

CRIAÇÃO DE REDE NEURAL PARA MONITORAMENTO PREDITIVO EM COMPRESSORES INDUSTRIAIS

Caio Correia Santos¹, Devisom Rodrigues Alves de Oliveira¹, Peterson da Silva Vital¹, Ruan Schultz Rigueti², Daniela Luz Leite³

¹Acadêmicos de Engenharia Mecânica - Multivix São Mateus/ES

²Mestre/ Engenheiro Mecânico/Docente/Orientador - Multivix São Mateus/ES

³Mestre em Energia/Engenheira Química/Docente/Coorientadora - Multivix São Mateus/ES

RESUMO

O presente trabalho teve como objetivo o desenvolvimento e demonstração de uma rede neural artificial aplicada à manutenção preditiva de compressores industriais. O estudo foi motivado pela crescente demanda por soluções inteligentes capazes de reduzir falhas inesperadas e otimizar o tempo de operação de equipamentos. Para viabilizar a pesquisa sem depender de dados proprietários de empresas, foi criado um conjunto de dados artificial, simulando variáveis típicas de sensores industriais. As condições operacionais, incluindo estados normais e nove tipos de falhas foram geradas a partir de combinações lógicas dessas variáveis, de forma a representar cenários realistas de operação. O dataset balanceado foi então utilizado no treinamento de uma rede neural multicamada desenvolvida em Python, com auxílio das bibliotecas TensorFlow e Scikit-learn. Durante o treinamento, foram aplicadas técnicas de normalização, codificação de rótulos e validação cruzada, buscando maximizar a acurácia do modelo. Os resultados mostraram boa capacidade de generalização, com acurácia estável ao longo das épocas de treino e validação. Além disso, foi criada uma interface gráfica interativa, permitindo que o usuário insira manualmente os valores de sensores e obtenha como saída a probabilidade de ocorrência de determinada falha nas próximas 24 horas. Conclui-se que o modelo proposto atinge o objetivo de demonstrar, de forma prática e didática, como uma rede neural pode ser aplicada na detecção de falhas industriais, contribuindo para a compreensão dos princípios de aprendizado de máquina e para o desenvolvimento de soluções inteligentes voltadas à manutenção preditiva.

Palavras-chave: redes neurais artificiais; manutenção preditiva; compressores Industriais; TensorFlow; Scikit-learn.

ABSTRACT

This work aimed to develop and demonstrate an artificial neural network applied to the predictive maintenance of industrial compressors. The study was motivated by the growing demand for intelligent solutions capable of reducing unexpected failures and optimizing equipment uptime. To enable the research without relying on proprietary company data, an artificial dataset was created, simulating typical variables of industrial sensors. The operating conditions, including normal states and nine types of failures, were generated from logical combinations of these variables to represent realistic operating scenarios. The balanced dataset was then used to train a multilayer neural network developed in Python, with the aid of the TensorFlow and Scikit-learn libraries. During training, normalization, label coding, and cross-validation techniques were applied, seeking to maximize the model's accuracy. The results showed good generalization capacity, with stable accuracy throughout the training and validation epochs. Furthermore, an interactive graphical interface was created, allowing the user to manually enter sensor values and obtain as output the probability of occurrence of a given failure in the next 24 hours. It is concluded that the proposed model achieves the objective of demonstrating, in a practical and didactic way, how a neural network can be applied in the detection of industrial failures, contributing to the understanding of machine learning principles and to the development of intelligent solutions aimed at predictive maintenance.

Keywords: artificial neural networks; predictive maintenance; industrial compressors; TensorFlow; Scikit-learn.

1 INTRODUÇÃO

A manutenção industrial ganhou destaque nas organizações a partir de 1939, após o início da Segunda Guerra Mundial, diante do aumento da complexidade dos equipamentos, dos avanços tecnológicos, das exigências do mercado por produtos sem defeitos, das alterações nos sistemas de produção, além disso para as exportações que ganharam força após a Segunda Guerra.

Nesse cenário, foram estabelecidas normas de roscas, padrões de simbologia em desenhos técnicos e procedimentos de manutenção voltados a garantir a eficiência operacional das máquinas. A partir daí, surgiram as práticas de

manutenção preventiva e as rotinas de inspeção, realizadas pelos mecânicos com o objetivo de verificar as condições reais dos equipamentos e acompanhar o desenvolvimento de possíveis falhas, configurando os primeiros conceitos de manutenção preditiva.

Contudo, a manutenção industrial planejada é importante para atingir resultados, como a redução no número de falhas, aumento da confiabilidade e qualidade, um menor tempo de máquina parada, e aumento da segurança dos operadores.

A inteligência artificial tem se destacado como uma das ferramentas mais promissoras para a solução de problemas complexos nas mais diversas áreas do conhecimento. Entre suas aplicações, as redes neurais artificiais se sobressaem por sua capacidade de aprender padrões a partir de dados e realizar tarefas como classificação, previsão e detecção de anomalias (Haykin, 2001).

Nas últimas décadas, as redes neurais artificiais têm se consolidado como uma das tecnologias mais promissoras dentro do campo da inteligência artificial, oferecendo soluções eficazes para tarefas de classificação, reconhecimento de padrões e tomada de decisão. Seu impacto tem sido sentido amplamente em áreas como finanças, saúde, segurança digital e marketing.

