

industriais sustentáveis. Encontra-se em fase inicial (TRL 2-3), focando no estabelecimento de metodologias robustas e construção de conhecimento fundamental.

Introdução

A crescente complexidade dos sistemas industriais modernos e a pressão por maior eficiência operacional têm impulsionado o desenvolvimento de estratégias avançadas de manutenção. Neste contexto, a manutenção preditiva baseada em ML emerge como uma solução promissora, capaz de transformar dados operacionais em conhecimento acionável sobre o estado de saúde dos equipamentos.

Rolamentos são componentes críticos em máquinas rotativas, presentes em praticamente todos os sistemas mecânicos industriais. Estudos indicam que problemas em rolamentos são responsáveis por aproximadamente 40% das falhas em motores elétricos, frequentemente causados por instalação inadequada, lubrificação insuficiente e falta de manutenção preventiva sistemática. Essas falhas resultam em paradas não programadas que geram perdas significativas no processo produtivo, evidenciando a necessidade de programas de manutenção mais sofisticados e baseados em dados.

A estimação de RUL representa o núcleo da manutenção preditiva moderna, permitindo aos gestores de manutenção tomar decisões informadas sobre o momento ótimo para intervenções preventivas. Diferentemente de abordagens reativas ou baseadas apenas em tempo de operação, a estimação de RUL considera o estado real de degradação do equipamento através da análise de sinais de vibração, temperatura e outros indicadores de saúde, resultando em estratégias de manutenção mais eficientes e econômicas.

Justificativa

A estimação precisa de RUL representa um desafio científico e tecnológico de grande relevância para a indústria moderna. A capacidade de prever com antecedência o momento de falha de componentes críticos permite:

- Redução de custos operacionais através da eliminação de paradas não programadas
- Otimização de inventários de peças de reposição
- Aumento da segurança operacional ao prevenir falhas catastróficas
- Extensão da vida útil de equipamentos através de manutenção adequadamente temporizada
- Contribuição para a sustentabilidade industrial ao reduzir desperdício de recursos

Do ponto de vista científico, a estimação de RUL em sistemas complexos apresenta desafios únicos relacionados à natureza estocástica da degradação, variabilidade nas condições operacionais, e complexidade dos modos de falha. A aplicação de técnicas avançadas de ML, particularmente arquiteturas de deep learning como LSTM (Long Short-Term Memory), CNN (Convolutional Neural Networks), e modelos híbridos, tem demonstrado resultados promissores na literatura, mas ainda requer desenvolvimento metodológico adicional para aplicações práticas robustas.

Este projeto justifica-se pela necessidade de desenvolver competência nacional em manutenção preditiva avançada, área estratégica para a competitividade industrial brasileira e alinhada com as tendências da Indústria 4.0 e manufatura inteligente.

Fundamentação Teórica

Manutenção Preditiva e RUL

A manutenção preditiva baseia-se no monitoramento contínuo das condições operacionais de equipamentos para identificar padrões indicativos de degradação. O conceito de RUL refere-se ao tempo estimado até que um sistema ou componente atinja um estado de falha, definido por critérios específicos da aplicação.

Pesquisas recentes em prognóstico de falhas demonstram que modelos baseados em deep learning superam abordagens tradicionais baseadas em features engenheiradas manualmente. Peng et al. (2022) propuseram um modelo combinando Stack Sparse Autoencoder melhorado (imSSAE) e Echo State Network melhorada (imESN), demonstrando precisão superior em experimentos com o dataset C-MAPSS. Zhao et al. (2024) introduziram o framework TranDRL, integrando arquiteturas Transformer com Deep Reinforcement Learning para não apenas prever RUL, mas também otimizar ações de manutenção.

Arquiteturas de Deep Learning para RUL

As arquiteturas de redes neurais profundas mais relevantes para estimação de RUL incluem:

LSTM Networks: Redes LSTM são particularmente adequadas para capturar dependências temporais em séries temporais de sensores. Peringal et al. demonstraram que LSTMs superam consistentemente Multilayer Perceptrons (MLPs) em tarefas de predição de RUL, graças à sua capacidade de aprender padrões temporais de longo prazo.

