

Avaliação de Desempenho de Modelos Preditivos para Estimação da Vida Útil Remanescente em Rolamentos de Máquinas Rotativas

Valdir F. Filho, Márcio H. Costa, Bruno C. Bispo, Diego M. Carmo e Danilo Braga

Resumo— Este trabalho apresenta um estudo sobre técnicas de estimação de vida útil remanescente (RUL) em rolamentos de máquinas rotativas. Foram comparados dois métodos baseados em modelos matemáticos (crescimento exponencial) e dois orientados por dados (autoencoder e rede LSTM). Para mitigar a restrição na disponibilidade de dados, sinais sintéticos foram gerados a partir da caracterização de um sinal real e empregados no treinamento. Métricas quantitativas foram calculadas para quatro sinais reais provenientes de dois bancos de dados. Os resultados evidenciam as potencialidades e limitações das estratégias avaliadas. Conclui-se que os modelos preditivos atuais não apresentam diferenças substanciais de desempenho e, portanto, a estimação robusta e universal da RUL ainda representa um desafio em aberto.

Palavras-Chave— Vida útil remanescente, RUL, Rolamentos, Manutenção preditiva.

Abstract— This paper presents a study on remaining useful life estimation techniques for bearings in rotating machines. Two methods based on mathematical models (exponential growth) and two data-driven methods (autoencoder and LSTM network) were compared. To mitigate the restriction in data availability, synthetic signals generated from real signal characteristics were employed in training. Quantitative metrics were calculated for four real signals from two databases. The results highlight the potential and limitations of the evaluated strategies. It is concluded that current predictive models do not show substantial differences in performance, and therefore, robust, and universal RUL estimation still represents an open challenge.

Keywords— Remaining useful life, RUL, Bearings, Predictive maintenance.

I. INTRODUÇÃO

Uma das principais estratégias de manutenção no contexto industrial é o prognóstico e gestão da saúde (PHM). Seu objetivo é atender à crescente demanda por maior eficiência na gestão de ativos e controle de falhas [1]. Entre as propostas mais modernas encontra-se a estimação da vida útil remanescente (RUL). A RUL é o tempo restante de vida de um determinado ativo (componente, equipamento ou sistema) antes que atinja uma condição de falha (Fig. 1) [2]. A previsão antecipada da falha permite redução de custos na manutenção de equipamentos industriais.

Rolamentos de máquinas rotativas têm sido uma das principais aplicações da RUL [3]. Ao longo do tempo de operação, as condições mecânicas dos rolamentos são afetadas por diferentes fatores que podem levar à falha, como a falta de lubrificação e carga excessiva. Como resultado, é comum o surgimento de níveis elevados de vibração antes da quebra [4].

Valdir Filho, Márcio Costa e Bruno Bispo, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis-SC, e-mails: valdir.filho@posgrad.ufsc.br, {marcio.costa, bruno.bispo}@ufsc.br. Diego Carmo e Danilo Braga, Dynamox, Florianópolis-SC, e-mails: {diego.carmo, danilo}@dynamox.net.

Uma parcela não desprezível das falhas em rolamentos apresenta degradação gradual, tornando possível detectar potenciais avarias antes que se tornem severas e inviabilizem o funcionamento do sistema. Para realizar a previsão de uma condição crítica, podem ser utilizados sinais de vibração coletados por acelerômetros. Dessa forma, é possível realizar a substituição programada dos rolamentos, otimizando-se as manutenções preventivas [5] [6].




Fig. 1. Modelo de previsão da RUL com base em séries temporais.

Os métodos de estimação da RUL podem ser classificados em duas categorias principais: métodos baseados em modelos e métodos baseados em dados [7]. As técnicas fundamentadas em modelos, sejam eles matemáticos ou físicos, utilizam conhecimento prévio e explícito sobre o funcionamento dos rolamentos ou do processo de degradação. Sua principal vantagem é a interpretabilidade do procedimento, permitindo obter estimações confiáveis quando há uma descrição acurada do processo [8]. Os métodos baseados em dados, também chamados de métodos de aprendizado de máquina, têm ganhado destaque pela possibilidade de processar grandes volumes de dados históricos para identificar padrões e tendências de degradação em sistemas complexos [9]. Sua grande limitação é a dificuldade em obter uma quantidade representativa de mensurações que atinjam a condição de falha [8] [9], como também o elevado custo computacional vinculado. De forma geral, a estimação da RUL está associada a um elevado grau de incerteza, pois os processos de degradação possuem considerável variabilidade, mesmo em conjuntos de dados obtidos sob condições controladas [10].

Ao longo dos últimos anos, a área de estimação da RUL tem ganhado destaque, tendo como um de seus marcos principais a competição *IEEE 2012 PHM Data Challenge* [11]. Embora diversas técnicas tenham sido propostas desde então, observa-se uma ausência de estudos comparativos que avaliem o desempenho dessas técnicas em um mesmo cenário.

