

DESENVOLVIMENTO E APLICAÇÃO DE REDES NEURAIIS NA PREVISÃO DE FALHAS EM COMPONENTES AERONÁUTICOS: UM ESTUDO EXPLORATÓRIO NA AVIAÇÃO

Larissa Pereira de Lima¹, Marcella Scoczynski Ribeiro Martins²

RESUMO: O estudo explora o uso de redes neurais recorrentes (RNN) e de longa memória (LSTM) para prever falhas em motores de aeronaves, aplicando manutenção preditiva. A justificativa é clara: garantir a segurança dos passageiros e reduzir os altos custos de manutenção ao manter os motores em condições ótimas. O objetivo principal é desenvolver modelos capazes de, a partir do histórico de dados sensoriais e ciclos de operação, prever quando um motor falhará em um ciclo futuro específico. A metodologia envolve várias etapas, desde a importação de bibliotecas até o pré-processamento e normalização dos dados, seguido da criação da variável alvo de classificação e da análise exploratória de dados (EDA). Foram testados diversos modelos de RNN, incluindo um simples com uma feature e outro mais complexo com 25 features, além de uma versão bidirecional. Em seguida, modelos LSTM foram criados para aprimorar a previsão, lidando melhor com a natureza sequencial e dependências de longo prazo dos dados. Os resultados indicam que os modelos RNN mais complexos, com 25 features, superaram os modelos simples em termos de precisão e outras métricas de avaliação. O estudo conclui que tanto as RNNs quanto as LSTMs são ferramentas eficazes para manutenção preditiva, destacando a importância de um bom planejamento para evitar falhas, que geram custos elevados e riscos à segurança.

Palavras-chave: manutenção preditiva; redes neurais recorrentes; LSTM; falhas em motores; segurança aeronáutica.

1. INTRODUÇÃO

A segurança na aviação comercial é um dos fatores mais críticos para garantir a integridade e o crescimento sustentável do setor, que desempenha um papel fundamental no transporte de passageiros e cargas em nível global. No Brasil, a aviação enfrenta desafios constantes, especialmente em relação à manutenção de aeronaves, que é uma área essencial para assegurar operações seguras. Segundo dados do Painel SIPAER, vinculado ao Centro de Investigação e Prevenção de Acidentes Aeronáuticos (CENIPA), entre 2012 e 2022 foram registrados 309 acidentes aéreos no país, sendo que apenas 5,2% envolveram aeronaves comerciais. Esse dado ressalta o alto nível de segurança da aviação comercial, em contraste com aeronaves particulares, onde a manutenção inadequada contribuiu significativamente para o número de incidentes.

A aviação comercial brasileira, devido à sua importância econômica e social, é altamente regulamentada e exige padrões elevados de manutenção. No entanto, falhas

mecânicas ainda ocorrem, principalmente em aeronaves de pequeno porte e em voos particulares, reforçando a necessidade de adoção de métodos mais avançados e eficientes de manutenção. Historicamente, as abordagens tradicionais, como a manutenção preventiva e corretiva, têm sido amplamente utilizadas, mas apresentam limitações, principalmente no que diz respeito à capacidade de prever falhas em componentes críticos com antecedência.

Com o avanço das tecnologias de aprendizado de máquina, novas possibilidades têm surgido para enfrentar esses desafios. Em especial, as redes neurais recorrentes (RNNs) e as redes de memória de longo prazo (LSTMs) se destacam como ferramentas poderosas para a análise de séries temporais e dados sequenciais. Essas características são essenciais no contexto de dados de manutenção de aeronaves, que envolvem informações contínuas sobre o desempenho dos motores e outros sistemas críticos. A aplicação de modelos baseados em redes neurais no campo da manutenção preditiva pode trazer benefícios significativos, como a antecipação de falhas, otimização dos processos de manutenção, redução de custos operacionais e, consequentemente, maior segurança e eficiência para as operações aéreas.

2. OBJETIVO

O objetivo deste estudo é desenvolver, implementar e avaliar modelos preditivos baseados em redes neurais recorrentes (RNNs) e redes de memória de longo prazo (LSTMs) para prever falhas em motores de aeronaves. A análise de dados históricos de ciclos de operação e de sensores permitirá criar modelos capazes de identificar padrões e antecipar falhas antes que se tornem críticas, aumentando a confiabilidade dos motores.

Especificamente, o estudo visa explorar o desempenho de diferentes arquiteturas de RNNs e LSTMs na análise de dados sequenciais referentes à operação dos motores. Além disso, será feita a comparação entre modelos simples e complexos, com diferentes quantidades de variáveis (features), para otimizar a precisão das previsões. Também será investigado o impacto do uso de dados temporais em várias janelas de tempo, buscando maximizar a capacidade de detectar falhas antes de eventos específicos.

O estudo pretende, ainda, avaliar o potencial de redução de custos operacionais e de manutenção não programada. Com a antecipação de falhas e a adoção de uma abordagem preditiva eficiente, será possível garantir maior segurança e eficiência nas operações das aeronaves, beneficiando diretamente as companhias aéreas.