Convolutional Neural Networks (CNNs): CNNs demonstram eficácia na extração automática de features relevantes de dados de vibração e outras séries temporais multivariadas. Sua capacidade de identificar padrões locais torna-as valiosas para detecção de anomalias e caracterização de modos de falha.

Hybrid Architectures: Modelos híbridos combinando CNNs para extração de features espaciais e LSTMs para modelagem temporal têm demonstrado resultados superiores. Essas arquiteturas exploram sinergias entre diferentes tipos de redes neurais, capturando tanto características locais quanto dependências temporais globais.

Physics-Informed Machine Learning (PIML): Abordagens recentes incorporam conhecimento físico sobre processos de degradação diretamente nas arquiteturas de ML, melhorando a interpretabilidade e generalizabilidade dos modelos. Nagaraj e Hickok (2024) exploraram métodos PIML aplicados ao dataset C-MAPSS, demonstrando como a incorporação de princípios físicos pode melhorar a precisão preditiva.

Datasets de Referência

C-MAPSS Dataset (NASA): O dataset C-MAPSS constitui um benchmark fundamental na pesquisa de RUL. Compreende dados simulados de run-to-failure de motores turbofan comerciais, amplamente utilizado em pesquisa de Prognostics and Health Management (PHM). O dataset inclui quatro subconjuntos (FD001, FD002, FD003, FD004), cada um representando diferentes combinações de condições operacionais e modos de falha. Cada

subconjunto contém séries temporais multivariadas coletadas de múltiplos motores operando até a falha, com 21 sensores registrando parâmetros operacionais e 3 configurações operacionais. Os dados de treino incluem trajetórias completas até a falha, enquanto os dados de teste terminam em pontos aleatórios antes da falha, com os valores verdadeiros de RUL fornecidos para avaliação.

PRONOSTIA / FEMTO-ST Bearing Dataset: Dataset crítico desenvolvido pelo instituto FEMTO-ST (França) especificamente para validação de algoritmos de detecção, diagnóstico e prognóstico de falhas em rolamentos. Este dataset foi utilizado no IEEE PHM 2012 Data Challenge e tornou-se referência padrão na comunidade científica para testes de algoritmos de RUL em rolamentos. A plataforma experimental PRONOSTIA permite testes acelerados de degradação de rolamentos sob condições operacionais controladas e/ou variáveis.

Características técnicas do PRONOSTIA dataset: O dataset compreende 17 rolamentos de esferas de contato angular (deep groove ball bearings) operados até falha completa em três condições operacionais distintas. Cada condição representa combinações diferentes de velocidade de rotação (1500-1800 RPM) e carga radial (4000-5000 N), simulando diferentes cenários de operação industrial. Os dados são organizados em três condições:

- Condição 1: 7 rolamentos (Bearing1_1 a Bearing1_7) operados em condições específicas de velocidade e carga
- Condição 2: 7 rolamentos (Bearing2_1 a Bearing2_7) sob condições operacionais diferentes
- Condição 3: 3 rolamentos (Bearing3_1 a Bearing3_3) em uma terceira configuração operacional

Cada experimento captura sinais de vibração através de dois acelerômetros DYTRAN 3035B posicionados ortogonalmente (horizontal e vertical) para capturar componentes completas das vibrações. A aquisição é realizada com frequência de amostragem de 25,6 kHz durante janelas de 0,1 segundo a cada 10 segundos de operação, gerando arquivos com 2560 pontos de dados por aquisição. Adicionalmente, sensores de temperatura monitoram as condições térmicas dos rolamentos, embora dados de temperatura não estejam disponíveis para todos os testes. Esta configuração experimental permite análise detalhada da evolução temporal da degradação desde condições normais até falha catastrófica.

Desafios do PRONOSTIA dataset: O dataset apresenta características realistas que o tornam particularmente desafiador e valioso para pesquisa: (1) condições de degradação acelerada que comprimem processos que normalmente levariam anos em dias ou semanas; (2) variabilidade significativa entre rolamentos mesmo sob mesmas condições operacionais, refletindo diferenças de manufatura e instalação; (3) ausência de definição clara de limiar de falha, requerendo que pesquisadores desenvolvam critérios próprios; (4) níveis variáveis de ruído não controlado dependentes do processo de degradação; (5) necessidade de técnicas robustas de extração de features devido à complexidade dos sinais de vibração.

