



## 26° Encontro Nacional de Conservação Rodoviária (ENACOR) 49ª Reunião Anual de Pavimentação (RAPV)

# APLICAÇÃO DA APRENDIZAGEM DE MÁQUINA PARA A DETERMINAÇÃO DA MACROTEXTURA EM PISTAS DE POUSO E DECOLAGEM

*Madalena Osório Leite<sup>1</sup>;  
Carlos Augusto Uchoa da Silva<sup>2</sup>; Francisco Heber Lacerda de Oliveira<sup>2</sup>*

### RESUMO

A macrotextura é a textura superficial dos pavimentos aeroportuários, crucial para a aderência pneu-pavimento e essencial na drenagem de água para prevenir aquaplanagem. Este estudo tem como objetivo utilizar técnicas de Aprendizado de Máquina para prever a macrotextura das pistas. A metodologia empregada envolveu a coleta de dados de três diferentes aeroportos e a aplicação de modelos de Redes Neurais Artificiais (RNAs). Foram testadas duas arquiteturas de redes neurais, conforme as recomendações de Hecht & Nielsen (1989) e Lippmann (1987), visando comparar a eficácia das diferentes configurações de neurônios na camada intermediária. As análises demonstraram que a modelagem por Aprendizado de Máquina é uma ferramenta válida para entender as variáveis que afetam a macrotextura. O modelo final alcançou uma precisão preditiva de 69%, indicando um desempenho considerável, mas também destacando a necessidade de refinamentos futuros para melhorar a capacidade de previsão e a generalização dos modelos às condições variadas de operação aeroportuária.

**PALAVRAS-CHAVE:** Macrotextura; Aprendizado de Máquina; Pistas de Pouso e Decolagem.

### ABSTRACT

Macrotexture refers to the surface texture of airport pavements, crucial for tire-pavement adherence and essential in water drainage to prevent hydroplaning. This study aims to use Machine Learning techniques to predict the macrotexture of runways. The methodology involved data collection from three different airports and the application of Artificial Neural Network (ANN) models. Two neural network architectures were tested, following the recommendations of Hecht & Nielsen (1989) and Lippmann (1987), to compare the effectiveness of different configurations of neurons in the intermediate layer. The analyses demonstrated that Machine Learning modeling is a valid tool for understanding the variables affecting macrotexture. The final model achieved a predictive accuracy of 69%, indicating considerable performance but also highlighting the need for future refinements to improve prediction capacity and the models' generalization to varied airport operation conditions.

**KEY WORDS:** Macrotexture; Machine Learning; Runways.

<sup>1</sup> Universidade de Fortaleza (UNIFOR), [madalenaosorioleite@unifor.br](mailto:madalenaosorioleite@unifor.br).

<sup>2</sup> Departamento de Engenharia de Transportes, Bloco 703, Campus do Pici, Universidade Federal do Ceará (UFC), [heber@det.ufc.br](mailto:heber@det.ufc.br); [uchoa@det.ufc.br](mailto:uchoa@det.ufc.br).



## INTRODUÇÃO

A ANAC (2023) determina que o operador de aeródromo deve planejar e executar os serviços de manutenção e reabilitação (M&R) da pista de pouso e decolagem (PPD) e das demais infraestruturas aeroportuárias para manter a sua segurança. O pavimento aeroportuário deve, portanto, cumprir duas funções básicas: conforto ao rolamento e segurança. Tais funções são verificadas por meio da avaliação da condição funcional dos pavimentos, que abrange a análise da irregularidade longitudinal, do atrito, da macrotextura e da ocorrência de defeitos. Para Sales et al. (2021), a aderência efetiva pode ser alcançada por meio do controle da macrotextura e do coeficiente de atrito, combinados com processos de drenagem superficial do pavimento e de remoção do acúmulo de borracha sobre o revestimento.

A profundidade da macrotextura da superfície dos pavimentos aeroportuários é um dos fatores que mais afeta a resistência à derrapagem de aeronaves em superfícies molhadas, pois possibilita maior ou menor perda de energia ao contato com os pneus (Fonseca, 1990). Bernucci *et al.* (2007) afirmam que as condições de aderência dos pavimentos dos aeroportos, representadas pela profundidade da macrotextura, são fundamentais para que se promova a avaliação da situação das superfícies e que se decida sobre as manutenções.

Segundo Géron (2017), a *Machine Learning* (Aprendizagem de Máquina) pode ser aplicada para a resolução de problemas cujas soluções exijam longas listas de regras. Além disso, que estejam em cenários complexos em que não há boas respostas com o uso de abordagens tradicionais em ambientes versáteis ou quando há necessidade de mudanças com certa frequência.

