



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

TÚLIO RODRIGUES RIBEIRO

DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE COEFICIENTE DE
ATRITO EM PISTAS DE POUSO E DECOLAGEM DOS AEROPORTOS
INTERNACIONAIS DE FORTALEZA E BRASÍLIA COM REDES NEURAIAS
ARTIFICIAIS

FORTALEZA

2022

TÚLIO RODRIGUES RIBEIRO

DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE COEFICIENTE DE ATRITO
EM PISTAS DE POUSO E DECOLAGEM DOS AEROPORTOS INTERNACIONAIS DE
FORTALEZA E BRASÍLIA COM REDES NEURAS ARTIFICIAIS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes, do Centro de Tecnologia, 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

2022

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

R372d Ribeiro, Túlio Rodrigues.
Desenvolvimento de modelos de previsão de coeficiente de atrito em pista de pouso e decolagem dos aeroportos internacionais de Fortaleza e Brasília com redes neurais artificiais / Túlio Rodrigues Ribeiro. – 2022.
83 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Fortaleza, 2022.
Orientação: Prof. Dr. Francisco Heber Lacerda de Oliveira .

1. Pavimentos. 2. Aeroportos. 3. Segurança. 4. Coeficiente de atrito. 5. Redes neurais artificiais. I. Título.

CDD 388

TÚLIO RODRIGUES RIBEIRO

DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE COEFICIENTE DE ATRITO
EM PISTA DE POUSO E DECOLAGEM DOS AEROPORTOS INTERNACIONAIS DE
FORTALEZA E BRASÍLIA COM REDES NEURAIIS ARTIFICIAIS

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.

Aprovada em: __/__/____.

BANCA EXAMINADORA

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

Prof^a. Dra. Suelly Helena de Araújo Barroso
Universidade Federal do Ceará (UFC)

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

AGRADECIMENTOS

Agradeço, primeiramente, a Deus, por permitir a realização dessa conquista.

Ao amigo e querido professor, Dr. Francisco Heber Lacerda de Oliveira, pela orientação e pelo direcionamento.

À minha querida esposa, pelo apoio incondicional, principalmente nos momentos de insegurança e ansiedade.

À minha família, pelo apoio e incentivo durante essa jornada.

Aos colegas Pedro Henrique e Breno Quariguasi, pelo apoio e auxílio no desenvolvimento desta pesquisa.

RESUMO

As operações de pouso e decolagem representam as fases mais críticas de um voo, nas quais diversos fatores influenciam, tais como a habilidade do piloto, as condições climáticas e de aderência pneu-pavimento. Nesse contexto, os parâmetros de textura dos revestimentos dos pavimentos aeroportuários, representados pelo coeficiente de atrito e pela macrotextura, são critérios objetivos para a segurança operacional no quesito aderência pneu-pavimento. Estes parâmetros têm interferência de diferentes aspectos, nomeadamente a idade do revestimento do pavimento, a umidade relativa do ar, a temperatura, o acúmulo de borracha nas pistas de pouso e decolagem oriundo dos pneus das aeronaves, a presença de ranhuras transversais, dentre outros. Em vista disso, o presente estudo objetiva desenvolver modelos de previsão para o coeficiente de atrito medido a 3 e a 6 metros do eixo de pistas de pouso e decolagem pelos equipamentos *GripTester*, *Skiddometer* e *Mu-meter*, em diferentes localizações e condições da superfície do revestimento, com a finalidade de auxiliar o operador de aeródromo quanto à garantia da segurança operacional. Além disso, no estudo pretende-se verificar a influência do *grooving* no desempenho do coeficiente de atrito. Isso posto, utilizou-se a técnica de Redes Neurais Artificiais para elaboração de modelos de previsão de coeficiente de atrito obtido por meio de relatórios das medições em campo, as quais foram realizadas nos aeroportos internacionais de Fortaleza e de Brasília, entre os anos de 2012 e 2018. Além desses dados, também foram aplicadas informações acerca das condições climáticas e da quantidade de operações de pouso e decolagem obtidas pelas empresas operadoras dos aeródromos e pela Agência Nacional de Aviação Civil (ANAC). Dessa forma, este estudo produziu modelos eficientes para prever o coeficiente de atrito, além de proporcionar uma contribuição para os modelos existentes. Os modelos desenvolvidos apresentaram resultados satisfatórios consoante a complexidade do problema, demonstrando que, embora necessitem de aprimoramentos futuros, eles podem contribuir com a segurança das operações de pouso e decolagem e com o gerenciamento dos pavimentos aeroportuários pelos operadores dos aeródromos brasileiros, bem como auxiliar os serviços de fiscalização por parte da ANAC.

Palavras-chave: pavimentos; aeroportos; segurança; coeficiente de atrito; redes neurais artificiais.

ABSTRACT

Landing and take-off operations represent the most critical phases of a flight, in which several factors influence, such as the pilot's skill, weather conditions and tire-pavement adherence. In this context, the texture parameters of the coatings on airport pavements, represented by the coefficient of friction and the macrotexture, are objective criteria for operational safety in terms of tire-pavement adherence. These parameters are influenced by different aspects, such as the age of the pavement covering, the relative humidity of the air, the temperature, the accumulation of rubber on the runways and takeoff from aircraft tires, and the presence of transverse grooves, among others. In view of this, the general objective of this research is to develop prediction models for the coefficient of friction measured at 3 and 6 meters from the axis of landing and takeoff runways by GripTester, Skiddometer and Mu-meter equipment in different locations and coating surface conditions in order to assist the aerodrome operator in ensuring operational safety. In addition, this research also aimed to verify the influence of grooving on the performance of the coefficient of friction. That said, the technique of Artificial Neural Networks was used to develop predictive models of the coefficient of friction obtained through reports of measurements in the field, which were carried out at the international airports of Fortaleza and Brasília, between the years of 2012 and 2018. In addition to these data, information about weather conditions and the number of landing and takeoff operations obtained by the companies operating the aerodromes and by the National Civil Aviation Agency (ANAC) was also applied. Thus, this study produced efficient models to predict the coefficient of friction, in addition to providing a contribution to existing models. The developed models showed satisfactory results given the complexity of the problem, demonstrating that, despite the need for future improvements, they can contribute to the safety of landing and takeoff operations and to the management of airport pavements by operators of Brazilian aerodromes, as well as helping inspection services by ANAC.

Keywords: pavements; airports; safety; coefficient of friction; artificial neural networks.

LISTA DE FIGURAS

Figura 1 – Forças de desaceleração típicas durante o pouso operando em <i>Autobrake</i> Baixo ..	22
Figura 2 – Efeito dos dispositivos de frenagem na energia e na distância de parada.....	22
Figura 3 – Mecanismos do atrito ao deslizamento	23
Figura 4 – Influência da adesão, histerese e desgaste no atrito ao de deslizamento	24
Figura 5 – Pneu estático submetido a uma carga vertical.....	25
Figura 6 – Pneu dinâmico submetido a uma carga vertical	25
Figura 7 – Coeficiente de atrito ao rolamento em relação à velocidade e ao tipo de pneu	27
Figura 8 – Coeficiente de atrito em relação à presença de água na pista	27
Figura 9 – Equipamentos portáteis	29
Figura 10 – Equipamentos de rodas oblíquas.....	30
Figura 11 – Equipamentos de roda parcialmente bloqueada	31
Figura 12 – CAL medido em três tipos diferentes de revestimentos asfálticos e diferentes velocidades.....	31
Figura 13 – Variação da textura com o coeficiente de atrito em diferentes tipos de misturas asfálticas.....	32
Figura 14 – Variação do atrito ao longo do tempo e do tráfego em 3 tipos de revestimentos..	33
Figura 15 – Valores do BPN em 11 tipos de pavimento.....	34
Figura 16 – Micro e macrotextura na superfície de um revestimento asfáltico	35
Figura 17 – Combinações de macro e microtextura	35
Figura 18 – Grooving executado em PPD	37
Figura 19 – Variação do atrito conforme a idade do pavimento.....	38
Figura 20 – Redução do atrito em razão do aumento do tráfego.....	38
Figura 21 – Variação do coeficiente de atrito na extensão da PPD	39
Figura 22 – Ação do acúmulo de borracha no atrito.....	40
Figura 23 – Alteração sazonal do atrito	40
Figura 24 – Variação do coeficiente de atrito de acordo com a temperatura.....	41
Figura 25 – Modelo não linear de um neurônio	45
Figura 26 – Diagrama de uma rede MLP	48
Figura 27 – Diagrama do procedimento forward de uma rede MLP.....	48
Figura 28 – Diagrama do procedimento backward de uma rede MLP.....	49
Figura 29 – Principais funções de ativação	49
Figura 30 – Diagrama de viés e variância	51

Figura 31 – Exemplos de modelos	51
Figura 32 – Equilíbrio ideal de um modelo	52
Figura 33 – Validação cruzada com $k = 5$	54
Figura 34 – Ilustração da RNA com as variáveis utilizadas	65
Figura 35 – Gráfico de dispersão do teste dos modelos AT3 e AT6	67
Figura 36 – Gráficos de dispersão do coeficiente de atrito de acordo com a distância de medição na PPD sem grooving	72
Figura 37 – Gráficos de dispersão do coeficiente de atrito de acordo com a distância de medição na PPD com grooving	72

LISTA DE TABELAS

Tabela 1 – Classificação da textura	34
Tabela 2 – Principais funções de ativação	49
Tabela 3 – Características físicas e operacionais do SBFZ e SBBR	57
Tabela 4 – Descrição e representação das variáveis categóricas	60
Tabela 5 – Matriz de correlação entre as variáveis.....	63
Tabela 6 – Datas dos relatórios de medição utilizados no modelo	64
Tabela 7 – Estatística descritiva das variáveis selecionadas para o modelo.....	65
Tabela 8 – Arquitetura dos modelos AT3 e AT6	66
Tabela 9 – Resultados dos modelos AT3 e AT6	67
Tabela 10 – Resultados dos Modelo AT3 com alteração das variáveis	69
Tabela 11 – Resultados dos Modelo AT6 com alteração das variáveis	70
Tabela 12 – Estatística descritiva do coeficiente de atrito em relação ao grooving	71

LISTA DE QUADROS

Quadro 1 – Pesquisas acerca da influência da temperatura no atrito	41
Quadro 2 – Variáveis removidas nos Modelos AT3 e AT6	68

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizagem de Máquina
ANAC	Agência Nacional da Aviação Civil
BPN	<i>British Pendulum Number</i>
CA	Concreto Asfáltico
CAL	Coeficiente de atrito longitudinal
CAT	Coeficiente de atrito transversal
Cenipa	Centro de Investigação e Prevenção de Acidentes Aeronáuticos
CPA	Camada Porosa de Atrito
DFT	<i>Dynamic Friction Tester</i>
EQM	Erro Quadrático Médio
FAA	<i>Federal Aviation Administration</i>
ICAO	<i>International Civil Aviation Organization</i>
ICEA	Instituto de Controle do Espaço Aéreo
Infraero	Empresa Brasileira de Infraestrutura Aeroportuária
LTTP	<i>Long-Term Pavement Performance</i>
LM	<i>Levenberg-Marquardt</i>
LTU	<i>Linear Threshold Unit</i>
MAE	<i>Mean Absolute Error</i>
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
mms	<i>MinMaxScaler</i>
MSE	<i>Mean Squared Error</i>
MTPA	Ministério dos Transportes, Portos e Aviação Civil
M&R	Manutenção e Reabilitação
NOTAM	<i>Notice to Airman</i>
PDF	<i>Portable Document Format</i>
PPD	Pista de Pouso e Decolagem
REQM	Raiz do Erro Quadrático Médio
RMSE	<i>Root Mean Squared Error</i>
RNA	Redes Neurais Artificiais
SAC	Secretaria da Aviação Civil

SBFZ	Aeroporto Internacional de Fortaleza
SBBR	Aeroporto Internacional de Brasília
SGP	Sistema de Gerência de Pavimentos
SGPA	Sistema de Gerência de Pavimentos Aeroportuários
SAI	Superintendência de Infraestrutura Aeroportuária
SMA	<i>Stone Matrix Asphalt</i>
Std	<i>Standard Scaler</i>

LISTA DE SÍMBOLOS

μ_s	Coeficiente de atrito estático
μ_k	Coeficiente de atrito dinâmico
f_k	Força de atrito dinâmico
f_s	Força de atrito estático
F_N	Força normal
F_D	Força de atrito por deslizamento real
F_A	Força de atrito devido à adesão
F_H	Força de atrito devido à histerese
F_W	Força de atrito devido ao desgaste
F_R	Resistência ao rolamento
e	Distância horizontal entre o eixo da roda e o centro de pressão da área de contato
r	Raio do pneu carregado
μ_R	Coeficiente de atrito ao rolamento
HS	Profundidade da textura
V	volume de areia
D_m	Diâmetro médio da mancha de areia
Tanh	Tangente hiperbólica
ReLU	Linear retificada
z	Valor normalizado
$\bar{x}$	Média das amostras
s	Desvio padrão das amostras
R	Coeficiente de Correlação
R^2	Coeficiente de Determinação
MSE	<i>Mean Squared Error</i>
MAE	<i>Mean Absolute Error</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Considerações iniciais	16
1.2	Justificativa	17
1.3	Problema de pesquisa	18
1.4	Objetivos.....	19
1.5	Estrutura do trabalho	19
2	REVISÃO DA LITERATURA.....	20
2.1	Aderência Pneu-Pavimento	20
2.1.1	<i>O Coeficiente de Atrito na Segurança das Operações</i>	20
2.1.2	<i>Atrito Decorrente do Deslizamento.....</i>	23
2.1.3	<i>Resistência ao Rolamento</i>	24
2.1.4	<i>Hidroplanagem.....</i>	27
2.2	Equipamentos para aferição do coeficiente de atrito	29
2.3	Fatores que influenciam o coeficiente de atrito	31
2.3.1	<i>Tipo de pavimento.....</i>	31
2.3.2	<i>Textura superficial.....</i>	34
2.3.3	<i>Tráfego e tempo</i>	37
2.3.4	<i>Remoção de acúmulo de borracha.....</i>	38
2.3.5	<i>Condições climáticas</i>	40
2.4	Inteligência Computacional (IC).....	42
2.5	Redes Neurais Artificiais (RNA)	44
2.5.1	<i>Perceptron Multicamadas (MLP) e o algoritmo de retropropagação do erro</i>	47
2.5.2	<i>Funções de ativação</i>	49
2.5.3	<i>Hiperparâmetros.....</i>	50
2.5.4	<i>Validação cruzada.....</i>	53
2.5.5	<i>Aplicação das Redes Neurais Artificiais na Infraestrutura de Transportes</i>	54
3	MÉTODO DE PESQUISA	57
3.1	Seleção dos aeródromos	57
3.2	Escolha das variáveis e coleta de dados	57
3.3	Processamento e tratamento de dados.....	60
3.4	Desenvolvimento do modelo	61
4	ANÁLISE E DISCUSSÃO DOS RESULTADOS	63

4.1	Determinação das variáveis.....	63
4.2	Resultados dos modelos AT3 e AT6.....	66
4.3	Resultados dos modelos AT3 e AT6 com alteração das variáveis.....	68
4.4	Influência do Grooving.....	70
5	CONCLUSÕES E RECOMENDAÇÕES	73
5.1	Principais conclusões.....	73
5.2	Principais limitações.....	74
5.3	Recomendações para trabalhos futuros	75
	REFERÊNCIAS	76

1 INTRODUÇÃO

Neste capítulo, apresenta-se uma síntese do desenvolvimento da aviação civil no Brasil, nos últimos quinze anos, bem como a relevância dos parâmetros de aderência pneu-pavimento na segurança das operações de pouso e decolagem. Descreve-se, também, a justificativa e o problema que fomentou o estudo, a descrição dos objetivos (geral e específicos), bem como a estrutura expositiva do texto.

1.1 Considerações iniciais

O desenvolvimento socioeconômico de diversas regiões em torno do mundo tem sido impulsionado pela indústria da aviação civil. Essa indústria possui números consideráveis e uma notável tendência de crescimento quanto à sua contribuição às atividades econômicas, à quantidade de empregos gerados e ao total de pessoas e cargas transportadas.

Segundo SAC/PR (2020), o fluxo de passageiros nos aeroportos brasileiros e a movimentação das aeronaves referentes aos voos regulares e não regulares obtiveram, no período de 2009 a 2019, um crescimento médio anual de 5,44% e 1,26%, respectivamente. Estima-se que essas porcentagens se mantenham em 4,60% e 3,51%, respectivamente, até 2038 (MTPA, 2018). Ressalta-se que esses números não consideraram o efeito da pandemia do novo coronavírus sobre o tráfego aéreo.

Desse modo, as pistas de pouso e decolagem (PPD) passam a ser mais solicitadas à medida que o transporte aéreo cresce. O aumento do fluxo de cargas, bem como o surgimento de novas operações com aeronaves maiores e mais pesadas contribuem para o desgaste precoce dos pavimentos aeroportuários. Esse aumento pode implicar uma maior quantidade de acidentes e incidentes aeronáuticos, os quais possuem maior ocorrência e risco de segurança durante as operações em solo (ICAO, 2019)

Considerando o contexto nacional e internacional, cerca de 50% dos acidentes e incidentes aéreos, registrados na última década, ocorreram durante as operações de pouso e decolagem. Esses tipos de operações dependem, principalmente, das condições meteorológicas, da habilidade dos pilotos e da textura superficial dos pavimentos (AIRBUS, 2020; BOEING, 2021; CENIPA, 2020; ICAO, 2019).

Shahin (2005) afirma que a relevância da conservação da textura dos pavimentos aeroportuários é óbvia, visto que a sua má condição pode contribuir para a ocorrência de um incidente ou acidente aéreo. Isso se deve, em muitos casos, a deficiências no revestimento,

principalmente no que se refere aos parâmetros de aderência pneu-pavimento (o coeficiente de atrito e a macrotextura), os quais são afetados, também, pelo acúmulo de borracha proveniente dos pneus das aeronaves.

Além das condições de aderência, uma adversidade climática pode resultar na contaminação da PPD pela água, o que pode causar um impacto negativo na frenagem, na aceleração e na estabilidade das aeronaves. A presença de água na superfície do pavimento é atribuída, principalmente, às suas características de superfície e de drenagem (ICAO, 2019).

Nesse contexto, entende-se que a avaliação dos parâmetros de aderência pneu-pavimento é fundamental para assegurar a segurança das operações de pouso e decolagem. O número de medições desses parâmetros é diretamente proporcional à quantidade de operações na PPD (ANAC, 2019). Em razão disso, a PPD pode ser fechada ou parcialmente interditada, restringindo as operações no aeroporto, caso as condições de aderência não atendam aos requisitos técnicos exigidos pela ANAC. Dessa forma, justifica-se a aplicação de ferramentas dotadas de modelos matemáticos capazes de prever as condições de aderência do revestimento das PPD.

1.2 Justificativa

Os acidentes e incidentes aéreos estão relacionados a diversos fatores que envolvem as condições climáticas, o estado da superfície dos pavimentos e a capacidade dos pilotos na condução da aeronave, sobretudo durante as operações de pouso e decolagem. Em razão disso, ressalta-se a relevância do monitoramento e da avaliação periódica dos parâmetros de aderência pneu-pavimento, pois eles são fundamentais à segurança operacional nas PPD. Esses parâmetros também auxiliam na tomada de decisão do operador do aeródromo quanto às estratégias de manutenção e reabilitação (M&R) e facilitam a fiscalização por parte da autoridade de aviação civil, no caso do Brasil, a Agência Nacional de Aviação Civil (ANAC).

A FAA (2014) indica que as estratégias de M&R, em pavimentos aeroportuários adotadas pelos operadores de aeródromo, têm sido fundamentadas na necessidade imediata ou de forma empírica. Contudo, esse método não é eficaz, pois não possibilita uma análise lógica e racional da estratégia correta, ocasionando uma ineficiência na aplicação dos recursos disponíveis para M&R.

