79	0,8	1	1	600	1	0
179	0,78	1,03	1	1	600	1	0
180	0,69	1,37	0	1	600	0	0
181	1,04	0,89	1	1	600	1	0
182	0,7	1,06	1	1	600	1	0
183	0,8	0,8	1	1	600	1	0
184	0,71	0,63	0	1	600	0	0
185	0,72	0,92	0	1	600	1	0
186	0,68	1,35	1	1	600	0	0
187	0,76	0,6	1	1	600	0	0
188	0,86	0,94	1	1	600	1	0
189	0,5	0,59	1	1	600	0	0
190	0,69	0,99	0	1	600	0	0
191	0,68	0,79	1	1	600	0	0
192	0,98	0,93	1	1	600	1	0
193	0,89	1,09	1	1	600	1	0
194	0,82	1,22	1	1	600	1	0
195	0,81	0,8	1	1	600	1	0
196	0,82	1,03	1	1	600	1	0
197	0,74	1,37	0	1	600	1	0
198	1,14	0,89	1	1	600	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
199	0,77	1,06	1	1	600	1	0
200	0,85	0,8	1	1	600	1	0
201	0,73	0,63	0	1	600	0	0
202	0,67	0,92	0	1	600	0	0
203	0,73	1,35	1	1	600	1	0
204	0,76	0,6	1	1	700	0	0
205	0,74	1,14	1	1	700	1	0
206	0,65	0,57	1	1	700	0	0
207	0,66	0,93	0	1	700	0	0
208	0,83	0,97	1	1	700	1	0
209	0,79	1,27	1	1	700	1	0
210	0,88	1,12	1	1	700	1	0
211	0,81	0,69	1	1	700	0	0
212	0,86	1,02	1	1	700	1	0
213	0,78	1,07	1	1	700	1	0
214	0,81	1,28	0	1	700	1	0
215	1,13	0,85	1	1	700	1	0
216	0,86	0,87	1	1	700	1	0
217	0,8	1,1	1	1	700	1	0
218	0,71	0,54	0	1	700	0	0
219	0,71	1,03	0	1	700	1	0
220	0,76	0,98	1	1	700	1	0
221	0,75	0,6	1	1	700	0	0
222	0,84	1,14	1	1	700	1	0
223	0,73	0,57	1	1	700	0	0
224	0,58	0,93	0	1	700	0	0
225	0,77	0,97	1	1	700	1	0
226	0,99	1,27	1	1	700	1	0
227	0,92	1,12	1	1	700	1	0
228	0,95	0,69	1	1	700	0	0
229	0,94	1,02	1	1	700	1	0
230	0,88	1,07	1	1	700	1	0
231	0,83	1,28	0	1	700	1	0
232	1,11	0,85	1	1	700	1	0
233	0,92	0,87	1	1	700	1	0
234	0,81	1,1	1	1	700	1	0
235	0,78	0,54	0	1	700	0	0
236	0,75	1,03	0	1	700	1	0
237	0,75	0,98	1	1	700	1	0
238	0,81	0,62	1	1	800	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
239	0,77	0,86	1	1	800	1	0
240	0,7	0,82	1	1	800	1	0
241	0,52	1,09	0	1	800	0	0
242	0,77	1,16	1	1	800	1	0
243	0,65	0,86	1	1	800	0	0
244	0,86	0,96	1	1	800	1	0
245	0,85	0,88	1	1	800	1	0
246	0,8	1,07	1	1	800	1	0
247	0,73	1,08	1	1	800	1	0
248	0,87	1,43	0	1	800	1	0
249	1,11	1,12	1	1	800	1	0
250	0,82	1,18	1	1	800	1	0
251	0,94	1,07	1	1	800	1	0
252	0,77	1,26	0	1	800	1	0
253	0,78	0,85	0	1	800	1	0
254	0,79	1,03	1	1	800	1	0
255	0,66	0,62	1	1	800	0	0
256	0,81	0,86	1	1	800	1	0
257	0,83	0,82	1	1	800	1	0
258	0,61	1,09	0	1	800	0	0
259	0,69	1,16	1	1	800	0	0
260	0,9	0,86	1	1	800	1	0
261	0,91	0,96	1	1	800	1	0
262	0,92	0,88	1	1	800	1	0
263	0,93	1,07	1	1	800	1	0
264	0,91	1,08	1	1	800	1	0
265	0,88	1,43	0	1	800	1	0
266	1,19	1,12	1	1	800	1	0
267	0,79	1,18	1	1	800	1	0
268	0,82	1,07	1	1	800	1	0
269	0,76	1,26	0	1	800	1	0
270	0,78	0,85	0	1	800	1	0
271	0,75	1,03	1	1	800	1	0
272	0,8	0,72	1	1	900	0	0
273	0,8	0,76	1	1	900	0	0
274	0,79	0,5	1	1	900	0	0
275	0,59	0,9	0	1	900	0	0
276	0,77	0,95	1	1	900	1	0
277	0,69	0,55	1	1	900	0	0
278	0,87	0,82	1	1	900	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
279	0,94	0,98	1	1	900	1	0
280	0,9	1	1	1	900	1	0
281	0,76	0,94	1	1	900	1	0
282	0,84	1,08	0	1	900	1	0
283	1,01	0,99	1	1	900	1	0
284	0,8	0,85	1	1	900	1	0
285	0,98	1,06	1	1	900	1	0
286	0,77	0,89	0	1	900	1	0
287	0,82	1,34	0	1	900	1	0
288	0,79	1,05	1	1	900	1	0
289	0,7	0,72	1	1	900	0	0
290	0,81	0,76	1	1	900	0	0
291	0,86	0,5	1	1	900	0	0
292	0,63	0,9	0	1	900	0	0
293	0,67	0,95	1	1	900	0	0
294	0,77	0,55	1	1	900	0	0
295	0,88	0,82	1	1	900	1	0
296	0,91	0,98	1	1	900	1	0
297	0,9	1	1	1	900	1	0
298	0,87	0,94	1	1	900	1	0
299	0,89	1,08	0	1	900	1	0
300	1,17	0,99	1	1	900	1	0
301	0,77	0,85	1	1	900	1	0
302	0,92	1,06	1	1	900	1	0
303	0,76	0,89	0	1	900	1	0
304	0,76	1,34	0	1	900	1	0
305	0,78	1,05	1	1	900	1	0
306	0,8	1,11	1	2	1000	1	0
307	0,8	0,83	1	2	1000	1	0
308	0,81	0,8	1	2	1000	1	0
309	0,64	1,54	0	2	1000	0	0
310	0,72	0,88	1	2	1000	1	0
311	0,74	0,88	1	2	1000	1	0
312	0,87	0,84	1	2	1000	1	0
313	0,87	0,58	1	2	1000	0	0
314	0,83	1,01	1	2	1000	1	0