Este trabalho delimita-se ao estudo e aplicação das Redes Neurais Artificiais voltadas à previsão de falhas em compressores industriais, analisando variáveis coletadas por sensores, como pressão, temperatura, vibração, corrente elétrica, vazão e outros indicadores operacionais. A pesquisa concentra-se no desenvolvimento de um modelo supervisionado capaz de identificar padrões que indiquem condições anormais de funcionamento, como superaquecimento e baixa eficiência, com base em dados previamente rotulados.

O escopo da investigação está restrito ao uso de um conjunto de dados estruturados e disponíveis no momento da realização do estudo, sem a necessidade de coleta experimental em campo. Não há envolvimento de indivíduos, nem delimitação geográfica específica, uma vez que todo o trabalho foi conduzido em ambiente computacional. A análise também está limitada ao contexto temporal atual, considerando apenas informações existentes até 2025.

A proposta possui caráter acadêmico e introdutório, buscando demonstrar a aplicação prática de uma rede neural simples dentro da área de manutenção preditiva na engenharia mecânica. Não se pretende, nesta etapa, implementar o

modelo diretamente em ambientes industriais, mas sim estabelecer uma base conceitual e técnica para estudos futuros.

Quando se trata da engenharia mecânica, a adoção prática dessas ferramentas ainda caminha a passos lentos. Técnicas baseadas em redes neurais podem ser aplicadas, por exemplo, na identificação precoce de anomalias em equipamentos, no monitoramento contínuo de sistemas mecânicos por meio de sensores e na análise de padrões operacionais para estimar a vida útil remanescente dos ativos (Silva et al., 2023; Rao, 1996).

Na atualidade ainda existe uma lacuna no ambiente acadêmico da engenharia, no que se refere ao uso prático de inteligência artificial. Muitos estudantes têm contato teórico com conceitos como redes neurais, mas poucos desenvolvem projetos que envolvem a aplicação real. Socialmente, a disseminação de tecnologias como redes neurais pode favorecer a inovação em empresas de menor porte, oferecendo alternativas de baixo custo para problemas operacionais e contribuindo para o avanço tecnológico em diferentes regiões. A democratização desse conhecimento é, portanto, cientificamente relevante, tecnologicamente útil e socialmente necessária.

Diante do exposto esse estudo tem como objetivo geral desenvolver e demonstrar o funcionamento de uma rede neural artificial capaz de prever falhas em compressores industriais. E quanto aos objetivos específicos esse estudo de propõe: Criar um conjunto de dados balanceado e simulado, representando diferentes condições operacionais do compressor (normais e de falha); Treinar e validar o modelo de rede neural utilizando técnicas de aprendizado supervisionado; Analisar o desempenho do modelo com base em métricas como acurácia e perda durante o treinamento; Desenvolver uma interface gráfica para inserção manual ou automatizada de dados de sensores e exibição das previsões de falha; Demonstrar a aplicabilidade prática da rede neural como ferramenta auxiliar na manutenção preditiva industrial.

2 REFERENCIAL TEÓRICO

2.1 INTRODUÇÃO À MANUTENÇÃO INDUSTRIAL

A manutenção industrial representa um dos pilares fundamentais para a operação eficiente, segura e contínua de sistemas produtivos. Tradicionalmente associada à simples correção de falhas, essa atividade evoluiu significativamente nas últimas décadas, passando de uma abordagem reativa para estratégias mais inteligentes e preditivas, impulsionadas pelo avanço tecnológico e pelas exigências da Indústria 4.0 (Jardine, 2006).

De modo geral, a manutenção industrial pode ser definida como o conjunto de ações técnicas e administrativas voltadas para garantir o funcionamento ideal de máquinas, equipamentos e instalações, assegurando sua disponibilidade, confiabilidade e segurança ao longo do tempo. Segundo Mobley (2002) a manutenção tem como objetivo principal assegurar que os ativos físicos funcionem com o menor custo total possível, dentro dos padrões de qualidade e produtividade exigidos.

O histórico da manutenção revela um percurso de adaptação às transformações tecnológicas e às necessidades do mercado. Inicialmente, predominava a manutenção corretiva, que consistia na substituição ou reparo do equipamento apenas após a falha. Contudo, os altos custos decorrentes de paradas não programadas e os riscos à segurança impulsionaram o desenvolvimento de abordagens preventivas, com inspeções e serviços programados em intervalos regulares. Nas últimas décadas, com o avanço da automação e da instrumentação, surge a manutenção preditiva, baseada no monitoramento contínuo de variáveis operacionais, como vibração, temperatura e pressão (Mobley, 2002; Santos; Oliveira, 2021).

O conceito de manutenção industrial também está fortemente ligado à competitividade organizacional. Empresas que adotam estratégias eficazes de manutenção conseguem reduzir desperdícios, maximizar a vida útil dos ativos e manter um padrão de produção elevado, mesmo diante de variáveis externas instáveis. Nesse contexto, a manutenção passa a ser vista não como um custo, mas como investimento estratégico para o sucesso do negócio (Paladini, 2011). Além dos ganhos operacionais e financeiros, a manutenção bem planejada

contribui diretamente para a segurança do trabalho, evitando acidentes relacionados a falhas técnicas.

De acordo com a Associação Brasileira de Normas Técnicas NBR ISO 55000 (2014), a gestão de ativos — incluindo práticas de manutenção — deve ser orientada por critérios de desempenho, riscos e custos do ciclo de vida, promovendo a sustentabilidade e a integridade dos sistemas produtivos.