O objetivo do presente artigo é utilizar a Aprendizagem de Máquina para estimar os índices de macrotextura, em pistas de pouso e decolagem. Foi utilizado o banco de dados de três pistas que pertencem ao Aeroporto Internacional de Salvador Luís Eduardo Magalhães, ao Aeroporto Internacional de Belém e ao Aeroporto Internacional de Porto Alegre Salgado Filho.

## REFERENCIAL TEÓRICO

### Macrotextura

A macrotextura, segundo Bernucci et al. (2007), é a textura associada à rugosidade do conjunto masticado asfáltico e agregados. Para Rodrigues Filho (2006), a macrotextura é representada pela altura média, em mm, do relevo da superfície. Segundo Oliveira (2016), a macrotextura é o principal responsável pela drenagem ativa da água da superfície dos pavimentos aeroportuários. Existe a preocupação com relação à impregnação de borracha, já que esse contaminante pode preencher as ranhuras e não permitir o adequado escoamento da água, favorecendo os eventos de aquaplanagem.

O ensaio da mancha de areia é utilizado para a medição da textura superficial de pavimentos. Consiste no espalhamento uniforme de um volume conhecido de areia sobre uma área da superfície do pavimento da pista de pouso e decolagem e na determinação da distância média entre os picos e vales da macrotextura do pavimento (profundidade da macrotextura) mediante a divisão do volume



de areia utilizado pela área de espalhamento (ANAC, 2023). No Brasil, este ensaio é normalizado por ABNT (2016). A medição de macrotextura, segundo ANAC (2023), deve ser feita em toda a extensão operacional da PPD e de forma alternada a cada 100 m, à esquerda e à direita do eixo, com, no mínimo, três medições para cada área. Após o cálculo da profundidade média da macrotextura de cada terço da pista, o operador do aeródromo deve classificar os resultados, devendo a profundidade média da macrotextura ser igual ou superior a 0,60 mm.

ANAC (2023) indica que a profundidade média da macrotextura deve ser maior ou igual a 0,60 mm para uma PPD e que, no caso de valores inferiores, o operador de aeródromo deve informá-la de quais ações serão tomadas para aumentar esse valor e garantir a segurança das operações. ICAO (2002) recomenda que a profundidade média da macrotextura de pavimentos novos não seja inferior a 1 mm, pois esse valor proporciona boas características de atrito em condições de pista molhada. Valores de profundidades inferiores a 1 mm podem proporcionar uma boa drenagem para pista, mas recomenda-se o uso de valores altos, pois a sua superfície da pista se deteriorará com o tempo de operação.

A segurança e eficiência das operações aeroportuárias dependem de uma variedade de fatores, desde a manutenção adequada das pistas até o uso de tecnologias inovadoras para otimizar processos. Nesse sentido, é crucial considerar não apenas os padrões regulatórios estabelecidos para garantir a integridade das superfícies de pouso, como também explorar novas abordagens que possam aprimorar a gestão e segurança das instalações aeroportuárias. Ao mesmo tempo, avanços significativos têm sido feitos no campo da ciência da computação, especialmente na Aprendizagem de Máquina, oferecendo oportunidades empolgantes para aprimorar a eficiência e a tomada de decisões em ambientes aeroportuários.

### **Aprendizagem de Máquina (*Machine Learning*)**

A Aprendizagem de Máquina, também chamada de Machine Learning, é um campo da ciência da computação que se destaca por sua capacidade de desenvolver algoritmos e modelos capazes de aprender e tomar decisões com base em dados. Conforme mencionado por Mitchell (1997), a principal ideia por trás do Machine Learning é construir sistemas que possam se adaptar e aprender com a experiência, melhorando seu desempenho ao longo do tempo. Os algoritmos da Aprendizagem de Máquina têm a habilidade de identificar padrões complexos nos dados e generalizá-los para realizar previsões e tomar decisões.

A Aprendizagem de Máquina, com sua capacidade de automatizar decisões a partir de dados, é destacada pela diversidade de suas aplicações, como reconhecimento de padrões e análise de dados. Segundo Géron (2017), ela se divide em categorias como supervisionada, onde algoritmos aprendem de dados rotulados para fazer previsões, e não supervisionada, que identifica padrões ocultos sem orientação específica. Este campo evoluiu rapidamente, abrindo novos caminhos para a inovação e eficiência em diversos setores.

Já as redes neurais artificiais são técnicas de Aprendizagem de Máquina inspiradas no funcionamento do cérebro humano. Para tanto, são utilizados sistemas paralelos distribuídos compostos por unidades de processamento simples, chamados de nodos, que calculam determinadas



funções matemáticas, em geral não lineares. Tais unidades são dispostas em uma ou mais camadas que são interligadas por um expressivo número de conexões (Ribeiro, 2013).