315	0,84	0,9	1	2	1000	1	0
316	0,88	0,81	0	2	1000	1	0
317	1,17	0,85	1	2	1000	1	0
318	0,8	0,78	1	2	1000	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
319	0,96	0,66	1	2	1000	0	0
320	0,71	1	0	2	1000	1	0
321	0,76	1,18	0	2	1000	1	0
322	0,72	1,38	1	2	1000	1	0
323	0,74	1,11	1	2	1000	1	0
324	0,82	0,83	1	2	1000	1	0
325	0,89	0,8	1	2	1000	1	0
326	0,68	1,54	0	2	1000	0	0
327	0,66	0,88	1	2	1000	0	0
328	0,81	0,88	1	2	1000	1	0
329	0,93	0,84	1	2	1000	1	0
330	0,96	0,58	1	2	1000	0	0
331	0,85	1,01	1	2	1000	1	0
332	0,93	0,9	1	2	1000	1	0
333	0,9	0,81	0	2	1000	1	0
334	1,17	0,85	1	2	1000	1	0
335	0,77	0,78	1	2	1000	0	0
336	0,98	0,66	1	2	1000	0	0
337	0,74	1	0	2	1000	1	0
338	0,73	1,18	0	2	1000	1	0
339	0,75	1,38	1	2	1000	1	0
340	0,81	0,77	1	2	1100	0	0
341	0,77	0,73	1	2	1100	0	0
342	0,88	0,86	1	2	1100	1	0
343	0,7	0,84	0	2	1100	1	0
344	0,78	0,81	1	2	1100	1	0
345	0,75	0,86	1	2	1100	1	0
346	0,9	0,79	1	2	1100	0	0
347	0,93	0,79	1	2	1100	0	0
348	0,89	0,89	1	2	1100	1	0
349	0,84	1,04	1	2	1100	1	0
350	0,82	1,05	0	2	1100	1	0
351	1,18	0,96	1	2	1100	1	0
352	0,81	0,93	1	2	1100	1	0
353	0,85	0,85	1	2	1100	1	0
354	0,74	1,14	0	2	1100	1	0
355	0,71	1,17	0	2	1100	1	0
356	0,73	1,34	1	2	1100	1	0
357	0,75	0,77	1	2	1100	0	0
358	0,83	0,73	1	2	1100	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
359	0,88	0,86	1	2	1100	1	0
360	0,68	0,84	0	2	1100	0	0
361	0,68	0,81	1	2	1100	0	0
362	0,82	0,86	1	2	1100	1	0
363	1	0,79	1	2	1100	0	0
364	0,94	0,79	1	2	1100	0	0
365	0,91	0,89	1	2	1100	1	0
366	0,95	1,04	1	2	1100	1	0
367	0,82	1,05	0	2	1100	1	0
368	1,18	0,96	1	2	1100	1	0
369	0,81	0,93	1	2	1100	1	0
370	0,83	0,85	1	2	1100	1	0
371	0,74	1,14	0	2	1100	1	0
372	0,7	1,17	0	2	1100	1	0
373	0,75	1,34	1	2	1100	1	0
374	0,76	0,62	1	2	1200	0	0
375	0,76	0,92	1	2	1200	1	0
376	0,9	0,74	1	2	1200	0	0
377	0,68	1,12	0	2	1200	0	0
378	0,75	0,94	1	2	1200	1	0
379	0,72	1	1	2	1200	1	0
380	0,89	0,88	1	2	1200	1	0
381	0,87	0,56	1	2	1200	0	0
382	0,9	0,86	1	2	1200	1	0
383	0,8	0,99	1	2	1200	1	0
384	0,71	1,34	0	2	1200	1	0
385	1,14	0,97	1	2	1200	1	0
386	0,78	0,99	1	2	1200	1	0
387	0,64	0,92	1	2	1200	0	0
388	0,8	1,11	0	2	1200	1	0
389	0,71	1,13	0	2	1200	1	0
390	0,73	0,98	1	2	1200	1	0
391	0,74	0,62	1	2	1200	0	0
392	0,8	0,92	1	2	1200	1	0
393	0,88	0,74	1	2	1200	0	0
394	0,67	1,12	0	2	1200	0	0
395	0,71	0,94	1	2	1200	1	0
396	0,87	1	1	2	1200	1	0
397	0,97	0,88	1	2	1200	1	0
398	1,01	0,56	1	2	1200	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
399	0,82	0,86	1	2	1200	1	0
400	0,94	0,99	1	2	1200	1	0
401	0,82	1,34	0	2	1200	1	0
402	1,18	0,97	1	2	1200	1	0
403	0,76	0,99	1	2	1200	1	0
404	0,73	0,92	1	2	1200	1	0
405	0,7	1,11	0	2	1200	1	0
406	0,71	1,13	0	2	1200	1	0
407	0,7	0,98	1	2	1200	1	0
408	0,76	0,7	1	2	1300	0	0
409	0,74	0,84	1	2	1300	1	0
410	0,87	0,76	1	2	1300	0	0
411	0,67	1,17	0	2	1300	0	0
412	0,76	1,04	1	2	1300	1	0
413	0,63	0,91	1	2	1300	0	0
414	0,86	0,9	1	2	1300	1	0
415	0,77	1,13	1	2	1300	1	0
416	0,81	1	1	2	1300	1	0
417	0,76	1,24	1	2	1300	1	0
418	0,73	1,49	0	2	1300	1	0
419	1,15	1,21	1	2	1300	1	0
420	0,57	0,84	1	2	1300	0	0
421	0,8	0,9	1	2	1300	1	0
422	0,75	1,4	0	2	1300	1	0
423	0,75	1,2	0	2	1300	1	0
424	0,84	1,1	1	2	1300	1	0
425	0,73	0,7	1	2	1300	0	0
426	0,78	0,84	1	2	1300	1	0
427	0,88	0,76	1	2	1300	0	0
428	0,65	1,17	0	2	1300	0	0
429	0,7	1,04	1	2	1300	1	0
430	0,84	0,91	1	2	1300	1	0
431	0,97	0,9	1	2	1300	1	0
432	0,94	1,13	1	2	1300	1	0
433	0,82	1	1	2	1300	1	0
434	0,88	1,24	1	2	1300	1	0
435	0,81	1,49	0	2	1300	1	0
436	1,14	1,21	1	2	1300	1	0
437	0,77	0,84	1	2	1300	1	0
438	0,85	0,9	1	2	1300	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
439	0,69	1,4	0	2	1300	0	0
440	0,71	1,2	0	2	1300	1	0
441	0,69	1,1	1	2	1300	0	0
442	0,76	0,61	1	2	1400	0	0
443	0,78	0,87	1	2	1400	1	0
444	0,9	0,65	1	2	1400	0	0
445	0,65	0,89	0	2	1400	0	0