A modernização da manutenção também está alinhada com as diretrizes da Indústria 4.0, que incorpora recursos como Internet das Coisas (IoT), inteligência artificial e análise preditiva para criar ambientes industriais mais autônomos e responsivos. De acordo com Lopes et al. (2022) o uso de sensores conectados à nuvem permite acompanhar, em tempo real, a condição de componentes críticos, antecipando falhas e programando intervenções com base em dados concretos. Portanto, a compreensão do papel da manutenção industrial e de sua evolução histórica é essencial para engenheiros e gestores que desejam maximizar a eficiência dos processos produtivos. No contexto deste trabalho, essa análise será aplicada especificamente à manutenção do canhão de extrusoras de polietileno, com foco na criação de um cronograma que contemple ações preventivas e preditivas, envolvendo aspectos mecânicos e elétricos do equipamento.

2.2 TIPOS DE MANUTENÇÃO

A manutenção industrial pode ser classificada de acordo com a estratégia adotada para lidar com falhas e garantir a continuidade operacional dos equipamentos. Com a evolução tecnológica e o amadurecimento da gestão industrial, surgiram diversos tipos de manutenção, cada qual com características, aplicações e objetivos distintos. Entre os principais estão: manutenção corretiva, preventiva, preditiva e proativa.

A manutenção corretiva é o tipo mais simples e tradicional. Ela ocorre após a falha do equipamento, quando o componente danificado é reparado ou substituído. Sua aplicação está geralmente associada à ausência de planejamento ou à impossibilidade de prever o defeito. Segundo Mobley (2002) trata-se de uma ação reativa que, embora útil em situações específicas, representa uma das abordagens mais custosas e arriscadas, especialmente em sistemas críticos.

A principal vantagem da manutenção corretiva está na simplicidade de execução, pois não requer inspeções constantes nem investimentos em tecnologia. No entanto, suas desvantagens são significativas: aumento do tempo de inatividade, risco de acidentes, perdas produtivas e custos elevados com reparos emergenciais (Santos; Oliveira, 2021).

A manutenção preventiva consiste na realização programada de intervenções com o objetivo de evitar falhas antes que ocorram. Baseia-se em cronogramas fixos ou recomendações do fabricante e pode incluir inspeções, limpezas, ajustes, trocas de peças e testes de funcionamento.

Segundo Paladini (2011) a manutenção preventiva é uma forma racional de manter o desempenho dos ativos industriais, reduzindo significativamente a probabilidade de falhas e prolongando a vida útil dos componentes. Para isso, é necessário planejamento, definição de periodicidade e registro histórico das manutenções realizadas. Em extrusoras de polietileno, por exemplo, ações preventivas como verificação de resistências de aquecimento, limpeza de filtros e inspeção visual do canhão e do fuso podem evitar o desgaste prematuro dos componentes e minimizar o risco de parada.

A manutenção preditiva baseia-se na análise contínua das condições reais de funcionamento dos equipamentos, utilizando sensores e sistemas de monitoramento. Diferente da preventiva, que opera com base em intervalos fixos, a preditiva antecipa falhas por meio da detecção de sinais sutis de degradação, como variações de vibração, temperatura, ruído, pressão e análise de óleo.

De acordo com Mobley (2002) essa abordagem permite reduzir os custos de manutenção em até 30% ao evitar intervenções desnecessárias e focar apenas nos pontos realmente críticos. Na prática, tecnologias como termografia, ultrassom, análise de partículas metálicas e monitoramento de corrente elétrica são amplamente utilizadas em equipamentos industriais, incluindo extrusoras. Um exemplo comum é o uso da termografia infravermelha para avaliar a uniformidade da temperatura nas zonas de aquecimento do canhão de uma extrusora, identificando pontos de superaquecimento ou falhas de isolamento térmico.

2.3 FUNDAMENTOS DAS REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são um dos principais pilares da inteligência artificial, sendo inspiradas no funcionamento dos neurônios biológicos do cérebro humano. Essas estruturas são formadas por camadas de neurônios artificiais interconectados, que realizam o processamento de informações por meio de conexões ponderadas. Essas conexões são ajustadas durante o treinamento, permitindo que o sistema aprenda padrões complexos com base em exemplos fornecidos previamente (Spadini, 2024).

No contexto da aprendizagem de máquina (*machine learning*), as RNAs configuram uma subárea especializada, destacando-se pela capacidade de modelar relações não lineares e realizar previsões em ambientes com grande volume e variedade de dados.

Segundo a *International Business Machines* (2021), ao contrário dos modelos tradicionais, que exigem forte intervenção humana, as redes neurais conseguem extrair automaticamente características diretamente dos dados, o que as torna adequadas para lidar com informações não estruturadas, como sons, imagens e séries temporais.

Com o avanço das técnicas de deep learning, uma vertente das RNAs composta por múltiplas camadas ocultas, tornou-se possível alcançar maior precisão em tarefas sofisticadas, como reconhecimento de voz, detecção de anomalias e previsão de falhas industriais. Conforme destaca a Salesforce (2018), o diferencial do deep learning está na sua capacidade de automatizar a extração de atributos, eliminando a necessidade de intervenção manual e proporcionando maior eficiência em sistemas preditivos.

Portanto, compreender os princípios de funcionamento das redes neurais é fundamental para o sucesso na aplicação da inteligência artificial em contextos técnicos e científicos. A literatura atual é unânime ao reconhecer que, combinando dados relevantes com um modelo neural adequadamente projetado, é possível alcançar altos níveis de desempenho e confiabilidade na resolução de problemas complexos, tanto em áreas tradicionais, como engenharia e saúde, quanto em setores emergentes ligados à automação e a análise de grandes volumes de dados.