Em virtude disso, a ANAC (2019) determina que o operador do aeródromo deve monitorar e avaliar o estado das PPD, utilizando um Sistema de Gerenciamento de Pavimentos Aeroportuários (SGPA). Esse sistema, segundo FAA (2014), visa estabelecer uma sistemática

para coletar e armazenar dados sobre a estrutura e a condição do pavimento existente, bem como avaliar a sua condição de forma objetiva e repetitiva. Dentre os diversos parâmetros que devem ser monitorados, no que se refere à condição superficial dos pavimentos aeroportuários, destacam-se o coeficiente de atrito, a macrotextura e o acúmulo de borracha, principalmente quando existem ranhuras transversais (*grooving*) nas PPDs.

Wells e Young (2019) recomendam a execução do *grooving* para ampliar a capacidade de drenagem da água presente nos pavimentos aeroportuários e aumentar o coeficiente de atrito, isto é, melhorar a aderência pneu-pavimento. Contudo, as áreas com a presença do dispositivo tendem a acumular mais borracha proveniente dos pneus das aeronaves, de forma a reduzir o coeficiente de atrito com os pousos sucessivos, sendo necessárias remoções periódicas do resíduo (CHEN *et al.*, 2008).

Nesse contexto, Fwa, Chan e Lim (1997), Yao *et al.*, (2019) e Quariguasi, Oliveira e Reis (2021) têm utilizado modelos de previsão por meio de Redes Neurais Artificiais (RNA) para estimar os parâmetros de aderência pneu-pavimento e, conseqüentemente, indicar a necessidade de intervenção no pavimento. Esse tipo de ferramenta contribui para a tomada de decisão do operador de aeródromo, além de colaborar para um SGPA mais efetivo.

Seguindo o entendimento, Géron (2017) evidencia que a Aprendizagem de Máquina (*Machine Learning*) abrange ferramentas como as RNA e que pode ser aplicada em diversos cenários, tais como situações complexas nas quais os métodos tradicionais não apresentam soluções eficazes, cenários inconstantes com alterações em uma certa frequência e circunstâncias complexas com grandes quantidades de dados.

Assim, as RNA constituem em uma ferramenta com um potencial para serem utilizadas no SGPA por meio dos dados disponíveis das PPD. Isso posto, essa técnica foi aplicada neste trabalho a fim de prever o coeficiente de atrito nas PPD dos aeroportos internacionais de Fortaleza/CE e de Brasília/DF.

1.3 Problema de pesquisa

Encontram-se na literatura modelos de previsão que usam RNA para pavimentos rodoviários e aeroportuários (BOSURGI; TRIFIRÒ, 2005; DOMITROVIĆ *et al.*, 2018; FLINTSCH; ZANIEWSKI; DELTON, 1996; FLINTSCH; KHALEGHIAN, 2019; FWA; CHAN; LIM, 1997; HOSSAIN; GOPISETTI; MIAH, 2019; THUBE, 2012; NAJAFI; YAO *et al.*, 2019; QUARIGUASI; OLIVEIRA; REIS, 2021). Contudo, as pesquisas que abordam as PPD, geralmente, limitam a análise apenas ao coeficiente de atrito medido a 3 m do eixo da

PPD e consideram apenas um tipo de equipamento na medição em PPD com revestimento de concreto asfáltico.

Dessa forma, percebe-se uma lacuna referente a um modelo que utilize dados medidos, também, a 6 m do eixo da PPD, em ambos os lados, direita e esquerda, visto que se observa a utilização de aeronaves cada vez maiores e que, por consequência, atuam nessa região. Além disso, a utilização de dados medidos por diferentes equipamentos proporciona uma contribuição mais abrangente para os modelos existentes.

1.4 Objetivos

O objetivo geral deste estudo é desenvolver modelos de previsão de coeficiente de atrito medido por diferentes equipamentos, localizações e condições da superfície do revestimento em pistas de pouso e decolagem dos aeroportos internacionais de Fortaleza/CE e Brasília/BR utilizando Redes Neurais Artificiais (RNA). Quanto aos objetivos específicos, estes consistem em:

- a) Definir as variáveis utilizadas nos modelos de previsão de coeficiente de atrito;
- b) Analisar a viabilidade técnica de um modelo de RNA para previsão do coeficiente de atrito medido pelos equipamentos *GripTester*, *Skiddometer* e *Mu-meter*;
- c) Desenvolver modelos de previsão do coeficiente de atrito medido a 3m e a 6m de distância do eixo da PPD, em ambos os lados;
- d) Avaliar a acurácia dos modelos desenvolvidos com alteração das variáveis;
- e) Verificar a influência do *grooving* no desempenho do coeficiente de atrito.

1.5 Estrutura do trabalho

Este trabalho contém cinco capítulos. Além deste capítulo introdutório, no capítulo 2 consta uma revisão da literatura sobre o coeficiente de atrito e os fatores que o influenciam, além de modelos de previsão baseados em *Machine Learning* via RNA. No capítulo estão as variáveis, a escolha dos aeródromos, a coleta de dados, o processamento e o tratamento dos dados e o desenvolvimento do modelo. No capítulo 4 expõe-se a determinação das variáveis, as análises de estruturas testadas no modelo, a correlação e a sensibilidade das variáveis utilizadas e, por fim, os resultados dos modelos de previsão, bem como a análise da sua taxa de acerto e de seus erros. O capítulo 5 apresenta a conclusão e as proposições para trabalhos futuros.

2 REVISÃO DA LITERATURA

O presente capítulo objetiva expor uma breve revisão de obras que abordam os parâmetros de aderência pneu-pavimento com foco em coeficiente de atrito e a influência deste nas pistas de pouso e decolagem (PPD). Em seguida, apresentam-se os equipamentos utilizados para aferição do coeficiente de atrito, assim como as variáveis que o afetam. Por fim, são apresentados breves conceitos sobre Redes Neurais Artificiais (RNA) e sua aplicação na Infraestrutura de Transportes.

2.1 Aderência Pneu-Pavimento

Segundo Rodrigues Filho (2006), as forças de atrito existentes entre o pneumático e o pavimento são essenciais para garantir a segurança das aeronaves, principalmente em pistas de pouso e decolagem curtas, cuja extensão disponível é aproximada à distância necessária para a frenagem. Dessa forma, essas forças são o principal recurso para a parada da aeronave após o procedimento de pouso ou decolagem interrompida, pois a reversão dos motores é considerada apenas um complemento, embora possa contribuir de forma significativa na ação de frenagem em pistas com pouco atrito.

A ANAC (2019) considera que a aderência de uma PPD proporciona resistência à derrapagem e o controle direcional às aeronaves durante as operações. Essa propriedade física é representada pela força de contato entre os pneus da aeronave e a superfície da camada de rolamento do pavimento. Tais condições de aderência são fornecidas, majoritariamente, pelo coeficiente de atrito e pela textura superficial.

A segurança das operações de pouso e decolagem depende, além de outros fatores, da aderência fornecida pelo contato pneu-pavimento. Tal propriedade é fortemente influenciada pela qualidade da área de contato, sendo que a presença ou não de contaminantes é um fator importante a se considerar, como a água, por exemplo. Portanto, uma boa interação entre o pneumático e o pavimento é obtida por meio da macrotextura e de uma drenagem apropriada, dado que uma pista com acúmulo de água ou outro contaminante favorece à ocorrência de hidroplanagem (ou aquaplanagem), fenômeno esse em que ocorre perda de tração, ocasionando frenagem ineficiente, possibilitando a perda do controle direcional da aeronave e a ocorrência de acidentes (SILVA, 2008).

2.1.1 O Coeficiente de Atrito na Segurança das Operações

Segundo Wells e Young (2019), o atrito existente na superfície das PPD possibilita a aceleração das aeronaves durante a operação de decolagem, bem como a desaceleração de forma segura durante o pouso. Um coeficiente de atrito deficiente pode proporcionar a perda de controle da aeronave na pista através de ocorrências indesejáveis, tais como derrapagem, deslizamento ou aquaplanagem.

De acordo com Fonseca (1990), o coeficiente de atrito é representado pelo efeito da macrotextura associado à microtextura. A ação da textura superficial sobre o coeficiente de atrito das pistas de pouso e decolagem está sujeita à velocidade desenvolvida pelas aeronaves e à eficácia da drenagem do pavimento (KAZDA; CAVES, 2007).

Dessa forma, entende-se que a condição de atrito da PPD é um dos principais fatores a ser considerado quanto à segurança das operações de pouso e decolagem, uma vez que as constantes de atrito estático e cinético podem revelar bastante informações sobre as características das superfícies. Tal propriedade possibilita que a aeronave realize o procedimento de decolagem, no qual ela sai da inércia e alcança a velocidade necessária para levantar voo, assim como no procedimento de pouso, instante em que a aeronave se aproxima a uma determinada velocidade e precisa parar com conforto e segurança (SANTOS, 2004).

Rodrigues Filho (2006) afirma que para operações em PPD envolvendo aeronaves a jato, o coeficiente de atrito deve ser analisado com mais atenção, visto que esses equipamentos desenvolvem velocidades de pouso e decolagem elevadas, ratificando a importância do atrito pneu-pavimento. Na desaceleração da aeronave ao tocar na pista até a velocidade de taxiamento, o piloto dispõe de três forças, quais sejam:


- a) o arrasto aerodinâmico, produzido por superfícies especialmente projetadas;
- b) o reverso, produzido pela inversão do empuxo dos motores;
- c) o atrito gerado entre os pneus da aeronave e o pavimento, quando da aplicação dos freios de roda.

Um estudo realizado pela FSF ALAR (2000) verificou que 11 acidentes e incidentes graves ocorridos durante as aproximações ou pousos entre 1984 e 1997 aconteceram em pista molhada, isto é, com a presença de contaminante, reduzindo o atrito pneu-pavimento. Este estudo analisou a influência do atrito para uma condição de pouso automático utilizando o sistema *Autobrake*, o qual integra as aeronaves modernas a jato e, quando ativado pelo piloto, age automaticamente no comando dos freios de roda, momento em que os pneus da aeronave tocam o pavimento, conforme ilustrado nas Figuras 1 e 2.

A força proveniente da resistência ao rolamento, ou seja, do atrito entre o pneumático e a superfície do pavimento, é o mais importante fator de frenagem da aeronave até

a velocidade aproximada de 130 km/h (70 nós), sendo praticamente o único fator para velocidades inferiores à 74 km/h (40 nós). Em contrapartida, em se tratando de velocidades superiores à 70 nós, o principal elemento é o reverso dos motores aliado à resistência aerodinâmica, conforme apresentado na Figura 1.


Figura 1 – Forças de desaceleração típicas durante o pouso operando em *Autobrake* Baixo



Fonte: Adaptada de FSF ALAR (2000).

A energia dissipada pelo atrito representa aproximadamente 45% da energia total necessária para a parada da aeronave, considerando o cenário de desaceleração e parada na menor extensão. Já a influência do reverso das turbinas e do arrasto aerodinâmico representa, respectivamente, em torno de 20% e 35% da energia total dissipada até a parada total da aeronave, conforme a Figura 2.

Figura 2 – Efeito dos dispositivos de frenagem na energia e na distância de parada




Fonte: Adaptada de FSF ALAR (2000).

2.1.2 Atrito decorrente do deslizamento

Segundo Andresen e Wambold (1999), o atrito decorrente do deslizamento real deve ser interpretado como aquele que é realizado em razão do movimento correspondente entre a banda de rodagem do pneumático e a pista. Dessa forma, a referida força de atrito pode ser representada como a soma de três componentes, quais sejam, adesão, histerese e desgaste, conforme apresentado na Figura 3.

Figura 3 – Mecanismos do atrito ao deslizamento



Fonte: Rodrigues Filho (2006).

De acordo com Rodrigues Filho (2006), a força de atrito por ação da adesão é proporcional à área de contato efetiva entre o pneu e a superfície do pavimento. Na interação entre essas duas superfícies surgem forças aderentes entre as moléculas dos dois materiais, cuja intensidade depende do tempo de contato, e, logo, da velocidade de deslizamento, além da dimensão da superfície da interface, da composição da borracha e da microtextura. Quando as superfícies forem levemente isoladas por um contaminante, a adesão pode ser influenciada e diminuir rapidamente (SILVA, 2008).

Enquanto a adesão está relacionada com a microtextura ($\lambda < 0,5 \text{ mm}$), a histerese refere-se à macrotextura ($0,5 \text{ mm} \leq \lambda < 50 \text{ mm}$), afirmam Andresen e Wambold (1999). As perdas por histerese ocorrem devido à deformação da borracha do pneu, quando a banda de rodagem desliza sobre as irregularidades da superfície. A intensidade dessa componente de atrito é diretamente proporcional à velocidade de deslizamento, e seu valor máximo ocorre para maiores velocidades quando há o aumento da temperatura. Entretanto, as perdas por histerese

não são influenciadas quando as superfícies de contato são levemente isoladas por algum contaminante (SILVA, 2008).

O desgaste, por sua vez, ocorre na banda de rodagem quando há o arrancamento de partículas do pneu na superfície de contato do pavimento, fenômeno conhecido também como emborrachamento da pista. A força de atrito devido a este elemento é proporcional à área de contato na banda de rodagem e é influenciada pela textura da superfície (RODRIGUES FILHO, 2006). Andresen e Wambold (1999) estudaram a interação dos mecanismos atuantes no atrito ao deslizamento em dois tipos de pavimento utilizando o mesmo pneu. A análise foi realizada em um pavimento nas condições seca e úmida e em uma via não pavimentada, conforme a Figura 4.

Figura 4 – Influência da adesão, histerese e desgaste no atrito ao de deslizamento



Fonte: Adaptada de Andresen e Wambold (1999).

Percebe-se que para uma pista cuja superfície está em um estado limpo e seco, a atuação do desgaste é relativamente pequena quanto à histerese e à adesão. Contudo, em uma situação de pista com a presença de água, a influência da adesão é consideravelmente reduzida com o aumento da velocidade, enquanto a histerese responde, quase que integralmente, pela resistência ao deslizamento, tendo em vista que a macrotextura é responsável por mais de 90% da força de atrito em velocidades superiores à 90 km/h (ANDRESEN; WAMBOLD, 1999).


Nesse contexto, a presença de um terceiro elemento na pista, qual seja, a água, entre o pneu e o pavimento, promove a redução das forças de adesão e a lubrificação do contato. Desse modo, ocorre a atenuação do desgaste, o qual apesar de não ser tão atuante como a adesão e a histerese nas duas primeiras situações, é o principal mecanismo de atrito em superfícies não pavimentadas (ANDRESEN; WAMBOLD, 1999).

2.1.3 Resistência ao rolamento

Segundo Rodrigues Filho (2006), quando um pneumático estacionado sobre uma pista é submetido a um carregamento vertical, verifica-se nele uma deformação e, logo, uma distribuição de pressões na área de contato, a qual possui como resultante uma força vertical

que passa pelo centro da roda, conforme ilustrado na Figura 5. Devido à deflexão do pneu, também estão presentes forças horizontais locais, porém, para o pneu estático, a resultante dessas forças é nula.


Figura 5 – Pneu estático submetido a uma carga vertical



Fonte: Rodrigues Filho (2006).

Uma vez que o pneu passa para o estado dinâmico, verifica-se uma alteração na distribuição de pressões na área de contato em razão das propriedades viscoelásticas da borracha. Logo, considerando o centro da roda como referência, a força vertical resultante se desloca para frente, opondo-se à rotação. Caso a rotação permaneça em razão da ação de uma força de tração no eixo da roda, uma força equivalente com sentido contrário é formada na área de contato, a qual é denominada de resistência ao rolamento, conforme ilustrado na Figura 6. Essa força tem sentido contrário ao movimento e é consequência da deformação da banda rodagem, seu valor pode ser obtido através da Equação 1 (RODRIGUES FILHO, 2006).

Figura 6 – Pneu dinâmico submetido a uma carga vertical



Fonte: Rodrigues Filho (2006).

$$F_R = F_N \times \frac{e}{r} \quad (1)$$

Em que:

F_R – Resistência ao rolamento;

F_N – Força Normal;

e – Distância horizontal entre o eixo da roda e o centro de pressão da área de contato;

r – raio do pneu carregado.

Destaca-se, contudo, que as variáveis “ e ” e “ r ” apresentam leves alterações durante a rotação. Desse modo, o coeficiente de atrito ao rolamento pode ser definido pela Equação 2.

$$\mu_R = \frac{F_R}{F_N} \quad (2)$$

Em que:

μ_R – Coeficiente de atrito ao rolamento;

F_R – Resistência ao rolamento;


F_N – Força Normal.

A histerese é o principal mecanismo que possibilita a resistência ao rolamento, devido ao comportamento viscoelástico do material constituinte do pneu. Estudos experimentais indicaram que a histerese representa em torno de 90% a 95% das perdas verificadas no rolamento de pneus na faixa de velocidade de 128km/h a 152 km/h, enquanto o atrito entre o pneu e o pavimento representa de 2% a 10% e a ação da resistência do ar representa de 1,5% a 3,5% (WONG, 2001).

De acordo com Wong (2001), existem diversos fatores que podem afetar a resistência ao rolamento de um pneu, a saber: (i) estrutura: tipo de construção e componentes utilizados; e (ii) circunstâncias operacionais: superfície de rolamento, pressão de enchimento, velocidade aplicada e temperatura. Além disso, destaca-se a velocidade de deslocamento como um aspecto significativo presente na resistência ao rolamento, visto que há um aumento de energia dissipada por deformação e um aumento das vibrações na estrutura do pneu.

Silva (2008) considera que a estrutura de um pneu pode ser classificada em dois tipos: diagonal ou radial. O primeiro, também chamado de convencional, possui uma carcaça estruturada com lonas têxteis entrecruzadas. O segundo é formado por uma estrutura têxtil ou de aço, cujos cordonéis estão dispostos no sentido do raio, além de possuírem também cinturas de aço colocadas debaixo da banda de rodagem, as quais complementam a sua estrutura. Wong (2001) utilizou pneus diagonal e radial de veículos de passeio para verificar a variação do coeficiente de atrito ao rolamento em relação à velocidade, levando em consideração um pavimento suave e plano, além das mesmas pressões e cargas de enchimento, e observou que a estrutura diagonal promove maiores valores de coeficiente de atrito, conforme a Figura 7.

Figura 7 – Coeficiente de atrito ao rolamento em relação à velocidade e ao tipo de pneu




Fonte: Adaptada de Wong (2001).

2.1.4 Hidroplanagem

A força de atrito disponível em um pavimento com a presença de água é substancialmente menor do que em uma pista seca. Isso ocorre em razão do fluido contaminante, existente entre o pneu e a superfície da pista, não ser expulso totalmente. Essa fina película de água que se encontra na área de contato reduz significativamente a adesão, a qual é um mecanismo importante da resistência à derrapagem (SILVA, 2008).

De acordo com Silva (2008), à medida que a velocidade aumenta, reduz-se o tempo de contato da banda de rodagem com o pavimento e o tempo disponível para a expulsão completa do fluido. Horne e Dreher (1963) estudaram o comportamento do coeficiente de atrito consoante a velocidade da aeronave em solo, em duas situações de superfície de pista – molhada e seca –, utilizando uma aeronave 880 Jet em pista de concreto com sistema antiderrapante ativado, conforme a Figura 8.

Figura 8 – Coeficiente de atrito em relação à presença de água na pista



Fonte: Adaptada de Horne e Dreher (1963).

Com efeito, a presença de uma película de água na interface pneu-pavimento pode ocasionar hidroplanagem (ou aquaplanagem), a qual é um dos principais elementos que influenciam acidentes com aeronaves. Esse fenômeno decorre da perda total de contato entre o pneumático e a superfície do pavimento, pois a massa e a viscosidade do fluido influenciam o desempenho do atrito (RODRIGUES FILHO, 2006).

Segundo a ANAC (2018), a hidroplanagem pode ser classificada em três tipos, a saber: dinâmica, viscosa e desvulcanização. A hidroplanagem dinâmica decorre da perda de contato entre o pneu e a superfície do pavimento, isto é, o pneumático é suspenso em razão da camada de água presente na pista e desliza sem rotação. Nesse cenário, os freios, sejam eles manuais ou automáticos, com ou sem sistema antiderrapagem das rodas, tornam-se ineficientes na frenagem da aeronave.