446	0,79	1,19	1	2	1400	1	0
447	0,67	1,03	1	2	1400	0	0
448	0,87	0,93	1	2	1400	1	0
449	0,81	0,63	1	2	1400	0	0
450	0,82	0,79	1	2	1400	0	0
451	0,8	1,26	1	2	1400	1	0
452	0,89	1,06	0	2	1400	1	0
453	1,18	0,91	1	2	1400	1	0
454	0,75	0,92	1	2	1400	1	0
455	0,95	0,79	1	2	1400	0	0
456	0,74	1,06	0	2	1400	1	0
457	0,74	1,27	0	2	1400	1	0
458	0,73	0,98	1	2	1400	1	0
459	0,69	0,61	1	2	1400	0	0
460	0,8	0,87	1	2	1400	1	0
461	0,89	0,65	1	2	1400	0	0
462	0,7	0,89	0	2	1400	1	0
463	0,71	1,19	1	2	1400	1	0
464	0,86	1,03	1	2	1400	1	0
465	0,9	0,93	1	2	1400	1	0
466	0,96	0,63	1	2	1400	0	0
467	0,84	0,79	1	2	1400	0	0
468	0,89	1,26	1	2	1400	1	0
469	0,77	1,06	0	2	1400	1	0
470	1,16	0,91	1	2	1400	1	0
471	0,76	0,92	1	2	1400	1	0
472	0,92	0,79	1	2	1400	0	0
473	0,71	1,06	0	2	1400	1	0
474	0,68	1,27	0	2	1400	0	0
475	0,72	0,98	1	2	1400	1	0
476	0,75	0,87	1	2	1500	1	0
477	0,84	0,97	1	2	1500	1	0
478	0,82	0,94	1	2	1500	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
479	0,61	0,75	0	2	1500	0	0
480	0,73	1	1	2	1500	1	0
481	0,7	0,9	1	2	1500	1	0
482	0,84	0,9	1	2	1500	1	0
483	0,82	0,68	1	2	1500	0	0
484	0,83	0,78	1	2	1500	0	0
485	0,75	0,99	1	2	1500	1	0
486	0,82	1,12	0	2	1500	1	0
487	1,13	0,91	1	2	1500	1	0
488	0,65	0,96	1	2	1500	0	0
489	0,89	0,83	1	2	1500	1	0
490	0,64	1,03	0	2	1500	0	0
491	0,68	1,31	0	2	1500	0	0
492	0,71	1,02	1	2	1500	1	0
493	0,71	0,87	1	2	1500	1	0
494	0,78	0,97	1	2	1500	1	0
495	0,88	0,94	1	2	1500	1	0
496	0,65	0,75	0	2	1500	0	0
497	0,67	1	1	2	1500	0	0
498	0,83	0,9	1	2	1500	1	0
499	0,88	0,9	1	2	1500	1	0
500	0,96	0,68	1	2	1500	0	0
501	0,8	0,78	1	2	1500	0	0
502	0,86	0,99	1	2	1500	1	0
503	0,78	1,12	0	2	1500	1	0
504	1,15	0,91	1	2	1500	1	0
505	0,71	0,96	1	2	1500	1	0
506	0,87	0,83	1	2	1500	1	0
507	0,66	1,03	0	2	1500	0	0
508	0,64	1,31	0	2	1500	0	0
509	0,71	1,02	1	2	1500	1	0
510	0,71	0,73	1	2	1600	0	0
511	0,79	0,86	1	2	1600	1	0
512	0,8	0,76	1	2	1600	0	0
513	0,65	1,36	0	2	1600	0	0
514	0,73	1,01	1	2	1600	1	0
515	0,67	0,92	1	2	1600	0	0
516	0,92	0,93	1	2	1600	1	0
517	0,96	0,9	1	2	1600	1	0
518	0,93	0,97	1	2	1600	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
519	0,74	0,99	1	2	1600	1	0
520	0,77	0,88	0	2	1600	1	0
521	1,16	0,92	1	2	1600	1	0
522	0,77	0,96	1	2	1600	1	0
523	0,64	0,84	1	2	1600	0	0
524	0,66	0,98	0	2	1600	0	0
525	0,69	1,27	0	2	1600	0	0
526	0,68	1,22	1	2	1600	0	0
527	0,68	0,73	1	2	1600	0	0
528	0,78	0,86	1	2	1600	1	0
529	0,88	0,76	1	2	1600	0	0
530	0,66	1,36	0	2	1600	0	0
531	0,61	1,01	1	2	1600	0	0
532	0,83	0,92	1	2	1600	1	0
533	0,87	0,93	1	2	1600	1	0
534	0,89	0,9	1	2	1600	1	0
535	0,81	0,97	1	2	1600	1	0
536	0,81	0,99	1	2	1600	1	0
537	0,77	0,88	0	2	1600	1	0
538	1,12	0,92	1	2	1600	1	0
539	0,74	0,96	1	2	1600	1	0
540	0,98	0,84	1	2	1600	1	0
541	0,79	0,98	0	2	1600	1	0
542	0,59	1,27	0	2	1600	0	0
543	0,77	1,22	1	2	1600	1	0
544	0,71	0,88	1	2	1700	1	0
545	0,76	0,77	1	2	1700	0	0
546	0,81	1,12	1	2	1700	1	0
547	0,61	1,1	0	2	1700	0	0
548	0,72	1,16	1	2	1700	1	0
549	0,82	0,97	1	2	1700	1	0
550	0,93	0,92	1	2	1700	1	0
551	1,02	0,91	1	2	1700	1	0
552	0,93	0,93	1	2	1700	1	0
553	0,75	1	1	2	1700	1	0
554	0,73	1,06	0	2	1700	1	0
555	1,16	0,98	1	2	1700	1	0
556	0,72	0,99	1	2	1700	1	0
557	0,87	0,88	1	2	1700	1	0
558	0,7	0,9	0	2	1700	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
559	0,69	1,19	0	2	1700	0	0
560	0,66	1,21	1	2	1700	0	0
561	0,69	0,88	1	2	1700	0	0
562	0,76	0,77	1	2	1700	0	0
563	0,85	1,12	1	2	1700	1	0
564	0,64	1,1	0	2	1700	0	0
565	0,62	1,16	1	2	1700	0	0
566	0,84	0,97	1	2	1700	1	0
567	0,8	0,92	1	2	1700	1	0
568	0,91	0,91	1	2	1700	1	0
569	0,8	0,93	1	2	1700	1	0
570	0,83	1	1	2	1700	1	0
571	0,75	1,06	0	2	1700	1	0
572	1,11	0,98	1	2	1700	1	0
573	0,67	0,99	1	2	1700	0	0
574	0,92	0,88	1	2	1700	1	0
575	0,61	0,9	0	2	1700	0	0
576	0,58	1,19	0	2	1700	0	0
577	0,69	1,21	1	2	1700	0	0