2.4 APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA MANUTENÇÃO INDUSTRIAL

A manutenção preditiva tem se consolidado como estratégia central na Indústria 4.0 ao permitir a transição de modelos reativos e preventivos para diagnósticos inteligentes baseados em dados (Silva, 2025). Seu uso em equipamentos industriais promove economia operacional e maior disponibilidade de ativos. Redes neurais têm desempenhado papel crucial nesse processo, graças à capacidade de detectar padrões de anomalias em sinais sensoriais (Explorer, 2025).

As RNAs processam sinais de vibração, temperatura, pressão e corrente elétrica por meio do aperfeiçoamento de seus “neurônios” em múltiplas camadas. Essa característica permite identificar variações iniciais e sutis no comportamento dos equipamentos, antecipando falhas que, sem esse monitoramento, causariam interrupções (Fundação Vanzolini, 2025).

Long Short-Term Memory (LSTM) são especialmente eficazes para análise de séries temporais. Sua habilidade de manter informações relevantes ao longo de intervalos estendidos as tornam indicadas para prever a evolução de parâmetros de sensores. Esse modelo auxilia a antecipar eventos de falhas em sistemas hidráulicos ou térmicos, gerando alertas antes de ocorrências críticas.

Além das Long Short-Term Memory (LSTM), outras arquiteturas, como as redes convolucionais Convolutional Neural Networks (CNNs), são aplicadas em dados sensoriais não estruturados, por exemplo, na análise de imagens térmicas e sinais sonoros de maquinário. A capacidade de reconhecer padrões visuais e acústicos torna a detecção de falhas mais precisa em condições operacionais adversas. Em muitos casos, RNAs mais simples, como Perceptrons Multicamadas Minimum Lovable Product (MLP), são utilizados em dados tabulares, enquanto variantes mais complexas se destinam à análise de sinais dinâmicos e subjetivos.

A interconexão entre sensores, Internet of Things (IoT) e RNAs permite o monitoramento em tempo real e distribuído dos ativos industriais, mesmo em locais remotos ou de difícil acesso. Com esse conjunto, redes podem operar em dispositivos embarcados, reduzindo a latência de resposta e possibilitando intervenção imediata.

Em suma, o uso de RNAs na manutenção preditiva representa um salto qualitativo na forma de gerir ativos industriais. A adoção dessas tecnologias

promove diminuição de custos, incremento de eficiência e elevação da competitividade em um mercado global, valorizando profissionais de engenharia preparados para integrar inteligência artificial em diagnósticos e decisões estratégicas.

2.5 TÉCNICAS DE MACHINE LEARNING APLICADAS À ENGENHARIA MECÂNICA

A aplicação de técnicas de *Machine Learning* (ML) na engenharia mecânica representa uma transformação profunda na forma como os sistemas industriais são projetados, operados e mantidos. A capacidade dessas técnicas de extrair padrões de grandes volumes de dados, mesmo em ambientes ruidosos e incertos, tem impulsionado inovações em áreas como manutenção preditiva, otimização de projeto e análise estrutural. À medida que sensores inteligentes e tecnologias de conectividade se tornam mais acessíveis, o uso de modelos de ML torna-se ainda mais viável e necessário para garantir eficiência, segurança e competitividade no setor industrial.

Uma das principais aplicações dessas técnicas é a previsão da vida útil remanescente *Remaining Useful Life* (RUL) de componentes críticos, como mancais, eixos, turbinas e motores. Essa estimativa é essencial para a manutenção preditiva, pois permite agendar intervenções apenas quando necessário, evitando paradas imprevistas e prolongando a vida útil dos equipamentos. Técnicas como redes neurais recorrentes (RNNs) e redes do tipo LSTM têm demonstrado excelente desempenho ao lidar com séries temporais provenientes de sensores. No estudo de Cheng *et al.* (2023) o uso dessas arquiteturas em turbinas eólicas offshore possibilitou uma redução significativa de falhas inesperadas, otimizando a manutenção e os custos operacionais.

Além das redes neurais, algoritmos supervisionados como Máquinas de Vetores de Suporte (SVMs), Random Forest e XGBoost também são amplamente empregados na classificação e detecção de falhas em sistemas mecânicos. Em compressores, redutores e motores, esses modelos são treinados com dados de vibração, temperatura e corrente elétrica, permitindo identificar padrões que indicam desgaste ou funcionamento anômalo. Segundo a pesquisa de Serradilla *et al.* (2020) esses métodos, mesmo com conjuntos de dados ruidosos, frequentemente

superam os 90% de acurácia em diagnósticos de falhas, o que os torna altamente valiosos em ambientes industriais complexos. Em paralelo, o *Machine Learning* tem se mostrado eficaz na otimização de projetos mecânicos.

Algoritmos como *Deep Neural Networks* (DNNs) e métodos de otimização bayesiana são utilizados para explorar múltiplas variáveis de projeto de forma simultânea, buscando combinações ideais entre desempenho estrutural, resistência e custo.

Rashid e Kausik (2024) argumentam que o uso de modelos híbridos que combinam técnicas de ML com simulações baseadas em elementos finitos permite reduzir o número de protótipos físicos, encurtar ciclos de desenvolvimento e melhorar a qualidade final do produto. Isso se traduz em maior agilidade no lançamento de novos componentes e em melhor adaptação às necessidades específicas do mercado.