Ainda de acordo com a ANAC (2018), a ocorrência de hidroplanagem dinâmica total demanda uma quantidade considerável de água, análoga à quando os pneus de automóveis passam sobre uma poça d'água. Entretanto, constata-se uma maior frequência da aquaplanagem parcial, na qual inexistente uma separação completa entre o pneu e a pista por todo o tempo – embora essa redução de aderência permita o deslizamento do pneu. Rodrigues Filho (2006) afirma que, quando o pneu sofre hidroplanagem completa, não há perdas de energia cinética por adesão, havendo apenas perdas por histerese no interior da área de contato.

Para Silva (2008), a hidroplanagem viscosa decorre da presença de contaminantes, seja água, poeira, resíduos de borracha ou óleo, os quais agem como um lubrificante em superfícies asfálticas, de modo a reduzir o atrito pneu-pavimento. Esse tipo de aquaplanagem é comumente verificado em cabeceiras e zonas de toque da PPD durante longos períodos de chuva, estando relacionado a superfícies lisas devido ao acúmulo de borracha que se aglomera nessas áreas. Ainda, a ocorrência desse fenômeno pode ser vista em velocidades menores, em comparação aos outros tipos de hidroplanagem (ANAC, 2018).

Por fim, a hidroplanagem por desvulcanização ou com destruição da borracha dos pneus, conhecida também por reversão de borracha, é constatada quando há o travamento dos freios em uma pista com presença de água. Dessa forma, a fricção entre o pneu bloqueado em deslizamento e a superfície da pista produz um aquecimento capaz de transformar a umidade em vapor d'água, ocasionando a fundição da borracha e produzindo pressão sob o pneu, separando-o parcialmente da superfície da pista. O selo formado no pneu dificulta a dispersão de água e o vapor gerado contribui para a aquaplanagem, pois prejudica o atrito entre o pneu e a pista (ANAC, 2018; SILVA, 2008).

2.2 Equipamentos para aferição do coeficiente de atrito

O atrito é medido usualmente em pista molhada, tendo em vista que superfícies secas tendem a apresentar resultados melhores de resistência à derrapagem, e pode ser avaliado por meio de duas variáveis, quais sejam, o Coeficiente de Atrito Longitudinal (CAL) e o Coeficiente de Atrito Transversal (CAT). Destaca-se que os seus valores variam em razão das circunstâncias do ensaio, a saber: tipo de pneu utilizado, espessura da lâmina d'água, ângulo de inclinação da roda e a velocidade do equipamento (COUCHINHO, 2011).

Couchinho (2011) entende que o CAL diz respeito, principalmente, à distância de frenagem, estando diretamente relacionado à força que se desenvolve na área de contato entre o pneumático e a superfície da pista. Enquanto o CAT refere-se à segurança em curvas, pois é o fator que mais influencia a velocidade de circulação e, conseqüentemente, os acidentes. Esse parâmetro é representado pela força desenvolvida na interação pneu-pavimento, perpendicular ao plano de rotação da roda, quando esta circula formando um ângulo em relação à sua direção de rotação.

Segundo APS (2006), os equipamentos de medida de atrito podem ser classificados em quatro tipos: estático (ou portáteis), roda oblíqua, roda bloqueada e roda parcialmente bloqueada. Os dispositivos portáteis são utilizados para medições em ensaios pontuais ou em laboratório. São exemplos desse tipo de equipamento o Pêndulo Britânico (*British Pendulum*) e o *Dynamic Friction Tester* (DFT), conforme ilustrado na Figura 9.

Figura 9 – Equipamentos portáteis



(a) Pêndulo Britânico

(b) *Dynamic Friction Tester*

Fonte: (a) Bernucci *et al.*, (2008); (b) Rodriguez (2009).

Os equipamentos de rodas oblíquas (com ângulo de deslizamento lateral) verificam o esforço lateral causado pelo pneu, o qual forma um ângulo variável em relação à direção da rotação. Esta resultante lateral é relacionada com o coeficiente de atrito e, logo, tem-se o CAT. Dentre os equipamentos existentes, destaca-se o *Mu-meter*, o qual é muito utilizado nos aeroportos brasileiros, e o SCRIM, conforme apresentado na Figura 10 (APS, 2006; COUCHINHO, 2011).

Figura 10 – Equipamentos de rodas oblíquas



Fonte: (a) Aero Expo (2021), (b) Rosanne (2021).

Por sua vez, os equipamentos de roda bloqueada fornecem uma condição de deslizamento de 100%, de modo que a velocidade relativa entre o pneu e a superfície da pista é igual à velocidade do veículo. O início da medição dá-se pela ativação do bloqueio das rodas que derrapam, possibilitando a aferição da força de frenagem (processo que dura de 1 a 2 segundos). Esses dispositivos possuem sistema para testes em pistas molhadas, nas quais é aplicada uma película d'água de cerca de 1,0 mm, sendo a medição contínua, possibilitando verificar o pico de atrito. Um exemplo desse tipo de equipamento é o Adhera (BERNUCCI *et al.*, 2008; COUCHINHO, 2011).

Por fim, os equipamentos de roda parcialmente bloqueada avaliam o coeficiente de atrito de modo contínuo, funcionando com deslizamento fixo. Esses instrumentos operam geralmente com uma taxa de deslizamento entre 10% e 20%. Dentre os equipamentos existentes, estão os de deslizamento variável, como o *Tatra Runway Tester* e *Oscar*; e os de deslizamento fixo, como o *Skidometer* e *GripTester*, evidentes na Figura 11 (COUCHINHO, 2011; WAMBOLD *et al.*, 1995).

Figura 11 – Equipamentos de roda parcialmente bloqueada



(a) Skiddometer

(b) Griptester

Fonte: (a) Moventor (2021), (b) Griptester (2021).


2.3 Fatores que influenciam o coeficiente de atrito

Neste item, apresentam-se as principais características que impactam o coeficiente de atrito em um pavimento.

2.3.1 Tipo de pavimento

Aps (2006) afirma que, na França, foram realizadas verificações do coeficiente de atrito longitudinal (CAL) em múltiplos revestimentos asfálticos por meio do equipamento Adhera. A análise relacionou o CAL de acordo com a velocidade em três tipos de revestimentos asfálticos em estado molhado, quais sejam, um Drenante, um Pré-misturado a Frio e um Concreto Asfáltico (CA), conforme exposto na Figura 12.

Figura 12 – CAL medido em três tipos diferentes de revestimentos asfálticos e diferentes velocidades




Fonte: Adaptada de Brosseaud (2002 apud Bernucci et al., 2008).

Constata-se que, de modo geral, o revestimento drenante apresenta um desempenho

melhor para o CAL e uma maior estabilidade do atrito diante do desenvolvimento da velocidade. Isso é consequência, principalmente, do efeito de drenagem da água superficial pelos vazios interconectados. Todavia, evidenciaram-se os menores valores de CAL no CA, o qual é o mais influenciado pelo aumento da velocidade.

Corley-Lay (1998) analisou a variação da textura superficial em relação ao coeficiente de atrito medido, por meio do Pêndulo Britânico, em 14 trechos de superfícies compostas de 7 tipos diferentes de misturas asfálticas, das quais apresentam-se 6 na Figura 13. Verifica-se que o tipo de mistura asfáltica tem influência relevante na macrotextura, obtida pelo método da mancha de areia, e no coeficiente de atrito, representado pelo *British Pendulum Number* (BPN) ou Valor de Resistência a Derrapagem (VRD).


Figura 13 – Variação da textura com o coeficiente de atrito em diferentes tipos de misturas asfálticas



Fonte: Adaptada de Aps (2006).

McDaniel *et al.*, (2010) realizaram a análise do comportamento do coeficiente de atrito em determinados segmentos de rodovias norte-americanas, desde a abertura das pistas ao tráfego até um intervalo de 5 anos, por meio do equipamento DFT a uma velocidade de 20 km/h. Esses trechos eram compostos de 3 tipos diferentes de revestimentos, quais sejam: Concreto Asfáltico (CA) convencional, *Stone Matrix Asphalt* (SMA) e Camada Porosa de Atrito (CPA). Dessa forma, foram gerados resultados considerando a ação do tempo e do tráfego para cada tipo de revestimento, conforme apresentado na Figura 14.

Figura 14 – Variação do atrito ao longo do tempo e do tráfego em 3 tipos de revestimentos




Fonte: Adaptada de McDaniel *et al.*, (2010).

Percebe-se que os segmentos constituídos de SMA e CPA apresentam, antes da abertura do tráfego, menores resultados de atrito (DF 20) em relação às medições em idades posteriores. Entretanto, para McDaniel *et al.*, (2010), este comportamento é esperado, visto que os pavimentos recém executados possuem, usualmente, menores valores de microtextura devido ao aglutinante que reveste a superfície dos agregados. Após a liberação do tráfego, a película de asfalto é normalmente removida pela ação do polimento dos agregados, ocasionada por meio dos pneus dos automóveis, resultando em um aumento do coeficiente de atrito.

Em resumo, observou-se que as superfícies com SMA e CPA apresentaram níveis de coeficiente de atrito estáveis e semelhantes entre si, porém, significativamente maiores que o CA, mesmo este encontrando-se em uma condição aceitável. Ademais, não foi percebida tendência consistente de queda e destaca-se que, após a ação do tráfego, o trecho com CA apresentou os menores valores de atrito dentre os tipos de revestimentos analisados.

Costa, Castelo Branco e Freitas (2017) investigaram a variação do coeficiente de atrito em diferentes técnicas de pavimentação, por meio do equipamento Pêndulo Britânico, fundamentado em dados encontrados na literatura técnica. Foram avaliadas 11 técnicas de pavimentação, quais sejam: Concreto Asfáltico convencional usinado a quente (CA); CA com adição de Borracha (CA-B); CA com MicroFresagem (CA-MF); Camada Porosa de Atrito (CPA); Concreto de Cimento Portland (CCP); CA com *Grooving* (G); CA com *Grooving* Emborrachado (G-E); MicroRevestimento asfáltico (MR); *Stone Matrix Asphalt* (SMA); Tratamento Superficial Duplo (TSD); e Tratamento Superficial Simples (TSS). Os resultados do coeficiente de atrito (BPN), de acordo com o tipo de revestimento, estão na Figura 15.

Figura 15 – Valores do BPN em 11 tipos de pavimento



Fonte: Adaptada de Costa, Castelo Branco e Freitas (2017).

Observa-se que o Concreto Asfáltico com adição de borracha (CA-B) manifestou o menor BPN, apresentando valores inferiores ao Concreto Asfáltico convencional (CA). Enquanto o pavimento com a presença de *Grooving* (G) obteve o maior BPN, ou seja, uma maior resistência à derrapagem. Entretanto, quando a componente de emborrachamento é incluída (G-E), tem-se uma redução de cerca de um terço do valor de BPN. Isso ocorre devido ao processo de preenchimento das ranhuras transversais com resíduos de borracha oriundos do desgaste dos pneus dos veículos.

2.3.2 Textura superficial

Rodrigues Filho (2006) afirma que o melhor modo de caracterizar a superfície de um pavimento é através da avaliação da textura, a qual pode ser classificada em quatro categorias: a microtextura, a macrotextura, a megatextura e a irregularidade. Dessa forma, foram estabelecidos os limites para as escalas de irregularidade de superfícies de pavimentos rodoviários, atribuindo faixas de classificação de acordo com o comprimento de ondas (horizontal) e a amplitude (vertical), conforme apresentado na Tabela 1 (APS, 2006).

Tabela 1 – Classificação da textura


Escalas	Intervalo de dimensões	
	Horizontal	Vertical
Microtextura	0 - 0,5 mm	0 - 0,2 mm
Macrotextura	0,5 - 50 mm	0,2 - 10 mm
Megatextura	50 - 500 mm	1 - 50 mm
Irregularidade	0,5 - 50 m	1 - 200 mm

Fonte: Adaptada de Aps (2006).

Bernucci *et al.*, (2008) entendem que a megatextura e a irregularidade influenciam na dinâmica do veículo e no contato entre o veículo e o pavimento, interferindo na estabilidade direcional e na aderência em pistas molhadas. A microtextura é uma propriedade da superfície

e aspereza dos agregados, ao passo que a macrotextura tem relação com a rugosidade do conjunto de agregados e mastique, conforme ilustrado na Figura 16.

Para pavimentos aeroportuários a textura superficial é caracterizada pela microtextura e macrotextura, conforme entendimento de Fonseca (1990), ICAO (2002), Kazda e Caves (2007). Essas duas características, representadas na Figura 16, são fundamentais para o coeficiente de atrito e a aderência pneu-pavimento.



Fonte: Adaptada de Bernucci *et al.*, (2008).

Entretanto, conforme entendimento de Yager (2014), as velocidades mais altas associadas às operações de pouso e decolagem de aeronaves indicam que a macrotextura não medida pelo Pêndulo Britânico possui maior relevância para a resistência à derrapagem do que a microtextura. Dessa forma, a resistência à derrapagem de pavimentos aeroportuários é usualmente avaliada em campo através de ferramentas de medição de fricção contínua.

Com efeito, a aderência pneu-pavimento é resultado das características da microtextura e macrotextura. Essas combinações podem formar quatro tipos de textura, quais sejam: rugosa e aberta; rugosa e fechada; polida e aberta; e polida e fechada, conforme ilustrado na Figura 17 (APS, 2006).

Figura 17 – Combinações de macro e microtextura

Microtextura	Macrotextura	Superfície	Tipo de Textura
Rugosa	Aberta		Rugosa e Aberta
	Fechada		Rugosa e Fechada
Polida ou Lisa	Aberta		Polida e Aberta
	Fechada		Polida e Fechada

Fonte: Aps (2006).

Segundo Kazda e Caves (2007), a macrotextura observada, na maioria dos casos nos pavimentos aeroportuários, é aberta, diferentemente dos pavimentos rodoviários que é geralmente fechada. Essa diferença ocorre devido às diferenças encontradas na drenagem dos diferentes tipos de pneumáticos (veículo e aeronave). Ademais, um dos fatores que mais influenciam a resistência à derrapagem das aeronaves em superfícies molhadas é a profundidade da macrotextura, pois esta proporciona maior ou menor perda de energia durante o contato com os pneumáticos (FONSECA, 1990).


Para avaliação da macrotextura, existem diversos métodos recomendados pela ICAO (2002), tais como: método da mancha de areia, da mancha de graxa, do papel carbono, da régua de copiar perfis, do molde, estereofotográfico, medição direta no pavimento e corrente de água. Porém, as técnicas mais utilizadas na prática da administração aeroportuária são o método da mancha de areia e o da mancha de graxa.

De acordo com Rodrigues Filho (2006), o método da mancha de areia objetiva determinar a média da profundidade da altura da mancha de areia em superfícies de pavimentos. Esta altura é resultando da diferença entre os picos e os vales (depressões) da textura da superfície. Deve-se realizar, no mínimo, três medições de profundidade de textura, das quais é obtida uma média a cada 100 m com início na cabeceira mais solicitada da pista. Tais medições são realizadas em pontos situados a 3 m do eixo, alternando à direita e à esquerda deste. Caso sejam constatados defeitos na textura superficial, deve-se executar um número maior de medições (ANAC, 2019).

Destaca-se que em áreas do pavimento com a presença de ranhuras transversais, também conhecidas como *grooving*, a medição de macrotextura não é obrigatória, visto que esse dispositivo amplia a capacidade de escoamento superficial da água precipitada. Outra exceção é relativa às PPD compostas de CPA, haja vista que se trata de revestimento drenante.

Wells e Young (2019) indicam a execução de *grooving* como método eficaz e econômico para reduzir a ocorrência de aquaplanagem e, conseqüentemente, eleva o coeficiente de atrito dos pavimentos aeroportuários. A ferramenta consiste em pequenos canais transversais executados na superfície do pavimento, flexível ou rígido, com o intuito de encaminhar a água acumulada para fora da pista, conforme a Figura 18. Entretanto, o *grooving* não possui significado físico idêntico a uma textura superficial grossa composta de agregados graúdos dispostos aleatoriamente, os quais formam inúmeros canais de circulação e escoamento da água (RODRIGUES FILHO, 2006).

Figura 18 – Grooving executado em PPD



Fonte: Rodrigues Filho (2006).

Para Mallick e El-Korchi (2017), a macrotextura é fundamental para pistas de pouso e decolagem, devido às altas velocidades desenvolvidas pelas aeronaves nas operações de pousos e decolagens, assim como para garantir a drenagem durante a precipitação de água. Kazda e Caves (2007) consideram que as pistas de pouso e decolagem devem apresentar uma macrotextura aberta e uma microtextura áspera. Esta combinação resulta geralmente em um nível de atrito alto e permite a drenagem substancial de uma película fina de água quando na ocorrência de chuvas. Seguindo o raciocínio, Rodrigues Filho (2006) afirma que uma pista com essas características (macrotextura aberta e microtextura áspera) é a melhor escolha para atender aos elementos de aderência pneu-pavimento.

Diversos autores investigaram uma possível relação linear entre a macrotextura e o coeficiente de atrito. Bezerra Filho e Oliveira (2013) analisaram dados obtidos por meio do método de mancha de areia (macrotextura) e do *Skidometer* (atrito) de ensaios realizados, entre 2011 e 2012, no Aeroporto Internacional de Fortaleza, cujas PPD são compostas por Concreto Asfáltico (CA). Foram encontrados Coeficientes de Correlação (R) entre 0,26 e 0,60.

Pinheiro Neto, Oliveira e Aguiar (2015) avaliaram esta relação no mesmo aeroporto, em 2014, encontrando um R entre -0,08 e 0,52. Ramos *et al.*, (2015), por sua vez, analisaram o vínculo desses parâmetros nos aeródromos de Fortaleza, Juazeiro do Norte e Petrolina, cujas PPD são em CA, obtendo um R variando de 0,01 a 0,80.


Percebe-se que não há uma correlação forte entre esses dois parâmetros, tendo obtido relações que vão de nula a moderada. Entretanto, Pinheiro Neto, Oliveira e Aguiar (2015) e Ramos *et al.*, (2015) justificam que a causa desses resultados pode ser o método de medição da macrotextura, a mancha de areia, por ser uma avaliação estática e pontual, em contrapartida às medições do coeficiente de atrito, as quais são dinâmicas e contínuas.

2.3.3 Tráfego e tempo

Skerritt (1993) entende que o atrito em pavimentos novos é proveniente,

principalmente, da macrotextura, pois os agregados ainda estão recobertos com uma película de asfalto. No entanto, à medida que os veículos trafegam pela via, essa camada é reduzida e os agregados ficam expostos ao polimento. Em determinado tempo, todos os agregados da superfície desgastam-se até atingirem uma condição de equilíbrio, conforme ilustrado na Figura 19. Esse estado é alcançado após a passagem de 1 a 5 milhões de veículos de passageiros ou depois de um período de dois anos.


Figura 19 – Variação do atrito conforme a idade do pavimento



Fonte: Adaptada de Skeritt (1993).

A geometria da pista e a intensidade do tráfego de veículos, principalmente dos comerciais, exercem influência direta no polimento dos agregados. Portanto, vias com volume de tráfego elevado demandam mais precaução com o atrito, de acordo com o gráfico da Figura 20 (CHELLIAH *et al.*, 2002).

Figura 20 – Redução do atrito em razão do aumento do tráfego




Fonte: Adaptada de Chelliah *et al.*, (2002).

2.3.4 Remoção de acúmulo de borracha

A borracha acumulada na superfície do pavimento resultante do desgaste dos pneus das aeronaves durante as operações, sobretudo nos pousos, influencia o atrito disponível nas pistas. Esse fenômeno ocorre na zona de toque das PPD.

O atrito disponível em uma PPD é influenciado consideravelmente pela quantidade de borracha depositada na superfície do pavimento, a qual é decorrente do desgaste dos pneus das aeronaves durante as operações, sobretudo nos pousos. A zona de toque da PPD é a área mais afetada pelo acúmulo de borracha, o qual pode ser extenso e preencher toda a textura da superfície do pavimento, resultando na perda da capacidade de frenagem e do controle direcional da aeronave caso haja água na pista. Isto posto, a segurança das operações nas PPD é o motivo que torna essencial a remoção do acúmulo de borracha (CHEN *et al.*, 2008).


