

CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE PISTAS DE POUSO E DECOLAGEM USANDO REDES *MULTILAYER PERCEPTRON*

¹CAMILA LIMA MAIA, ¹CARLOS AUGUSTO UCHÔA DA SILVA,

¹FRANCISCO HEBER LACERDA DE OLIVEIRA, ¹RENATA DE SOUZA SALES

¹Universidade Federal do Ceará (UFC)

<camilalima@det.ufc.br> <uchoa@det.ufc.br> <heber@det.ufc.br> <renatasales@det.ufc.br>

DOI: 10.21439/conexoes.v19.3736

Resumo. As condições de resistência à derrapagem de pavimentos aeroportuários são fatores importantes para a manutenção da segurança operacional de pouso e decolagens e fundamentais para o gerenciamento de riscos em aeroportos. Essa resistência pode ser incrementada por meio da caracterização do revestimento das pistas, que ficam em contato direto com os pneus das aeronaves, medidas por meio do coeficiente de atrito e da macrotextura. O objetivo deste artigo é obter um modelo de classificação da segurança operacional de pistas de pouso e decolagem (PPD) com revestimento em Concreto Asfáltico (CA) e Camada Porosa de Atrito (CPA). Foram utilizadas variáveis como coeficiente de atrito, profundidade da macrotextura, remoção do acúmulo de borracha, localização e terço da PPD e tipo de revestimento asfáltico, oriundos de relatórios disponibilizados pela Autoridade de Aviação Civil entre 2014 e 2018. Foram empregadas técnicas de machine learning, especificamente uma rede neural do tipo *Multilayer Perceptron*. Os resultados apresentaram uma taxa de acerto de 99,5% no teste adicional e demonstraram que o modelo gerado é capaz de classificar adequadamente a segurança operacional das PPD. Dessa forma, espera-se contribuir para os Sistemas de Gerência de Pavimentos Aeroportuários, ao fornecer uma ferramenta para aprimorar a eficiência e segurança das operações aeroportuárias.

Palavras-chave: coeficiente de atrito; macrotextura; redes neurais MLP.

CLASSIFICATION OF THE OPERATIONAL SAFETY OF RUNWAYS USING MULTILAYER PERCEPTRON NETWORKS

Abstract. The skid resistance conditions of airport pavements are important factors for maintaining the operational safety of landings and takeoffs and are fundamental for airport risk management. This resistance can be increased by characterizing the runway coating in direct contact with aircraft tires, measured through the coefficient of friction and macrotexture. The objective of this article is to obtain a classification model for the operational safety of runways (PPD) with Asphalt Concrete (CA) and Porous Friction Layer (CPA) coatings. Variables such as coefficient of friction, depth of the macrotexture, removal of rubber accumulation, location and a third of the PPD, and type of asphalt coating were used, originating from reports made available by the Civil Aviation Authority between 2014 and 2018. Machine learning techniques were explicitly used a Multilayer Perceptron neural network. The results present an accuracy rate of 99.5% in the additional test and demonstrate that the generated model can adequately classify the operational safety of PPDs. This is expected to contribute to Airport Pavement Management Systems by providing a tool to improve the efficiency and safety of airport operations.

Keywords: friction coefficient; macrotexture; MLP neural networks.



1 INTRODUÇÃO

De acordo com ANAC 2021, 22,5% dos acidentes aéreos registrados entre os anos de 2016 e 2020, no Brasil, estão relacionados à excursão em pista, que ocorre quando uma aeronave se afasta das extremidades ou da lateral da pista durante as fases de pouso ou decolagem. Este tipo de acidente está relacionado, entre outros fatores, à qualidade do revestimento da pista de pouso e decolagem (PPD). Em vista disso, manter as condições adequadas do pavimento é fundamental para a segurança das operações aeroportuárias.

Em relação à segurança operacional, a condição a ser observada é a resistência à derrapagem, que pode ser medida por meio do coeficiente de atrito e da profundidade da macrotextura. O coeficiente de atrito é definido como a relação entre a força tangencial entre os pneus da aeronave e a superfície do pavimento, que os mantém em um movimento relativo uniforme, e a força perpendicular que as mantêm em contato. A macrotextura é um tipo de textura de superfície e está relacionada ao ligante que compõe o revestimento asfáltico, e, principalmente, aos agregados e ao espaço entre suas partículas da mistura asfáltica ICAO 2002. Os operadores de aeródromos devem estabelecer um Sistema de Gerência de Pavimentos Aeroportuário (SGPA) para gerenciamento do risco que atendam aos limites mínimos desses parâmetros [ANAC 2023].

Kumar *et al.* 2023 desenvolveram um estudo sobre os métodos de mensuração e modelagem da resistência à derrapagem em países em desenvolvimento, comparando testes de campo e de laboratório. Os fatores que mais influenciam na resistência à derrapagem são a presença de água, com ocorrência de hidroplanagem, aderência pneu-pavimento, temperatura e textura da superfície. O estudo ainda sugere que devem ser desenvolvidos modelos de resistência à derrapagem mais confiáveis, usando métodos computacionais como as Redes Neurais Artificiais (RNA).

O tipo de revestimento asfáltico utilizado também é um fator que influencia na resistência à derrapagem de PPD. Segundo Aps 2006, as comparações entre os coeficientes de atrito medido em diferentes revestimentos asfálticos, como a Camada Porosa de Atrito (CPA), o Concreto Asfalto (CA) e o Pré-Misturado a Frio (PMF) mostraram que, em geral, a CPA apresenta os maiores resultados de coeficiente de atrito, enquanto o CA foi o revestimento que apresentou os menores valores.

Outro fator que influencia na resistência à derrapagem da PPD é a remoção do acúmulo de borracha do revestimento. Sales *et al.*(2021) analisaram a efetividade da remoção de borracha em PPD por meio de testes de hipóteses com amostras pareadas de coeficiente de atrito e macrotextura. Os resultados mostraram que a frequência de execução da remoção de borracha pode ser considerada eficiente para à segurança de poucos e decolagens.