578	0,72	0,69	1	3	1800	0	0
579	0,75	0,68	1	3	1800	0	0
580	0,72	0,74	1	3	1800	0	0
581	0,65	0,92	0	3	1800	0	0
582	0,73	1,04	1	3	1800	1	0
583	0,64	1,09	1	3	1800	0	0
584	0,81	1,01	1	3	1800	1	0
585	0,91	1,21	1	3	1800	1	0
586	0,83	1,17	1	3	1800	1	0
587	0,84	0,99	1	3	1800	1	0
588	0,7	1,06	0	3	1800	1	0
589	1,1	1,08	1	3	1800	1	0
590	0,71	0,92	1	3	1800	1	0
591	0,8	0,81	1	3	1800	1	0
592	0,63	1,04	0	3	1800	0	0
593	0,68	1,08	0	3	1800	0	0
594	0,63	1,39	1	3	1800	0	0
595	0,7	0,69	1	3	1800	0	0
596	0,79	0,68	1	3	1800	0	0
597	0,78	0,74	1	3	1800	0	0
598	0,58	0,92	0	3	1800	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
599	0,6	1,04	1	3	1800	0	0
600	0,88	1,09	1	3	1800	1	0
601	0,81	1,01	1	3	1800	1	0
602	0,91	1,21	1	3	1800	1	0
603	0,74	1,17	1	3	1800	1	0
604	0,79	0,99	1	3	1800	1	0
605	0,71	1,06	0	3	1800	1	0
606	1,08	1,08	1	3	1800	1	0
607	0,7	0,92	1	3	1800	1	0
608	0,85	0,81	1	3	1800	1	0
609	0,66	1,04	0	3	1800	0	0
610	0,59	1,08	0	3	1800	0	0
611	0,69	1,39	1	3	1800	0	0
612	0,8	0,88	1	3	1900	1	0
613	0,75	0,97	1	3	1900	1	0
614	0,74	0,92	1	3	1900	1	0
615	0,57	0,79	0	3	1900	0	0
616	0,71	0,99	1	3	1900	1	0
617	0,66	1,03	1	3	1900	0	0
618	0,76	1,04	1	3	1900	1	0
619	0,8	1	1	3	1900	1	0
620	0,72	1,06	1	3	1900	1	0
621	0,81	1,08	1	3	1900	1	0
622	0,61	0,93	0	3	1900	0	0
623	1,03	1,02	1	3	1900	1	0
624	0,69	0,87	1	3	1900	0	0
625	0,78	0,92	1	3	1900	1	0
626	0,61	1,53	0	3	1900	0	0
627	0,61	0,8	0	3	1900	0	0
628	0,59	1,26	1	3	1900	0	0
629	0,71	0,88	1	3	1900	1	0
630	0,9	0,97	1	3	1900	1	0
631	0,71	0,92	1	3	1900	1	0
632	0,61	0,79	0	3	1900	0	0
633	0,59	0,99	1	3	1900	0	0
634	0,76	1,03	1	3	1900	1	0
635	0,78	1,04	1	3	1900	1	0
636	0,83	1	1	3	1900	1	0
637	0,85	1,06	1	3	1900	1	0
638	0,81	1,08	1	3	1900	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
639	0,61	0,93	0	3	1900	0	0
640	0,96	1,02	1	3	1900	1	0
641	0,65	0,87	1	3	1900	0	0
642	0,8	0,92	1	3	1900	1	0
643	0,58	1,53	0	3	1900	0	0
644	0,55	0,8	0	3	1900	0	0
645	0,61	1,26	1	3	1900	0	0
646	0,81	0,79	1	3	2000	0	0
647	0,86	0,86	1	3	2000	1	0
648	0,84	0,75	1	3	2000	0	0
649	0,72	0,74	0	3	2000	0	0
650	0,72	0,72	1	3	2000	0	0
651	0,8	0,79	1	3	2000	0	0
652	0,81	0,81	1	3	2000	1	0
653	0,9	1,09	1	3	2000	1	0
654	0,89	1,08	1	3	2000	1	0
655	0,78	0,85	1	3	2000	1	0
656	0,73	0,91	0	3	2000	1	0
657	1,15	0,95	1	3	2000	1	0
658	0,91	0,87	1	3	2000	1	0
659	0,82	0,87	1	3	2000	1	0
660	0,71	1,38	0	3	2000	1	0
661	0,7	1,15	0	3	2000	1	0
662	0,67	1,11	1	3	2000	0	0
663	0,73	0,79	1	3	2000	0	0
664	0,87	0,86	1	3	2000	1	0
665	0,81	0,75	1	3	2000	0	0
666	0,68	0,74	0	3	2000	0	0
667	0,72	0,72	1	3	2000	0	0
668	0,9	0,79	1	3	2000	0	0
669	0,82	0,81	1	3	2000	1	0
670	0,95	1,09	1	3	2000	1	0
671	0,83	1,08	1	3	2000	1	0
672	0,7	0,85	1	3	2000	1	0
673	0,72	0,91	0	3	2000	1	0
674	1,11	0,95	1	3	2000	1	0
675	0,89	0,87	1	3	2000	1	0
676	0,77	0,87	1	3	2000	1	0
677	0,75	1,38	0	3	2000	1	0
678	0,7	1,15	0	3	2000	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
679	0,68	1,11	1	3	2000	0	0
680	0,77	0,9	1	3	2100	1	0
681	0,84	0,97	1	3	2100	1	0
682	0,81	0,85	1	3	2100	1	0
683	0,63	0,79	0	3	2100	0	0
684	0,76	0,8	1	3	2100	1	0
685	0,81	0,97	1	3	2100	1	0
686	0,91	0,95	1	3	2100	1	0
687	0,94	1,15	1	3	2100	1	0
688	0,91	1,14	1	3	2100	1	0
689	0,79	0,92	1	3	2100	1	0
690	0,7	0,87	0	3	2100	1	0
691	1,15	0,99	1	3	2100	1	0
692	0,93	0,82	1	3	2100	1	0
693	0,78	0,65	1	3	2100	0	0
694	0,76	0,9	0	3	2100	1	0
695	0,74	1,16	0	3	2100	1	0
696	0,73	1,13	1	3	2100	1	0
697	0,71	0,9	1	3	2100	1	0
698	0,87	0,97	1	3	2100	1	0
699	0,8	0,85	1	3	2100	1	0
700	0,63	0,79	0	3	2100	0	0
701	0,75	0,8	1	3	2100	1	0
702	0,9	0,97	1	3	2100	1	0
703	0,88	0,95	1	3	2100	1	0
704	0,94	1,15	1	3	2100	1	0
705	0,86	1,14	1	3	2100	1	0
706	0,93	0,92	1	3	2100	1	0
707	0,74	0,87	0	3	2100	1	0
708	1,13	0,99	1	3	2100	1	0