Chen *et al.*, (2008) analisaram o desempenho do coeficiente de atrito em relação ao efeito do acúmulo de borracha em uma PPD do Aeroporto Internacional de Kaohsiung, em Taiwan. Constatou-se que após os 200 m iniciais, com início da cabeceira predominante, já é possível observar a presença de pequenos depósitos de borracha. Contudo, são entre os trechos de 500 m e 1.000 m que se observam os maiores acúmulos de borracha e, conseqüentemente, as menores medidas de coeficiente de atrito, conforme apresentado na Figura 21.



Fonte: Adaptada de Chen *et al.*, (2008).

Chen *et al.*, (2008) também verificaram que o número de pousos é diretamente proporcional à espessura do depósito de borracha na PPD, onde cada pouso contribui com cerca de 0,05 mm para tal medida. Esse material, ao ser mantido na pista, é submetido a um processo de compactação em razão do peso e do calor das aeronaves durante a aterrissagem. Por consequência, forma-se uma camada de borracha que ocupa a superfície das PPD, a qual dificulta a aderência pneu-pavimento, reduzindo o coeficiente de atrito em áreas com mais acúmulo de borracha, como exposto no gráfico da Figura 22.

Figura 22 – Ação do acúmulo de borracha no atrito




Fonte: Adaptada de Chen *et al.*, (2008).

2.3.5 Condições climáticas

Flintsch, Luo e Al-Qadi (2005) entendem que fatores relacionados ao clima, tais como precipitação, temperatura, umidade, velocidade do vento, entre outros, são parcialmente responsáveis pelas variações sazonais nas propriedades do atrito na interface pneu-pavimento. Assim, existem diferentes padrões de variações sazonais nos níveis de resistência à derrapagem, tornando-se mais notório ao longo dos meses de verão, em razão das maiores temperaturas observadas nessa estação (MASAD *et al.*, 2009)

Para Masad *et al.*, (2009), os níveis de atrito apresentam os menores valores durante o período de verão. Isso ocorre em virtude do maior acúmulo de pequenas partículas e detritos na superfície do pavimento, que aceleram o polimento da superfície do pavimento e, por conseguinte, reduzem a resistência à derrapagem. Com efeito, observa-se uma variação de cerca de 30% do atrito entre um mínimo no verão e um pico durante o inverno, conforme ilustrado na Figura 23 (CHELLIAH *et al.*, 2002).

Figura 23 – Alteração sazonal do atrito



Fonte: Adaptada de Chelliah *et al.*, (2002).

Sobre a influência da temperatura, diversos estudos concordam acerca da ação da temperatura nos quatros elementos da aderência pneu-pavimento, quais sejam: ar, água, pneu e pavimento. Luo (2003) afirma que vários pesquisadores analisaram essas relações e, mesmo


que os estudos possuam diferentes formatos, concordam quanto à alta correlação entre esses parâmetros, conforme é apresentado no Quadro 1.

Quadro 1 – Pesquisas acerca da influência da temperatura no atrito

Fontes	Locais	Elementos verificados	Ação da temperatura sobre o atrito
Kummer and Meyer (1962)	Flórida	Borracha	Coeficiente de atrito diminui com a temperatura
Tung <i>et al.</i> , (1977)	Pennsylvania	Pavimento	Coeficiente de atrito a 0km/h diminui a com temperatura
Hill and Henry (1978)	Pennsylvania	Pavimento	Coeficiente de atrito a 0km/h diminui a com temperatura
Anderson <i>et al.</i> , (1984)	Nova Iorque, Virgínia e Pennsylvania	Ar durante o ensaio	Efeito significativo da temperatura
Mitchell <i>et al.</i> , (1986)	Maryland	Ar durante o ensaio	Não foi observado efeito significativo
Oliver (1989)	Austrália	Pavimento e pneu	Coeficiente de atrito longitudinal e VRD diminui com a temperatura

Fonte: Adaptado de Luo (2003).

Anupam *et al.*, (2013) verificaram o comportamento do coeficiente de atrito quanto à temperatura do pavimento, do ar e do ar contido no pneu, em três tipos diferentes de misturas asfálticas, a saber: pavimento drenante, SMA e revestimento delgado. Os resultados indicam que a temperatura é inversamente proporcional ao atrito, independentemente do tipo de superfície. A variação do atrito em relação aos elementos utilizados em um revestimento *drenant* pode ser observada na Figura 24. Além disso, os autores desenvolveram modelos de previsão do atrito, utilizando dados de temperatura, por meio de regressões cujos Coeficientes de Determinação (R^2) resultaram entre 0,81 e 0,94.



Fonte: Adaptada de Anupam *et al.*, (2013).

Diversos autores têm pesquisado sobre modelos de previsão para as condições superficiais de pavimentos, principalmente para o atrito. Esses sistemas utilizam técnicas variadas, como regressão linear múltipla, regressão não-linear e Redes Neurais Artificiais. Além disso, empregam dados relativos ao tipo de pavimento, aos agregados, à geometria da via, ao tráfego e às condições climáticas (BECKLEY, 2016; CEREZO; DO; KANE, 2012; HOSSAIN; GOPISETTI; MIAH, 2019; OLIVEIRA, 2017; SANTOS *et al.*, 2014; SUSANNA *et al.*, 2017; YAO *et al.*, 2019).

2.4 Inteligência Computacional (IC)

A Inteligência Computacional (IC) constitui um ramo da Inteligência Artificial (IA) que busca o desenvolvimento de sistemas inteligentes por meio de técnicas inspiradas na natureza, as quais objetivam reproduzir elementos do comportamento humano, tais como aprendizado, percepção, raciocínio, evolução e adaptação. Para desenvolver tais sistemas são utilizadas técnicas como Rede Neurais Artificiais (RNA), Algoritmos Genéticos, Lógica *Fuzzy* e Sistemas Especialistas (PACHECO, 1999).

As RNA são modelos computacionais inspirados na ordenação e atividade do cérebro humano. Tais modelos buscam reproduzir características humanas como aprendizado, associação, generalização e abstração. Esse tipo de técnica possui eficácia no aprendizado em modelos com dados não lineares, com ruído, incompletos ou compostos de amostras contraditórias (RIBEIRO, 2013).

Os Algoritmos Genéticos, por sua vez, são algoritmos matemáticos baseados na evolução biológica e na recombinação genética. Essa técnica proporciona um mecanismo de busca adaptativa que é fundamentado no princípio Darwiniano de reprodução e sobrevivência dos mais aptos (PACHECO, 1999).

Zadeh (1965) define que a Lógica Nebulosa (*Fuzzy Logic*) objetiva modelar o raciocínio humano, tendo em vista produzir sistemas computacionais aptos a tomar decisões racionais a partir de informações incertas. Essa técnica fornece um modo de alterar dados relativos, tais como as definições de muito, pouco, alto e pequeno, por exemplo. Dessa forma, o algoritmo consegue apresentar uma resposta similar para uma questão baseada em referências inexatas, incompletas ou não totalmente confiáveis.

Os Sistemas Especialistas são modelos computacionais baseados em um campo especializado do conhecimento humano, os quais objetivam responder a uma aplicação determinada e limitada pelo conhecimento do humano especialista. Este método utiliza técnicas de IA, base de conhecimento e raciocínio inferencial (PACHECO, 1999).

Samuel (1959), que descreveu o termo Aprendizado de Máquina (AM), também conhecido por *Machine Learning*, o definiu como um campo de estudo que fornece aos computadores a capacidade de aprender sem serem explicitamente programados. Mitchell (1997), numa definição mais moderna, diz que um programa de computador aprende com a experiência em relação à determinada tarefa e a uma medida de desempenho, se seu desempenho nessa tarefa, conforme aferido pelo desempenho, melhora com a experiência.

Géron (2017) afirma que existem diversas técnicas de AM, as quais podem ser categorizadas de acordo com: (i) o modo de supervisão do treinamento – supervisionado, não supervisionado, semi-supervisionado e aprendizagem por reforço; (ii) a forma de incrementação – *on-line* e *batch*; (iii) o funcionamento, onde por ser comparado pontos de dados novos com conhecidos ou identificado padrões nos dados de treinamento e construindo um modelo de previsão – baseado em exemplos ou em modelo.

O sistema de AM usualmente utilizado é a aprendizagem supervisionada, na qual deseja-se definir uma função capaz de prever rótulos desconhecidos a partir de um conjunto de dados rotulados previamente estabelecidos, visto que o algoritmo não possui a capacidade de aprender sozinho, sendo necessário um operador para apresentar o conhecimento, bem como as saídas corretas. Nessa técnica de aprendizado, há um ajuste de parâmetros por meio da relação entre os pares de entradas e saídas, sucessivamente. Em seguida ao treinamento, o algoritmo tenta reproduzir o comportamento ensinado pelo intermediador. Ribeiro (2013) utilizou esse tipo de aprendizagem na classificação de solos para fins de pavimentação rodoviária.

Para os cenários de aprendizagem não supervisionada, Bocanegra (2002) afirma que as respostas ou saídas não estão presentes na base de dados apresentada ao algoritmo e que o sistema não faz comparações para definir a resposta ideal. Então o conjunto de treinamento modifica os pesos da rede de maneira a produzir saídas consistentes, isto é, que um conjunto de dados suficientemente equivalente ao de treinamento, produzirá o mesmo padrão nas saídas.

Para Matsubara (2004), o AM supervisionada necessita de uma base de dados rotulados robusta para o desenvolvimento de um parâmetro aceitável. Porém, obter esse conjunto de dados rotulados demanda geralmente bastante tempo, além de ser eventualmente um processo manual e custoso. Dessa forma, o uso da aprendizagem supervisionada pode ser inviabilizado pela dificuldade de obtenção desse tipo de dado, sendo o AM semi-supervisionado uma alternativa, na qual especialistas rotulam alguns dados com alta convicção acerca do rótulo associado no intuito de obter melhores resultados.

A aprendizagem por reforço, por sua vez, não possui a presença de um operador, mas sim de um analista externo, o qual executa procedimentos de tentativa e erro com o objetivo

de potencializar um sinal de reforço. Desse modo, o sistema é fortalecido quando a ação realizada pelo algoritmo resulta em um efeito satisfatório, caso não, o modelo é enfraquecido, aonde um reforço positivo ou negativo implica em recompensa ou punição, respectivamente. Ainda, há casos de não haver nenhum dos dois, o qual é chamado de reforço nulo. Em suma, o desempenho dessa técnica baseia-se em qualquer ação que possa ser fornecida ao sistema (COUTINHO NETO, 2000).

Para a classificação em relação ao modo de incrementação do algoritmo, Géron (2017) afirma que, na aprendizagem *batch*, o sistema deve ser treinado utilizando todos os dados e é incapaz de aprender de forma incremental. Este tipo de AM necessita de treinamento sempre que novos dados forem adicionados, além de ser geralmente elaborado *off-line* para depois ser lançado, devido à grande demanda de tempo e de recursos computacionais. Ao passo que, no modo *on-line*, o algoritmo é treinado de maneira incremental ao acrescentar os dados sequencialmente, seja individualmente ou por meio de pequenos grupos denominados de *mini-batch*. A vantagem dessa técnica consiste na velocidade e em uma menor demanda de recursos computacionais, permitindo que o sistema se ajuste a cada novo dado adicionado (GÉRON, 2017).

Por fim, Géron (2017) define que a classificação de sistemas AM pelo modo de funcionamento consiste na capacidade do algoritmo abranger amostras inéditas considerando um número de exemplos de treinamento, isto é, o objetivo é atingir um desempenho satisfatório em novas amostras e não somente no treinamento. As duas abordagens principais são:

- a) Aprendizagem baseada em exemplos: o modelo aprende com base nos dados inseridos e, assim, generaliza para novos casos por meio de similaridade;
- b) Aprendizagem baseada em modelo: desenvolve modelos que servem como suporte para sua aprendizagem e, logo após, os utilizam para realizar previsões.

2.5 Redes Neurais Artificiais (RNA)

As RNA são técnicas computacionais que retratam um modelo matemático inspirado na estrutura neural de organismos inteligentes, como o cérebro humano, e que ganham conhecimento por meio da experiência. Neste método, são empregadas unidades de processamento simples que compõem sistemas paralelos distribuídos, denominados de nodos, cujo objetivo é calcular determinadas funções matemáticas, geralmente não lineares. Essas unidades são estruturadas em uma ou mais camadas, as quais são interligadas por um número significativo de conexões (RIBEIRO, 2013).


As tentativas de descobrir conceitos matemáticos de processamento de informações

em sistemas biológicos definiram o termo “rede neural” que tem sido bastante utilizado para retratar diversos tipos de modelos. Entretanto, a eficiência do reconhecimento estatístico de padrões em redes neurais concentra-se na classe específica que demonstraram ter uma maior capacidade prática, isto é, o *Perceptron* Multicamadas ou *Multilayer Perceptron* (MLP) (BISHOP, 2006).

McCulloch e Pitts (1943) foram pioneiros em pesquisas envolvendo RNA, nas quais desenvolveram um modelo computacional simples que posteriormente passou a ser chamado de neurônio artificial e que evidenciava como os neurônios biológicos são capazes de trabalhar juntos para realizar cálculos complexos utilizando lógica proposicional. Esse modelo consistia em um sistema simples, contendo uma ou mais entradas binárias, denominadas por *on* e *off*, e uma saída binária que é ativada quando mais de um determinado número de entradas está ativo (GÉRON, 2017).

Haykin (2009) define neurônio como uma unidade de processamento de informações essencial para o funcionamento de uma rede neural. O modelo de um neurônio molda a premissa para o projeto de uma grande conjunto de redes neurais, conforme exposto na Figura 25.

Figura 25 – Modelo não linear de um neurônio



Fonte: Adaptada de Haykin (2009).

Segundo Haykin (2009), identificam-se três componentes primários do modelo neural, quais sejam: conjunto de sinapses ou elos de conexão, elemento de soma e função de ativação. No primeiro, cada um é definido por um peso ou força própria. Notadamente, multiplica-se um sinal x_j conectado ao neurônio k na entrada da sinapse j pelo peso sináptico w_{kj} . Ressalta-se a importância de registrar a maneira como os subscritos do peso sináptico w_{kj} são escritos. O neurônio em foco é representado pelo primeiro índice em w_{kj} , enquanto o final da entrada da sinapse com seu respectivo peso é retratado pelo segundo. O peso sináptico de

um neurônio artificial pode encontrar-se em um intervalo que contém valores positivos e negativos, em oposição ao peso de uma sinapse no cérebro.

O elemento de soma, por sua vez, realiza um somatório dos sinais de entrada, os quais são ponderados pelos respectivos pesos sinápticos do neurônio, constituindo uma combinação linear. Por fim, a função de ativação, conhecida também como função de esmagamento, determina a amplitude da saída de um neurônio, de forma a limitar a faixa de amplitude permitido do sinal de saída para algum valor finito (HAYKIN, 2009).

O intervalo de amplitude normalizada da saída de um neurônio varia, tipicamente, de $[0,1]$ ou $[-1,1]$. Além disso, pode-se observar pela Figura 25 a presença de um viés, denominado de *bias*, o qual é apontado por b_k e empregado externamente. Esse viés possui a finalidade de alterar a função de ativação da rede, podendo aumentá-la ou diminuí-la, conforme seja positiva ou negativa, respectivamente (HAYKIN, 2009).

Abiodun *et al.*, (2018) descrevem que os neurônios de viés são definidos, em todo caso, como iguais a um, além de terem uma similaridade com o interceptor da regressão linear ($y = ax + b$), na qual a e b representam, nessa ordem, o coeficiente angular da função linear x e o interceptador. Haykin (2009) expõe matematicamente o neurônio k , presente na Figura 25, por meio das Equações 3, 4 e 5.

$$z_k = \sum_{j=1}^m w_{kj} \times x_j \quad (3)$$

$$v_k = z_k + b_k \quad (4)$$

$$y(x) = f(v_k) \quad (5)$$

Em que:

z_k – soma das saídas;

x_j – sinais de entrada;

w_{kj} – respectivos pesos sinápticos do neurônio k ;

$y(x)$ – sinal de saída do neurônio;

$f(.)$ – função de ativação;

b_k – viés ou *bias*.

Neste cenário, Rosenblatt (1958) apresentou os *Perceptrons* que são unidades mais elementares de RNA e baseiam-se em neurônios artificiais ligeiramente distintos, denominados

de unidade de limite linear ou *Linear Threshold Unit* (LTU). Nesse componente cada conexão de entrada é relacionada a um peso e as entradas e saídas são números reais (GÉRON, 2017).

Segundo Haykin (2009), o *Perceptron* foi a primeira rede neural definida como algoritmo, ocupando uma posição de destaque na trajetória de desenvolvimento deste contexto. Essa unidade traduz-se basicamente em um único neurônio composto de pesos sinápticos ajustáveis e viés, além de representar o modo mais elementar de uma rede neural utilizada para classificar padrões tidos como linearmente separáveis, isto é, modelos que se encontram em lados contrários de um hiperplano.


Por último, o processo de treinamento de uma rede *Perceptron* pode ser explicado pelo aumento do peso da conexão entre dois neurônios ao passo que eles têm a mesma saída, tendo em vista o erro cometido pela rede e de modo a não reforçar os vínculos que direcionam à saída errada. Dessa forma, o *Perceptron* gera as observações de treinamento uma por vez, fazendo previsões para cada observação. Logo, para cada neurônio de saída que efetuou uma previsão incorreta, o algoritmo reforça os pesos de conexão das entradas que teriam favorecido para a previsão correta (GÉRON, 2017).

2.5.1 *Perceptron Multicamadas (MLP) e o algoritmo de retropropagação do erro*

O *Perceptron Multicamadas* (MLP) consiste em um tipo de rede neural similar ao *Perceptron* simples, porém com um número indeterminado de neurônios presentes em um conjunto de camadas, quais sejam: camada de entrada; uma ou mais camadas ocultas ou intermediárias (*hidden layers*); camada de saída. Dessa forma, os sinais de entrada percorrem a rede, camada por camada, em sentido positivo, ou seja, da entrada para a saída, movimento denominado *feedforward* (BOCANEGRA, 2002).

Em seguida ao *feedforward*, o algoritmo realiza um contraste entre o valor esperado e o valor atingido pelo modelo, de forma a identificar os erros na saída. Então, a rede verifica a contribuição de cada neurônio, presente na camada intermediária anterior, para o erro da saída. Esse processo continua até o modelo atingir a camada de entrada. Na Figura 26 expõe-se o diagrama de uma rede MLP.

Figura 26 – Diagrama de uma rede MLP




Fonte: Adaptada de Géron (2017).

Para Géron (2017), o MLP elabora uma previsão no sentido entrada-saída para cada exemplo de treinamento por meio do algoritmo de retropropagação (*backpropagation*). Dessa forma, essa ferramenta percorre cada camada no sentido inverso (saída-entrada) para medir o erro e verificar a contribuição dessa incorreção para cada conexão. Por fim, o algoritmo faz ajustes nos pesos da conexão a fim de reduzir o erro.

De acordo com Bishop (2006), o algoritmo de retropropagação do erro consiste em duas fases principais, a saber: *forward* e *backward*. O primeiro procedimento se resume na aplicação e propagação de um vetor com os dados de entrada (x) na rede com o objetivo de identificar as ativações de todos os neurônios ocultos e de saída. Então, analisa-se o erro encontrado entre o valor alvo (*target*) e o valor estimado pela rede. Logo, tem-se o segundo procedimento que se traduz na retropropagação do erro no sentido oposto (saída-entrada) a fim de verificar o erro em cada neurônio. Por fim, os pesos são ajustados por meio das derivadas das funções de ativação dos neurônios. As Figuras 27 e 28 apresentam os procedimentos de *forward* e *backward*, respectivamente. Ressalta-se que o viés (*bias*) foi omitido do diagrama para fins de simplificação.

Figura 27 – Diagrama do procedimento forward de uma rede MLP



$$y_l = f(z_l)$$

$$z_l = \sum_{k \in H2} w_{kl} y_k$$

$$y_k = f(z_k)$$


$$z_k = \sum_{j \in H1} w_{jk} y_j$$

$$y_j = f(z_j)$$

$$z_j = \sum_{i \in \text{Input}} w_{ij} x_i$$

Fonte: Adaptada de Lecun, Bengio e Hinton (2015).