Desse modo, a caracterização dos parâmetros relacionados à resistência à derrapagem da PPD pode auxiliar os operadores aeroportuários e as autoridades de aviação civil na tomada de decisão quanto à segurança operacional Chen e Li 2016. Diante do exposto, o objetivo deste artigo é obter um modelo de classificação da segurança operacional de PPD usando uma RNA do tipo *Multilayer Perceptron*, considerando dois tipos de revestimento asfáltico, a CPA e o CA.

2 REFERENCIAL TEÓRICO

A resistência à derrapagem de uma PPD se deteriora devido a fatores como desgaste mecânico, polimento da textura do pavimento provocada pelos pneus das aeronaves e presença de contaminantes, como o acúmulo de borracha, além do tipo de revestimento utilizado FAA 2007. Dessa forma, controlar os parâmetros relacionados à resistência à derrapagem e realizar os procedimentos de manutenção, como a remoção de borracha, é fundamental para a segurança de poucos e decolagens.

Mota, Oliveira e Aguiar 2016 analisaram as condições físicas de pavimentos aeroportuários e buscaram priorizar aquelas que tivessem maior influência sobre a segurança operacional, por meio de consulta a profissionais da área. Os resultados mostraram que o coeficiente de atrito e a macrotextura possuem uma influência de 48% sobre a segurança das operações, devendo ter prioridade nas atividades de manutenção e reabilitação (M&R), seguidas pelas condições funcionais e estruturais do pavimento.

Nesse contexto, a deterioração do coeficiente de atrito na superfície do revestimento é um fator crítico para a segurança das operações aeroportuárias, especialmente em presença de água. Com o objetivo de estudar os efeitos dessa deterioração, Zhu *et al.* (2021) avaliaram três tipos de revestimentos asfálticos, a saber, CPA, CA e *Stone Mastic Asphalt* (SMA). Como resultado, observou-se que o coeficiente de atrito diminui consideravelmente nos três tipos de pavimentos analisados, a partir de uma taxa de desgaste igual a 30.

O operador de aeródromo deve mensurar o coeficiente de atrito com frequência regulamentada em ANAC 2020, a fim de mantê-lo em condições de segurança operacional adequadas. Quando o valor médio do coeficiente de atrito está abaixo do valor mínimo, ações de manutenção devem ser tomadas, além de investigações sobre as causas dos valores baixos [ANAC 2020].

Outro fator importante para a segurança operacional das PPD é a profundidade da macrotextura, determinada por meio do ensaio da mancha de areia ANAC 2020. A profundidade média da macrotextura para a PPD deve permanecer acima de 0,60 mm. No entanto, essa classificação é diferente para revestimentos constituídos de CPA, cuja profundidade média da macrotextura deve ser no mínimo 1,20 mm, com a classificação de textura Muito Aberta [ANAC 2023]. No caso de valores inferiores a 0,60 mm, o operador de aeródromo deve informar o órgão fiscalizador sobre quais ações serão tomadas para atender à regulamentação e garantir a segurança das operações.

Maia, Oliveira e Silva 2023 analisaram dados de coeficiente de atrito e macrotextura de três PPD brasileiras entre 2015 e 2021. Os dados de coeficiente de atrito tiveram maior homogeneidade, com menores coeficientes de variação, em relação à macrotextura, fato que pode estar relacionado à forma de execução do ensaio utilizado para a obtenção da macrotextura.

Maia *et al.* 2023 analisaram as condições de resistência à derrapagem de PPD, antes e após processo de reabilitação, a fim de verificar o efeito dessa intervenção nos parâmetros de coeficiente de atrito e macrotextura. Após a obra de reabilitação, o coeficiente de atrito apresentou um aumento, enquanto a macrotextura não apresentou melhores condições, apesar de sua conformidade com os limites estabelecidos em ANAC 2023. Ainda, os autores identificaram um comportamento cíclico no coeficiente de atrito e uma diminuição ao longo do tempo para a macrotextura.

Três PPD brasileiras com revestimento em CA, CPA e com presença de *grooving*, foram avaliadas por Sales *et al.* (2022) com o objetivo de verificar a existência de correlação entre a remoção de acúmulo de borracha e a melhoria das condições de resistência à derrapagem. Observou-se que a remoção do acúmulo de borracha é um processo de manutenção eficiente no pavimento, pois possibilita que os níveis mínimos exigidos pelos órgãos regulamentadores para a macrotextura e o coeficiente de atrito sejam mantidos. Entretanto, o processo não garante aumentos significativos a longo prazo, não devendo ser a única ferramenta de manutenção das PPD.

Zheng *et al.* (2018) estudaram as características que afetam a resistência à derrapagem. Foram analisados três tipos de revestimento asfáltico, CPA, CA e SMA. A resistência à derrapagem diminui com o aumento da velocidade em todas as condições. No entanto, foi observado que o pavimento de CPA tem uma maior aderência mesmo na presença de película de água e em condições com altas velocidades. O pavimento de CA apresentou a pior condição, com redução de 15,4% da resistência em um evento de hidroplanagem, enquanto o SMA cerca de 12% e a CPA 10%.

As relações existentes entre a resistência à derrapagem e o conforto ao rolamento em PPD foram estudadas por Oliveira *et al.* (2016). Foram utilizados dados de macrotextura, coeficiente de atrito e *International Roughness Index* (IRI). Os autores verificaram que em alguns trechos da PPD, sobretudo no segmento central, o comportamento entre os parâmetros analisados apresenta tendência divergente.

As Redes Neurais Artificiais (RNA) são algoritmos que utilizam simulações matemáticas de neurônios biológicos para processar informações e prever padrões (Quariguasi *et al.*, 2019). Uma RNA é composta por camadas de elementos de processamento paralelo (neurônios). Entre uma camada de entrada e uma de saída podem existir uma ou mais camadas intermediárias. Os neurônios dessas camadas estão conectados aos neurônios de uma camada vizinha por fatores de ponderação, também chamados de pesos (W) e bias (b), ajustados durante o processo de treinamento da rede.