### APLICAÇÃO DA MODELAGEM NEURAL

Por meio da utilização de Redes Neurais Artificiais (RNAs), mais especificamente a arquitetura de Redes de Múltiplas Camadas (MLP), foram analisados os dados relativos aos parâmetros de aderência, provenientes das pistas aeroportuárias, para investigar a complexidade do índice de macrotextura das superfícies das pistas de pouso e decolagem.

Para a aplicação da Modelagem Neural a determinação do número ideal de neurônios na camada intermediária de uma arquitetura é uma consideração crucial para otimizar a eficácia do modelo. Duas abordagens distintas, propostas por Hecht & Nielsen (1989) e Lippmann (1987), oferecem diretrizes para essa questão. Hecht & Nielsen (1989) recomendam que a camada intermediária contenha o dobro mais um de neurônios em relação ao número de variáveis de entrada. Lippmann (1987) propõe que a quantidade de neurônios na camada intermediária seria determinada pela multiplicação do número de saídas pelo número de neurônios de entrada, acrescido de um. A Figura 1 mostra as etapas da aplicação.

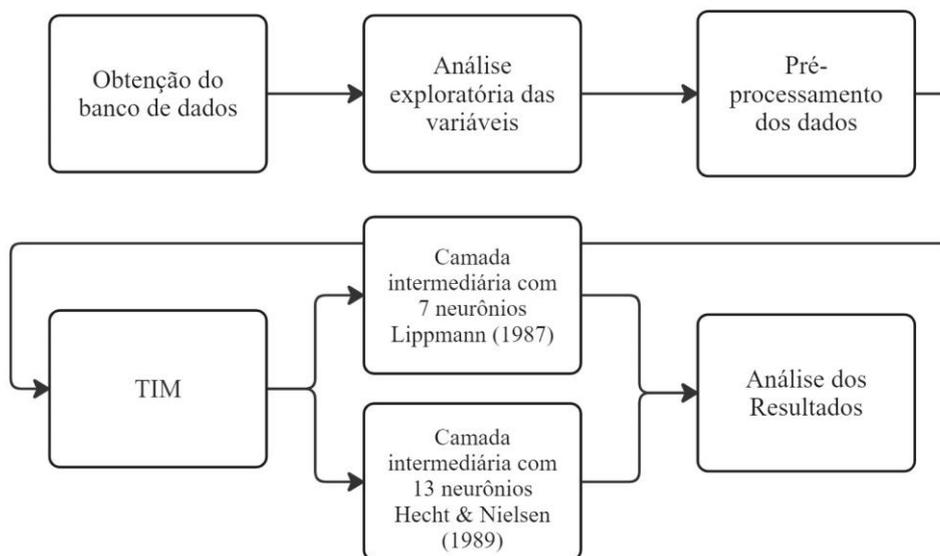


Figura 1. Etapas da aplicação da Rede Neural

O fluxograma descreve o processo de desenvolvimento e avaliação de uma rede neural para a análise de dados. O processo inicia com a obtenção do banco de dados, seguida por uma análise exploratória das variáveis para entender as características dos dados. Em seguida, ocorre o pré-processamento dos dados para prepará-los para a modelagem, incluindo normalização ou padronização, tratamento de valores ausentes e conversão de variáveis categóricas. A definição da arquitetura da rede neural é realizada usando a ferramenta *Network Fitting (Nftool)*. O diagrama mostra duas ramificações que diferem na configuração da camada intermediária: uma com 7 neurônios, conforme proposto por Lippmann em 1987, e outra com 13 neurônios, conforme sugerido por Hecht & Nielsen em 1989. O processo é concluído com a análise dos resultados.



### Obtenção do banco de dados

Para este estudo, foram utilizados dados secundários provenientes de bancos de dados de três pistas aeroportuárias distintas. As pistas analisadas estão localizadas no Aeroporto Internacional de Salvador Luís Eduardo Magalhães, no Aeroporto Internacional de Belém e no Aeroporto Internacional de Porto Alegre Salgado Filho.

A técnica de modelagem escolhida foi a utilização de Redes Neurais Artificiais (RNAs), mais especificamente a arquitetura de Redes de Múltiplas Camadas (MLP), com camada única, contendo o número mínimo de neurônios necessário para a tarefa. Essa seleção baseia-se na capacidade das RNAs de lidar com a complexidade inerente a previsão do índice de macrot textura em pistas de pouso e decolagem. Trata-se de um modelo de aprendizado supervisionado, especificamente projetado para realizar tarefas de regressão, que envolve variáveis contínuas e a necessidade de prever valores numéricos para o índice mencionado.