Figura 28 – Diagrama do procedimento backward de uma rede MLP



Fonte: Adaptada de Lecun, Bengio e Hinton (2015).

2.5.2 Funções de ativação


Ribeiro (2013) define a função de ativação como a responsável pelo processamento em cada neurônio, isto é, qualquer unidade de processamento está relacionada a um estado de ativação determinado por essa função, a qual envia um sinal por um certo neurônio aos demais a ele vinculados. As funções comumente utilizadas são a linear, a degrau, a sigmóide, a tangente hiperbólica e a linear retificada (ReLU), conforme apresentado na Tabela 2 e na Figura 29.

Tabela 2 – Principais funções de ativação

Descrição	Função	Derivada
Soma dos pesos das entradas (inputs)	$z = w^T \times X$	-
Função Linear	$f(z) = z$	Constante
Função Sigmóide	$\sigma(z) = \frac{1}{1 + e^{-z}}$	$\sigma'(z) = \sigma(z) \times (1 - \sigma(z))$
Função Tangente Hiperbólica	$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	$\tanh'(z) = 1 - \tanh^2(z)$
Função Linear Retificada	$\text{ReLU}(z) = \max(0, z)$	$\text{ReLU}'(z) = \begin{cases} 1 & \text{se } z \geq 0 \\ 0 & \text{caso contrário} \end{cases}$

Fonte: Elaborada pelo autor.

Figura 29 – Principais funções de ativação



Fonte: Adaptada de Géron (2017).

Por fim, existem outras funções de ativação que derivam das funções principais

supracitadas, tais como: *SoftPlus*, *Softmax*, *Softsign*, *Hard_sigmoid*. Contudo, ressalta-se que o objeto desta pesquisa pretende analisar a aplicação das RNA como ferramenta de modelagem para a previsão do coeficiente de atrito medido em pistas de pouso e decolagem brasileiras. Dessa forma, este estudo não tem a intenção de abordar novos conceitos ou propor teorias para o melhoramento, aprofundamento ou entendimento desta técnica.

2.5.3 Hiperparâmetros


As RNA possuem diversos hiperparâmetros de entrada que influenciam diretamente os resultados do algoritmo, tais como: a arquitetura da rede (número de camadas ocultas e de neurônios), as funções de ativação, entre outros. Com efeito, faz-se necessário a verificação de cada hiperparâmetro para analisar quais valores favorecem a prevenção de erros relacionados ao viés (*bias*) e à variância, e assim, elevar sua precisão.

O erro associado ao viés pode ser retratado como o contraste entre o valor previsto pelo algoritmo e o valor alvo (*target*) exato, o qual o modelo tenta antecipar. De acordo como novos dados são combinados, executa-se uma nova análise e, conseqüentemente, um novo modelo é gerado. Desse modo, os modelos resultantes disporão de várias previsões em razão da aleatoriedade presente nos conjuntos de dados subjacentes. Em síntese, o viés afere a distância entre as previsões destes modelos e o valor correto (FORTMANN-ROE, 2012).

Segundo Fortmann-Roe (2012), o erro em virtude da variância pode ser compreendido como a oscilação de uma previsão de modelo para um certo ponto de dados. Desse modo, o processo descrito anteriormente é repetido, no qual a inserção de novos dados e a realização de novas análises resultam em novos modelos. Logo, a variância diz respeito à quantidade de variação entre diferentes realizações do modelo em relação a um determinado ponto.

Fortmann-Roe (2012) afirma que o impasse entre o viés e a variância é dado conforme a complexidade do modelo, o qual é definido de acordo com: o número de observações de treinamento; as variáveis de entrada; as camadas ocultas e de seus neurônios; os neurônios de saída; a quantidade de iterações. A Figura 30 expõe o diagrama de viés e variância.

Figura 30 – Diagrama de viés e variância




Fonte: Adaptada de Fortmann-Roe (2012)

De acordo com Singh (2018), o subajuste no aprendizado supervisionado acontece quando há um número muito pequeno de dados para desenvolver um modelo acurado ou quando são utilizados dados não lineares para tentar construir um modelo linear. Isso posto, esse termo, denominado também por *underfitting*, é observado, geralmente, em modelos com alto viés e baixa variação.

O sobreajuste, por sua vez, ocorre quando o modelo assimila o ruído junto ao padrão existente nos dados. Esse termo, chamado também de *overfitting*, é verificado quando se utiliza conjunto de dados com muito ruído para treinar os modelos, os quais possuem, em geral, baixo viés e alta variância, além de serem complexos. Na Figura 31 são ilustrados exemplos de modelos com *overfitting*, *underfitting* e balanceado (SINGH, 2018).


Figura 31 – Exemplos de modelos



Fonte: Adaptada de Singh (2018).

Para Fortmann-Roe (2012), o erro de um modelo pode ser definido por meio do viés, da variância e do erro irreduzível. Este último, por sua vez, representa o ruído existente no modelo e não pode ser diminuído por nenhum modelo. Todavia, os dois primeiros termos podem ser reduzidos a zero, mas considerando uma hipótese de dados finitos, necessitando minorar o viés e a variância no sentido de obter o melhor resultado, conforme exposto na Figura 32.

Figura 32 – Equilíbrio ideal de um modelo



Fonte: Adaptada de Fortmann-Roe (2012)

Shahin, Maier e Jaksa (2004) destacam certas abordagens para o fracionamento dos dados em subconjuntos de treino, teste e validação do algoritmo, das quais ressaltam-se:

- a) Divisão aleatória dos dados: recurso mais comum empregado, no qual os dados geralmente são divididos em parcelas que variam de 70 a 90% para o treinamento e de 30 a 10% para o teste;
- b) Estatisticamente consistente: estratégia em que se busca preservar as mesmas propriedades estatísticas, como a média e o desvio padrão, para todos os subconjuntos;
- c) Mapa auto-organizável (*Self-Organizing Map* – SOM): método em que há a redução da dimensionalidade dos dados e a garantia de que todos os subconjuntos são representativos uns dos outros. Além disso, não existe a necessidade de determinar quais proporções do conjunto de dados deve ser reservada para cada subconjunto, diferentemente das duas primeiras abordagens.
- d) *Fuzzy Clustering*: estratégia que opera equivalente ao SOM, por meio do agrupamento de dados semelhantes.

Segundo Bossche *et al.*, (2021), os principais hiperparâmetros de entrada utilizados em códigos MLP são: neurônios ou nodos; quantidade de camadas ocultas; função de ativação; *solver*; *alpha*; taxa de aprendizagem; taxa de aprendizagem inicial; número máximo de iterações. Estes elementos são empregados no desenvolvimento de um sistema MLP por meio da biblioteca *Scikit-learn*, o qual pode ser definido como uma parcela da linguagem de programação *Python* que é uma das mais populares, além de compor uma vasta diversidade de algoritmos de *Machine Learning* para resolução de problemas supervisionados ou não de escala mediana (PEDREGOSA *et al.*, 2011).

Além da *Scikit-learn*, tem-se também a biblioteca *TensorFlow*, a qual objetiva facilitar o desenvolvimento de redes neurais mais profundas (aquelas com mais de uma camada

oculta e que utilizam uma grande quantidade de dados). Esta biblioteca pode ser utilizada em variados modelos de aprendizagem e treinamento sem interferir no funcionamento padrão dos sistemas nos quais está sendo empregada (ABADI *et al.*, 2016; GÉRON, 2017).

Assim, estabelece-se a estrutura da rede por meio das camadas ocultas e dos neurônios presentes nelas. Logo após, faz-se a seleção da função de ativação, quais sejam: linear – *identity*; sigmóide – *logistic*; tangente hiperbólica – *tanh*; linear retificada – *relu* (BOSSCHE *et al.*, c2007-2021). Ao passo que o *solver*, de acordo com Bossche *et al.*, (2021), é descrito como um otimizador de pesos, em que se utiliza geralmente o *LBFGS* ou o *Stochastic Gradient Descent* (SGD). O primeiro pertence à família do método quase-Newton e é empregado em conjuntos de dados menores, visto que o resultado pretendido é alcançado mais rapidamente, entretanto, possui algumas limitações como não permitir a parada antecipada, não empregar o conjunto de validação e não apresentar a curva de função de perda do treinamento do algoritmo. Já o SGD é aplicado para conjuntos de dados maiores, da ordem de milhares.

Tem-se também outros otimizadores como o Adagrad e o RMSprop, os quais são baseados em gradiente e aplicados na biblioteca *Tensorflow*. O primeiro consiste em um algoritmo que adapta a taxa de aprendizagem aos parâmetros, realizando atualizações menores (ou seja, taxas de aprendizagem baixas) para parâmetros associados a recursos de ocorrência frequente e atualizações maiores (ou seja, alta aprendizagem taxa) para parâmetros associados a recursos pouco frequentes. Enquanto o RMSprop é um método de taxa de aprendizagem adaptativa não publicado proposto por Geoff Hinton, o qual foi desenvolvido pela necessidade de resolver as taxas de aprendizagem radicalmente decrescentes do Adagrad e consiste em uma técnica de otimização que é utilizada no treinamento de RNA (DUCHI, HAZAN; SINGER, 2011; TIELEMAN; HINTON, 2012).


Segundo Bossche *et al.*, (2021), o objetivo do *alpha* é evitar o excesso de ajuste, de modo a atuar como componente de regularização para que o algoritmo adquira a capacidade de ter um desempenho aceitável mesmo em um conjunto para o qual não foi treinado. A taxa de aprendizagem define a proporção de atualização dos pesos que pode ser estipulada como constante, diminuição gradual e adaptável, de modo que a taxa inicial determina a extensão fase na atualização dos pesos. Os hiperparâmetros pertencentes a este elemento são empregados somente para o otimizador SGD. Por último, a quantidade máxima de iterações diz respeito ao número de iterações que o algoritmo pode realizar até obter um modelo com erro mínimo.

2.5.4 Validação cruzada

A validação cruzada pode ser descrita como uma técnica para avaliar a capacidade de generalização de modelos de *Machine Learning*, na qual encontram-se diversos métodos, tais como: *Leave One Out* (LOO), *Leave P Out* (LPO), *k-fold*, entre outros. Essa técnica permite detectar o sobreajuste, isto é, a não generalização de um padrão (BOSSCHE *et al.*, 2022).

De acordo com Bossche *et al.*, (2022), o método *k-fold* consiste em dividir o conjunto de dados aleatoriamente em *k* (*folds*) subconjuntos iguais e mutualmente exclusivos. Assim, o modelo é treinado para todas as partições menos em uma ($k - 1$) do conjunto de dados para, em seguida, testar na partição que não foi utilizada no treinamento. Esse processo é realizado *k* vezes com um subconjunto diferente destinado para a avaliação e excluído do treinamento, conforme a Figura 33.

Figura 33 – Validação cruzada com $k = 5$



Fonte: Bossche *et al.*, (2022).

A Figura 33 exibe um exemplo de validação cruzada com cinco *folds*, na qual são gerados cinco subconjuntos de treinamento e de teste a partir de um conjunto de dados. Dessa forma, para cada processamento (*split*) utiliza-se um subconjunto (*fold*) diferente para teste e o demais para treinamento, de forma sucessiva (BOSSCHE *et al.*, 2022).

2.5.5 Aplicação das Redes Neurais Artificiais na Infraestrutura de Transportes

Ao abordar a utilização das Redes Neurais Artificiais (RNA) em infraestrutura de transportes, especificamente na área de Sistema de Gerência de Pavimentos (SGP), Flintsch, Zaniewski e Delton (1996) produziram um modelo, por meio de RNA, para auxiliar a seleção de segmentos de rodovias que receberam atividades de manutenção, utilizando dados dos

pavimentos relacionados às suas condições, à sua localização e aos seus custos de manutenção. Este estudo pretendia diminuir a subjetividade deste procedimento e reduzir a probabilidade de erros. O resultado obtido foi uma arquitetura capaz de acertar 76% na fase teste, a qual é constituída por 18 neurônios na camada de entrada, 15 neurônios em uma camada oculta e um neurônio em uma camada de saída [18-15-1].

Fwa, Chan e Lim (1997) desenvolveram um modelo com a finalidade de indicar a precisão ou não de manutenção em PPD e, dessa forma, reduzir a relatividade presente na tomada de decisão que usualmente gera decisões diferentes entre a equipe técnica acerca do momento ideal para realizar a remoção de acúmulo de borracha da PPD. A estrutura era composta de 4 neurônios de entrada, 11 na camada oculta e 1 na camada de saída [4-11-1] e apresentou somente 9,4% de previsões erradas, das quais menos de 4% dos cenários indicaram divergência da necessidade de manutenção.

No mesmo contexto, Bosurgi e Trifirò (2005) criaram dois modelos de RNA com o intuito de auxiliar a tomada de decisão em relação à escolha de serviços de manutenção, visando a solução mais econômica e com o maior coeficiente de atrito. A arquitetura do primeiro modelo visava determinar o Coeficiente de Atrito Transversal (CAT) e apresentava 2 neurônios na camada de entrada, 3 neurônios em uma camada oculta e um neurônio na camada de saída [2-3-1]. Os resultados revelaram para as fases de treinamento e teste, um Erro Quadrático Médio (EQM), de 0,045 e 0,072, respectivamente. Quanto ao segundo modelo, este foi desenvolvido com o intuito de prever a quantidade de acidentes nas rodovias definidas e apresentava uma estrutura [7-5-1], atingindo um EQM de 0,037 e 0,063 para as fases de treinamento e teste, respectivamente.

Thube (2012), por sua vez, elaborou modelos de previsão, por meio de RNA, de determinados parâmetros superficiais de pavimentos, como a taxa de área trincada e o Índice Internacional de Irregularidade (IRI), com o objetivo de contribuir para a tomada de decisão quanto à manutenção em rodovias de baixo volume de tráfego da Índia. Verificou-se que esses modelos apresentaram Coeficientes de Determinação (R^2) variando de 91,9 a 98,9% e que eles foram mais eficientes em relação aos modelos utilizados pelo *software* HDM-4.

Domitrović *et al.*, (2018), também para indicar atividades de manutenção necessárias, desenvolveram algoritmo de RNA com o propósito de contribuir com o SGP. Como resultado, o modelo apresentou na fase de teste um EQM de 0,031 e 0,023.

Najafi, Flintsch e Khaleghian (2019) utilizaram os algoritmos *Levenberg-Marquardt* (LM), gradiente conjugado e retropropagação resiliente, para produzir três modelos de RNA, os quais visavam prever a taxa de acidentes em pavimentos com e sem a presença de

água. A rede, utilizando o código LM e uma estrutura [4-8-2], apresentou o melhor desempenho, apresentando como resultado um EQM de 0,006 e 0,016 para condições de ausência e de presença de água, respectivamente.

Hossain, Gopisetti e Miah (2019) criaram um modelo de RNA para prever o IRI em rodovias norte-americanas por meio de dados fornecidos no *Long-Term Pavement Performance* (LTTP). O resultado, considerado aceitável, retratou uma Raiz do Erro Quadrático Médio (REQM), de 0,01 operando com uma estrutura [7-9-9-1].

Modelos de RNA foram elaborados por Yao *et al.*, (2019) para prever certos parâmetros de rodovias chinesas, dentre eles o CAT. Como resultado, foram observados nas fases de treinamento e de teste um R^2 de 86,53% e 86,10%, respectivamente. Em se tratando do CAT, foram utilizadas cerca de 120 mil observações a fim de obter um modelo de previsão eficiente.

Por fim, Quariguasi, Oliveira e Reis (2021) produziram um modelo de RNA para estimar o coeficiente de atrito em PPD, utilizando uma estrutura com duas camadas ocultas com 94 e 73 neurônios. Os resultados indicaram, para as fases de treinamento e teste, um R^2 de 77,63% e 77,51%, e um EQM de 0,0018 e 0,0021, respectivamente. De acordo com os autores, o modelo demonstrou ser viável para a aplicação e gerenciamento das condições de segurança operacional.

3 MÉTODO DE PESQUISA

Neste capítulo, descreve-se o método para o levantamento e processamento dos dados, assim como as variáveis escolhidas e o desenvolvimento do modelo de Redes Neurais Artificiais (RNA) para a previsão do coeficiente de atrito medido a 3 e a 6 metros nas pistas de pouso e decolagem (PPD) dos aeroportos internacionais de Fortaleza/CE e de Brasília/DF. Além disso, expõem-se as técnicas utilizadas para verificação da taxa de acerto e dos erros dos modelos desenvolvidos.

3.1 Seleção dos aeródromos

Os aeródromos escolhidos foram os aeroportos internacionais de Fortaleza (código ICAO: SBFZ) e de Brasília (código ICAO: SBBR), ambos com pavimentos flexíveis de concreto asfáltico em suas PPD. O primeiro foi selecionado em razão da quantidade de dados disponibilizados pela Agência Nacional de Aviação Civil (ANAC) e pela sua relevância para o estado do Ceará, sendo o terceiro com maior participação na Região Nordeste para o ano de 2021 (ANAC, 2021a). Por sua vez, o segundo foi definido devido a existência de *grooving* em uma de suas PPD e por ser importante para a movimentação aérea do país. Expõem-se algumas características físicas e operacionais relevantes desses aeroportos na Tabela 3.

Tabela 3 – Características físicas e operacionais do SBFZ e SBBR

Código ICAO	Identificação da pista	Comprimento da PPD (m) / Largura da PPD (m)	Número de operações de pousos e decolagens		Participação no cenário nacional (ANAC, 2021a)	Classificação (ANAC, 2021a)
			2020	2021		
SBFZ	13/31	2.755/45	32.897	41.343	2,47%	12°
SBBR	11L/29R	3.200/45	79.415	102.897	7,03%	3°
SBBR	11R/29L	3.300/45				

Fonte: Elaborada pelo autor.

Ressalta-se que a PPD do SBFZ foi ampliada de 2.545 m para 2.755 m em agosto de 2021 (ANAC, 2021b). Ainda, o tráfego aéreo reduziu consideravelmente no ano de 2020 devido à pandemia do novo Coronavírus. A queda da quantidade de operações entre o ano de 2019 e 2020 foi de cerca de 44% para ambos os aeroportos. Em 2019, o SBFZ realizou 59.693 operações, enquanto o SBBR operou 143.772. Por outro lado, o tráfego aéreo cresceu em 2021, mas não atingiu os números pré-pandemia (FRAPORT, 2022; INFRAMÉRICA, 2022).

3.2 Escolha das variáveis e coleta de dados

Diversos são os fatores que impactam a aderência pneu-pavimento e, consequentemente, o coeficiente de atrito, dentre os principais, ressaltam-se aqueles referentes ao tipo de revestimento do pavimento (concreto asfáltico), ao tráfego de aeronaves e às condições climáticas.

Dessa forma, empregaram-se variáveis com precedentes em modelos passados aplicados em rodovias e aeroportos, a saber: manutenção periódica (remoção de borracha), idade do revestimento, temperatura ambiente, umidade relativa do ar e tráfego (ANUPAM *et al.*, 2013; FWA; CHAN; LIM, 1997; OLIVEIRA, 2017; QUARIGUASI; OLIVEIRA; REIS, 2021; SANTOS *et al.*, 2014; SUSANNA *et al.*, 2017; YAO *et al.*, 2019). Além disso, destaca-se que, neste trabalho, foi considerada a existência ou não de *grooving* na PPD e que foram utilizados dados de coeficiente de atrito medido pelos equipamentos *GripTester*, *Skidometer* e *Mu-Meter*. Em seguida, realizou-se a coleta dos dados, a saber:

- a) Coeficiente de atrito medido a 3 m e 6 m de ambos os lados – direito e esquerdo – do eixo da pista;
- b) Distância longitudinal de medição do coeficiente de atrito em metros;
- c) Lado – direito/esquerdo – da medição do coeficiente de atrito;
- d) Equipamento utilizado na medição do coeficiente de atrito;
- e) Data da remoção do acúmulo de borracha;
- f) Idade do revestimento da PPD em meses;
- g) Temperatura ambiente em grau Celsius;
- h) Umidade relativa do ar em porcentagem;
- i) Existência de *grooving*;
- j) Quantidade de operações (pousos e decolagens).