Para o correto funcionamento da RNA é necessário um componente não linear, chamado de função de ativação. Dentre as funções mais comuns, tem-se a linear, a sigmoide, a tangente hiperbólica (TANH) e a linear retificada (ReLU). Em relação ao aprendizado da rede, elas podem ser classificadas como supervisionadas ou não supervisionadas (Quariguasi *et al.*, 2019).

Segundo Géron 2017, dentre os tipos de RNA mais utilizadas, destaca-se o *Multilayer Perceptron* (MLP). Conforme Gajewski e Sadowski (2014), a rede MLP possui um algoritmo de aprendizado relativamente simples e eficaz. Ela é capaz de aproximar mapeamentos complexos e amplamente aplicada em problemas de classificação e previsão. Além disso, o MLP possui um tempo de resposta curto, o que permite a sua aplicação em tarefas em que a resposta em tempo real é necessária.

A rede MLP utiliza um algoritmo de retropropagação (*backpropagation*), que faz uma previsão do vetor alvo,

verifica o erro e segue através de cada camada em sentido reverso para medir a contribuição do erro de cada conexão. Com isso, é possível ajustar os pesos das conexões e diminuir o erro, este denominado Gradiente Descendente [Géron 2017].

No caso dos modelos de classificação, é possível avaliar a sua qualidade por meio de diferentes métricas, como a *Receiver Operating Characteristic Curve* (ROC), que demonstra o desempenho de um modelo de classificação binária. Para simplificar a análise da curva ROC pode ser usada a Área *Under the ROC Curve* (AUC), parâmetro que varia de 0 até 1 e o limiar entre classes é 0,5. Quanto maior o AUC, melhor (Hossin; Sulaiman, 2015).

Outras métricas que podem ser utilizadas são a matriz de confusão e o *Mean Squared Error* (MSE). A matriz de confusão é uma tabela que permite a visualização do desempenho de um algoritmo de classificação ao interpor os dados reais e os valores preditos pelo modelo Franceschi 2019. O MSE é uma métrica comumente usada para verificar a acurácia de modelos [Beuren e Gerchman 2016].

Modelos de previsão foram desenvolvidos por Ribeiro e Oliveira (2023) utilizando redes MLP para o coeficiente de atrito medido a 3 e a 6 metros do eixo de PPD por meio de diferentes tipos de equipamento. O objetivo foi auxiliar os operadores de aeródromos quanto à garantia da segurança operacional, além de verificar a influência do *grooving* no desempenho do coeficiente de atrito. Os modelos desenvolvidos apresentaram resultados satisfatórios com R^2 de aproximadamente 70%.

Quariguasi *et al.* (2021) desenvolveram um modelo de previsão do coeficiente de atrito medido em uma PPD, com o uso de redes MLP. A pesquisa utilizou o coeficiente de atrito, a remoção do acúmulo de borracha da pista, o número de pouso e descolagens, a umidade relativa e a idade do revestimento. O modelo resultou em um R^2 de 77,5%.

Devido à deficiência de métodos de identificação de trincas em pavimentos rodoviários, Praticò *et al.* (2020) desenvolveram um algoritmo de aprendizagem supervisionada para a identificação e classificação dessas trincas. Diferentes classificadores de *machine learning* foram utilizados, como o MLP, a Rede Neural Convolucional (RNC), o Random Forest Classifier (RFC) e o Support Vector Classifier (SVC). O MLP e a RNC foram capazes de classificar conjuntos de dados com precisões que variaram de 83% a 95,4%. O RFC apresentou precisão de 91,0% e o SVC 99,1%.

Niu *et al.* 2020 desenvolveram uma estimativa do coeficiente de atrito de PPD com base na junção de informações de vários sensores e na correlação com um modelo de coeficiente de atrito. Foram utilizados sensores acústicos, ópticos, de banda de rodagem e outros sensores físicos para medir parâmetros relacionados ao atrito e correlacioná-los por meio de uma RNA. Os modelos desenvolvidos incluem o Índice Internacional de Atrito da Pista (IRFI), o Índice de Atrito da Pista do Canadá (CRFI). O modelo gerado obteve resultado satisfatório com R^2 superior a 80%.

Assis *et al.* 2016 desenvolveram modelos de previsão da condição de pavimentos aeroportuários com uso de RNA e Função de Base Radial. As análises foram realizadas considerando-se três escalas de condição do pavimento, contendo 7, 5 e 3 categorias. O estudo utilizou como variáveis a Severidade, Densidade do Defeito, Valor Deduzido e o Índice de Condição do Pavimento, além das variáveis categóricas Seção, Severidade e Defeito. Obteve-se uma taxa de acerto variando de 66% e 98% e os melhores resultados foram obtidos com a escala com três categorias (Condição Boa, Regular ou Ruim).

Três abordagens diferentes para a classificação de defeitos em pavimentos asfálticos foram comparadas por Rababaah *et al.* (2005), com uma abordagem composta de pré-processamento de imagens, detecção, representação e classificação de trincas. Os algoritmos utilizados foram o *genetic algorithms*, o MLP e o *selforganizing maps*. A técnica mais efetiva foi o MLP, apresentando uma precisão de 98,6%.

3 MÉTODO

Para a realização desta pesquisa, foram utilizados dados obtidos por meio de relatórios técnicos de duas PPD brasileiras (2014 a 2018), fornecidos pela Agência Nacional de Aviação Civil (ANAC). As PPD estudadas possuem revestimento asfáltico, sendo uma em Concreto Asfáltico (CA) e a outra com Camada Porosa de Atrito (CPA).

Para o desenvolvimento das etapas metodológicas, foi utilizado o software *MatLab* R2023b em sua versão acadêmica, com licença obtida por meio da Universidade Federal do Ceará (UFC). Também foi utilizado o aplicativo *Jupyter Notebook*, compatível com *Python* 3.10, cuja licença é aberta. Para organização dos dados foi utilizado o software *Microsoft Excel*®.

CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE PISTAS DE POUSO E DECOLAGEM USANDO REDES *MULTILAYER PERCEPTRON*

Foram analisados 42 relatórios de profundidade da macrotextura e 76 relatórios de coeficiente de atrito para as duas PPD, totalizando 1238 amostras. Em relação ao coeficiente de atrito, as medições foram realizadas com o equipamento *Grip Tester* a uma velocidade de 65 km/h a 3 m e 6 m do eixo da PPD. As medições da macrotextura foram realizadas conforme ANAC 2020. Esses parâmetros foram analisados por meio de estatística descritiva. Para a classificação da segurança operacional utilizou-se a regra descrita na Tabela 1.

Tabela 1: Regra para a classificação da segurança operacional da PPD.

Tipo de revestimento	Regra	Classificação da Segurança Operacional
CPA	Profundidade da macrotextura menor que 1,20 mm ou coeficiente de atrito menor que 0,65	Não adequada
	Profundidade da macrotextura maior do que 1,20 mm e coeficiente de atrito maior do que 0,65	Adequada
CA	Profundidade da macrotextura menor que 0,80 mm ou coeficiente de atrito menor que 0,70	Não adequada
	Profundidade da macrotextura maior que 0,80 mm e coeficiente de atrito maior que 0,70	Adequada

Para entender a natureza do problema e das variáveis utilizadas foi realizada uma análise exploratória e observou-se que o fenômeno estudado é não linear e pode ser linearmente separável. Além disso, a segurança operacional de uma PPD é afetada por vários fatores, como o coeficiente de atrito e a profundidade da macrotextura; a remoção de borracha; o tipo de revestimento asfáltico; a localização na PDD; e o terço da PDD. Como o problema utiliza múltiplas variáveis independentes, ele é multivariado. O banco de dados foi organizado assim:(a) Variável dependente: classificação da segurança operacional (binária, 0 para não adequada e 1 para adequada); (b) Variáveis independentes: coeficiente de atrito (contínua), profundidade da macrotextura (contínua), remoção de borracha (binária, 0 para remoção de borracha, 1 para não remoção de borracha), terço da PPD (discreta, 1, 2 e 3 para representar o primeiro, o segundo e o terceiro terço da pista, respectivamente), localização na pista (discreta, contado a cada 100 m) e tipo de revestimento asfáltico (binária, 0 para CA e 1 para CPA).

Baseando-se nas características do fenômeno, no tamanho do banco de dados e na análise exploratória dos dados, verificou-se que o uso de redes *Multilayer Perceptron* (MLP) poderia ser adequada para a modelagem pretendida neste estudo. Para o treinamento da rede MLP adotou-se a recomendação de Lippmann 1987, que diz que, no caso de apenas uma camada intermediária, ela deverá ter $s.(i+1)$ neurônios, onde: s é o número de neurônios na camada de saída e i é o número de neurônios na camada de entrada. Assim, a arquitetura inicial da rede é 6:7:1, ou seja, 6 neurônios na camada de entrada, 7 neurônios (1.(6+1)) na camada intermediária e 1 neurônio na camada de saída.

Adotou-se também a recomendação de Hecht-Nielsen 1989, que recomendam que a camada intermediária deve ter $(2i+1)$ neurônios, onde i é o número de neurônios na camada de entrada. Dessa forma, a arquitetura inicial da rede, de acordo com essa recomendação, é 6:13:1, ou seja, 6 neurônios na camada de entrada, 13 neurônios na camada intermediária (2.6+1) e 1 neurônio na camada de saída.

Além das arquiteturas iniciais, também foram testadas as taxas de aprendizagem de 5%, 10%, 15% e 20%; as funções de ativação Sigmoid e ReLU; os algoritmos *Backpropagation* e *Levenberg-Marquardt*. Dessa forma, foram testadas 18 arquiteturas diferentes para escolha do modelo mais adequado à classificação pretendida.

Para o pré-processamento dos dados, inicialmente criou-se uma ordem aleatória no conjunto de dados e foi realizada a sua normalização usando o método Min-Max entre 0 e 1. Em seguida, os dados foram separados em 2 subconjuntos, mutuamente exclusivos, em que 70% correspondem ao subconjunto de treinamento, validação e teste do modelo. Assim, destes 70%, 15% foram usados para teste, 15% para validação e 70% para o treinamento. Os outros 30% dos dados foram usados no subconjunto de teste adicional, ou seja, estes dados não foram usados durante a etapa de treinamento da rede, sendo apresentados a ela após o treinamento, para avaliar a sua capacidade de aprendizado e generalização. Para isso, foi usada a matriz de confusão, a curva ROC, a AUC e o MSE.

4 RESULTADOS E DISCUSSÕES

Com o intuito de compreender melhor os dados utilizados neste estudo, foi realizada uma análise descritiva das variáveis coeficiente de atrito e profundidade da macrotextura, mostrada na Tabela 2.

Tabela 2: Análise descritiva.

Análise Descritiva	CA		CPA		CA+CPA	
	A	PM	A	PM	A	PM
Média	0,78	0,96	0,66	1,38	0,74	1,11
Desv. Pad.	0,13	0,20	0,06	0,13	0,12	0,27
CV (%)	16,26	21,39	9,30	9,71	16,72	24,63
Intervalo	0,01	0,01	0,01	0,01	0,01	0,02
Limite Superior	0,79	0,97	0,66	1,39	0,74	1,13
Limite Inferior	0,77	0,94	0,65	1,37	0,73	1,10

A – Coeficiente de Atrito; PM – Profundidade da macrotextura.

A média para o coeficiente de atrito é maior para o revestimento de Concreto Asfáltico, enquanto a média da macrotextura é maior para o revestimento de Camada Porosa de Atrito (Tabela 2). Isso pode ter ocorrido porque a CPA é um revestimento poroso, com textura superficial mais aberta, caracterizando os maiores valores de macrotextura. O coeficiente de variação foi maior para os valores de profundidade da macrotextura, possivelmente devido ao método de medição utilizado – o ensaio de mancha de areia. Esse método pode apresentar maiores variações nos resultados, conforme observado por Pinheiro Neto *et al.* (2015) e Maia, Oliveira e Silva 2023. Com o intuito de avaliar a relação entre as variáveis utilizadas nesse estudo, foi obtida a matriz de correlação apresentada na Tabela 3.

Tabela 3: Matriz de correlação.