### Análise exploratória das variáveis

No contexto de modelagem e predição utilizando redes neurais, é necessário entender as características e interações entre as variáveis envolvidas. Antes de avançar para o treinamento de modelos, é crucial identificar multicolinearidade entre variáveis preditoras, pois isso pode afetar a estabilidade e a interpretabilidade do modelo. Redes neurais podem discernir padrões complexos e não-lineares; no entanto, a presença de alta correlação entre variáveis preditoras pode reduzir a precisão das predições. Além disso, é importante reconhecer que a correlação entre variáveis não estabelece uma relação causal. Conclusões sobre causalidade devem ser baseadas em conhecimento do domínio específico. A Tabela 1 mostra o *dataset* com todas as variáveis disponíveis.

Tabela 1. Trecho da planilha de dados coletados antes da análise exploratória.

| ID   | Variável de entrada 1 | Variável de entrada 2 | Variável de entrada 3 | Variável de entrada 4 | Variável de entrada 5 | Variável de entrada 6 | Variável de entrada 7 | Variável de entrada 8 | Variável de saída          |
|------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|----------------------------|
| ID   | Distância             | Pista                 | Lado                  | Terço                 | Dias_Remocao_anterior | Data_Remocao          | Data_medicao          | Ano                   | Valor_Macrotexura ESPERADO |
| 1    | 0                     | 1                     | 0                     | 1                     | 96                    | 19/06/2015            | 23/09/2015            | 2015                  | 0,61                       |
| 2    | 100                   | 1                     | 1                     | 1                     | 96                    | 19/06/2015            | 23/09/2015            | 2015                  | 0,49                       |
| 3    | 200                   | 1                     | 0                     | 1                     | 96                    | 19/06/2015            | 23/09/2015            | 2015                  | 0,42                       |
| 4    | 300                   | 1                     | 1                     | 1                     | 96                    | 19/06/2015            | 23/09/2015            | 2015                  | 0,51                       |
| 5    | 400                   | 1                     | 0                     | 1                     | 96                    | 19/06/2015            | 23/09/2015            | 2015                  | 0,52                       |
| 1490 | 1800                  | 3                     | 1                     | 3                     | 231                   | 09/10/2020            | 28/05/2021            | 2021                  | 1,51                       |
| 1491 | 1900                  | 3                     | 0                     | 3                     | 231                   | 09/10/2020            | 28/05/2021            | 2021                  | 1,49                       |
| 1492 | 2000                  | 3                     | 1                     | 3                     | 231                   | 09/10/2020            | 28/05/2021            | 2021                  | 1,49                       |
| 1493 | 2100                  | 3                     | 0                     | 3                     | 231                   | 09/10/2020            | 28/05/2021            | 2021                  | 1,14                       |
| 1494 | 2200                  | 3                     | 1                     | 3                     | 231                   | 09/10/2020            | 28/05/2021            | 2021                  | 1,72                       |

A análise da correlação entre variáveis foi realizada utilizando o coeficiente de correlação de Pearson. Essa abordagem permitiu determinar se as variáveis estão correlacionadas positiva ou negativamente, ou se não há relação aparente entre elas. Os resultados dessa análise estão apresentados na Figura 2, onde foram identificados padrões de comportamento. Essa análise é crucial para a seleção das variáveis mais relevantes para o treinamento de redes neurais, além de auxiliar na detecção de possíveis problemas de multicolinearidade, os quais podem afetar a precisão e a interpretação dos modelos resultantes.