3 METODOLOGIA

Esse estudo trata-se de uma pesquisa de natureza básica e aplicada, pesquisa bibliográfica e pesquisa descritiva e qualitativa.

A metodologia adotada neste projeto envolveu a construção e o treinamento de uma rede neural artificial (RNA) para a previsão de falhas em compressores industriais, a partir de um conjunto de dados (dataset) simulados representando diferentes condições operacionais.

O desenvolvimento foi dividido em seis etapas principais: caracterização do compressor, criação dos dados, definição das variáveis e critérios, organização das condições de falha, treinamento e avaliação do modelo, e, por fim, o desenvolvimento da interface gráfica para utilização do sistema.

3.1 CARACTERÍSTICAS DO COMPRESSOR

O compressor analisado neste projeto representa um equipamento industrial típico de ar comprimido, utilizado em processos de manufatura e manutenção. As características usadas não são baseadas em um modelo específico, e sim em partes que geralmente compõem um compressor industrial. Durante a operação, diversas variáveis são monitoradas continuamente por sensores. As principais variáveis estão citadas no Quadro 1 abaixo.

Quadro 1 - Descrição das variáveis utilizadas como entrada na rede neural.

Variáveis	Unidades	Descrições
Pressão de entrada	bar	Pressão do ar antes da compressão
Pressão de saída	bar	Pressão do ar após a compressão
Temperatura do ar de saída	°C	Aquecimento gerado pela compressão do ar
Corrente elétrica do motor	A	Esforço elétrico exigido do motor
Vazão	m ³ /h	Volume de ar comprimido produzido por hora
Vibração RMS	mm/s	Nível de vibração mecânica do conjunto.
Delta P	bar	Diferença entre pressões de entrada e saída.
Temperatura do motor	°C	Grau de aquecimento do motor elétrico.
Horas de operação	h	Tempo total acumulado de funcionamento.
Nível de óleo	%	Quantidade de lubrificante disponível.

Fonte: Próprios autores, 2025.

Essas variáveis foram utilizadas como entradas (features) da rede neural, e a saída (label) representa a condição operacional do compressor.

3.2 CRIAÇÃO DOS DADOS

Como parte do objetivo era o desenvolvimento de um modelo funcional sem depender de dados proprietários de empresas, o dataset foi criado artificialmente a partir de simulações realistas, com base em faixas típicas de operação industrial observadas na literatura técnica e em relatórios de manutenção.

O conjunto de dados totalizou 20.000 registros, distribuídos entre dez condições operacionais: condições normais (5000 casos), superaquecimento (2000 casos), desgaste no rolamento (2000 casos), sobrecarga elétrica (2000 casos), filtro obstruído (2000 casos), vazamento (2000 casos), baixa eficiência (1500 casos),

lubrificação insuficiente (1500 casos), partida anômala (1000 casos), oscilação de carga (1000 casos).

Cada linha do dataset representa uma amostra instantânea de funcionamento, com os valores das dez variáveis medidas e a classificação correspondente da condição. É importante destacar que o dataset não foi balanceado com base em limites fixos (como “superaquecimento acima de 90°C”), mas sim por combinações de variáveis simultâneas, de forma que os padrões de comportamento emergissem naturalmente, refletindo o contexto real de um sistema físico complexo.

3.3 SENSORES, VARIÁVEIS E CRITÉRIOS DE CONDIÇÃO

Cada condição de operação do compressor foi definida a partir da combinação das variáveis monitoradas refletindo diferentes estados de funcionamento do equipamento.

A condição normal ocorre quando todas as variáveis permanecem dentro de faixas estáveis, indicando operação equilibrada. O superaquecimento é identificado por aumento nas temperaturas do ar e do motor, junto de corrente elevada. O desgaste de rolamento apresenta vibração Root Mean Square (RMS) alta e leve acréscimo de temperatura. A sobrecarga elétrica ocorre quando a corrente do motor se eleva significativamente, podendo vir acompanhada de aquecimento. O filtro obstruído manifesta-se por aumento do delta P e redução da vazão.

No caso de vazamento, há queda na pressão de saída e na vazão, com corrente normal ou levemente reduzida. A baixa eficiência combina menor vazão e temperaturas um pouco acima do ideal, sem falha evidente. A lubrificação insuficiente aparece quando o nível de óleo está baixo, elevando a temperatura e a vibração. A partida anômala é caracterizada por picos momentâneos de corrente e vibração nas primeiras medições após o acionamento. Por fim, a oscilação de carga se evidencia por flutuações cíclicas na corrente e na vazão, indicando variações na demanda ou instabilidade operacional.

3.4 ORGANIZAÇÃO DOS EXEMPLOS E BALANCEAMENTO

Após a geração das amostras, o dataset foi balanceado proporcionalmente entre as condições, sem impor valores numéricos rígidos, para que a rede neural

aprendesse padrões de correlação entre variáveis, e não simples limiares de medição.

Foi aplicado o processo de normalização dos dados, utilizando a técnica Standard Scaler, que converte todos os valores para uma escala média (0) e desvio padrão (1). Isso evita que variáveis com unidades diferentes (como temperatura em °C e vazão em m³/h) influenciem de forma desigual no aprendizado da rede.

3.5 TREINAMENTO DA REDE NEURAL E AVALIAÇÃO DA ACURÁCIA

A rede neural artificial foi desenvolvida com a biblioteca TensorFlow/Keras. O modelo é do tipo Sequential, com três camadas principais:

- Camada de entrada: 10 neurônios, correspondentes às variáveis monitoradas.
- Camada intermediária (oculta): duas camadas densas com 64 e 32 neurônios, respectivamente, ativadas com a função ReLU (Rectified Linear Unit).
- Camada de saída: neurônios equivalentes ao número de classes (4), utilizando a função Softmax, que calcula a probabilidade de o compressor estar em cada condição.