Aplicações em pesquisa: O PRONOSTIA dataset tem sido extensivamente utilizado em estudos de RUL para rolamentos. Trabalhos recentes incluem abordagens baseadas em Continuous Wavelet Transform (CWT) combinada com CNN-LSTM, métodos híbridos

integrando Temporal Convolutional Networks (TCN) com attention mechanisms, e técnicas de transfer learning para generalização entre diferentes condições operacionais. O dataset permite avaliação comparativa rigorosa de diferentes metodologias utilizando o mesmo conjunto de dados de referência.

Operational Datasets (Kaggle): Plataformas como Kaggle disponibilizam diversos datasets de manutenção preditiva de fontes industriais reais, incluindo dados de rolamentos (NASA Bearing Dataset, CWRU Bearing Dataset), sistemas hidráulicos, e outros equipamentos rotativos. Estes datasets complementam dados simulados, fornecendo desafios realistas relacionados a ruído, dados faltantes, e variabilidade operacional típica de ambientes industriais.

Objetivo Geral

Desenvolver e validar metodologias baseadas em aprendizado de máquina para estimação precisa de vida útil remanescente (RUL) em sistemas mecânicos, com foco em rolamentos e motores turbofan, contribuindo para o avanço do conhecimento em manutenção preditiva e para a formação de recursos humanos qualificados na área.

Objetivos Específicos

- Realizar revisão sistemática da literatura sobre técnicas de estimação de RUL, identificando estado da arte e lacunas de pesquisa
- Implementar e avaliar arquiteturas de deep learning (LSTM, CNN, modelos híbridos) utilizando os datasets C-MAPSS e PRONOSTIA
- Desenvolver técnicas de pré-processamento e engenharia de features específicas para sinais de vibração de rolamentos e sensores de motores turbofan
- Investigar métodos de fusão de informações de múltiplos sensores (vibração horizontal/vertical, temperatura) para melhorar precisão preditiva
- Estudar técnicas de transfer learning entre diferentes condições operacionais do PRONOSTIA e entre os dois tipos de equipamentos (rolamentos e motores)
- Validar modelos desenvolvidos em datasets operacionais reais disponíveis em repositórios públicos
- Estabelecer métricas apropriadas para avaliação de desempenho de modelos de RUL
- Desenvolver base de conhecimento e competência no Laboratório de Processamento de Sinais do NUPEM em manutenção preditiva
- Publicar resultados em conferências e periódicos científicos de qualidade
- Formar recursos humanos (alunos de iniciação científica, mestrado e doutorado) na área

Metas

- 1 - Revisão bibliográfica e análise de dados
- 2 - Desenvolvimento dos modelos
- 3 - Validação e Análise Comparativa.
- 4 - Disseminação de Resultados.

Metodologia da Execução do Projeto

O projeto será desenvolvido seguindo uma abordagem metodológica estruturada em fases sequenciais e iterativas, com experimentos paralelos nos datasets C-MAPSS (motores turbofan) e PRONOSTIA (rolamentos) para validação cruzada das metodologias:

Fase 1: Revisão Bibliográfica e Análise de Dados (Meses 1-4)

- Condução de revisão sistemática da literatura em RUL, manutenção preditiva e prognóstico de rolamentos
- Análise exploratória aprofundada do C-MAPSS (21 sensores, múltiplas condições operacionais)
- Análise exploratória do PRONOSTIA (17 rolamentos, sinais de vibração horizontal/vertical, 3 condições operacionais)
- Caracterização estatística dos dados: distribuições, correlações, padrões de degradação específicos de cada tipo de equipamento
- Análise de sinais de vibração no domínio do tempo e frequência (FFT, espectrogramas, wavelets)
- Identificação de desafios específicos (desbalanceamento, ruído, sensores redundantes)
- Estabelecimento de baseline com modelos clássicos de ML (Random Forest, Gradient Boosting, SVM)

Fase 2: Desenvolvimento de Modelos (Meses 5-12)