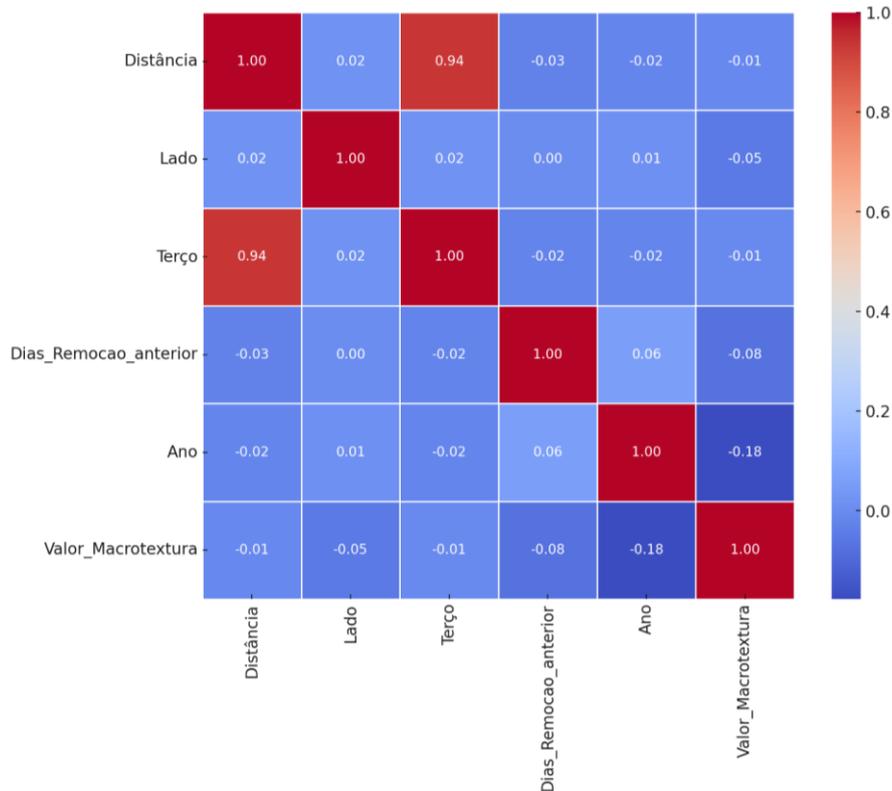


Figura 2. Matriz de correlação das variáveis numéricas.

Na análise dos dados sobre as condições de macrotextura das pistas de aeroportos, construiu-se uma matriz de correlação para examinar as relações entre variáveis numéricas. A matriz de calor revela correlações significativas, destacando-se a relação entre as variáveis Distância e o Terço (da pista), que apresenta um coeficiente elevado, indicando uma forte dependência linear entre essas variáveis, ambas marcadoras de locais específicos ao longo da pista.

A variável Valor\_macrotectura, por outro lado, mostrou correlações negativas com as demais variáveis, indicando que influências mais sutis ou não lineares podem estar afetando esta métrica de textura da superfície. Adicionalmente, a correlação mínima entre Ano da medição e as outras variáveis sugere que as alterações temporais anuais têm pouco impacto direto nas condições observadas, refletindo uma possível estabilidade nas práticas de manutenção e nas características construtivas ao longo do tempo.

Apesar das correlações identificadas, todas as variáveis serão incorporadas na análise das condições de macrotextura das pistas de aeroportos. Essa abordagem completa permitirá uma compreensão mais ampla dos fatores que afetam as condições das pistas. Assim, mesmo com a correlação negativa leve de Valor\_macrotectura com outras variáveis, todas serão consideradas para assegurar uma avaliação precisa e abrangente das condições das pistas de aeroportos.

Após a análise de correlação, essa estrutura de dados categorizados foi tratada através da técnica de *dummyização*, onde cada variável foi convertida em representações numéricas. No caso de Nome da



pista, três variáveis binárias distintas seriam criadas para representar cada valor único (1, 2, 3). Para Lado da pista, uma única variável binária foi utilizada, representando os dois valores possíveis (0 ou 1). Por fim, para Terço da pista, três variáveis binárias foram criadas para cada valor único (1, 2, 3). Os nomes das seis variáveis foram revisados no conjunto de dados para facilitar sua compreensão. Essa revisão foi realizada com o objetivo de tornar mais fácil o entendimento e a interpretação das variáveis no modelo de rede neural.

### Pré-processamento dos dados

O processo de pré-processamento do conjunto de dados foi conduzido por meio de um script (código m) implementado no Matlab. Inicialmente, os dados foram lidos a partir de um arquivo gerado no software Excel, onde os dados ocuparam as células de B3 à H1496. Essa leitura resultou na formação de um *dataset*, o qual foi reordenado aleatoriamente para introduzir uma ordem de embaralhamento, visando evitar possíveis vieses nos padrões usados na modelagem.

Posteriormente, a etapa de normalização Min-Max foi aplicada ao *dataset*. Essa técnica foi empregada para normalizar as variáveis, exceto a coluna 7 (saída), trazendo-as para uma faixa comum de valores entre 0 e 1. Após a normalização, o *dataset* foi dividido em dois conjuntos mutuamente exclusivos: um conjunto de treinamento e um conjunto de teste. Assim, 70% dos dados foram alocados para o conjunto de treinamento, enquanto 30% foram destinados ao conjunto de teste, como pode ser observado na Figura 3.

```

1
2 % Ler o arquivo Excel
3 dataset = xlsread('Dadosmadalena.xlsx', 1, 'B3:H1496');
4
5 % Criar uma ordem aleatória no conjunto de dados (embaralhar)
6 randomOrder = randperm(size(dataset, 1));
7 dataset = dataset(randomOrder, :);
8
9 % Aplica a normalização Min-Max
10 colsToNormalize = 1:size(dataset, 2);
11 colsToNormalize(colsToNormalize == size(dataset, 2)) = [];
12 colsToNormalize(colsToNormalize == 7) = [];
13 dataset(:, colsToNormalize) = (dataset(:, colsToNormalize) - min(dataset(:, colsToNormalize))) ./ (ma
14
15 % Separar em 2 conjuntos de dados mutuamente exclusivos
16 numRows = size(dataset, 1);
17
18 % 70% dos dados para treinamento
19 numTrain = round(0.7 * numRows);
20
21 % Conjunto de treinamento
22 treinamento = dataset(1:numTrain, :);
23
24 % Conjunto de teste
25 teste = dataset(numTrain+1:end, :);
26
27 % Dividir cada conjunto em dois subconjuntos
28
29 % Colunas B até G
30 entradaTreinamento = treinamento(:, 1:end-1);
31
32 % Coluna H

```

Figura 3. Janela de comando do Matlab para o pré-processamento dos dados.