Durante o treinamento, o modelo passou por 50 épocas de aprendizado, com o método de otimização Adam e o uso da técnica de Early Stopping — que interrompe o treinamento automaticamente caso o erro de validação pare de diminuir, prevenindo sobreajuste (overfitting). A base de dados foi dividida em 80% para treinamento e 20% para validação.

3.6 CRIAÇÃO DA INTERFACE GRÁFICA

Após o treinamento, o modelo final foi salvo em formato .h5 e integrado a uma interface gráfica (GUI) desenvolvida em Tkinter — biblioteca nativa do Python.

Essa interface permite que o usuário insira manualmente os valores das variáveis medidas pelo compressor e obtenha uma previsão automática da condição operacional.

O sistema exibe a probabilidade de falha em até 24 horas, podendo ser ajustado para diferentes horizontes de previsão (por exemplo, 48h), além de mostrar a porcentagem correspondente a cada possível condição (normal, superaquecimento, vazamento, obstrução).

4 RESULTADOS E DISCUSSÃO

4.1 AVALIAÇÃO DA ACURÁCIA E PERDA

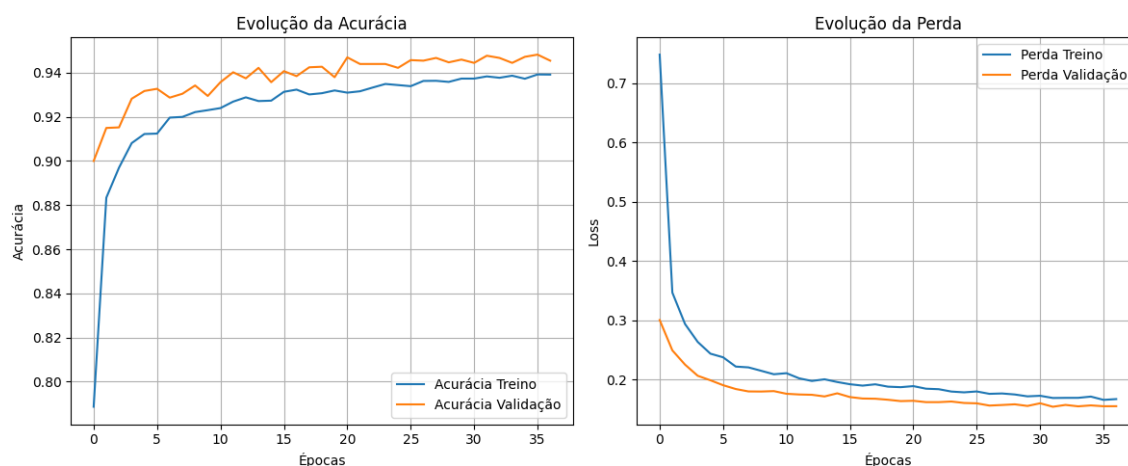
Ao final do processo foram obtidos gráficos de desempenho, representando:

- Evolução da acurácia: mostra o quanto a rede melhorou a capacidade de classificar corretamente as condições a cada época de treinamento.
- Evolução da perda (loss): indica o erro do modelo; quanto menor, melhor a performance.

Durante o treinamento da rede neural, foram gerados os gráficos de acurácia e perda (loss) para avaliar o desempenho do modelo.

De modo geral, a rede apresentou acurácia superior a 90% nos testes de validação, demonstrando boa capacidade de generalização (Figura 1).

Figura 1 - Gráficos de Acurácia e Perda.



Fonte: Próprios autores, 2025.

O Gráfico de acurácia mostra a taxa de acertos do modelo ao classificar as condições do compressor. As curvas de treino e validação indicam, respectivamente, o aprendizado nos dados usados no treinamento e o desempenho em dados novos. Quando ambas crescem juntas e permanecem próximas, o modelo apresenta boa capacidade de generalização.

Já o Gráfico de perda indica o erro cometido pela rede durante o aprendizado. A perda deve diminuir ao longo das épocas, demonstrando que o modelo está se ajustando corretamente. Valores estáveis e baixos de perda, aliados a uma acurácia crescente, representam um treinamento eficiente e equilibrado, sem sinais de *overfitting*.

4.2 INTERFACE HOMEM-MÁQUINA (IHM)

Por meio da interface homem-máquina (Figura 2), o usuário pode inserir valores medidos manualmente ou, em uma aplicação real, esses dados poderiam ser coletados automaticamente de sensores instalados no equipamento. Ao clicar em “Prever”, o sistema processa as informações com base no modelo previamente treinado e fornece como saída a condição operacional prevista.

Essa interface representa a integração entre o modelo preditivo e a aplicação prática, demonstrando o potencial do sistema para auxiliar no monitoramento automatizado e na manutenção preditiva de compressores industriais.

Figura 2 - Interface gráfica homem-máquina (IHM)



Previsão de Fa... — □ ×

pressao_entrada_bar

pressao_saida_bar

temp_ar_saida_c

corrente_motor_a

vazao_m3h

vibracao_rms_mms

delta_p

temp_motor_c

horas_operacao

nivel_oleo_perc

Prever

Fonte: Próprios autores, 2025.