	A	PM	RAB	TP	LP	RV	CSO
A	1,00						
PM	-0,40	1,00					
RAB	0,17	0,04	1,00				
TP	0,15	-0,16	-0,02	1,00			
LP	0,34	-0,41	-0,07	0,86	1,00		
RV	-0,49	0,75	0,18	-0,17	-0,49	1,00	
CSO	0,54	0,03	0,04	0,06	0,16	-0,22	1,00

A – Coeficiente de Atrito; PM – Profundidade da macrotextura; RAB – Remoção de borracha; TP – Terço da PPD; LP – Lado da PPD; RV – Tipo de revestimento; CSO – Classificação da segurança operacional.

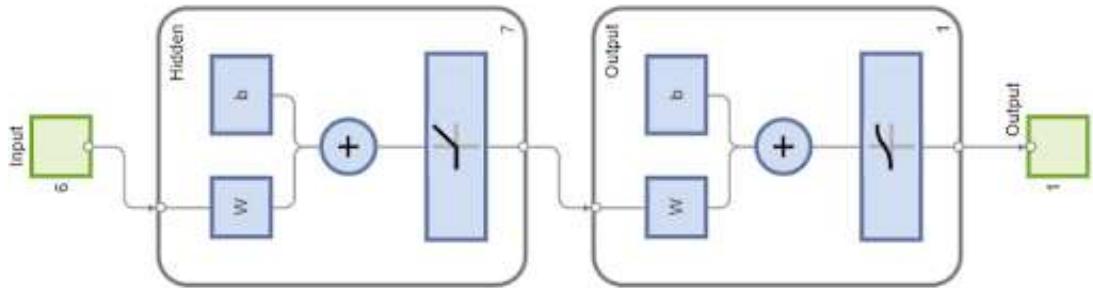
Da Tabela 3, observa-se que a classificação da segurança operacional obteve maiores correlações com o coeficiente de atrito, a localização na PPD e uma correlação inversa com o tipo de revestimento asfáltico. Além disso, observa-se uma correlação inversa entre o coeficiente de atrito e a profundidade da macrotextura. A maior correlação observada foi entre a profundidade da macrotextura e o tipo de revestimento asfáltico.

Em relação ao treinamento da rede MLP, os melhores resultados foram obtidos para a rede com arquitetura de 7 neurônios na camada intermediária, pois a rede com 13 neurônios começou a apresentar *overfitting*. Segundo Quariquasi (2020), o *overfitting* ocorre quando a rede se ajusta demasiadamente aos dados de treinamento, diminuindo a sua capacidade de generalização.

Em relação aos algoritmos utilizados, o *Levenberg-Marquardt* apresentou melhores resultados do que o *Back-propagation* padrão. O algoritmo de *Levenberg-Marquardt* é conhecido por sua eficiência e precisão, uma vez que aumenta a velocidade de treinamento sem perda de desempenho da rede (Telles *et al.*, 2013).

Para as funções de ativação, os melhores resultados foram obtidos com a função ReLU. Essa função é computacionalmente mais eficiente, convergindo mais rapidamente (Rizzo e Canato, 2020). Além disso, foram testadas quatro taxas de aprendizado diferentes, obtendo-se melhores resultados com a taxa de aprendizado de 20%. A Arquitetura da rede utilizada neste estudo está apresentada na Figura 1.

Figura 1: Arquitetura da rede MLP.



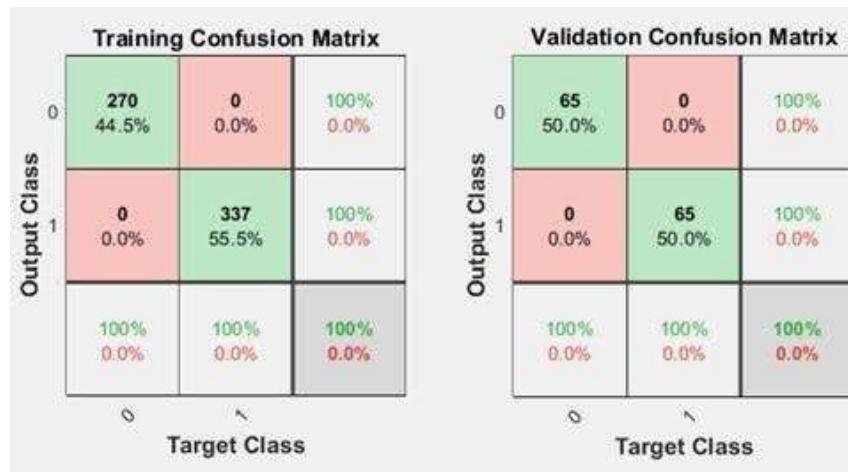
Assim, a rede MLP que apresentou os melhores resultados para a modelagem pretendida neste estudo tem sua arquitetura conforme descrito na Tabela 4. A performance da rede foi calculada usando o MSE, com os resultados apresentados também na Tabela 4.

Tabela 4: Arquitetura da rede MLP e performance.

Arquitetura		Performance	
Entrada	6	Performance	0,0012
Intermediária	7	trainPerformance	$4,5078 \times 10^{-10}$
Saída	1	valPerformance	$9,4633 \times 10^{-8}$
Algoritmo	<i>Levenberg–Marquardt</i>	testPerformance	0,0077
Função de ativação	ReLU	testPerformance	0,0054
Taxa de aprendizado	20%		

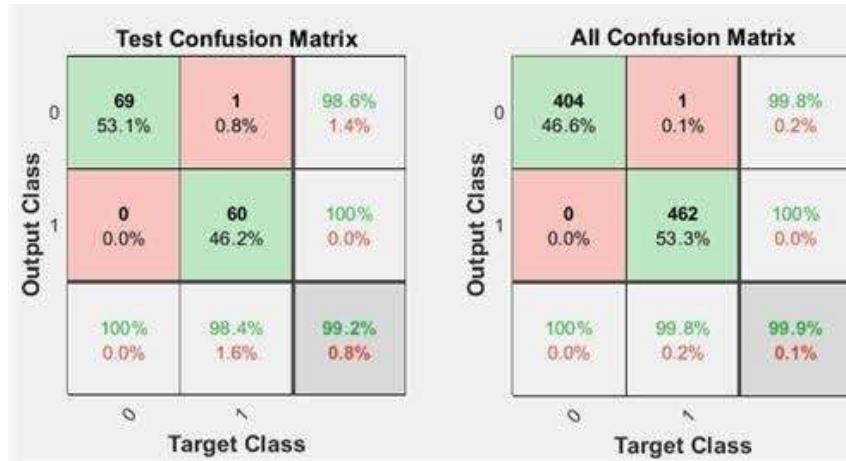
O MSE para os conjuntos de teste foram de 0,0077 e 0,0054 (Tabela 4), valores considerados baixos, mostrando que a rede conseguiu classificar adequadamente a segurança operacional da PPD para os dados utilizados neste estudo. As Figuras 2 e 3 mostram as matrizes de confusão das etapas de treinamento, validação e teste.