- Implementação de pipeline de pré-processamento específico para cada dataset: normalização, filtragem de ruído, tratamento de outliers
- Extração de features no domínio temporal (RMS, kurtosis, crest factor, skewness) e frequencial (PSD, envelope spectrum)
- Desenvolvimento de arquiteturas LSTM para modelagem de séries temporais de degradação
- Implementação de CNNs para extração automática de features de sinais de vibração e sensores de motores
- Criação de arquiteturas híbridas CNN-LSTM e TCN-LSTM explorando complementaridades
- Aplicação de Continuous Wavelet Transform (CWT) como representação de entrada para redes neurais
- Investigação de attention mechanisms (CBAM, multi-head attention) para ponderação de features relevantes
- Técnicas de ensemble learning para melhorar robustez preditiva
- Estudos de transfer learning entre condições operacionais do PRONOSTIA
- Otimização de hiperparâmetros via grid search, random search ou otimização bayesiana
- Validação cruzada e análise de generalização dos modelos

Fase 3: Validação e Análise Comparativa (Meses 13-18)

- Avaliação de desempenho utilizando métricas padrão: RMSE, MAE, RUL Score, erro percentual
- Comparação com resultados publicados na literatura para os mesmos datasets

- Validação cruzada entre subconjuntos do C-MAPSS (FD001, FD002, FD003, FD004)
- Validação cruzada entre condições do PRONOSTIA (treino em Condição 1, teste em Condição 2/3)
- Análise de sensibilidade dos modelos a variações em condições operacionais
- Testes de robustez frente a ruído e dados faltantes
- Aplicação dos modelos a datasets operacionais reais do Kaggle
- Análise de interpretabilidade dos modelos (importância de features, atenção)

Fase 4: Disseminação de Resultados (Meses 16-24)

- Redação e submissão de artigos científicos ao IEEE PHM Conference e conferências internacionais relacionadas
- Preparação de manuscritos para periódicos de alto impacto (IEEE Transactions on Industrial Informatics, Mechanical Systems and Signal Processing, Reliability Engineering & System Safety)
- Apresentação de resultados em seminários e workshops
- Desenvolvimento de documentação técnica e código aberto (quando apropriado)
- Orientação de trabalhos de conclusão de curso e dissertações baseados no projeto
- Realização de palestras de divulgação científica no CEFET-RJ Campus Nova Iguaçu

Acompanhamento e Avaliação do Projeto

O acompanhamento do projeto será realizado através de:

- Reuniões semanais da equipe do Laboratório de Processamento de Sinais do NUPEM
- Apresentações mensais de progresso pelos alunos envolvidos
- Relatórios parciais semestrais detalhando atividades realizadas e resultados obtidos
- Avaliação de marcos técnicos: implementação de modelos, validação em datasets, preparação de publicações
- Monitoramento de métricas de desempenho dos modelos desenvolvidos (RMSE, MAE, RUL Score)
- Registro de publicações, apresentações em conferências, e orientações concluídas

O prazo de 24 meses é adequado para o desenvolvimento completo do projeto, permitindo a execução de todas as fases metodológicas propostas. A avaliação de sucesso será baseada em indicadores qualitativos e quantitativos, incluindo publicações científicas, formação de recursos humanos, e avanços no estado da arte da área.

Disseminação dos Resultados

Os principais resultados esperados deste projeto incluem:

Contribuições Científicas

- Desenvolvimento de metodologias inovadoras para estimação de RUL baseadas em deep learning aplicadas a rolamentos e motores turbofan
- Análise comparativa sistemática de diferentes arquiteturas de redes neurais para prognóstico em ambos os datasets
- Identificação de melhores práticas em pré-processamento e engenharia de features para dados de manutenção preditiva
- Estudos de transfer learning entre diferentes condições operacionais do PRONOSTIA

- Submissão de artigos em conferências internacionais de alto nível (ex: IEEE PHM Conference, IJCNN)
- Preparação de artigos para periódicos indexados (ex: IEEE Transactions on Industrial Informatics, Mechanical Systems and Signal Processing)

Formação de Recursos Humanos

- Orientação de projetos de Iniciação Científica (PIBIC)
- Orientação de Trabalhos de Conclusão de Curso (TCC)
- Contribuição para dissertações de mestrado em andamento no NUPEM
- Capacitação da equipe em técnicas avançadas de ML, deep learning e análise de sinais de vibração