709	0,9	0,82	1	3	2100	1	0
710	0,8	0,65	1	3	2100	0	0
711	0,8	0,9	0	3	2100	1	0
712	0,74	1,16	0	3	2100	1	0
713	0,74	1,13	1	3	2100	1	0
714	0,7	0,73	1	3	2200	0	0
715	0,78	0,77	1	3	2200	0	0
716	0,88	0,8	1	3	2200	1	0
717	0,93	1,01	1	3	2200	1	0
718	0,86	1,11	1	3	2200	1	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
719	0,8	0,84	1	3	2200	1	0
720	0,77	0,91	0	3	2200	1	0
721	1,16	0,95	1	3	2200	1	0
722	0,95	0,86	1	3	2200	1	0
723	0,82	0,8	1	3	2200	1	0
724	0,73	0,59	0	3	2200	0	0
725	0,73	1,21	0	3	2200	1	0
726	0,73	0,71	1	3	2200	0	0
727	0,73	0,73	1	3	2200	0	0
728	0,86	0,77	1	3	2200	0	0
729	0,84	0,8	1	3	2200	1	0
730	0,91	1,01	1	3	2200	1	0
731	0,87	1,11	1	3	2200	1	0
732	0,85	0,84	1	3	2200	1	0
733	0,71	0,91	0	3	2200	1	0
734	1,14	0,95	1	3	2200	1	0
735	0,86	0,86	1	3	2200	1	0
736	0,76	0,8	1	3	2200	1	0
737	0,73	0,59	0	3	2200	0	0
738	0,68	1,21	0	3	2200	0	0
739	0,7	0,71	1	3	2200	0	0
740	0,67	0,7	1	3	2300	0	0
741	0,71	0,8	1	3	2300	1	0
742	0,81	0,83	1	3	2300	1	0
743	0,83	1,08	1	3	2300	1	0
744	0,78	1,06	1	3	2300	1	0
745	0,79	0,76	1	3	2300	0	0
746	0,68	0,82	0	3	2300	0	0
747	1,15	0,88	1	3	2300	1	0
748	0,86	0,67	1	3	2300	0	0
749	0,74	0,61	1	3	2300	0	0
750	0,79	0,65	0	3	2300	0	0
751	0,73	1,07	0	3	2300	1	0
752	0,76	0,82	1	3	2300	1	0
753	0,77	0,7	1	3	2300	0	0
754	0,83	0,8	1	3	2300	1	0
755	0,81	0,83	1	3	2300	1	0
756	0,77	1,08	1	3	2300	1	0
757	0,69	1,06	1	3	2300	0	0
758	0,82	0,76	1	3	2300	0	0

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
759	0,74	0,82	0	3	2300	1	0
760	1,17	0,88	1	3	2300	1	0
761	0,87	0,67	1	3	2300	0	0
762	0,84	0,61	1	3	2300	0	0
763	0,78	0,65	0	3	2300	0	0
764	0,75	1,07	0	3	2300	1	0
765	0,73	0,82	1	3	2300	1	0
766	0,83	0,72	1	3	2400	0	0
767	0,7	0,68	1	3	2400	0	0
768	0,66	0,87	1	3	2400	0	0
769	0,83	0,65	1	3	2400	0	0
770	0,71	1,17	1	3	2400	1	0
771	0,69	0,72	1	3	2400	0	0
772	0,86	0,72	1	3	2400	0	0
773	0,72	0,68	1	3	2400	0	0
774	0,85	0,87	1	3	2400	1	0
775	0,8	0,65	1	3	2400	0	0
776	0,68	1,17	1	3	2400	0	0
777	0,7	0,72	1	3	2400	0	0
778	0,7	1,3	1	1	100	1	1
779	0,68	1,18	0	1	100	0	1
780	0,7	1,18	1	1	100	0	1
781	0,6	1,49	1	1	100	0	1
782	0,63	1,47	1	1	100	0	1
783	0,69	1,47	1	1	100	1	1
784	0,61	1,4	1	1	100	0	1
785	0,66	1,27	1	1	100	1	1
786	0,61	1,37	1	1	100	0	1
787	0,61	1,38	1	1	100	0	1
788	0,69	1,22	1	1	100	1	1
789	0,61	1,22	1	1	100	0	1
790	0,69	1,16	1	1	100	0	1
791	0,72	1,32	0	1	100	1	1
792	0,62	1,4	1	1	100	0	1
793	0,76	1,4	1	1	100	1	1
794	0,8	1,45	1	1	100	1	1
795	0,66	1,57	1	1	100	1	1
796	0,86	1,39	1	1	100	1	1
797	0,66	1,54	1	1	100	1	1
798	0,68	1,34	1	1	100	1	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
799	0,57	1,58	1	1	100	0	1
800	0,74	1,65	1	1	100	1	1
801	0,7	1,3	1	1	100	1	1
802	0,65	1,18	0	1	100	0	1
803	0,68	1,18	1	1	100	0	1
804	0,6	1,49	1	1	100	0	1
805	0,62	1,47	1	1	100	0	1
806	0,64	1,47	1	1	100	0	1
807	0,61	1,4	1	1	100	0	1
808	0,57	1,27	1	1	100	0	1
809	0,61	1,37	1	1	100	0	1
810	0,61	1,38	1	1	100	0	1
811	0,63	1,22	1	1	100	0	1
812	0,61	1,22	1	1	100	0	1
813	0,7	1,16	1	1	100	0	1
814	0,67	1,32	0	1	100	1	1
815	0,57	1,4	1	1	100	0	1
816	0,78	1,4	1	1	100	1	1
817	0,63	1,45	1	1	100	0	1
818	0,69	1,57	1	1	100	1	1
819	0,63	1,39	1	1	100	0	1
820	0,67	1,54	1	1	100	1	1
821	0,67	1,34	1	1	100	1	1
822	0,58	1,58	1	1	100	0	1
823	0,62	1,65	1	1	100	0	1
824	0,7	1,3	1	1	200	1	1
825	0,68	1,18	0	1	200	0	1
826	0,7	1,18	1	1	200	0	1
827	0,6	1,49	1	1	200	0	1
828	0,63	1,47	1	1	200	0	1
829	0,69	1,47	1	1	200	1	1
830	0,61	1,4	1	1	200	0	1
831	0,66	1,27	1	1	200	1	1
832	0,61	1,37	1	1	200	0	1
833	0,61	1,38	1	1	200	0	1
834	0,69	1,22	1	1	200	1	1
835	0,61	1,22	1	1	200	0	1
836	0,69	1,16	1	1	200	0	1
837	0,72	1,32	0	1	200	1	1
838	0,62	1,4	1	1	200	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
839	0,76	1,4	1	1	200	1	1
840	0,8	1,45	1	1	200	1	1
841	0,66	1,57	1	1	200	1	1