Cada um desses conjuntos foi ainda subdividido em duas partes distintas. No conjunto de treinamento, as colunas de B até G foram separadas para representar as entradas do modelo, enquanto a coluna H foi isolada para representar a variável de saída esperada. O mesmo procedimento foi realizado para o conjunto de teste, garantindo consistência entre os subconjuntos e permitindo a correta alimentação do modelo com os dados de entrada e de saída para fins de treinamento e validação.



### Definição da Arquitetura da Rede Neural Neural

A determinação do número ideal de neurônios na camada intermediária de uma arquitetura neural é crucial para a eficácia do modelo. Diferentes abordagens propostas por Hecht & Nielsen (1989) e Lippmann (1987) oferecem orientações sobre essa questão.

A partir do que disse Lippmann (1987) foi realizada uma abordagem baseada na relação entre o número de variáveis de entrada e a saída desejada. De acordo com esta teoria, a quantidade de neurônios na única camada intermediária seria dada pela multiplicação do número de saídas pelo número de neurônios de entrada somado com um. Considerando uma saída e seis variáveis de entrada, a arquitetura recomendada resultaria em 7 neurônios na camada intermediária, resultando em uma rede com a arquitetura 6:7:1 (Figura 4).

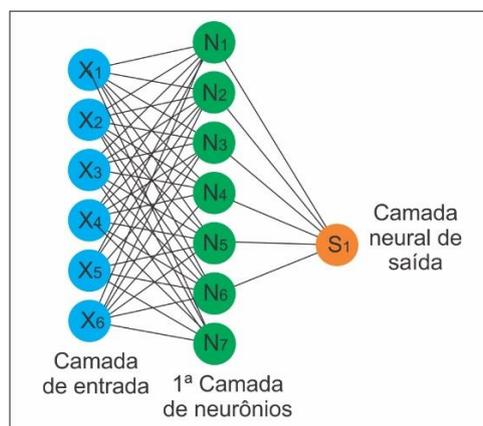


Figura 4. Proposta de Rede Neural a partir de Lippmann (1987).

Seguindo as recomendações de Hecht & Nielsen (1989), estabeleceu-se outra estrutura da camada intermediária sugerindo que esta deva conter o dobro mais um de neurônios em relação ao número de variáveis de entrada. Por exemplo, para o índice de macrotextura, composto por seis variáveis de entrada, a arquitetura proposta resultaria em 6:13:1 neurônios. Posteriormente à definição dessas diretrizes para a estrutura da camada intermediária da rede neural, foram elaboradas as arquiteturas completas.

### Neural Network Fitting (Nftool) com 1 camada intermediária

Após o código aplicado no Matlab, vem a utilização do Nftool, uma ferramenta disponível no Matlab para configurar e treinar redes neurais. Através de sua interface, é possível definir a estrutura da rede, como o número de camadas e neurônios, escolher as funções de ativação e os algoritmos de treinamento. Além disso, viabiliza a divisão do conjunto de dados para treinamento e validação. Essa ferramenta simplifica o processo de criação de redes neurais.

No primeiro treinamento foi usada a configuração da rede como 6:7:1. Os conjuntos de dados de entrada e saída foram adequadamente formatados e integrados à ferramenta, possibilitando a configuração e execução do processo de treinamento. Na definição dos parâmetros da rede, o número de camadas intermediárias ficou de 7 neurônios e funções de ativação. O resultado do



primeiro teste mostrou um percentual de avaliação de 46% (Figura 5), o que não é um bom resultado. Espera-se um valor superior a 80%.

|                   | Observations | MSE    | R      |
|-------------------|--------------|--------|--------|
| <b>Training</b>   | 732          | 0.1801 | 0.5936 |
| <b>Validation</b> | 157          | 0.1985 | 0.4586 |
| <b>Test</b>       | 157          | 0.1498 | 0.6018 |

Figura 5. Tela do Matlab com o percentual de validação para a Rede 6:7:1.

Como o percentual de validação do primeiro teste não foi satisfatório, foi necessário explorar diferentes arquiteturas de redes neurais para melhorar o desempenho do modelo. Durante esse processo, foram realizadas iterações para ajustar a rede neural, com o objetivo de aprimorar sua capacidade de generalização e adaptabilidade aos padrões presentes nos conjuntos de dados. As simulações realizadas com uma quantidade maior de neurônios na camada intermediária resultaram em desempenho inferior em comparação com a configuração que continha 7 neurônios.