Impacto Institucional

- Estabelecimento de competência em manutenção preditiva no CEFET-RJ Campus Nova Iguaçu
- Criação de base de conhecimento e repositório de códigos reutilizáveis
- Fortalecimento de colaborações com grupos de pesquisa nacionais e internacionais na área
- Realização de palestras e workshops de divulgação científica no campus
- Fundamentos para projetos futuros de maior maturidade tecnológica (TRL 4-6)

Referências Bibliográficas

Chao, M. A., Kulkarni, C., Goebel, K., & Fink, O. (2021). Aircraft engine run-to-failure dataset under real flight conditions for prognostics and diagnostics. *Data*, 6(1), 5.

Nagaraj, S., & Hickok, T. (2024). Physics informed machine learning (PIML) methods for estimating the remaining useful lifetime (RUL) of aircraft engines. *arXiv preprint arXiv:2406.15619*.

Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-Morello, B., Zerhouni, N., & Varnier, C. (2012). PRONOSTIA: An experimental platform for bearings accelerated degradation tests. In *IEEE International Conference on Prognostics and Health Management (PHM'12)* (pp. 1-8). Denver, Colorado, USA.

Peng, C., Chen, Y., Gui, W., Tang, Z., & Li, C. (2022). Remaining useful life prognosis of turbofan engines based on deep feature extraction and fusion. *Scientific Reports*, 12(1), 6481.

Peringal, A., Mohiuddin, M. B., & Hassan, A. (2024). Remaining useful life prediction for aircraft engines using LSTM. *arXiv preprint arXiv:2401.07590*.

Saxena, A., Goebel, K., Simon, D., & Eklund, N. (2008). Damage propagation modeling for aircraft engine run-to-failure simulation. In *Proceedings of the 1st International Conference on Prognostics and Health Management (PHM08)*, Denver, CO.

Yan, M., Wang, X., Wang, B., Chang, M., & Muhammad, I. (2020). Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model. *ISA Transactions*, 98, 471-482.

Zhang, C., Lim, P., Qin, A. K., & Tan, K. C. (2024). Enhanced bearing RUL prediction based on dynamic temporal attention and mixed MLP. *Autonomous Intelligent Systems*, 4(1), 1-15.

Zhang, X., Liu, Y., Zhou, J., & Wang, L. (2025). A novel RUL prediction method for rolling bearing: TcLstmNet-CBAM. *Scientific Reports*, 15, 1-18.

Zhao, Y., Yang, J., Wang, W., Yang, H., & Niyato, D. (2024). TranDRL: A transformer-driven deep reinforcement learning enabled prescriptive maintenance framework. *arXiv preprint arXiv:2309.16935*.

NASA. (2025). C-MAPSS Jet Engine Simulated Data. NASA Open Data Portal. Disponível em: <https://data.nasa.gov/dataset/cmapss-jet-engine-simulated-data>

NASA Prognostics Center of Excellence. (2025). FEMTO Bearing Data Set. NASA Ames Research Center. Disponível em: <https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>

Kaggle. (2025). Operational Dataset - Machine Predictive Maintenance. Disponível em: <https://www.kaggle.com/datasets/datatobe/operational-dataset>

Organização das Nações Unidas. (2015). Transformando Nosso Mundo: A Agenda 2030 para o Desenvolvimento Sustentável. Disponível em: <https://brasil.un.org/pt-br/sdgs>

NASA. (1995). Technology Readiness Levels (TRL). NASA Technical Reports Server.