842	0,86	1,39	1	1	200	1	1
843	0,66	1,54	1	1	200	1	1
844	0,68	1,34	1	1	200	1	1
845	0,57	1,58	1	1	200	0	1
846	0,74	1,65	1	1	200	1	1
847	0,7	1,3	1	1	200	1	1
848	0,65	1,18	0	1	200	0	1
849	0,68	1,18	1	1	200	0	1
850	0,6	1,49	1	1	200	0	1
851	0,62	1,47	1	1	200	0	1
852	0,64	1,47	1	1	200	0	1
853	0,61	1,4	1	1	200	0	1
854	0,57	1,27	1	1	200	0	1
855	0,61	1,37	1	1	200	0	1
856	0,61	1,38	1	1	200	0	1
857	0,63	1,22	1	1	200	0	1
858	0,61	1,22	1	1	200	0	1
859	0,7	1,16	1	1	200	0	1
860	0,67	1,32	0	1	200	1	1
861	0,57	1,4	1	1	200	0	1
862	0,78	1,4	1	1	200	1	1
863	0,63	1,45	1	1	200	0	1
864	0,69	1,57	1	1	200	1	1
865	0,63	1,39	1	1	200	0	1
866	0,67	1,54	1	1	200	1	1
867	0,67	1,34	1	1	200	1	1
868	0,58	1,58	1	1	200	0	1
869	0,62	1,65	1	1	200	0	1
870	0,7	1,3	1	1	300	1	1
871	0,68	1,18	0	1	300	0	1
872	0,7	1,18	1	1	300	0	1
873	0,6	1,49	1	1	300	0	1
874	0,63	1,47	1	1	300	0	1
875	0,69	1,47	1	1	300	1	1
876	0,61	1,4	1	1	300	0	1
877	0,66	1,27	1	1	300	1	1
878	0,61	1,37	1	1	300	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
879	0,61	1,38	1	1	300	0	1
880	0,69	1,22	1	1	300	1	1
881	0,61	1,22	1	1	300	0	1
882	0,69	1,16	1	1	300	0	1
883	0,72	1,32	0	1	300	1	1
884	0,62	1,4	1	1	300	0	1
885	0,76	1,4	1	1	300	1	1
886	0,8	1,45	1	1	300	1	1
887	0,66	1,57	1	1	300	1	1
888	0,86	1,39	1	1	300	1	1
889	0,66	1,54	1	1	300	1	1
890	0,68	1,34	1	1	300	1	1
891	0,57	1,58	1	1	300	0	1
892	0,74	1,65	1	1	300	1	1
893	0,7	1,3	1	1	300	1	1
894	0,65	1,18	0	1	300	0	1
895	0,68	1,18	1	1	300	0	1
896	0,6	1,49	1	1	300	0	1
897	0,62	1,47	1	1	300	0	1
898	0,64	1,47	1	1	300	0	1
899	0,61	1,4	1	1	300	0	1
900	0,57	1,27	1	1	300	0	1
901	0,61	1,37	1	1	300	0	1
902	0,61	1,38	1	1	300	0	1
903	0,63	1,22	1	1	300	0	1
904	0,61	1,22	1	1	300	0	1
905	0,7	1,16	1	1	300	0	1
906	0,67	1,32	0	1	300	1	1
907	0,57	1,4	1	1	300	0	1
908	0,78	1,4	1	1	300	1	1
909	0,63	1,45	1	1	300	0	1
910	0,69	1,57	1	1	300	1	1
911	0,63	1,39	1	1	300	0	1
912	0,67	1,54	1	1	300	1	1
913	0,67	1,34	1	1	300	1	1
914	0,58	1,58	1	1	300	0	1
915	0,62	1,65	1	1	300	0	1
916	0,7	1,3	1	1	400	1	1
917	0,68	1,18	0	1	400	0	1
918	0,7	1,18	1	1	400	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
919	0,6	1,49	1	1	400	0	1
920	0,63	1,47	1	1	400	0	1
921	0,69	1,47	1	1	400	1	1
922	0,61	1,4	1	1	400	0	1
923	0,66	1,27	1	1	400	1	1
924	0,61	1,37	1	1	400	0	1
925	0,61	1,38	1	1	400	0	1
926	0,69	1,22	1	1	400	1	1
927	0,61	1,22	1	1	400	0	1
928	0,69	1,16	1	1	400	0	1
929	0,72	1,32	0	1	400	1	1
930	0,62	1,4	1	1	400	0	1
931	0,76	1,4	1	1	400	1	1
932	0,8	1,45	1	1	400	1	1
933	0,66	1,57	1	1	400	1	1
934	0,86	1,39	1	1	400	1	1
935	0,66	1,54	1	1	400	1	1
936	0,68	1,34	1	1	400	1	1
937	0,57	1,58	1	1	400	0	1
938	0,74	1,65	1	1	400	1	1
939	0,7	1,3	1	1	400	1	1
940	0,65	1,18	0	1	400	0	1
941	0,68	1,18	1	1	400	0	1
942	0,6	1,49	1	1	400	0	1
943	0,62	1,47	1	1	400	0	1
944	0,64	1,47	1	1	400	0	1
945	0,61	1,4	1	1	400	0	1
946	0,57	1,27	1	1	400	0	1
947	0,61	1,37	1	1	400	0	1
948	0,61	1,38	1	1	400	0	1
949	0,63	1,22	1	1	400	0	1
950	0,61	1,22	1	1	400	0	1
951	0,7	1,16	1	1	400	0	1
952	0,67	1,32	0	1	400	1	1
953	0,57	1,4	1	1	400	0	1
954	0,78	1,4	1	1	400	1	1
955	0,63	1,45	1	1	400	0	1
956	0,69	1,57	1	1	400	1	1
957	0,63	1,39	1	1	400	0	1
958	0,67	1,54	1	1	400	1	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
959	0,67	1,34	1	1	400	1	1
960	0,58	1,58	1	1	400	0	1
961	0,62	1,65	1	1	400	0	1
962	0,7	1,3	1	1	500	1	1
963	0,68	1,18	0	1	500	0	1
964	0,7	1,18	1	1	500	0	1
965	0,6	1,49	1	1	500	0	1
966	0,63	1,47	1	1	500	0	1
967	0,69	1,47	1	1	500	1	1
968	0,61	1,4	1	1	500	0	1
969	0,66	1,27	1	1	500	1	1
970	0,61	1,37	1	1	500	0	1
971	0,61	1,38	1	1	500	0	1
972	0,69	1,22	1	1	500	1	1
973	0,61	1,22	1	1	500	0	1
974	0,69	1,16	1	1	500	0	1
975	0,72	1,32	0	1	500	1	1
976	0,62	1,4	1	1	500	0	1
977	0,76	1,4	1	1	500	1	1
978	0,8	1,45	1	1	500	1	1