A análise passa então a ser conduzida com base nas recomendações de Hecht & Nielsen (1989), ajustando a estrutura da rede neural de acordo com suas orientações. Isso implica testar uma configuração com 13 neurônios na camada intermediária, conforme indicado por essa abordagem. Os resultados obtidos com essa nova configuração estão na Figura 6.

|                   | Observations | MSE    | R      |
|-------------------|--------------|--------|--------|
| <b>Training</b>   | 889          | 0.1412 | 0.6860 |
| <b>Validation</b> | 157          | 0.1330 | 0.6895 |
| <b>Test</b>       | 0            | NaN    | NaN    |

Figura 6. Tela do Matlab com o percentual de validação para a Rede 6:13:1.



Após realizar o ajuste na rede neural, configurando-a para operar com uma única camada composta por 13 neurônios, o resultado obtido demonstrou um desempenho de validação de 69%.

## ANÁLISES E DISCUSSÕES

Os resultados dos gráficos revelaram uma performance aquém do esperado durante a análise do modelo. Embora o desempenho da rede neural não tenha atingido as expectativas iniciais, também não pode ser considerado como insatisfatório.

Para avaliar a eficácia da rede neural proposta por Hecht & Nielsen (1989), com 13 neurônios na camada intermediária, foram elaborados a Matriz de confusão e o Gráfico de performance do modelo. Através desta análise, será possível entender melhor a capacidade de classificação do modelo e sua eficiência em termos de aprendizado e generalização.

A análise da matriz de confusão revela que o modelo apresenta uma alta precisão global, especialmente na identificação da classe 1. No entanto, a falta de detecção de verdadeiros negativos e a ocorrência de falsos positivos para a classe 0 sugerem um desequilíbrio no tratamento das classes, possivelmente devido a um desbalanceamento nos dados de treinamento ou uma inclinação do modelo para a classe mais comum. Recomenda-se revisar o balanceamento das classes no conjunto de dados de treinamento e ajustar a sensibilidade do modelo para melhorar sua precisão na identificação da classe 0. A Figura 7 mostra a Matriz de confusão.

|              |   | Matriz de Confusão |               |               |
|--------------|---|--------------------|---------------|---------------|
|              |   | 0                  | 1             |               |
| Output Class | 0 | 0<br>0.0%          | 9<br>2.0%     | 0.0%<br>100%  |
|              | 1 | 0<br>0.0%          | 439<br>98.0%  | 100%<br>0.0%  |
|              |   | 0                  | 1             |               |
|              |   | NaN%<br>NaN%       | 98.0%<br>2.0% | 98.0%<br>2.0% |
|              |   | Target Class       |               |               |

Figura 7. Matriz de confusão do modelo.

O gráfico da Figura 8 mostra o desempenho de uma rede neural durante o treinamento, validação e teste ao longo de 23 iterações. Observa-se que o erro quadrático médio (MSE) para o conjunto de



treinamento (linha azul) e validação (linha verde) diminui significativamente no início e depois se estabiliza, indicando que o modelo converge de maneira eficaz. O erro no conjunto de teste (linha vermelha) segue um padrão semelhante, o que sugere que o modelo está generalizando bem, uma vez que as linhas de validação e teste permanecem próximas após a estabilização. O ponto marcado com um círculo verde destaca o melhor desempenho de validação, que ocorre na iteração 17, com um MSE de 0.2086.