Ao final, o trabalho buscará contribuir para o desenvolvimento de soluções tecnológicas inovadoras para a aviação, facilitando a adoção de práticas de manutenção preditiva mais eficazes. Isso não só aumentará a segurança dos passageiros, como também melhorará a gestão de recursos financeiros e operacionais das empresas, reduzindo o número de manutenções emergenciais e prolongando a vida útil dos motores das aeronaves.

3 METODOLOGIA

A presente pesquisa busca desenvolver e aplicar redes neurais recorrentes (RNNs) para a previsão de falhas em componentes críticos de aeronaves, utilizando dados de manutenção e operação. A metodologia adotada é descrita abaixo, contemplando as etapas de tratamento de dados, implementação dos modelos e comparação entre os métodos utilizados.

Tratamento de dados

O primeiro passo consistiu no tratamento dos dados de manutenção e operação de aeronaves, que foram normalizados e organizados em matrizes adequadas para a aplicação em redes neurais. A normalização dos dados foi realizada utilizando a técnica MinMaxScaler, que ajusta os valores das variáveis para um intervalo comum, geralmente entre 0 e 1. Esse processo é essencial para garantir que todas as variáveis contribuam de maneira equilibrada para o modelo de aprendizado de máquina.

Os dados foram organizados em sequências temporais, em forma de submatrizes, para permitir que o modelo capture os padrões temporais presentes nas características monitoradas ao longo do tempo. O comprimento dessas sequências foi definido com base nos dados disponíveis e em testes preliminares para otimizar o desempenho do modelo.

Implementação dos modelos de redes neurais

Três abordagens de redes neurais recorrentes (RNNs) foram implementadas utilizando a linguagem de programação Python e as bibliotecas TensorFlow e Keras. Os modelos desenvolvidos foram os seguintes:

RNN simples: Aplicada para o processamento de sequências temporais. A RNN simples foi usada para capturar dependências de curto e médio prazo nos dados.

RNN com 25 recursos: Essa variação da RNN inclui 25 características em cada passo de tempo, proporcionando uma representação mais rica e detalhada dos dados. A presença de múltiplos recursos permite que o modelo capture dependências mais complexas entre as variáveis monitoradas.

RNN bidirecional: Esse modelo foi utilizado para processar as sequências temporais em ambas as direções (passado para o futuro e futuro para o passado), capturando dependências temporais de forma mais abrangente.

LSTM (Long Short-Term Memory): Por fim, foi implementada uma rede LSTM, uma variação das RNNs tradicionais, projetada para capturar dependências de longo prazo nos dados. As LSTMs possuem portas de entrada, esquecimento e saída, que permitem um controle mais eficaz do fluxo de informações dentro do modelo.

Comparação dos métodos

Após o treinamento dos modelos, foi realizada uma comparação entre as abordagens descritas, utilizando métricas como precisão, recall e F1-score. A

comparação também levou em consideração a capacidade de cada método de capturar dependências de longo prazo e a eficiência computacional de cada modelo.

Os resultados foram avaliados de acordo com a capacidade de previsão de falhas de cada modelo, levando em consideração a complexidade dos dados e o desempenho das redes em tarefas de previsão sequencial.

4 RESULTADOS E DISCUSSÃO

Os resultados desta análise são baseados no desenvolvimento e validação de um modelo de Redes Neurais Recorrentes (RNN) aplicado ao conjunto de dados de manutenção preditiva, com foco na previsão de falhas em motores. O modelo foi treinado para prever falhas com base em dados históricos de sensores e ciclos de operação, buscando identificar padrões que indicam deterioração dos motores antes que uma falha ocorra.

Análise dos Sensores e Padrões de Desgaste

A análise dos dados dos sensores ao longo dos ciclos de operação revelou importantes padrões relacionados ao desgaste dos motores. Sensores específicos mostraram variações consistentes ao longo do tempo que, em muitos casos, indicaram a iminência de uma falha. Alguns sensores apresentaram um aumento gradual em seus valores, o que pode estar associado a uma sobrecarga progressiva ou desgaste mecânico do motor. Este comportamento foi interpretado como um sinal de que o motor está se aproximando de um ponto crítico, sugerindo a necessidade de uma manutenção preventiva para evitar falhas catastróficas.

Em contraste, outros sensores exibiram uma diminuição contínua ao longo dos ciclos. A redução nesses valores pode estar relacionada à queda no desempenho do motor ou à degradação de componentes específicos. Essa correlação entre a queda dos valores dos sensores e a proximidade de falhas reforça a utilidade desses dados para prever a necessidade de intervenções de manutenção.

Além disso, foi possível comparar o comportamento dos sensores entre diferentes motores. Ao observar motores com padrões de desgaste semelhantes, notou-se que certos sensores capturam características universais de deterioração, independentemente das variáveis específicas de cada motor. Essa consistência sugere que esses sensores podem ser especialmente úteis na construção de um modelo preditivo generalizável, capaz de antecipar falhas em diferentes unidades com base em dados semelhantes.