979	0,66	1,57	1	1	500	1	1
980	0,86	1,39	1	1	500	1	1
981	0,66	1,54	1	1	500	1	1
982	0,68	1,34	1	1	500	1	1
983	0,57	1,58	1	1	500	0	1
984	0,74	1,65	1	1	500	1	1
985	0,7	1,3	1	1	500	1	1
986	0,65	1,18	0	1	500	0	1
987	0,68	1,18	1	1	500	0	1
988	0,6	1,49	1	1	500	0	1
989	0,62	1,47	1	1	500	0	1
990	0,64	1,47	1	1	500	0	1
991	0,61	1,4	1	1	500	0	1
992	0,57	1,27	1	1	500	0	1
993	0,61	1,37	1	1	500	0	1
994	0,61	1,38	1	1	500	0	1
995	0,63	1,22	1	1	500	0	1
996	0,61	1,22	1	1	500	0	1
997	0,7	1,16	1	1	500	0	1
998	0,67	1,32	0	1	500	1	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
999	0,57	1,4	1	1	500	0	1
1000	0,78	1,4	1	1	500	1	1
1001	0,63	1,45	1	1	500	0	1
1002	0,69	1,57	1	1	500	1	1
1003	0,63	1,39	1	1	500	0	1
1004	0,67	1,54	1	1	500	1	1
1005	0,67	1,34	1	1	500	1	1
1006	0,58	1,58	1	1	500	0	1
1007	0,62	1,65	1	1	500	0	1
1008	0,7	1,3	1	2	600	1	1
1009	0,68	1,18	0	2	600	0	1
1010	0,7	1,18	1	2	600	0	1
1011	0,6	1,49	1	2	600	0	1
1012	0,63	1,47	1	2	600	0	1
1013	0,69	1,47	1	2	600	1	1
1014	0,61	1,4	1	2	600	0	1
1015	0,66	1,27	1	2	600	1	1
1016	0,61	1,37	1	2	600	0	1
1017	0,61	1,38	1	2	600	0	1
1018	0,69	1,22	1	2	600	1	1
1019	0,61	1,22	1	2	600	0	1
1020	0,69	1,16	1	2	600	0	1
1021	0,72	1,32	0	2	600	1	1
1022	0,62	1,4	1	2	600	0	1
1023	0,76	1,4	1	2	600	1	1
1024	0,8	1,45	1	2	600	1	1
1025	0,66	1,57	1	2	600	1	1
1026	0,86	1,39	1	2	600	1	1
1027	0,66	1,54	1	2	600	1	1
1028	0,68	1,34	1	2	600	1	1
1029	0,57	1,58	1	2	600	0	1
1030	0,74	1,65	1	2	600	1	1
1031	0,7	1,3	1	2	600	1	1
1032	0,65	1,18	0	2	600	0	1
1033	0,68	1,18	1	2	600	0	1
1034	0,6	1,49	1	2	600	0	1
1035	0,62	1,47	1	2	600	0	1
1036	0,64	1,47	1	2	600	0	1
1037	0,61	1,4	1	2	600	0	1
1038	0,57	1,27	1	2	600	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
1039	0,61	1,37	1	2	600	0	1
1040	0,61	1,38	1	2	600	0	1
1041	0,63	1,22	1	2	600	0	1
1042	0,61	1,22	1	2	600	0	1
1043	0,7	1,16	1	2	600	0	1
1044	0,67	1,32	0	2	600	1	1
1045	0,57	1,4	1	2	600	0	1
1046	0,78	1,4	1	2	600	1	1
1047	0,63	1,45	1	2	600	0	1
1048	0,69	1,57	1	2	600	1	1
1049	0,63	1,39	1	2	600	0	1
1050	0,67	1,54	1	2	600	1	1
1051	0,67	1,34	1	2	600	1	1
1052	0,58	1,58	1	2	600	0	1
1053	0,62	1,65	1	2	600	0	1
1054	0,7	1,3	1	2	700	1	1
1055	0,68	1,18	0	2	700	0	1
1056	0,7	1,18	1	2	700	0	1
1057	0,6	1,49	1	2	700	0	1
1058	0,63	1,47	1	2	700	0	1
1059	0,69	1,47	1	2	700	1	1
1060	0,61	1,4	1	2	700	0	1
1061	0,66	1,27	1	2	700	1	1
1062	0,61	1,37	1	2	700	0	1
1063	0,61	1,38	1	2	700	0	1
1064	0,69	1,22	1	2	700	1	1
1065	0,61	1,22	1	2	700	0	1
1066	0,69	1,16	1	2	700	0	1
1067	0,72	1,32	0	2	700	1	1
1068	0,62	1,4	1	2	700	0	1
1069	0,76	1,4	1	2	700	1	1
1070	0,8	1,45	1	2	700	1	1
1071	0,66	1,57	1	2	700	1	1
1072	0,86	1,39	1	2	700	1	1
1073	0,66	1,54	1	2	700	1	1
1074	0,68	1,34	1	2	700	1	1
1075	0,57	1,58	1	2	700	0	1
1076	0,74	1,65	1	2	700	1	1
1077	0,7	1,3	1	2	700	1	1
1078	0,65	1,18	0	2	700	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
1079	0,68	1,18	1	2	700	0	1
1080	0,6	1,49	1	2	700	0	1
1081	0,62	1,47	1	2	700	0	1
1082	0,64	1,47	1	2	700	0	1
1083	0,61	1,4	1	2	700	0	1
1084	0,57	1,27	1	2	700	0	1
1085	0,61	1,37	1	2	700	0	1
1086	0,61	1,38	1	2	700	0	1
1087	0,63	1,22	1	2	700	0	1
1088	0,61	1,22	1	2	700	0	1
1089	0,7	1,16	1	2	700	0	1
1090	0,67	1,32	0	2	700	1	1
1091	0,57	1,4	1	2	700	0	1
1092	0,78	1,4	1	2	700	1	1
1093	0,63	1,45	1	2	700	0	1
1094	0,69	1,57	1	2	700	1	1
1095	0,63	1,39	1	2	700	0	1
1096	0,67	1,54	1	2	700	1	1
1097	0,67	1,34	1	2	700	1	1
1098	0,58	1,58	1	2	700	0	1
1099	0,62	1,65	1	2	700	0	1
1100	0,7	1,3	1	2	800	1	1
1101	0,68	1,18	0	2	800	0	1
1102	0,7	1,18	1	2	800	0	1
1103	0,6	1,49	1	2	800	0	1
1104	0,63	1,47	1	2	800	0	1
1105	0,69	1,47	1	2	800	1	1
1106	0,61	1,4	1	2	800	0	1
1107	0,66	1,27	1	2	800	1	1
1108	0,61	1,37	1	2	800	0	1
1109	0,61	1,38	1	2	800	0	1
1110	0,69	1,22	1	2	800	1	1
1111	0,61	1,22	1	2	800	0	1