Os dados relativos ao coeficiente de atrito, quais sejam, medição a 3 m e a 6 m, distância de medição, lado da medição e o equipamento utilizado no ensaio, foram obtidos por meio de relatórios técnicos fornecidos pela Superintendência de Infraestrutura Aeroportuária da Agência Nacional de Aviação Civil (SIA/ANAC), totalizando 22 relatórios para o SBBR e 41 para o SBFZ realizados entre os anos de 2012 e 2018. Além desses elementos, também constavam nos relatórios a data em que foi realizada a última remoção de acúmulo de borracha e a existência ou não de *grooving*.

Ressalta-se que os valores de coeficiente de atrito iguais ou acima de 1,0 foram excluídos da base de dados, visto que os pavimentos analisados não são novos e possuem desgastes no revestimento causados pelo tráfego das aeronaves e ação ambiental. Os valores excluídos não condizem com o estado dos pavimentos em operação.

A idade do revestimento da PPD foi obtida por meio de informação fornecida pela Empresa Brasileira de Infraestrutura Aeroportuária (Infraero), pela ANAC e pela Inframérica, concessionária operadora do Aeroporto Internacional de Brasília.

As informações climáticas, por sua vez, foram conseguidas por meio da identificação da estação, situada no Aeroporto Internacional de Fortaleza, pelo número sinótico 82398, no sítio eletrônico do banco de dados climatológicos do Instituto de Controle do Espaço Aéreo (ICEA). Esses dados foram retratados pela média horária mensal devido à não disponibilização por dia e hora.

Para o SBFZ, a temperatura e a umidade relativa do ar foram obtidas tanto por meio do ICEA quanto pelos relatórios de medição do coeficiente de atrito. Para o SBBR, considerou-se apenas esses relatórios como fonte para estas duas variáveis.

Em relação à quantidade de operações de pousos e decolagens, essas foram obtidas por meio do sítio eletrônico da ANAC e da concessionária Inframérica. Esse dado foi computado de três modos diferentes com o intuito de representar diferentes cenários e um melhor desempenho dos modelos propostos neste trabalho. Assim, analisaram-se a quantidade de operações de pousos e decolagens:

- a) Entre as medições de coeficiente de atrito;
- b) Por ano;
- c) Entre os procedimentos de remoção de acúmulo de borracha.

Destaca-se que não houve especificação do modelo de aeronave utilizada em cada operação. Além disso, o número de operações foi contabilizado proporcionalmente de acordo com a data de medição, visto que este dado é disponibilizado por mês.

Os relatórios de medição de coeficiente de atrito utilizados nesta dissertação, para o SBFZ, foram realizados com os equipamentos *GripTester* e *Skiddometer*, ambos a 65 km/h, cuja distância de aceleração foi de 100 m a partir da cabeceira predominante. Para o SBBR, foi empregado o equipamento *Mu-meter* na mesma velocidade, porém, com uma distância de aceleração de 150 m a partir da cabeceira predominante.

Ressalta-se que o coeficiente de atrito possui valores detalhados a cada 100 m de segmento avaliado. Para o SBFZ, de modo geral, são medidos entre 2.300 m e 2.400 m da PPD com exceção de alguns relatórios que possuem 2.100 m. Para o SBBR, são aferidos entre 2.900 m e 3.000 m a depender da PPD. Dessa forma, têm-se no mínimo 84 valores de coeficiente de atrito por relatório, considerando as duas distâncias e os dois lados do eixo da PPD em uma extensão de 2.100 m.

3.3 Processamento e tratamento de dados

Em seguida à obtenção dos relatórios de coeficiente de atrito, sucedeu-se a extração manual e a ordenação dos dados em planilha eletrônica. Destaca-se que os relatórios são disponibilizados de forma não ordenada e em formato de imagem digitalizada em *Portable Document Format* (PDF). Além disso, os relatórios obtidos não fornecem todos os dados utilizados, havendo a necessidade de consultar outras fontes, tais como dados estatísticos obtidos por meio da ANAC e dos operadores de aeródromos. Foram utilizadas, também, quatro variáveis categóricas, conforme a Tabela 4.

Tabela 4 – Descrição e representação das variáveis categóricas

Descrição da variável categórica	Categoria	Representação no banco de dados
Realização de remoção de acúmulo de borracha desde a última medição	Não	0
	Sim	1
Lado no qual foi medido o coeficiente de atrito	Esquerdo	0
	Direito	1
Existência do elemento <i>Grooving</i>	Ausência	0
	Presença	1
Equipamento utilizado para aferição do coeficiente de atrito	<i>Mu-meter</i>	1
	<i>Skiddometer</i>	2
	<i>Griptester</i>	3

Fonte: Elaborada pelo autor.

Destaca-se que a operação de remoção de acúmulo de borracha foi considerada apenas para o primeiro terço da PPD, isto é, os 900 m e 1.100 m iniciais da cabeceira predominante para o SBFZ e SBBR, respectivamente. Isso foi considerado em razão desse segmento ser a zona de toque das aeronaves, na qual é depositada a borracha, sobretudo, durante os pousos.

Na sequência da ordenação dos dados, aplicou-se uma matriz de correlação entre as variáveis utilizadas para o desenvolvimento desse modelo, excetuando-se as do tipo categóricas. Dessa forma, tem-se uma análise inicial da relação entre os parâmetros independentes e dependentes. Ainda, testou-se o pré-processamento dos dados utilizando o *Standard Scaler* (std), no qual as variáveis apresentam média 0 e variância igual a 1, de acordo com a Equação 6.

$$z = \frac{(x - \bar{x})}{s} \quad (6)$$

Em que:

z – valor normalizado

x – valor a ser normalizado;

$\bar{x}$ – média das amostras de treinamento;

s – desvio padrão das amostras de treinamento.

O pré-processamento é um quesito comumente empregado em avaliadores de Aprendizado de Máquina (AM), visando padronizar os dados distribuídos para o modelo não apresentar resultados insatisfatórios e para as variáveis apresentarem um valor próximo entre elas, isto é, com a mesma grandeza. Desse modo, todos os dados são convergidos para um número próximo de 0 e possuem a mesma ordem de variação, estando contidos nos intervalos $[0,1]$ ou $[-1,1]$ (BOSSCHE *et al.*, 2021).

Por fim, os dados foram estruturados em uma matriz $M_{m \times n}$ para inserção no algoritmo. Nessa matriz, m representa a quantidade de ocorrências distribuídas em linhas e n a quantidade de variáveis separas em colunas, em que se incluem os *targets*, o coeficiente de atrito medido a 3 m e a 6 m, na última coluna. Logo, associou-se cada valor de coeficiente de atrito (y_1 e y_2) com sua respectiva linha de variáveis (x_i).

3.4 Desenvolvimento do modelo

Na última etapa, tem-se o desenvolvimento dos modelos de Redes Neurais Artificiais (RNA) tipo *Perceptron* Multicamadas (MLP), no qual foi aplicado o algoritmo de *backpropagation*. O conjunto de dados foi segmentado, sem repetição e de maneira aleatória, em uma proporção de 80% para treinamento e de 20% para teste.

Utilizou-se o Coeficiente de Determinação (R^2) para verificar a taxa de acerto do algoritmo, conforme exposto na Equação 7. Enquanto para a verificação do erro foram empregados o Erro Quadrático Médio ou *Mean Squared Error* (MSE) e o Erro Absoluto Médio ou *Mean Absolute Error* (MAE), representados pelas Equações 8 e 9.

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

$$\text{MSE}(y, \hat{y}) = \frac{1}{m} \sum_{i=0}^{m-1} (y_i - \hat{y}_i)^2 \quad (8)$$

$$\text{MAE}(y, \hat{y}) = \frac{1}{m} \sum_{i=0}^{m-1} |y_i - \hat{y}_i| \quad (9)$$

Em que:

R^2 – Coeficiente de Determinação;

y – valor de coeficiente de atrito observado;

$\hat{y}$ – valor de coeficiente de atrito previsto;

$\bar{y}$ – média do coeficiente de atrito observado;

MSE – *Mean Squared Error*;

m – quantidade observações;

MAE – *Mean Absolute Error*.

O modelo foi desenvolvido utilizando um *desktop* composto de um processador AMD Ryzen 5 1600X (CPU @ 3.6GHz) e de uma placa de vídeo GeForce GTX 1650 com 4GB de memória, bem como a linguagem de programação *Python* por meio da plataforma de distribuição *Anaconda*, a qual é gratuita, de código aberto e utilizada para aplicações relacionadas à ciência de dados e aprendizado de máquina. As bibliotecas empregadas no algoritmo foram a *Scikit-learn* e o *Tensorflow*.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Neste capítulo, apresentam-se a análise dos resultados e as discussões acerca dos modelos desenvolvidos nesta pesquisa. Primeiramente, verificou-se a correlação entre as variáveis. Na sequência, foram testadas diversas arquiteturas de Redes Neurais Artificiais (RNA) com diferentes funções de ativação e otimizadores com o objetivo de definir a estrutura mais eficaz para os modelos. Em seguida, analisou-se a acurácia dos modelos, utilizando todas as variáveis e depois removendo algumas variáveis. Por último, realizou-se uma verificação da influência do dispositivo *grooving* nos valores do coeficiente de atrito.

4.1 Determinação das variáveis

Os dados obtidos foram inicialmente ordenados em planilha eletrônica para melhor manipulação e organização, sucedendo a elaboração de uma matriz de correlação entre as variáveis quantitativas. Ressalta-se que a extração e ordenação dos dados foi realizada manualmente e demandou bastante tempo e esforço. Dessa forma, pode-se identificar a relação entre os parâmetros independentes e dependentes, conforme expresso na Tabela 5.

Tabela 5 – Matriz de correlação entre as variáveis

Variáveis	Distância de medição	Idade do pavimento	Temperatura	Umidade	Quantidade de operações entre medições	Quantidade de operações entre remoções	Quantidade de operações anuais	Coeficiente de atrito a 3 m	Coeficiente de atrito a 6 m
Distância de medição	1	-	-	-	-	-	-	-	-
Idade do pavimento	-0,03	1	-	-	-	-	-	-	-
Temperatura	-0,14	0,08	1	-	-	-	-	-	-
Umidade	-0,13	0,41	0,15	1	-	-	-	-	-
Quantidade de operações entre medições	0,10	0,01	-0,27	-0,20	1	-	-	-	-
Quantidade de operações entre remoções	0,04	-0,06	-0,06	-0,05	0,39	1	-	-	-
Quantidade de operações anuais	0,08	-0,08	-0,14	-0,46	0,26	0,08	1	-	-
Coeficiente de atrito a 3 m	0,01	0,10	0,29	0,28	-0,28	-0,07	-0,12	1	-
Coeficiente de atrito a 6 m	-0,16	0,07	0,17	0,27	-0,19	-0,07	-0,10	0,69	1

Fonte: Elaborada pelo autor.

Haykin (2001) indica utilizar variáveis com Coeficiente de Correlação (R) superiores a 0,30 ou inferiores a -0,30 em redes neurais, mas durante a modelagem neural recomenda-se utilizar todas as variáveis do banco de dados, mesmo aquelas que não atingiram o R indicado, para depois realizar uma seleção mais acertada das variáveis. Embora as variáveis não tenham apresentado a correlação linear indicada com o coeficiente de atrito, optou-se por utilizá-las na elaboração dos modelos devido à sua importância, principalmente para a variação do coeficiente de atrito e para a indicação da sua localização na PPD.

Foram selecionados 22 e 41 relatórios do SBBR e do SBFZ, respectivamente, contemplando as variáveis quantitativas de distância de medição, temperatura, umidade e coeficiente de atrito a 3 m e a 6 m, cujas datas de medição estão expostas na Tabela 6. Acerca da estatística descritiva das variáveis – exposta na Tabela 7, incluindo, também, as variáveis relativas às operações e à idade do pavimento.

Tabela 6 – Datas dos relatórios de medição utilizados no modelo

SBFZ			SBBR	
Pista 13/31			Pista 11L/29R	Pista 11R/29L
13/02/2012	24/03/2015	22/06/2017	10/10/2015	20/11/2015
23/06/2012	09/04/2015	09/10/2017	12/11/2015	12/07/2016
01/10/2012	13/05/2015	23/11/2017	08/01/2016	13/10/2016
20/11/2012	12/06/2015	20/02/2018	05/02/2016	13/04/2017
21/12/2012	10/07/2015	19/05/2018	25/02/2016	20/10/2017
20/01/2013	13/08/2015	15/08/2018	25/04/2016	23/03/2018
22/02/2013	10/09/2015	15/02/2019	10/05/2016	
24/05/2013	09/10/2015	15/05/2019	20/06/2016	
11/07/2013	10/11/2015	14/08/2019	24/06/2016	
25/08/2013	09/12/2015		22/07/2016	
30/11/2013	11/01/2016		11/08/2016	
23/02/2014	13/04/2016		29/08/2016	
18/05/2014	01/07/2016		19/12/2016	
12/08/2014	30/09/2016		09/01/2017	
24/11/2014	01/11/2016		04/04/2017	
21/02/2015	28/03/2017		13/07/2017	

Fonte: Elaborada pelo autor.


Tabela 7 – Estatística descritiva das variáveis selecionadas para o modelo

Variável	Média	Desvio Padrão	Coefficiente de variação	Mínimo	Máximo
Coeficiente de atrito a 3 m	0,71	0,10	0,14	0,38	0,99
Coeficiente de atrito a 6 m	0,74	0,08	0,11	0,47	0,99
Idade do pavimento (meses)	35,99	26,68	0,74	0,86	120,66
Temperatura (°C)	29,98	3,29	0,11	20	35
Umidade (%)	56,10	19,07	0,34	18	93
Quantidade de operações entre as medições de atrito	13.047	10.696	0,82	1.939	55.056
Quantidade de operações entre as remoções de borracha	10.654	11.761	1,10	121	61.235
Quantidade de operações anuais	31.314	20.841	0,66	1.691	82.759

Fonte: Elaborada pelo autor.

Dessa forma, buscou-se desenvolver dois modelos de previsão, cujos *targets* são o coeficiente de atrito a 3 m e a 6 m de distância do eixo da PPD em ambos os lados. Em ambos os modelos foram empregadas as mesmas variáveis categóricas e contínuas, quais sejam: distância de medição; lado da medição; remoção de borracha; *grooving*; equipamento utilizado na medição; idade do pavimento; temperatura; umidade; quantidade de operações entre as medições de atrito; quantidade de operações entre as remoções de borracha; quantidade de operações anuais. A Figura 34 ilustra a RNA com a camada de entrada, as camadas ocultas e a camada de saída.

Figura 34 – Ilustração da RNA com as variáveis utilizadas



Fonte: Elaborada pelo autor.

Buscou-se também desenvolver uma Rede Neural Artificial que compreendesse os parâmetros de coeficiente de atrito mínimo e de manutenção definidos pela ANAC (2019), os quais são diferentes para cada tipo de equipamento utilizado na medição. Então, estudou-se a possibilidade de utilizar a diferença entre o coeficiente de atrito medido em pista e os valores desses parâmetros. Entretanto, essa estratégia não se mostrou eficaz, visto que esses parâmetros são números fixos que variam somente na mudança do equipamento de medição, ou seja, essa distância seria uma variável dependente apenas do coeficiente de atrito medido, o qual seria a variável alvo mais adequada.

O processamento demandou muito esforço computacional, pois foram necessárias, em média, 35 horas para testar todas as arquiteturas. Por sua vez, o processamento do modelo escolhido levou em torno de 5 minutos.

4.2 Resultados dos modelos AT3 e AT6

Este item trata da análise dos resultados dos modelos denominados modelo AT3 e modelo AT6, os quais possuem o coeficiente de atrito a 3 m e a 6 metros do eixo da PPD como variável alvo, respectivamente. Inicialmente, foram utilizadas as seguintes variáveis: distância de medição; lado da medição; remoção de borracha; *grooving*; equipamento utilizado; idade do pavimento; temperatura; umidade; quantidade de operações entre as medições de atrito; quantidade de operações entre as remoções de borracha; e quantidade de operações anuais.

A arquitetura definida para os modelos consistiu em quatro camadas ocultas com 32, 64, 64 e 64 neurônios para o AT3 e quatro camadas ocultas com 64 neurônios cada para o AT6. Ambos os modelos utilizaram a função de ativação linear retificada e o otimizador de pesos RMSprop, conforme Tabela 8.

Tabela 8 – Arquitetura dos modelos AT3 e AT6

Arquitetura	Modelo AT3	Modelo AT6
Número de camadas	4	4
Quantidade de neurônios	32-64-64-64	64-64-64-64
Função de ativação	Linear retificada (ReLU)	
Otimizador de pesos	RMSprop	

Fonte: Elaborada pelo autor.

Ambos os modelos foram processados cinco vezes com o intuito de obter a média dos resultados. Ressalta-se que para cada processamento obtiveram-se resultados diferentes, porém próximos. Então, na Tabela 9 constam os resultados do teste dos modelos AT3 e AT6, utilizando o Coeficiente de Determinação (R^2), o Erro Quadrático Médio (MSE) e o Erro Absoluto Médio (MAE).

Tabela 9 – Resultados dos modelos AT3 e AT6

Processamento	AT3			AT6		
	R ²	MSE	MAE	R ²	MSE	MAE
1	0,697	0,003	0,043	0,647	0,003	0,044
2	0,699	0,003	0,042	0,649	0,003	0,040
3	0,698	0,003	0,041	0,687	0,003	0,038
4	0,706	0,003	0,043	0,674	0,003	0,038
5	0,717	0,003	0,042	0,700	0,002	0,036
Média	0,703	0,003	0,042	0,671	0,003	0,039

Fonte: Elaborada pelo autor.


Verifica-se, por meio da Tabela 9, que o R² dos modelos resultou em valores em torno de 0,70, o que representa um valor satisfatório visto a complexidade do problema. O MSE resultou em 0,003 e o MAE ficou em torno de 0,040 para ambos os modelos.

Percebe-se o R² e o MAE apresentaram, respectivamente, um valor crescente e variado, de acordo com a ordem dos processamentos tanto para o modelo AT3 quanto para o AT6. Todavia, essa melhoria observada no resultado não tem correlação com a ordem ou a quantidade de processamentos.

Ressalta-se que os resultados dos modelos são diferentes a cada processamento devido ao procedimento de validação cruzada, o qual consiste em dividir aleatoriamente o conjunto de dados em k partições exclusivas. Nesse contexto, utiliza-se um subconjunto para teste e o restante para treinamento para cada partição, de forma alternada. Isto é, para cada processamento, o modelo é processado e testado com uma partição diferente dos dados.

A Figura 35 apresenta o gráfico de dispersão entre o coeficiente de atrito observado e o estimado da fase de treinamento dos modelos AT3 e AT6. Destaca-se que os modelos foram desenvolvidos com 3.136 instâncias e 11 classes, as quais representam o total de 63 relatórios dos aeródromos SBFZ e SBBR.

Figura 35 – Gráfico de dispersão do teste dos modelos AT3 e AT6



Fonte: Elaborada pelo autor.

Percebe-se, pela Figura 35, que os resultados dos modelos foram satisfatórios na generalização do problema. Isso porque os valores estão próximos à diagonal que representa a linha de tendência, exibindo uma correlação positiva entre o coeficiente de atrito observado e o estimado. Apesar de haver dispersão de alguns pontos, percebe-se que, no melhor resultado dos processamentos, os modelos AT3 e AT6 apresentaram um R^2 de 0,72 e 0,70, respectivamente. Em relação ao pior resultado, os modelos apresentaram um R^2 de 0,70 e 0,65.

4.3 Resultados dos modelos AT3 e AT6 com alteração das variáveis

A análise dos resultados decorrentes da alteração das variáveis de entrada dos modelos AT3 e AT6, nos quais foram realizadas duas modificações com o objetivo de melhorar a acurácia, é apresentada neste item. Ressalta-se que as arquiteturas dos modelos não foram alteradas, isto é, quatro camadas ocultas com 32, 64, 64 e 64 neurônios para o AT3 e quatro camadas ocultas com 64 neurônios cada para o AT6.