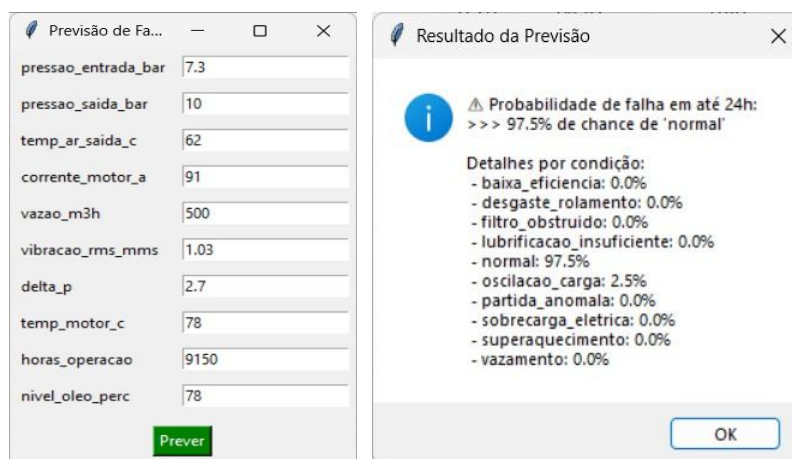
Abaixo está a demonstração da interface desenvolvida, exibindo tanto o preenchimento dos campos com os dados operacionais do compressor quanto as previsões geradas pelo modelo.

As simulações representam diferentes condições e ilustram como a rede neural responde a cada cenário, apresentando as probabilidades de ocorrência de falhas nas próximas 24 horas.

A interface exibe valores estáveis de operação, com pressões, temperaturas, corrente e vibração dentro das faixas ideais. O sistema opera em equilíbrio, sem

indícios de falha. O modelo previu alta probabilidade de operação normal, confirmando sua capacidade de reconhecer padrões estáveis de funcionamento, conforme (Figura 3).

Figura 3 - Interface mostrando resultado de condição normal de operação.

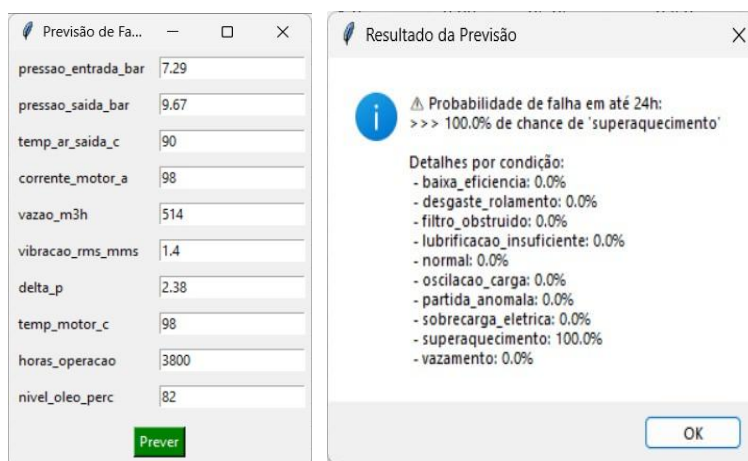


Fonte: Próprios autores, 2025.

Como exibido na Figura 4, os valores indicam aumento de temperatura do ar e do motor e corrente elétrica elevada, sugerindo sobrecarga térmica.

A rede neural identificou alta probabilidade de superaquecimento em até 24 horas, refletindo coerência entre os dados e o risco previsto.

Figura 4 - Interface mostrando resultado de condição de superaquecimento.

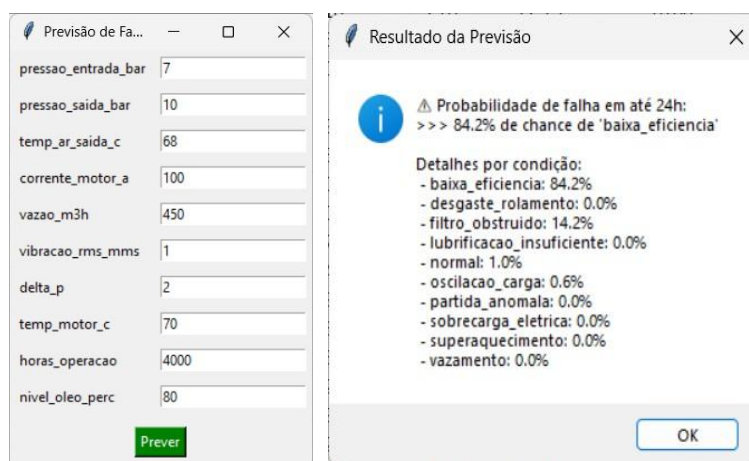


Fonte: Próprios autores, 2025.

Com os dados exibidos na Figura 5, a interface mostra variações de alguns parâmetros, enquanto os demais permanecem normais, indicando perda de desempenho.

O modelo apontou alta probabilidade de baixa eficiência em 24 horas, demonstrando sensibilidade para identificar degradações sutis no sistema.

Figura 5 - Interface mostrando resultado de baixa eficiência.



Fonte: Próprios autores, 2025.

5 CONSIDERAÇÕES FINAIS

O desenvolvimento deste trabalho permitiu alcançar com êxito os objetivos propostos, demonstrando de forma prática o funcionamento de uma rede neural artificial aplicada à previsão de falhas em compressores industriais. A construção do modelo, desde a criação de um dataset simulado até o treinamento e validação da rede, possibilitou compreender como esse tipo de sistema aprende a reconhecer padrões e realizar previsões a partir de dados numéricos de sensores.