Figura 2: Matriz de confusão das etapas de treinamento e validação.



Observando-se as Figuras 2 e 3, nota-se que a rede apresentou um acerto de 100% nas etapas de treinamento e validação, e um acerto de 99,2% na etapa de teste, com um acerto de 99,9% considerando todos os dados. Esse

Figura 3: Matriz de confusão das etapas de teste e todos os dados.



resultado mostra um bom desempenho geral. A Figura 4 mostra a matriz de confusão para o teste adicional, que foi realizado considerando 30% do conjunto de dados que não foram usados na etapa de treinamento.

Figura 4: Matriz de confusão para o teste adicional.



Da Figura 4, verifica-se que no teste adicional realizado exclusivamente com dados que nunca tinham sido apresentados à rede, o modelo apresentou um acerto de 99,5%. Ou seja, apenas 0,5% dos dados não foram classificados adequadamente, o que pode ser considerado um valor baixo, mostrando que o modelo gerado é promissor para classificar a segurança operacional da PPD. Ainda com o intuito de avaliar o desempenho da rede, foram utilizadas as curvas ROC, mostradas nas Figuras 5, 6 e 7.

Das Figuras 5, 6 e 7, é possível perceber que os valores de AUC foram muito próximos de 1 nas etapas de teste do modelo, com a curva ROC se aproximando do canto superior esquerdo. Quanto mais a curva ROC se aproxima do canto superior esquerdo, melhor é o modelo de classificação. Sendo assim, este resultado mostra a adequação do modelo gerado para a classificação da segurança operacional da PPD. A Tabela 5 apresenta um resumo das métricas obtidas para avaliação do modelo de classificação.

Tabela 5: Resumo das métricas de avaliação do modelo.

Métricas	Treinamento	Validação	Teste	Teste Adicional
Matriz de confusão	100%	100%	99,2%	99,5%
AUC	1	1	0,99	0,99

Figura 5: Curva ROC para as etapas de treinamento e validação.

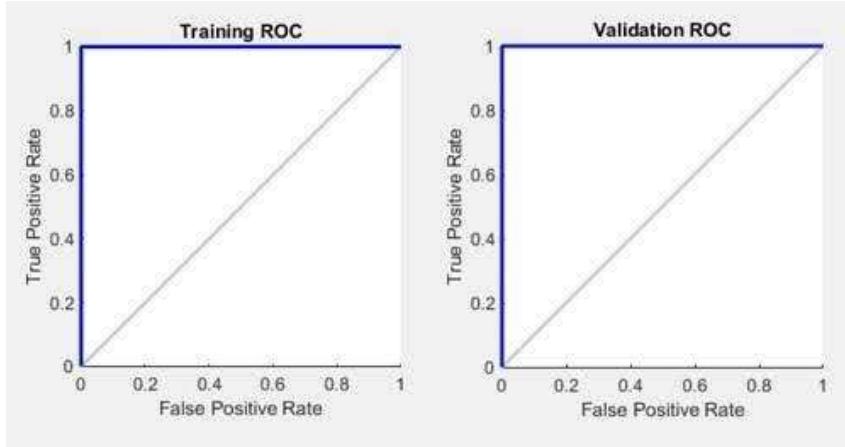


Figura 6: Curva ROC para as etapas de teste e todos os dados.

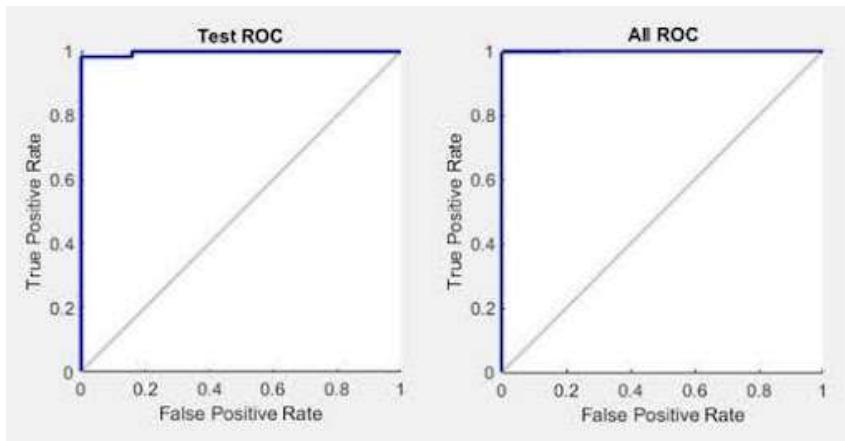
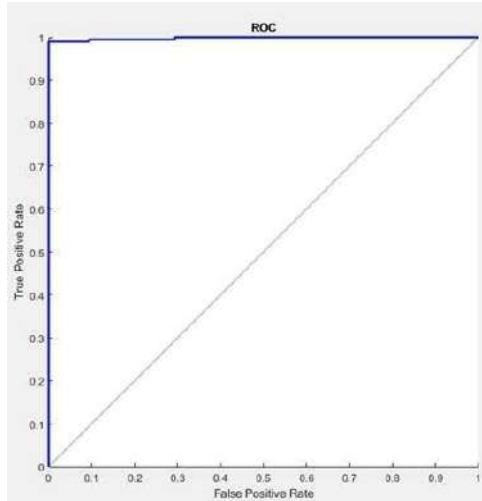


Figura 7: Curva ROC para a etapa de teste adicional.



CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE PISTAS DE POUSO E DECOLAGEM USANDO REDES *MULTILAYER PERCEPTRON*

Tanto a matriz de confusão, quanto a Curva ROC demonstram a adequação do modelo de classificação (Tabela 5). Com isso, espera-se contribuir para a segurança operacional de PPD ao fornecer uma ferramenta de apoio à tomada de decisão em relação aos parâmetros de resistência à derrapagem. Entretanto, algumas limitações devem ser consideradas. O modelo foi treinado e validado com dados específicos de duas PPD brasileiras, o que pode restringir sua aplicabilidade a outras pistas com características distintas. Além disso, fatores externos como variações climáticas e diferentes padrões de tráfego aéreo não foram incluídos na análise, o que pode impactar o desempenho do modelo em cenários não observados.

5 CONCLUSÃO

O objetivo deste artigo foi obter um modelo para classificação da segurança operacional de pistas de pouso em decolagem (PPD) usando uma rede neural do tipo *Multilayer Perceptron*. Foram utilizados dados de coeficiente de atrito, profundidade da macrotextura, dentre outros, de duas PPD, sendo uma com revestimento de Concreto Asfáltico (CA) e outra com Camada Porosa de Atrito (CPA). Foi possível acompanhar as condições de resistência à derrapagem, observando-se que a PPD com revestimento em CPA apresentou resultados satisfatórios para a profundidade da macrotextura e com CA, para o coeficiente de atrito.

O modelo gerado neste estudo mostrou a adequação ao uso da técnica de Redes Neurais Artificiais para classificar a segurança operacional de PPD. Constata-se o potencial das técnicas de *machine learning* na melhoria da segurança em PPD com diferentes tipos de revestimentos asfálticos. Assim, compreender e classificar a resistência à derrapagem de PPD é fundamental para garantir a segurança das operações aeroportuárias, uma vez que uma PPD com resistência deficiente pode contribuir para a ocorrência de incidentes e acidentes, especialmente em presença de água. Caracterizar essa resistência permite identificar áreas de risco e adotar medidas corretivas em pavimentos aeroportuários.

Agradecimentos

Os autores agradecem a Agência Nacional de Aviação Civil (ANAC) pela disponibilização dos dados e a Fundação Cearense de Apoio ao Desenvolvimento Tecnológico (FUNCAP) pelo auxílio financeiro concedido.

REFERÊNCIAS

ANAC. *Instrução Suplementar IS nº 153.205-001*. Brasília, DF: ANAC, 2020. Disponível em: <https://www.anac.gov.br/.../is153-205-001b.pdf>. Acesso em: 17 maio 2024.

ANAC. *Análise qualitativa dos relatórios finais das ocorrências com aeronaves de matrícula brasileira nos últimos 10 anos (2010–2019) classificadas como excursão de pista (Re)*. Brasília, DF: ANAC, 2021. Disponível em: https://www.gov.br/anac/.../Relatorio_RE_VersaoFinal.pdf. Acesso em: 24 maio 2022.

ANAC. *Regulamento Brasileiro da Aviação Civil Rbac nº 153 Emenda nº 07: Aeródromos - operação, manutenção e resposta à emergência*. Brasília, DF: ANAC, 2023. Disponível em: <https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-153>. Acesso em: 17 maio 2024.

APS, M. *Classificação da aderência pneu-pavimento pelo índice combinado IFI – International Friction Index para revestimentos asfálticos*. Tese (Doutorado) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2006. Disponível em: <https://doi.org/10.11606/T.3.2006.tde-11122006-144825>. Acesso em: 17 maio 2024.

ASSIS, R. K. M. et al. Uso de redes neurais artificiais para o desenvolvimento de modelos de previsão da condição de pavimentos de aeroportos. In: *Anais do Congresso Luso-Brasileiro para o Planejamento Urbano, Regional, Integrado e Sustentável (Pluris)*. Maceió: AL, 2016. Disponível em: <https://fau.ufal.br/.../Paper1062.pdf>. Acesso em: 17 maio 2024.

BEUREN, M. M.; GERCHMAN, M. Método de previsão de demanda de passageiros em aeroportos: um estudo de caso no Aeroporto Internacional Salgado Filho. *Produção em Foco*, v. 6, n. 1, 2016. Disponível em: <https://scholar.archive.org>. Acesso em: 17 maio 2024.

CHEN, W.; LI, J. Safety performance monitoring and measurement of civil aviation unit. *Journal of Air Transport Management*, v. 57, p. 228–233, 2016. Disponível em: <https://doi.org/10.1016/j.jairtraman.2016.08.015>. Acesso em: 17 maio 2024.

FAA. *AC 150/5320-12: Measurement, construction & maintenance of skid-resistant*

airport pavement surface

2007. Disponível em: https://www.faa.gov/.../150_5320_12c.PDF. Acesso em: 17 maio 2024.

FRANCESCHI, P. R. *Modelagens preditivas de churn: o caso do Banco do Brasil*. Dissertação (Mestrado) — Universidade do Vale do Rio dos Sinos, Porto Alegre, 2019. Disponível em: <https://repositorio.jesuita.org.br/.../9087>. Acesso em: 17 maio 2024.

GAJEWSKI, J.; SADOWSKI, T. Sensitivity analysis of crack propagation in pavement bituminous layered structures using a hybrid system integrating artificial neural networks and finite element method. *Computational Materials Science*, v. 82, p. 114–117, 2014.

GÉRON, A. *Hands-on machine learning with Scikit-learn*. Sebastopol, CA: O'Reilly, 2017.

HECHT-NIELSEN, R. *Neurocomputing*. Boston: Addison-Wesley Longman Publishing Co. Inc., 1989. Disponível em: <https://dl.acm.org/.../103996>. Acesso em: 17 maio 2024.

HOSSIN, M.; SULAIMAN, M. N. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, v. 5, n. 2, p. 1, 2015. Disponível em: <https://www.aircconline.com/ijdkp/V5N2/5215ijdkp01.pdf>.