Na primeira modificação foram removidas as variáveis idade do pavimento; operações entre as remoções de borracha; e operações anuais. Ao passo que na segunda alteração foi a retirada a variável *grooving*, além das removidas primeiramente, conforme Quadro 2.

Quadro 2 – Variáveis removidas nos Modelos AT3 e AT6

Alterações	Variáveis removidas
1 ^a	Idade do pavimento Operações entre as remoções de borracha Operações anuais
2 ^a	Idade do pavimento Operações entre as remoções de borracha Operações anuais <i>Grooving</i>

Fonte: Elaborado pelo autor.

A variável idade do pavimento foi removida devido a seu baixo coeficiente de correlação com o coeficiente de atrito a 3 m e a 6 m, apresentando valores de 0,10 e 0,07, respectivamente. Além disso, os dados apresentaram alta dispersão e um coeficiente de variação de 0,74, o que pode reduzir a acurácia do modelo. Ressalta-se que essa variação ocorreu devido ao intervalo médio de recapeamento das PPD de 120 meses, ou seja, os valores variaram entre 0 e 120 meses.

Acerca das variáveis relacionadas à quantidade de operações, buscou-se utilizar apenas uma das três variáveis empregadas no primeiro processamento com o intuito de reduzir a redundância desse tipo de dado. Desse modo, as duas variáveis removidas foram escolhidas

por terem menor coeficiente de correlação com o coeficiente de atrito. Enquanto a variável *grooving*, foi dispensada devido à sua menor quantidade de instâncias em relação ao conjunto de dados.

Foram obtidos dois resultados distintos para cada modelo relativos à primeira e a segunda alteração realizada. Isto posto, denominou-se quatro novos modelos para melhor interpretação, quais sejam: Modelos AT3-1, AT3-2, AT6-1, AT6-2. Assim, tem-se que os modelos alterados apresentaram resultados semelhantes ao primeiro processamento, conforme verificado na Tabela 10.

Tabela 20 – Resultados dos Modelo AT3 com alteração das variáveis

Processamento	AT3-1 (1ª alteração)			AT3-2 (2ª alteração)		
	R ²	MSE	MAE	R ²	MSE	MAE
1	0,697	0,003	0,044	0,680	0,003	0,045
2	0,714	0,003	0,041	0,663	0,004	0,046
3	0,707	0,003	0,041	0,680	0,004	0,045
4	0,715	0,004	0,046	0,692	0,003	0,043
5	0,704	0,003	0,042	0,708	0,003	0,043
Média	0,707	0,003	0,043	0,685	0,003	0,044
Resultados AT3	0,703	0,003	0,042	-	-	-

Fonte: Elaborada pelo autor.

Os modelos AT3-1 e AT3-2 apresentaram um R² médio de 0,707 e 0,685, respectivamente, além de um MSE de 0,003 e um MAE de 0,044. Em comparação com o R² de 0,703 do modelo AT3, verifica-se que a retirada das variáveis idade do pavimento, operações entre as remoções de borracha e as operações anuais melhorou o desempenho do modelo, enquanto a eliminação da variável *grooving* reduziu a acurácia, conforme a Tabela 10.

Os modelos AT6-1 e AT6-2 apresentaram um R² médio de 0,619 e 0,633 e um MAE de 0,043 e 0,040, respectivamente, além de um MSE de 0,003 em ambos, conforme Tabela 11. Os resultados das duas alterações realizadas foram inferiores àqueles obtidos no modelo AT6, isto é, o modelo obteve melhor acurácia e generalização utilizando todos os dados disponíveis.

O R² teve uma redução de 0,671 para 0,619 na primeira modificação e para 0,633 na segunda modificação, na qual a remoção da variável *grooving* aumentou a precisão do modelo em relação à primeira alteração. Isso pode estar associado à menor quantidade de dados que possuem a variável *grooving* em relação ao conjunto de dados.

Tabela 31 – Resultados dos Modelo AT6 com alteração das variáveis

Processamento	1ª alteração			2ª alteração		
	R ²	MSE	MAE	R ²	MSE	MAE
1	0,563	0,004	0,045	0,599	0,003	0,043
2	0,603	0,004	0,048	0,623	0,003	0,041
3	0,634	0,003	0,044	0,648	0,003	0,040
4	0,642	0,003	0,040	0,648	0,003	0,038
5	0,651	0,003	0,038	0,646	0,003	0,038
Média	0,619	0,003	0,043	0,633	0,003	0,040
Resultados AT6	0,671	0,003	0,039	-	-	-

Fonte: Elaborada pelo autor.

Apesar das alterações nas variáveis não terem promovido uma melhoria significativa na acurácia dos modelos, reduziu-se a quantidade de variáveis e de dados necessários para obter um resultado próximo aos dos modelos AT3 e AT6, os quais englobam todas as variáveis. Dessa forma, o esforço necessário para coleta e armazenamento de dados foi reduzido, bem como o dispêndio financeiro para essas atividades. Em uma possível aplicação desses modelos, a redução de custos para o operador de aeródromo e para a Agência Nacional de Aviação Civil (ANAC) é um fator importante para a implementação e manutenção de tais sistemas.

Além disso, a realização das medições de coeficiente de atrito na PPD representa um empenho financeiro, de pessoal e logístico para o operador de aeródromo, necessitando a interdição da PPD para tais atividades. Logo, a aplicação de modelos que possam auxiliar as medições realizadas em pista e, consequentemente, os custos atrelados a essas atividades, é útil para os operadores de aeródromo em relação gerenciamento dos pavimentos aeroportuários e para ANAC quanto à fiscalização.

Pode-se entender que houve um aperfeiçoamento dos modelos, uma vez que a quantidade de variáveis foi reduzida mantendo uma acurácia aproximada à observada nos modelos que utilizaram todos os dados disponíveis. Desse modo, a redução da base de dados, sem prejudicar a acurácia, representa uma melhoria nos modelos.

Por fim, os modelos desenvolvidos apresentaram valores de acurácia menores quando comparados aos elaborados por Yao *et al.*, (2019) e Quariguasi, Oliveira e Reis (2021). Esses autores desenvolveram modelos de RNA para estimar valores de coeficiente de atrito, os quais apresentaram um R² de 0,861 e 0,775, respectivamente. A acurácia menor pode ser atribuída à quantidade de dados e variáveis utilizadas, bem como a sua variabilidade.

4.4 Influência do Grooving

A análise estatística da relação do *grooving* com o coeficiente de atrito medido a 3 m e a 6 m do eixo da PPD é abordada neste item. Inicialmente, foi realizada a estatística descritiva dos dados dividindo as ocorrências pela distância do eixo – 3 m e 6 metros – e pela presença de *grooving*, conforme exposto na Tabela 12.

Tabela 42 – Estatística descritiva do coeficiente de atrito em relação ao *grooving*


Variável	Dados	Média	Desvio Padrão	Coeficiente de variação	Mínimo	Máximo
Coeficiente de atrito a 3 m	Todos	0,71	0,10	0,14	0,38	0,99
	Sem <i>grooving</i>	0,73	0,10	0,14	0,38	0,99
	Com <i>grooving</i>	0,65	0,06	0,10	0,48	0,83
Coeficiente de atrito a 6 m	Todos	0,75	0,09	0,12	0,47	0,99
	Sem <i>grooving</i>	0,76	0,09	0,11	0,47	0,99
	Com <i>grooving</i>	0,69	0,07	0,10	0,50	0,87

Fonte: Elaborada pelo autor.

Verifica-se que o coeficiente de atrito médio observado nas medições com *grooving* apresentou médias menores em relação às medidas sem o dispositivo, conforme a Tabela 12. Além disso, os valores máximo e mínimo do coeficiente de atrito foram verificados nas medidas sem *grooving*. Ressalta-se que foram utilizadas as medições de toda a extensão das PPD dos dois aeródromos analisados (SBFZ e SBBR) e que apenas a pista 11L/29R do SBBR possui *grooving*.


Por meio de uma análise da distribuição das ocorrências, constata-se que os coeficientes de atrito medidos a 3 m e a 6 m são maiores nas áreas sem *grooving*, conforme exposto na Figura 36 e 37. Nota-se também que as medições realizadas a 6 m são maiores do que as medições a 3 m. Isso pode estar associado, por exemplo, à quantidade de operações por porte de aeronave, isto é, as aeronaves de grande porte influenciam mais a 6 m do eixo da PPD por conta da largura dos seus trens de pouso e desgastam mais essa região da PPD quando comparadas às aeronaves de pequeno e médio porte que atuam na faixa dos 3 m.

Figura 36 – Gráficos de dispersão do coeficiente de atrito de acordo com a distância de medição na PPD sem *grooving*



Fonte: Elaborada pelo autor.

Figura 37 – Gráficos de dispersão do coeficiente de atrito de acordo com a distância de medição na PPD com *grooving*



Fonte: Elaborada pelo autor.

O fato das áreas com *grooving* apresentarem as menores medidas de coeficiente de atrito pode estar relacionado com a zona de toque da aeronave, localizada no 1º terço da PPD nas quais são realizadas as operações de pouso e decolagem. Essas áreas propendem a ter um maior acúmulo de borracha que tendem a preencher as ranhuras existentes e, por sua vez, uma redução do coeficiente de atrito.

Pode-se entender que a efetividade do *grooving* diminui na medida em que as operações na PPD são realizadas e o resíduo é depositado nas ranhuras. Logo, o procedimento de remoção da borracha importa justamente para tornar o coeficiente de atrito ao seu valor inicial. Porém, essas intervenções podem não ser realizadas no momento adequado, de forma a não remover o acúmulo de borracha e reduzir as medidas de coeficiente de atrito.

Por fim, recomenda-se a instalação do *grooving* para melhorar o coeficiente de atrito das PPD. Todavia, a funcionalidade do dispositivo está diretamente relacionada à realização de manutenção por meio da remoção da borracha em período adequado.

5 CONCLUSÕES E RECOMENDAÇÕES

Neste capítulo constam as principais conclusões sobre este trabalho, as quais foram obtidas a partir da análise dos dados e das demais informações descritas no decorrer desta pesquisa. Em seguida, foram expostas algumas limitações observadas durante a execução deste estudo, bem como as recomendações para trabalhos futuros.

5.1 Principais conclusões

Esta pesquisa buscou desenvolver e aperfeiçoar modelos de previsão para o coeficiente de atrito medido pelos equipamentos *GripTester*, *Skiddometer* e *Mu-Meter* a 3 m e 6 m de distância do eixo de pistas de pouso e decolagem (PPD), por meio de Redes Neurais Artificiais (RNA). Nesse contexto, o trabalho buscou contribuir com operadores de aeródromos nacionais e internacionais quanto à segurança operacional dos pousos e decolagens em PPD brasileiras quanto à condição de aderência pneu-pavimento.

Foram desenvolvidos dois modelos denominados de modelo AT3 e modelo AT6, os quais possuem o coeficiente de atrito a 3 m e a 6 metros do eixo da PPD como variável alvo, respectivamente. Desse modo, os modelos desenvolvidos apresentaram resultados satisfatórios, os quais validam a sua possibilidade de utilização pelo operador de aeródromo e pela Agência Nacional de Aviação Civil (ANAC) para obter estimativas do coeficiente de atrito. Além disso, esses resultados evidenciaram a viabilidade da utilização de dados de coeficiente de atrito medidos por diferentes equipamentos em modelos de RNA. Embora os modelos necessitem de aperfeiçoamento para melhorar a sua acurácia, entende-se que eles podem ter resultados satisfatórios a partir de uma base de dados maior quantitativamente e com uma maior quantidade de aeródromos.

Inicialmente, foram utilizadas todas as 11 variáveis disponíveis no banco de dados para a modelagem neural, quais sejam: distância de medição; lado da medição; remoção de borracha; *grooving*; equipamento utilizado; idade do pavimento; temperatura; umidade; quantidade de operações entre as medições de atrito; quantidade de operações entre as remoções de borracha; e quantidade de operações anuais. A partir desses dados de entrada, obteve-se um Coeficiente de Determinação (R^2) de 0,703 e 0,671 para os modelos AT3 e AT6, respectivamente, o que representa uma taxa de acerto satisfatória de dado a complexidade do problema e a quantidade de variáveis utilizada.

Em seguida, foram realizadas duas alterações nas variáveis a fim de melhorar a acurácia do modelo. Na primeira, foram removidas as variáveis idade do pavimento, operações

entre as remoções de borracha e operações anuais, e obteve-se um R^2 de 0,707 e 0,619 para os modelos AT3 e AT6, respectivamente. Na segunda alteração, além das variáveis removidas anteriormente, excluiu-se também a variável *grooving*, obtendo um R^2 de 0,685 e 0,633 para os modelos AT3 e AT6, nessa ordem.

Os resultados obtidos decorrentes das alterações, com x variáveis, foram similares ao processamento inicial, no qual foram utilizadas todas as y variáveis. A acurácia dos modelos alterados foi menor, porém próxima à do modelo inicial, com exceção da primeira modificação do modelo AT3, o qual obteve um resultado um pouco melhor.

Apesar da acurácia não ter sido ampliada com a alteração das variáveis, pode-se considerar um resultado adequado, visto que se alcançou um resultado similar ao do primeiro processamento utilizando uma quantidade menor de dados. Ressalta-se que a necessidade de uma base de dados menor representa um aperfeiçoamento dos modelos, tendo em vista a limitação na obtenção dos dados para realização desta pesquisa.

Em relação à análise do *grooving*, constatou-se que as medições que possuíam esse dispositivo apresentaram menores médias em relação às demais. Verificou-se que esse resultado pode estar associado à localização do *grooving* na PPD, isto é, as zonas de toque das aeronaves tendem a ter um menor coeficiente de atrito devido ao acúmulo de borracha. Além disso, a não realização de remoção do resíduo em período adequado pode ter contribuído também para uma quantidade de borracha acumulada maior e, conseqüentemente, um menor coeficiente de atrito.

Diante disso, evidencia-se que esta pesquisa contribuiu para o incremento da segurança das operações de pouso e decolagem em PPD brasileiras e com o gerenciamento dos pavimentos aeroportuários pelo operador de aeródromo quanto à condição de aderência pneu-pavimento. Além disso, esse trabalho também pode auxiliar nas atividades de fiscalização por parte da ANAC.

5.2 Principais limitações

Quanto às limitações desta pesquisa, ressalta-se a dificuldade na obtenção dos dados, uma vez que essas informações estão concentradas na Agência Nacional de Aviação Civil (ANAC) e nos operadores de aeródromos. Além disso, o processo de extração dos dados é manual e demanda bastante tempo.

Ademais, os relatórios de medição são disponibilizados de forma não estruturada e em formato de imagem digitalizada em *Portable Document Format* (PDF), o que exige a elaboração de um banco de dados estruturado, demandando bastante tempo e esforço. Essa

difficuldade reforça a importância da cultura de coleta e disponibilização dos dados técnicos das PPD, de forma a facilitar o acesso a eles em pesquisas futuras.

Ademais, os modelos foram desenvolvidos apenas com dados dos aeroportos internacionais de Fortaleza e Brasília e, por isso, podem não ser apropriados para outros aeródromos com características distintas. Além disso, apenas uma PPD apresentava *grooving*, isto é, havia uma quantidade maior de dados para as medidas sem o dispositivo.

Os modelos de previsão foram desenvolvidos para o coeficiente de atrito medido a 3 m e a 6 m de distância do eixo da PPD com os equipamentos *GripTester*, *Skidometer* e *Mu-meter* a 65 km/h, de modo que os modelos podem apresentar inconsistência em cenários distintos dessas circunstâncias. Ainda, a utilização de variáveis que extrapolam os valores utilizados para o treinamento dos modelos, também pode provocar erros.

5.3 Recomendações para trabalhos futuros

As recomendações para pesquisas futuras visam dar continuidade a trabalhos e análises no campo aeroportuário e da modelagem neural, além de contribuir com a atuação dos operadores de aeródromos e da ANAC. Dentre as principais recomendações desta pesquisa, tem-se:

- a) Desenvolvimento de modelos de previsão que contenham dados relativos às operações de pouso e decolagem por tipo de aeronave;
- b) Analisar o impacto do tipo de aeronave e do seu respectivo peso e configuração de trens de pouso nas medidas realizadas a 3 m e 6 m do eixo da PPD;
- c) Verificar o desempenho dos modelos utilizando apenas medidas que contenham o *grooving* implantados nas PPD;
- d) Incrementar os modelos existentes com uma base de dados maior com uma maior quantidade de aeródromos com características distintas.

REFERÊNCIAS

- ABADI, M. *et al.* TensorFlow: A system for large-scale machine learning. **The advanced computing systems associations**, n. 12, p. 265-283, 2016. Disponível em: <https://www.usenix.org/biblio/12th-usenix-symposium-operating-systems-design-and-implementation-osdi-16-0>. Acesso em: 15 mar. 2022
- ABIODUN, O. I. *et al.* State-of-the-art in artificial neural network applications: A survey. **Heliyon**, USA, v. 2, p. 1-41, 2018. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30519653/>. Acesso em: 11 jun. 2022.
- AERO EXPO. Runway Friction Tester. Mu-Meter FT256. **Aero expo**. 6 jan. 2021. Disponível em: <https://www.aeroexpo.online/prod/smets-technology-gmbh/product-168959-4204.html>. Acesso em: 20 jan. 2021.
- AIRBUS. A statistical analysis of commercial aviation accidents 1958-2019. **Airbus SE**. 11 fev. 2020. Disponível em: https://www.airbus.com/search.document.html?q=&results_page_index=2&start2=2020-01-29&calendar=false&lang=en&newsroom=true#searchresult-document-all-74. Acesso em: 1 mar. 2020.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. (Brasil). **Classificação dos tipos de aquaplanagem ou hidroplanagem**. Brasília, 2018. Disponível em: <https://www.anac.gov.br/assuntos/setor-regulado/profissionais-da-aviacao-civil/meteorologia-aeronautica/condicoes-meteorologicas-adversas-para-o-voo/chuvas-fortes#classificacao>. Acesso em: 10 jan. 2021.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. (Brasil). **Regulamento Brasileiro de Aviação Civil (RBAC)**. Brasília, 2019.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. (Brasil). **Consulta Interativa – Indicadores do Mercado de Transporte Aéreo**. Brasília, 2021a. Disponível em: <https://www.gov.br/anac/pt-br/assuntos/dados-e-estatisticas/mercado-de-transporte-aereo/consulta-interativa/demanda-e-oferta-origem-destino>. Acesso em: 15 mar. 2022.
- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. (Brasil). **Portaria nº 3.262/sia, de 19 de outubro de 2018 – Revisão 7**. Brasília, 2021b.
- ANDERSON, D. A. *et al.* Development of a Procedure for Correcting Skid-Resistance Measurements to a Standard End-of-Season Value. **Transportation Research Record**, USA, n. 1084, p. 40-48, 1984.
- ANDRESEN, A.; WAMBOLD, J. C. **Friction fundamentals, concepts and methodology**. Montreal: TRID, 1999.
- ANUPAM, K. *et al.* Influence of temperature on tire-pavement friction analyses. **Transportation Research Record**, USA, v. 2369, p. 114-124, 2013.

APS, M. **Classificação da aderência pneu-pavimento pelo índice combinado IFI – International Friction Index para revestimentos asfálticos**. 2006. Tese (Doutorado em Engenharia) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2006. Disponível em: <https://www.teses.usp.br/teses/disponiveis/3/3138/tde-11122006-144825/en.php>. Acesso em: 5 jul. 2020.

BECKLEY, M. E. **Pavement deterioration modeling using historical roughness data**. 2016. Dissertação (Master of Science) — Arizona State University, Tempe, 2016. Disponível em: <https://www.proquest.com/openview/5d507e84e6bc0c544cf0dc84171a465f/1?pq-origsite=gscholar&cbl=18750>. Acesso em: 7 out 2020.

BERNUCCI, L. B. *et al.* **Pavimentação asfáltica - Formação Básica para Engenheiros**. Rio de Janeiro: Abeda, 2008.

BEZERRA FILHO, C. I. F.; OLIVEIRA, F. H. L. Análise da correlação entre a macrotextura e o coeficiente de atrito em pavimentos aeroportuários. CONGRESSO DE PESQUISA E ENSINO EM TRANSPORTES, 27, 2013, Belém. **Anais [...]**. Belém: ANPET, 2013. p. 11.