1112	0,69	1,16	1	2	800	0	1
1113	0,72	1,32	0	2	800	1	1
1114	0,62	1,4	1	2	800	0	1
1115	0,76	1,4	1	2	800	1	1
1116	0,8	1,45	1	2	800	1	1
1117	0,66	1,57	1	2	800	1	1
1118	0,86	1,39	1	2	800	1	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
1119	0,66	1,54	1	2	800	1	1
1120	0,68	1,34	1	2	800	1	1
1121	0,57	1,58	1	2	800	0	1
1122	0,74	1,65	1	2	800	1	1
1123	0,7	1,3	1	2	800	1	1
1124	0,65	1,18	0	2	800	0	1
1125	0,68	1,18	1	2	800	0	1
1126	0,6	1,49	1	2	800	0	1
1127	0,62	1,47	1	2	800	0	1
1128	0,64	1,47	1	2	800	0	1
1129	0,61	1,4	1	2	800	0	1
1130	0,57	1,27	1	2	800	0	1
1131	0,61	1,37	1	2	800	0	1
1132	0,61	1,38	1	2	800	0	1
1133	0,63	1,22	1	2	800	0	1
1134	0,61	1,22	1	2	800	0	1
1135	0,7	1,16	1	2	800	0	1
1136	0,67	1,32	0	2	800	1	1
1137	0,57	1,4	1	2	800	0	1
1138	0,78	1,4	1	2	800	1	1
1139	0,63	1,45	1	2	800	0	1
1140	0,69	1,57	1	2	800	1	1
1141	0,63	1,39	1	2	800	0	1
1142	0,67	1,54	1	2	800	1	1
1143	0,67	1,34	1	2	800	1	1
1144	0,58	1,58	1	2	800	0	1
1145	0,62	1,65	1	2	800	0	1
1146	0,7	1,3	1	2	900	1	1
1147	0,68	1,18	0	2	900	0	1
1148	0,7	1,18	1	2	900	0	1
1149	0,6	1,49	1	2	900	0	1
1150	0,63	1,47	1	2	900	0	1
1151	0,69	1,47	1	2	900	1	1
1152	0,61	1,4	1	2	900	0	1
1153	0,66	1,27	1	2	900	1	1
1154	0,61	1,37	1	2	900	0	1
1155	0,61	1,38	1	2	900	0	1
1156	0,69	1,22	1	2	900	1	1
1157	0,61	1,22	1	2	900	0	1
1158	0,69	1,16	1	2	900	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
1159	0,72	1,32	0	2	900	1	1
1160	0,62	1,4	1	2	900	0	1
1161	0,76	1,4	1	2	900	1	1
1162	0,8	1,45	1	2	900	1	1
1163	0,66	1,57	1	2	900	1	1
1164	0,86	1,39	1	2	900	1	1
1165	0,66	1,54	1	2	900	1	1
1166	0,68	1,34	1	2	900	1	1
1167	0,57	1,58	1	2	900	0	1
1168	0,74	1,65	1	2	900	1	1
1169	0,7	1,3	1	2	900	1	1
1170	0,65	1,18	0	2	900	0	1
1171	0,68	1,18	1	2	900	0	1
1172	0,6	1,49	1	2	900	0	1
1173	0,62	1,47	1	2	900	0	1
1174	0,64	1,47	1	2	900	0	1
1175	0,61	1,4	1	2	900	0	1
1176	0,57	1,27	1	2	900	0	1
1177	0,61	1,37	1	2	900	0	1
1178	0,61	1,38	1	2	900	0	1
1179	0,63	1,22	1	2	900	0	1
1180	0,61	1,22	1	2	900	0	1
1181	0,7	1,16	1	2	900	0	1
1182	0,67	1,32	0	2	900	1	1
1183	0,57	1,4	1	2	900	0	1
1184	0,78	1,4	1	2	900	1	1
1185	0,63	1,45	1	2	900	0	1
1186	0,69	1,57	1	2	900	1	1
1187	0,63	1,39	1	2	900	0	1
1188	0,67	1,54	1	2	900	1	1
1189	0,67	1,34	1	2	900	1	1
1190	0,58	1,58	1	2	900	0	1
1191	0,62	1,65	1	2	900	0	1
1192	0,7	1,3	1	3	1000	1	1
1193	0,68	1,18	0	3	1000	0	1
1194	0,7	1,18	1	3	1000	0	1
1195	0,6	1,49	1	3	1000	0	1
1196	0,63	1,47	1	3	1000	0	1
1197	0,69	1,47	1	3	1000	1	1
1198	0,61	1,4	1	3	1000	0	1

ID	Coefficiente de Atrito	Prof. de Macrotextura	Remoção do acúmulo de borracha	Terço da pista	Localização na Pista (m)	Classificação da Segurança Operacional	Revestimento
1199	0,66	1,27	1	3	1000	1	1
1200	0,61	1,37	1	3	1000	0	1
1201	0,61	1,38	1	3	1000	0	1
1202	0,69	1,22	1	3	1000	1	1
1203	0,61	1,22	1	3	1000	0	1
1204	0,69	1,16	1	3	1000	0	1
1205	0,72	1,32	0	3	1000	1	1
1206	0,62	1,4	1	3	1000	0	1
1207	0,76	1,4	1	3	1000	1	1
1208	0,8	1,45	1	3	1000	1	1
1209	0,66	1,57	1	3	1000	1	1
1210	0,86	1,39	1	3	1000	1	1
1211	0,66	1,54	1	3	1000	1	1
1212	0,68	1,34	1	3	1000	1	1
1213	0,57	1,58	1	3	1000	0	1
1214	0,74	1,65	1	3	1000	1	1
1215	0,7	1,3	1	3	1000	1	1
1216	0,65	1,18	0	3	1000	0	1
1217	0,68	1,18	1	3	1000	0	1
1218	0,6	1,49	1	3	1000	0	1
1219	0,62	1,47	1	3	1000	0	1
1220	0,64	1,47	1	3	1000	0	1
1221	0,61	1,4	1	3	1000	0	1
1222	0,57	1,27	1	3	1000	0	1
1223	0,61	1,37	1	3	1000	0	1
1224	0,61	1,38	1	3	1000	0	1
1225	0,63	1,22	1	3	1000	0	1
1226	0,61	1,22	1	3	1000	0	1
1227	0,7	1,16	1	3	1000	0	1
1228	0,67	1,32	0	3	1000	1	1
1229	0,57	1,4	1	3	1000	0	1
1230	0,78	1,4	1	3	1000	1	1
1231	0,63	1,45	1	3	1000	0	1
1232	0,69	1,57	1	3	1000	1	1
1233	0,63	1,39	1	3	1000	0	1
1234	0,67	1,54	1	3	1000	1	1
1235	0,67	1,34	1	3	1000	1	1
1236	0,58	1,58	1	3	1000	0	1
1237	0,62	1,65	1	3	1000	0	1