ICAO. *Manual de servicios de aeropuertos: parte 2. Estado de la superficie de los pavimentos*. Lima: [s.n.], 2002.

KUMAR, A. et al. A state-of-the-art review of measurement and modelling of skid resistance: the perspective of developing nation. *Case Studies in Construction Materials*, v. 18, p. e02126, 2023. Disponível em: <https://doi.org/10.1016/j.cscm.2023.e02126>. Acesso em: 17 maio 2024.

LIPPmann, R. P. An introduction to computing with neural nets. *IEEE Assp Magazine*, v. 4, p. 4–22, 1987. Disponível em: <https://doi.org/10.1109/MASSP.1987.1165576>. Acesso em: 17 maio 2024.

MAIA, A. O.; OLIVEIRA, F. H. L.; SILVA, C. A. U. Um método de apoio à gestão para análise das condições de aderência em pavimentos aeroportuários. *Conexões - Ciência e Tecnologia*, IFCE, v. 17, p. e022016, 2023. Disponível em:

CLASSIFICAÇÃO DA SEGURANÇA OPERACIONAL DE PISTAS DE POUSO E DECOLAGEM USANDO REDES MULTILAYER
PERCEPTRON

- <https://conexoes.ifce.edu.br/.../1659>. Acesso em: 14 mar. 2024.
- MAIA, C. L. *et al.* Análise da resistência à derrapagem de pista de pouso e decolagem pré e pós-obra de reabilitação. In: *Anais do Encontro Nacional de Conservação Rodoviária (Enacor)*. Foz do Iguaçu: Paraná, 2023. Disponível em: <https://rapvenacor.com.br/.../TT898.pdf>. Acesso em: 17 maio 2024.
- MOTA, I. P. D. H.; OLIVEIRA, F. H. L.; AGUIAR, M. F. P. Verificação multicritério das condições físicas para a segurança operacional aeroportuária. *Transportes*, v. 24, n. 2, p. 21–26, 2016. Disponível em: <https://doi.org/10.14295/transportes.v24i2.1033>. Acesso em: 17 maio 2024.
- NIU, Y. *et al.* Estimation for runway friction coefficient based on multi-sensor information fusion and model correlation. *Sensors*, v. 20, p. 3886, 2020. Disponível em: <https://doi.org/10.3390/s20143886>. Acesso em: 17 maio 2024.
- OLIVEIRA, F. H. L. de; ALMEIDA, L. C. d.; RAMOS, S. P. Estudo do comportamento da aderência e do conforto ao rolamento em pistas de pouso e decolagem. *Transportes*, São Paulo-SP, v. 24, n. 2, p. 27–33, 2016.
- PRATICÒ, F. G. *et al.* Detection and monitoring of bottom-up cracks in road pavement using a machine-learning approach. *Algorithms*, v. 13, n. 4, p. 81, 2020.
- QUARIGUASI, J. B. F. *Previsão do coeficiente de atrito em pista de pouso e decolagem utilizando redes neurais artificiais*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2020. Disponível em: <https://repositorio.ufc.br/handle/riufc/55264>.
- QUARIGUASI, J. B. F.; OLIVEIRA, F. H. L. de; REIS, S. D. S. Estudo preliminar sobre proposição de modelo de previsão para o coeficiente de atrito medido em pista de pouso e decolagem. In: *SITRAER XVIII – Air Transportation Symposium*. [S.l.: s.n.], 2019. p. 9. Disponível em: [https://www.researchgate.net/...](https://www.researchgate.net/)
- QUARIGUASI, J. B. F.; OLIVEIRA, F. H. L. de; REIS, S. D. S. A prediction model of the coefficient of friction for runway using artificial neural network. *Transportes*, 2021.
- RABABAHH, H.; VRAJITORU, D.; WOLFER, J. Asphalt pavement crack classification: A comparison of GA, MLP, and SOM. In: *Proceedings of Genetic and Evolutionary Computation Conference, Late-Breaking Paper*. [S.l.: s.n.], 2005. Disponível em: https://cs.iusb.edu/isl/jim_papers/78_rababaah.pdf.
- RIBEIRO, T. R.; OLIVEIRA, F. H. L. de. Development of friction coefficient prediction models for brazilian runways using artificial neural networks. *Transportes*, v. 31, n. 2, p. 1–15, 2023. <https://doi.org/10.58922/transportes.v31i2.2792>.
- RIZZO, I. V.; CANATO, R. L. C. Inteligência artificial: funções de ativação. *Prospectus*, v. 2, n. 2, 2020. Disponível em: <https://prospectus.fatecitapira.edu.br/index.php/pst/article/view/37>.
- SALES, R. d. S.; OLIVEIRA, F. H. L. de; PRADO, L. d. A. Performance of tire-asphalt pavement adherence according to rubber removal on runways. *International Journal of Pavement Engineering*, v. 23, n. 10, p. 3566–3576, 2022.
- SALES, R. S.; MAIA, A. O.; OLIVEIRA, F. H. L. de. Análise da influência da remoção de borracha na aderência pneu-pavimento de pistas de pouso e decolagem. In: *Anais do 35º Congresso de Pesquisa e Ensino em Transportes da ANPET*. [S.l.: s.n.], 2021. Disponível em: https://www.anpet.org.br/.../1_130_AC.pdf.
- TELLES, W. R. *et al.* Simulação de uma pluma de contaminantes no rio macaé utilizando redes neurais artificiais. *Revista Brasileira de Recursos Hídricos*, v. 18, n. 2, p. 165–174, 2013. Disponível em: <https://files.abrhidro.org.br/Eventos/Trabalhos/153/...>
- ZHENG, B. *et al.* Adhesion characteristics of tire-asphalt pavement interface based on a proposed tire hydroplaning model. *Advances in Materials Science and Engineering*, v. 2018, 2018.
- ZHU, X. *et al.* Effects of surface texture deterioration and wet surface conditions on asphalt runway skid resistance. *Tribology International*, v. 153, p. 106589, 2021. Disponível em: <http://hdl.handle.net/1854/LU-8671575>.