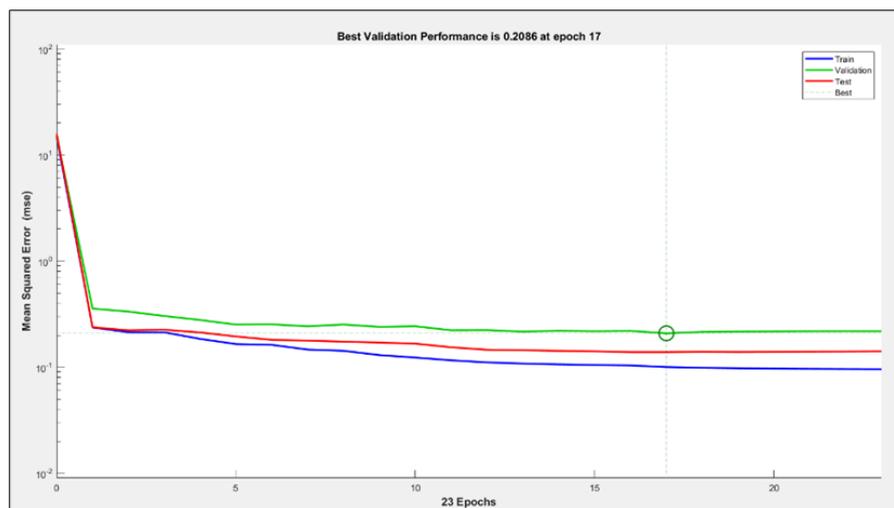


Figura 8. Performance do modelo

A iteração que marca o melhor desempenho de validação é crucial, pois sugere o momento ideal para cessar o treinamento e evitar o *overfitting*, assegurando que o modelo generalize bem para dados novos. Após este ponto, treinamentos adicionais podem não melhorar e até degradar o desempenho em dados desconhecidos. Esse fenômeno é evidenciado pelo fato de que as curvas de validação e teste permanecem estáveis e próximas uma da outra mesmo após a iteração 17, demonstrando que o modelo alcançou uma capacidade ótima de generalização sem memorizar os dados de treinamento.

## CONCLUSÕES

A investigação sobre aderência pneu-pavimento em pistas de pouso e decolagem, conduzida por meio de técnicas de Aprendizado de Máquina, especialmente o uso de Redes Neurais Artificiais (RNAs), destacou desafios significativos na previsão dos índices de macrotextura. Após análise e modelagem, o desempenho máximo alcançado para o conjunto de teste foi de 69%, revelando uma limitação na capacidade preditiva do modelo em relação a esses índices.

Esta avaliação técnica sugere uma necessidade urgente de refinamentos adicionais na estrutura do modelo. Um caminho viável envolve uma revisão detalhada das variáveis de entrada, considerando a exclusão seletiva de variáveis que contribuem de forma limitada para o modelo. Essa abordagem permitiria a inclusão de outras variáveis mais significantes para a explicação do fenômeno em questão.



Aprofundar a análise de correlações entre variáveis é crucial. Identificar relações lineares fortes ou redundâncias entre algumas delas pode resultar em um refinamento substancial do modelo. Embora os resultados atuais não tenham atendido às expectativas, a exploração deste estudo proporcionou insights e estabeleceu uma base sólida para futuros trabalhos.

Nesse sentido, a continuação desta pesquisa implica em buscar mais dados e refinar a modelagem para aprimorar a precisão preditiva do modelo. Incorporar novos parâmetros ou reavaliar as variáveis existentes é fundamental para estabelecer um modelo mais robusto e confiável para a previsão dos índices de macrotextura em pistas de pouso e decolagem, contribuindo para a segurança e eficiência operacional dos aeródromos.

## REFERÊNCIAS

- ANAC (2023). Regulamento Brasileiro de Aviação Civil Nº 153, de 14 de abril de 2023. Agência Nacional de Aviação Civil. Secretaria de Aviação Civil. Brasília, DF.
- BERNUCCI, L. B.; MOTA, L. M. G.; CERATI, J. A. P.; SOARES, J. B. (2007). Pavimentação Asfáltica - Formação Básica para Engenheiros. Rio de Janeiro : Petrobrás.
- FONSECA, O. A. (1990). Manutenção de Pavimentos de Aeroportos. Brasília: Diretoria de engenharia da Aeronáutica. Divisão de Estudos e Projetos de Infraestrutura. Ministério da Aeronáutica.
- GÉRON, A. (2017). Hands-on machine learning with Scikit-Learn and TensorFlow : concepts, tools, and techniques to build intelligent systems. Sebastopol, CA: O'Reilly Media. ISBN 978-1491962299.
- ICAO (2002) Manual de servicios de aeropuertos. Parte 2. Estado de la superficie de los pavimentos. Cuarta edición. Organización de Aviación Civil Internacional. Lima, Peru.
- MITCHELL, T. M. Machine learning. New York, NY: McGraw-Hill Science/Engineering/Math, 1997. 432 p. ISSN 03600300. ISBN 0070428077.
- OLIVEIRA, F. H. L. (2016). Desenvolvimento de um modelo de gerenciamento de pavimentos aeroportuários como apoio à tomada de decisão sobre estratégias de manutenção e reabilitação. 179f. Tese (Doutorado em Engenharia de Transportes) - Programa de Mestrado em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, CE.
- 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. 141 f. Dissertação (Mestrado em Engenharia de Transportes) - Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, 2013.
- RODRIGUES FILHO, O. S. (2006) Características de Aderência de Revestimentos Asfálticos Aeroportuários – Estudo de Caso do Aeroporto Internacional de São Paulo/Congonhas. Dissertação de Mestrado. Escola Politécnica da Universidade de São Paulo. São Paulo, SP.
- SALES, R. S.; OLIVEIRA, F. H. L. de; PRADO, L. A. (2021). Performance of tire-asphalt pavement adherence according to rubber removal on runways. INTERNATIONAL JOURNAL OF PAVEMENT ENGINEERING 2022, VOL. 23, NO. 10, 3566–3576 <https://doi.org/10.1080/10298436.2021.1907577>.