Desempenho do Modelo

O modelo de Redes Neurais Recorrentes (RNN) apresentou uma melhora contínua ao longo das épocas de treinamento, o que foi observado tanto no conjunto de treino quanto no de validação. A acurácia do modelo aumentou gradualmente, refletindo sua capacidade de aprender padrões significativos nos dados. A proximidade entre os

resultados de treino e validação indicou que o modelo evitou problemas comuns de superajuste (overfitting), mantendo uma boa generalização para dados não vistos.

Além da acurácia, a métrica de perda (erro) também foi monitorada ao longo do treinamento. A diminuição consistente na perda sugere que o modelo conseguiu se ajustar cada vez melhor aos dados, refinando sua capacidade preditiva sem se tornar excessivamente especializado nos dados de treino. Quando a perda de treino e validação seguiram trajetórias semelhantes, foi possível inferir que o modelo estava generalizando adequadamente, e sua robustez foi validada por um bom desempenho em ambos os conjuntos de dados.

Comparação de Modelos

Durante o processo de desenvolvimento, diferentes arquiteturas de RNN foram avaliadas, incluindo a RNN simples, a Bidirectional RNN, e o modelo LSTM (Long Short-Term Memory). Cada um desses modelos foi projetado para capturar padrões temporais complexos nos dados, e seus desempenhos foram comparados em termos de acurácia, perda e capacidade de previsão.

RNN Simples: Embora tenha mostrado um bom desempenho geral, o modelo RNN simples teve limitações na captura de padrões de longo prazo, devido à sua arquitetura básica.

Bidirectional RNN: Este modelo, ao processar os dados em ambas as direções temporais (passado e futuro), conseguiu capturar padrões mais complexos e fornecer previsões mais precisas em comparação à RNN simples, especialmente em relação a falhas que ocorrem após longos ciclos de operação.

LSTM: O modelo LSTM superou as outras arquiteturas em termos de captura de dependências de longo prazo. Sua capacidade de reter informações ao longo de sequências extensas de dados o tornou especialmente eficaz para prever falhas que dependem de eventos ocorridos em ciclos anteriores distantes.

Cada modelo teve seus pontos fortes, e a escolha final dependeu do equilíbrio entre a precisão das previsões e a complexidade computacional.

Previsões e Validação

As previsões feitas pelos modelos foram comparadas aos dados reais de falhas de motores, com o objetivo de verificar a precisão do sistema preditivo. As previsões mostraram alta correspondência com os valores reais, indicando que o modelo foi capaz de identificar corretamente a proximidade das falhas em vários casos. No entanto, algumas divergências ocorreram, sugerindo que o modelo pode se beneficiar de ajustes adicionais ou de mais dados de treino para melhorar a acurácia em cenários mais desafiadores.

Interpretação das Métricas de Avaliação

Além das métricas tradicionais de acurácia e perda, foi utilizada a matriz de confusão para avaliar o desempenho do modelo na previsão de falhas. A matriz revelou a quantidade de previsões corretas (verdadeiros positivos e verdadeiros negativos) e incorretas (falsos positivos e falsos negativos), proporcionando uma visão detalhada dos erros cometidos pelo modelo. Valores elevados na diagonal principal indicaram um bom desempenho, com poucas previsões errôneas.

Aplicação dos Resultados na Manutenção Preditiva

Com base nos resultados, ficou claro que o uso de modelos de RNN pode ser uma abordagem eficaz para manutenção preditiva de motores. Ao identificar padrões de desgaste e antecipar falhas, o modelo pode ser integrado a sistemas de monitoramento em tempo real, permitindo que equipes de manutenção atuem de forma proativa, minimizando o tempo de inatividade e os custos associados a falhas inesperadas.

A aplicação desses insights possibilita a transição de uma abordagem de manutenção corretiva para uma estratégia preditiva, aumentando a vida útil dos motores e otimizando a alocação de recursos para manutenção. O uso contínuo de dados operacionais, aliado ao refinamento do modelo, pode gerar melhorias adicionais na precisão e confiabilidade das previsões.

5 CONSIDERAÇÕES FINAIS

Este estudo comparou os métodos LSTM e RNN, com foco na previsão de falhas em aeronaves. O próximo passo será a implementação do XGBoost, visando avaliar sua eficiência em relação às LSTMs.

REFERÊNCIAS

- [1] Deep Learning for Predictive Maintenance https://github.com/Azure/lstms_for_predictive_maintenance/blob/master/Deep%20Learning%20Basics%20for%20Predictive%20Maintenance.ipynb
- [2] Predictive Maintenance: Step 2A of 3, train and evaluate regression models <https://gallery.cortanaintelligence.com/Experiment/Predictive-Maintenance-Step-2A-of-3-train-and-evaluate-regression-models-2>
- [3] A. Saxena and K. Goebel (2008). "Turbofan Engine Degradation Simulation Data Set", NASA Ames Prognostics Data Repository (<https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#turbofan>), NASA Ames Research Center, Moffett Field, CA
- [4] Understanding LSTM Networks <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>