Os resultados obtidos demonstraram que a rede neural foi capaz de identificar diferentes condições operacionais do compressor, simulando com coerência situações como superaquecimento, desgaste mecânico e vazamento.

Além disso, a criação de uma interface gráfica funcional consolidou o projeto, mostrando como um sistema de previsão poderia ser aplicado em um ambiente industrial real, recebendo dados automaticamente de sensores e emitindo diagnósticos em tempo real.

Portanto, o trabalho cumpriu seu propósito principal de apresentar, de maneira didática e aplicada, o potencial das redes neurais artificiais na manutenção preditiva, servindo como base para futuras implementações com dados reais e integração a sistemas de monitoramento automatizados.

REFERÊNCIAS

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT. **NBR ISO 55000**: Gestão de ativos – Visão geral, princípios e terminologia. Rio de Janeiro: ABNT, 2014. Disponível em: <https://www.abntcatalogo.com.br/norma.aspx?ID=332484>.

CHENG et al. Deep Reinforcement Learning for Cost-Optimal Condition-Based Maintenance Policy of Offshore Wind Turbine Components, **Ocean Engineering**, vol. 283, Set. 2023. Disponível em: <https://doi.org/10.1016/j.oceaneng>.

EXPLORER. **Manutenção Preditiva**: Como a Inteligência Artificial Ajuda a Reduzir Falhas Na Produção Industrial. Agência Explorer, 2025. Disponível em: agenciaexplorer.com.br/blog/industria/manutencao-preditiva-industrias/.

FUNDAÇÃO VANZOLINI. **Inteligência Artificial Na Indústria 4.0**. Fundação Vanzolini, 14 Jan. 2025. Disponível em: vanzolini.org.br/blog/inteligencia-artificial-na-industria-4-0/.

HAYKIN, S. **Redes neurais**: Princípios e prática. 2. ed. Porto Alegre: Bookman, 2001. Disponível em:

IBM. **What Is a Neural Network?** IBM, 6 Out. 2021. Disponível em: www.ibm.com/think/topics/neural-networks.

JARDINE, A. K. S. **Maintenance, Replacement and Reliability: Theory and Applications**. 2. ed. Boca Raton: CRC Press, 2006. Disponível em: <https://www.routledge.com/Maintenance-Replacement-and-Reliability/Jardine/p/book/9780849370410>.

LOPES, Henrique A.; MARTINS, Daniela R.; PEREIRA, Tiago S. Indústria 4.0 e a evolução da manutenção preditiva: aplicações e desafios no ambiente fabril. **Revista Tecnologia & Inovação Industrial**, v. 15, n. 3, p. 45–58, 2022. Disponível em: <https://revistatecnologiaindustrial.com.br/artigo/ind-4-0-manutencao-preditiva>.

MOBLEY, R. Keith. **An Introduction to Predictive Maintenance**. 2. ed. Boston: Butterworth-Heinemann, 2002. Disponível em: <https://www.sciencedirect.com/book/9780750675314/an-introduction-to-predictive-maintenance>.

PALADINI, Edson Pacheco. **Gestão da qualidade**: Teoria e Prática. 3. ed. São Paulo: Atlas, 2011. Disponível em: <https://www.atlas.com.br/livro/gestao-da-qualidade-teoria-e-pratica>.

RAO, S. S. **Engineering optimization: Theory and Practice**. 3rd ed. New York: John Wiley & Sons, 1996.

RASHI; KAUSIK. AI Revolutionizing Industries Worldwide: A Comprehensive Overview of Its Diverse Applications, **Hybrid Advances**, vol. 7, n.100277, 23 Aug. 2024, p. 100277–100277. Disponível em: www.sciencedirect.com/science/article/pii/S2773207X24001386. <https://doi.org/10.1016/j.hybadv.2024.100277>.

SANTOS, Vinícius A.; OLIVEIRA, Fernando R. Gestão e Planejamento da Manutenção Industrial: desafios e tendências na Indústria 4.0. **Revista Engenharia de Produção e Sistemas**, v. 9, n. 2, p. 77–91, 2021. Disponível em: <https://revistas.ufrgs.br/engprod/article/view/10291>.

SALESFORCE. **Deep e Machine Learning: Qual a Diferença?** Salesforce, 30 Abr. 2018. Disponível em: www.salesforce.com/br/blog/machine-learning-vs-deep-learning/.

SERRADILLA et al. **Deep Learning Models for Predictive Maintenance: A Survey, Comparison, Challenges and Prospect**. Arxiv.org, 7 Oct. 2020. Disponível em: arxiv.org/abs/2010.03207.

SILVA, W.R. et al. **A Utilização de Redes Neurais na Previsão de Falhas de Equipamentos Mecânicos**, Conbrepro, 2023. Disponível em: https://aprepro.org.br/conbrepro/anais/2023/arquivos/10312023_221014_6541a5b2703cc.pdf.

SILVA, José E. Entre Sensores E Algoritmos: A Nova Lógica Da Manutenção Industrial. **Revista E&S**, 9 Jun 2025. Disponível em: revistaes.com.br/colunas/entre-sensores-e-algoritmos-a-nova-logica-da-manutenc-ao-industrial/

SPADINI, A.S. **Arquiteturas de Redes Neurais: Aplicações Na IA**. Alura, 30 Oct. 2024. Disponível em: www.alura.com.br/artigos/arquiteturas-de-redes-neurais.