CRONOGRAMA DE EXECUÇÃO

Meta Atividade Especificação		Indicador(es) Qualitativo(s)	Responsável Participantes	Período de Execução	
				Início	Término
1	1	• Condução de revisão sistemática da literatura em RUL, manutenção preditiva e prognóstico de rolamentos • Análise exploratória aprofundada do C-MAPSS (21 sensores, múltiplas condições operacionais) • Análise exploratória do PRONOSTIA (17 rolamentos, sinais de vibração horizontal/vertical, 3 condições operacionais) • Caracterização estatística dos dados: distribuições, correlações, padrões de degradação específicos de cada tipo de equipamento • Análise de sinais de vibração no domínio do tempo e frequência (FFT, espectrogramas, wavelets) • Implementação de pipeline de pré-processamento específico para cada dataset: normalização, filtragem de ruído, tratamento de outliers • Extração de features no domínio temporal (RMS, kurtosis, crest factor, skewness) e frequencial (PSD, envelope spectrum)	• Identificação de desafios específicos (desbalanceamento, ruído, sensores redundantes) • Estabelecimento de baseline com modelos clássicos de ML (Random Forest, Gradient Boosting, SVM) Amaro Azevedo de Lima	01/07/2026	01/11/2026
2	1	• Otimização de hiperparâmetros via grid search, random search ou otimização bayesiana • Validação cruzada e análise de generalização dos modelos	Amaro Azevedo de Lima	01/11/2026	01/07/2027

Meta Atividade Especificação		Indicador(es) Qualitativo(s)	Responsável Participantes	Período de Execução Início Término		
3	1	Desenvolvimento de arquiteturas LSTM para modelagem de séries temporais de degradação • Implementação de CNNs para extração automática de features de sinais de vibração e sensores de motores • Criação de arquiteturas híbridas CNN-LSTM e TCN-LSTM explorando complementaridades • Aplicação de Continuous Wavelet Transform (CWT) como representação de entrada para redes neurais • Investigação de attention mechanisms (CBAM, multi-head attention) para ponderação de features relevantes • Técnicas de ensemble learning para melhorar robustez preditiva • Estudos de transfer learning entre condições operacionais do PRONOSTIA • Avaliação de desempenho utilizando métricas padrão: RMSE, MAE, RUL Score, erro percentual • Comparação com resultados publicados na literatura para os mesmos datasets • Validação cruzada entre subconjuntos do C-MAPSS (FD001, FD002, FD003, FD004) • Validação cruzada entre condições do PRONOSTIA (treino em Condição 1, teste em Condição 2/3) • Análise de sensibilidade dos modelos a variações em condições operacionais • Testes de robustez frente a ruído e dados faltantes • Redação e submissão de artigos científicos ao IEEE PHM Conference e conferências internacionais relacionadas • Preparação de manuscritos para periódicos de alto impacto (IEEE Transactions on Industrial Informatics, Mechanical Systems and Signal Processing, Reliability Engineering & System Safety) • Apresentação de resultados em seminários e workshops • Desenvolvimento de documentação técnica e código aberto (quando apropriado) • Orientação de trabalhos de conclusão de curso e dissertações baseados no projeto • Realização de palestras de divulgação científica no CEFET-RJ Campus Nova Iguaçu	• Aplicação dos modelos a datasets operacionais reais do Kaggle • Análise de interpretabilidade dos modelos (importância de features, atenção)	Amaro Azevedo de Lima	01/07/2027	01/01/2028
4	1	Produção de artigos, TCCs e dissertações.	Amaro Azevedo de Lima	01/01/2028	30/06/2028	

PLANO DE APLICAÇÃO

Classificação da Despesa	Especificação	PROPI (R\$)	DIGAE (R\$)	Campus Proponente (R\$)	Total (R\$)
TOTAIS		0	Anexo A0	0	0

MEMÓRIA DE CÁLCULO

CLASSIFICAÇÃO DE DESPESA	ESPECIFICAÇÃO	UNIDADE DE MEDIDA	QUANT.	VALOR UNITÁRIO	VALOR TOTAL
TOTAL GERAL					-

Documento Digitalizado Público

Projeto contemplado no Edital de Fomento 04/2026 DEPEQ/DIPPG/CEFET-RJ

Assunto: Projeto contemplado no Edital de Fomento 04/2026 DEPEQ/DIPPG/CEFET-RJ
Assinado por: Amaro Lima
Tipo do Documento: Projeto
Situação: Finalizado
Nível de Acesso: Público
Tipo do Conferência: Cópia Simples

Documento assinado eletronicamente por:

- **Amaro Azevedo de Lima, PROFESSOR ENS BASICO TECN TECNOLOGICO**, em 22/07/2026 15:49:51.

Este documento foi armazenado no SUAP em 22/07/2026. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.cefet-rj.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 263931

Código de Autenticação: 04acadce7f