BISHOP, C. M. **Pattern recognition and machine learning**. NY: Springer, 2006.

BOCANEGRA, C. W. R. **Procedimentos para tornar mais efetivo o uso das Redes Neurais Artificiais em planejamento de transportes**. 2002. Dissertação (Mestrado em Engenharia Civil) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2002. Disponível em: https://www.teses.usp.br/teses/disponiveis/18/18137/tde-06032002-131951/publico/C_Bocan.pdf. Acesso em: 16 set. 2020.

BOEING. Statistical summary of commercial jet airplane accidents: Worldwide Operations 1959 - 2018. **Sky Brary**. 25 ago. 2021. Disponível em: <https://skybrary.aero/articles/boeing-annual-summary-commercial-jet-airplane-accidents>. Acesso em: 1 out. 2021.

BOSSCHE, J. V. *et al.* Scikit-learn - Neural Network: Multilayer Perceptron Regressor. **Scikit-learn**. Jan/2021. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html#sklearn.neural_network.MLPRegressor. Acesso em: 15 fev. 2021.

BOSSCHE, J. V. *et al.* Scikit-learn – Cross-validation: Evaluating Estimator Performance. **Scikit-learn**. Maio/2002. Disponível em: https://scikit-learn.org/stable/modules/cross_validation.html. Acesso em: 3 jun. 2022.

BOSURGI, G.; TRIFIRO, F. A model based on artificial neural networks and genetic algorithms for pavement maintenance management. **International Journal of Pavement Engineering**, v. 6, n. 3, p. 201–209, 2005. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/10298430500195432>. Acesso: 2 out. 2020.

BRASIL. Secretaria de Aviação Civil. **Sistema Hórus – SAC**. Brasília, 2020. Disponível em: <https://www.labtrans.ufsc.br/sistema-horus/>. Acesso em: 16 abr. 2020.

BRASIL. MINISTÉRIO DOS TRANSPORTES, PORTOS E AVIAÇÃO CIVIL. **Plano Aeroviário Nacional – 2018-2038**. Brasília, 2018.

BROSSEAUD, Y. **Encontro do Asfalto**, 17. Rio de Janeiro: IBP, 2002.

CENIPA. Panorama dos acidentes nos últimos 10 anos. **SIPAER**. Jan/2020. Disponível em: <http://painelsipaer.cenipa.aer.mil.br>. Acesso em: 28 fev. 2020.

CEREZO, V.; DO, M. T.; KANE, M. Comparison of skid resistance evolution models. INTERNATIONAL CONFERENCE ON MAINTENANCE AND REHABILITATION OF PAVEMENTS AND TECHNOLOGICAL CONTROL, 7, 2012, Auckland. **Anais [...]**. Auckland: ARRB, 2012. p. 10.

CHELLIAH, T. *et al.* Developing a Design Policy to Improve Pavement Surface Characteristics. PAVEMENT EVALUATION CONFERENCE, 25, 2002, Virginia. **Anais [...]**. Virginia: ARRB, 2002. p. 1–19. Disponível em: <https://trid.trb.org/view/1211026>. Acesso em: 2 out. 2020.

CHEN, J.-S. *et al.* Effect of rubber deposits on runway pavement friction characteristics. **Transportation Research Record**, USA, v. 2068, n. 1, p. 119–125, 2008. Disponível em: <https://doi.org/10.3141/2068-13>. Acesso em: 10 out. 2020.

CORLEY-LAY, J. B. Friction and Surface Texture Characterization of 14 Pavement Test Sections in Greenville, North Carolina. **Transportation Research Record**, USA, n. 1639, p. 155-161, 1998. Disponível em: <https://journals.sagepub.com/doi/abs/10.3141/1639-17>. Acesso em: 9 ago. 2020.

COSTA, S. L.; CASTELO BRANCO, V. T. E.; FREITAS, E. F. Avaliação da aderência pneu-pavimento para diferentes tipos de pavimentos utilizando o International Friction Index (IFI). CONGRESSO DA ASSOCIAÇÃO NACIONAL DE PESQUISA E ENSINO EM TRANSPORTE, 31, 2017, Recife. **Anais [...]**. Recife: ANPET, 2017. p. 1–12.

COUCHINHO, R. P. S. **Medição do coeficiente de atrito da superfície de pavimentos: estudo do equipamento Grip Tester**. 2011. Dissertação (Mestrado em Engenharia Civil) — Instituto Superior de Engenharia de Lisboa, Lisboa, 2011. Disponível em: <https://repositorio.ipl.pt/handle/10400.21/1187>. Acesso em: 25 out. 2020.

COUTINHO NETO, B. **Redes Neurais Artificiais como procedimento para retroanálise de pavimentos flexíveis**. 2000. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000. Disponível em: <https://www.teses.usp.br/teses/disponiveis/18/18137/tde-01022018-122501/en.php>. Acesso em: 12 nov. 2020.

DOMITROVIC, J. *et al.* Application of an artificial neural network in pavement management system. **Technical Gazette**, Croatia, v. 25, n. 2, p. 466–473, 2018. Disponível em: <https://doi.org/10.17559/TV-20150608121810>. Acesso em: 28 out. 2020.

DUCHI, J.; HAZAN, E.; SINGER, Y. Adaptive subgradient methods for online learning and stochastic optimization. **Journal of Machine Learning Research**, USA, n.12, p.2121–2159, 2011. Disponível em: <https://www.jmlr.org/papers/volume12/duchi11a/duchi11a.pdf>. Acesso em: 1 nov. 2020.

FEDERAL AVIATION ADMINISTRATION. (United States). **Airport Pavement**

Management Program (PMP): advisory circular – 150/5380-7B. Washington: United States Department of Transportation, 2014.

FSF ALAR. Briefing Note 8.5 - Wet or Contaminated Runways. **FSF**. Ago-Nov/2000. Disponível em: <https://flightsafety.org/toolkits-resources/past-safety-initiatives/approach-and-landing-accident-reduction-alar/alar-tool-kit-and-other-resources/>. Acesso em: 18 jul. 2020.

FLINTSCH, G. W.; ZANIEWSKI, J. P.; DELTON, J. Artificial neural network for selecting pavement rehabilitation projects. **Transportation Research Record**, USA, v. 1524, n. 1, p. 185–193, 1996. Disponível em: <https://doi.org/10.1177/361198196152400128>. Acesso em: 14 nov. 2020.

FLINTSCH, G. W.; LUO, Y.; AL-QADI, I. L. **Analysis of the effect of pavement temperature on the frictional properties of flexible pavement surfaces**. Washington: TRB Annual Meeting, 2005.

FONSECA, O. A. **Manutenção de pavimentos de aeroportos**. Brasília: Ministério da Aeronáutica, 1990.

FORTMANN-ROE, S. Understanding the Bias-Variance Tradeoff. **Essays**. Junho/2012. Disponível em: <http://scott.fortmann-roe.com/docs/BiasVariance.html>. Acesso em: 20 jan. 2021.

FRAPORT. Fortaleza Airport: Movimentação Aeroportuária. **Fortaleza Airport**. Março/2022. Disponível em: <https://fortaleza-airport.com.br/pt/informacoes-operacionais/movimentacao-aeroportuaria>. Acesso em: 15 mar. 2022.

FWA, T. F.; CHAN, W. T.; LIM, C. T. Decision framework for pavement friction management of airport runways. **Journal of Transportation Engineering**, USA, v. 123, n. 6, p. 429–435, 1997. Disponível em: [https://ascelibrary.org/doi/abs/10.1061/\(ASCE\)0733-947X\(1997\)123:6\(429\)?casa_token=pSJoDZPdA5UAAAAA:NM9bOKPBRpMw4p-XiOrbUTZykNfcCwkIqQN33JllxPMU2ZnV-LprGEIIXsS3mDXzdeVnhVliyVYHhw](https://ascelibrary.org/doi/abs/10.1061/(ASCE)0733-947X(1997)123:6(429)?casa_token=pSJoDZPdA5UAAAAA:NM9bOKPBRpMw4p-XiOrbUTZykNfcCwkIqQN33JllxPMU2ZnV-LprGEIIXsS3mDXzdeVnhVliyVYHhw). Acesso em: 19 ago. 2020.

GÉRON, A. **Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems**. CA: O'Reilly Media, 2017.

GRIPTESTER. Griptester MK2. **Griptester**. Jan/2021. Disponível em: <https://griptester.us/>. Acesso em: 6 jan. 2021.

HAYKIN, S. **Neural Networks: a comprehensive foundation**. 2.ed. Canada: Pearson Education, 2001.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Canada: Pearson Education, 2009.

HILL, B. J.; HENRY, J. J. Short Term, Weather-Related Skid Resistance Variation. **Transportation Research Record**, USA, n. 836, p. 76-81, 1978. Disponível em: <https://onlinepubs.trb.org/Onlinepubs/trr/1981/836/836-012.pdf>. Acesso em: 19 ago. 2020.

HORNE, W. B.; DREHER, R. C. **Phenomena of pneumatic tire hidroplaning**. Washington: Langley Research Center, 1963.

HOSSAIN, M. I.; GOPISETTI, L. S. P.; MIAH, M. S. International Roughness Index Prediction of Flexible Pavements Using Neural Networks. **Journal of Transportation Engineering**, USA, v. 145, n. 1, p. 1–10, 2019. Disponível em: https://ascelibrary.org/doi/full/10.1061/JPEODX.0000088?casa_token=WQl4CxtOmGgAAA%3AAWRFiGAPKNPhbAv3k8xKKy5CcCqpipj5fmP6knn3v-xBHxYA3Xo9Usvn6-SjMdfUEsrq4a-6po9Aotw. Acesso em: 19 ago. 2020.

INTERNATIONAL CIVIL AVIATION ORGANIZATION. **Manual de servicios de aeropuertos**: Parte 2. Estado de la superficie de los pavimentos. 4. ed. Peru, 2002.

INTERNATIONAL CIVIL AVIATION ORGANIZATION. State of global aviation safety: safety report 2019. Disponível em: <https://www.icao.int/safety/Pages/Safety-Report.aspx>. Acesso em: 1 mar. 2020.

INFRAMÉRICA. Aeroporto de Brasília: estatísticas. **INFRAMÉRICA**. 2022. Disponível em: <https://www.bsb.aero/br/o-aeroporto/dados-operacionais/estatisticas/>. Acesso em: 15 mar. 2022.

KAZDA, A.; CAVES, R. E. **Airport design and operation**. 2. ed. New York: Publisher Elsevier Science, 2007.

KUMMER, H. W.; MEYER, W. E. Measurement of skid resistance, symposium on skid resistance. **ASTM Special Technical Publication**, USA, n. 326, p.3-28, 1962. Disponível em: <https://www.astm.org/stp44403s.html>. Acesso em: 15 abr. 2020.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, USA, v. 521, n. 7553, p. 436–444, 2015. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 17 dez. 2020.

LUO, Y. **Effect of pavement temperature on frictional properties of hot-mix-asphalt pavement surfaces at the Virginia smart road**. 2003. Dissertação (Master of Science in Civil and Environmental Engineering) — Faculty of Virginia Polytechnic Institute, State University, Blacksburg, 2003. Disponível em: <https://vtechworks.lib.vt.edu/handle/10919/31137>. Acesso em: 14 set. 2020.

MALLICK, B. R.; EL-KORCHI, T. **Pavement engineering**: principles and practice. 3. ed. New York: CRC Press, 2017.

MASAD, E. *et al.* **Predicting asphalt mixture skid resistance based on aggregate characteristics**. University Press: Austin, 2009.

MATSUBARA, E. T. **O Algoritmo de aprendizado semi-supervisionado CO-TRAINING e sua aplicação na Rotulação de Documentos**. 2004. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) — Instituto de Ciências Matemáticas e de Computação - ICMC-USP, São Carlos, 2004. Disponível em: <https://www.teses.usp.br/teses/disponiveis/55/55134/tde-19082004-092311/en.php>. Acesso em: 18 ago. 2020.

McCULLOCH, W. S.; PITTS, W. A logical calculus of ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, Switzerland, v. 5, p. 127–147, 1943. Disponível em: <https://doi.org/10.2307/2268029>. Acesso em: 7 jun. 2020.

McDANIEL, R. S. *et al.* **Long-term performance of a porous friction course**. University Press: West Lafayette, 2010.

MITCHELL, J. C. *et al.* **Report FHWA/MD-86/02: seasonal variation of friction numbers**. Maryland: Baltimore, 1986.

MITCHELL, T. M. **Machine learning**. New York: McGraw-Hill, 1997.

MOVENTOR. Factory Overhaul. **Moventor**. 2021. Disponível em: <https://moventor.com/factory-overhaul/>. Acesso em: 6 jan. 2021.

NAJAFI, S.; FLINTSCH, G. W.; KHALEGHIAN, S. Pavement friction management – artificial neural network approach. **International Journal of Pavement Engineering**, England, v. 20, n. 2, p. 125–135, 2019. Disponível em: <https://doi.org/10.1080/10298436.2016.1264221>. Acesso em: 18 ago. 2020.

OLIVEIRA, P. V. S. **Estudo preliminar do comportamento da capacidade de atrito nas pistas de pouso e decolagem do Aeroporto Pinto Martins**. 2017. Monografia (Graduação em Engenharia Civil) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2017. Disponível em: http://www.repositorio.ufc.br/bitstream/riufc/29491/3/2017_tcc_pvsoliveira. Acesso em: 10 nov. 2020.

PACHECO, M. A. C. **Algoritmos genéticos: princípios e aplicações**. PUC: Rio de Janeiro, 1999.

PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, USA, v. 12, p. 2825–2830, 2011. Disponível em: <https://www.jmlr.org/papers/volume12/pedregosa11a/pedregosa11a.pdf?ref=https://githubhelp.com>. Acesso: 1 nov. 2020.

PINHEIRO NETO, J. C.; OLIVEIRA, F. H. L.; AGUIAR, M. F. P. **Análise da correlação linear de parâmetros de aderência em pavimentos aeroportuários: estudo de caso do Aeroporto Internacional Pinto Martins**. Foz do Iguaçu: ENACOR, 2015.

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 networks. **Revista Transportes**, Fortaleza, v. 29, n. 2, p. 1-13, 2021. Disponível em: <https://repositorio.ufc.br/handle/riufc/68003>. Acesso em: 30 ago. 2021.

RAMOS, S. P. *et al.* **Verificação da correlação entre os parâmetros de aderência nas pistas de pousos e decolagens dos aeroportos de Fortaleza/CE, Juazeiro do Norte/CE e Petrolina/PE**. Fortaleza: CONTECC, 2015.

RIBEIRO, A. J. A. **Um método para localização e estimação das características geotécnicas dos solos da Região Metropolitana de Fortaleza-CE para fins de pavimentação**. 2013. Dissertação (Mestrado em Engenharia de Transportes) – Centro de

Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2013. Disponível em: <https://repositorio.ufc.br/handle/riufc/5461>. Acesso em: 5 fev. 2021.

RODRIGUES FILHO, O. S. **Características de aderência de revestimentos asfálticos aeroportuários**: estudo de caso do Aeroporto Internacional de São Paulo/Congonhas. 2006. Dissertação (Mestrado em Engenharia) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2006. Disponível em: <https://www.teses.usp.br/teses/disponiveis/3/3138/tde-01122006-142419/en.php>. Acesso em: 18 maio 2020.

RODRIGUEZ, O. D. G. **Evaluation of pavement surface friction seasonal variations**. 2009. Dissertação (Master of Science in Civil and Environmental Engineering) — Virginia Polytechnic Institute and State University, Blacksburg, 2009. Disponível em: <https://vtechworks.lib.vt.edu/handle/10919/31179>. Acesso em: 18 jun. 2020.

ROSANNE. Rolling Resistance, Skid Resistance, and Noise Emission measurement standards for road surfaces. **Rosanne**. 2021. Disponível em: <https://rosanne-project.eu/>. Acesso em: 6 jan. 2021.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological review**, USA, v. 65, n. 6, p. 386–408, 1958. Disponível em: <http://dx.doi.org/10.1037/h0042519>. Acesso em: 19 jun. 2020.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, USA, v. 3, p. 210–229, 1959. Disponível em: <https://ieeexplore.ieee.org/document/5392560>. Acesso em: 14 ago. 2020.

SANTOS, A. *et al.* **Degradation prediction model for friction in highways**. Holland: Springer, 2014.

SANTOS, E. L. **Análise histórica de medição de atrito das pistas do Aeroporto Santos Dumont - RJ**. 2004. Monografia (Graduação em Engenharia) - Instituto Tecnológico de Aeronáutica – ITA, São José dos Campos, 2004. Disponível em: <http://www.bdiita.bibl.ita.br/>. Acesso em: 12 jul. 2020.

SHAHIN, M. A.; MAIER, H. R.; JAKSA, M. B. Data division for developing neural networks applied to geotechnical engineering. **Journal of Computing in Civil Engineering**, USA, v. 18, n. 2, p. 105–114, 2004. Disponível em: [https://doi.org/10.1061/\(ASCE\)0887-3801\(2004\)18:2\(105\)](https://doi.org/10.1061/(ASCE)0887-3801(2004)18:2(105)). Acesso em: 19 dez. 2020.

SHAHIN, M. Y. **Pavement Management for Airports, Roads, and Parking Lots**. 2. ed. New York: Springer, 2005.

SILVA, J. P. S. **Aderência pneu-pavimento em revestimentos asfálticos aeroportuários**. 2008. Dissertação (Mestrado em Geotecnia) — Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2008. Disponível em: <https://repositorio.unb.br/handle/10482/3470>. Acesso em: 5 mar. 2020.

SINGH, S. Understanding the Bias-Variance Tradeoff. **TDS**. 21 maio 2018. Disponível em: <https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229>.

Acesso em: 10 fev. 2021.

SKERRITT, W. H. Aggregate type and traffic volume as controlling factors in bituminous pavement friction. **Transportation Research Record**, USA, n. 1418, p. 22–29, 1993. Disponível em: <https://trid.trb.org/view/389604>. Acesso em: 4 maio 2020.

SUSANNA, A. *et al.* Deterioration trends of asphalt pavement friction and roughness from medium-term surveys on major Italian roads. **International Journal of Pavement Research and Technology**, Switzerland, v. 10, n. 5, p. 421–433, 2017. Disponível em: <http://dx.doi.org/10.1016/j.ijprt.2017.07.002>. Acesso em: 3 fev. 2020.

THUBE, D. T. Artificial Neural Network (ANN) based pavement deterioration models for low volume roads in India. **International Journal of Pavement Research and Technology**, Switzerland, v. 5, n. 2, p. 115–120, 2012. Disponível em: <https://www.proquest.com/openview/1f6bc18c291ebb891b826e913f75135f/1?pq-origsite=gscholar&cbl=60371>. Acesso em: 3 dez. 2020.

TIELEMAN, T.; HINTON, G. **Lecture 6.5 - RMSProp, COURSERA: Neural Networks for Machine Learning**. USA: MIT Technical report, 2012.

TUNG, J. S. N. *et al.* **Statistical analysis of seasonal variations in pavement skid resistance**. Pennsylvania: Transportation Bureau of Materials, 1977.

WAMBOLD, J. *et al.* **International PIARC experiment to compare and harmonize texture and skid resistance measurements**. USA: PIARC, 1995.

WELLS, A. T.; YOUNG, S. B. **Airport planning & management**. New York: McGraw-Hill, 2019.

WONG, J. Y. **Theory of ground vehicles**. New York: John Wiley & Sons, 2001.

YAGER, T. J. **Runway friction assessment and maintenance for airports**. Singapore: Airfield Engineering and Maintenance Summit, 2014.

YAO, L. *et al.* Establishment of prediction models of asphalt pavement performance based on a novel data calibration method and neural network. **Transportation Research Record**, USA, n. 1, p. 66–82, 2019. Disponível em: <https://doi.org/10.1177/0361198118822501>. Acesso em: 2 nov. 2020.

ZADEH, L. A. Fuzzy Sets. **Information and control**, Holland, v.8, p. 338–353, 1965. Disponível em: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X). Acesso em: 1 set. 2020.