Este trabalho apresenta uma análise comparativa de desempenho entre técnicas de estimação da RUL. São abordados

dois métodos baseados em modelos matemáticos e dois orientados por dados. As principais contribuições deste trabalho são: (i) a comparação de técnicas de estimação da RUL sob uma mesma metodologia e condição de avaliação; (ii) a utilização de quimeras (sinais sintéticos) para treinamento dos métodos orientados por dados, compensando a pequena disponibilidade de sinais comum a esse tipo de aplicação; e (iii) a utilização de sinais de vibração reais de dois bancos de dados distintos, de forma a verificar a capacidade de generalização dos métodos abordados. As condições de análise se restringem a rolamentos cujos sinais de vibração permitam acompanhar a evolução da falha ao longo do tempo.

Este trabalho está organizado da seguinte maneira: a Seção II apresenta os métodos abordados de estimação da RUL; a Seção III descreve uma metodologia unificada para análise e comparação; na Seção IV são apresentados e discutidos os resultados; por fim, a Seção V apresenta as conclusões do trabalho.

II. TÉCNICAS DE ESTIMAÇÃO DA RUL

Neste trabalho uma análise crítica e comparativa de quatro métodos recentemente propostos para estimação da RUL é realizada sob as mesmas condições. São abordados dois métodos baseados em modelos exponenciais, o método de Wang e Xiang (2021) [6] e o de Kong e Yang (2019) [12], e dois métodos de aprendizado de máquina, o de Costa e Sánchez (2022) [1] e o de Berghout *et al.* (2022) [13].

A. Método de Kong e Yang (2019)

O método proposto por Kong e Yang utiliza um modelo exponencial para descrever o aumento de vibração que ocorre ao longo do processo de degradação do rolamento [12]. Uma contribuição deste trabalho foi a definição de um indicador de saúde (HI) para a descrição da evolução da falha ao longo do tempo. Para o processo de predição, ao invés do valor quadrático médio (RMS) do sinal de vibração (amplamente utilizado na literatura), os autores propuseram a característica RMS-MAVE. O primeiro ponto de anomalia (FPT), instante de tempo a partir do qual é iniciado o processo de predição, foi definido através da desigualdade de Chebyshev. Os resultados indicaram maior acurácia na estimação do RUL em relação a métodos previamente publicados na literatura.

B. Método de Wang e Xiang (2021)

A técnica de Wang e Xiang também utiliza um modelo de degradação exponencial para estimação da RUL em rolamentos de máquinas rotativas [6]. O método se diferencia por identificar o FPT a partir dos valores de RMS e curtose do sinal de vibração. Os autores também propuseram utilizar o método do gradiente descendente para a otimização dos parâmetros do modelo exponencial. Uma acurácia 1% superior à obtida pelo método de Paris [14] foi reportada.

C. Método de Costa e Sánchez (2022)

A metodologia proposta por Costa e Sánchez adota um *Variational Autoencoder* (VAE), uma arquitetura de aprendizado de máquina para a estimação da RUL [1]. Esse autoencoder comprime os dados recebidos em uma representação latente por meio de uma rede LSTM. Aos dados comprimidos é aplicada uma camada de regressão, diferentemente dos métodos tradicionais que geralmente

constroem um HI. O método foi treinado e testado utilizando uma base de dados da NASA relativa à simulação de motores turbofan em processo de degradação. A metodologia proposta apresentou resultados superiores aos métodos baseados em redes convolucionais descritos em estudos anteriores.

D. Método de Berghout *et al.* (2022)

O método de Berghout *et al.* combina aprendizado profundo e transferência de conhecimento para contornar a limitação imposta ao treinamento pela indisponibilidade de grandes conjuntos de sinais [13]. O método usa um HI e um parâmetro de estágio de saúde (HS). As informações de HI são processadas por uma rede LSTM e, paralelamente, os estágios de saúde são classificados utilizando modelos de misturas gaussianas. A transferência de conhecimento é empregada no treinamento do modelo para compartilhar informações de diferentes condições dos rolamentos.

III. METODOLOGIA

Nesta seção é descrita a metodologia utilizada para análise e comparação das técnicas descritas na seção II.

A. Banco de Dados

Foram utilizados dois bancos de dados contendo sinais de vibração provenientes de acelerômetros acoplados em máquinas rotativas. Em ambos, o processo de degradação dos rolamentos é realizado de forma acelerada.

O banco FEMTO fornece sinais referentes a 17 rolamentos submetidos a diferentes condições de carga e velocidades [11]. A frequência de amostragem é de 25,6 kHz, com intervalo de 10 segundos entre medições.

O banco XJTU-ST [8] possui 15 sinais. A frequência de amostragem é de 25,6 kHz, com intervalo de 1 minuto entre medições. Para compatibilizar os intervalos de medições, os sinais do XJTU-ST foram interpolados (6:1).

Para todos os sinais dos dois bancos de dados, valores RMS e curtose foram calculados e normalizados.




Fig. 2. Estágios do processo de falha de um rolamento, a partir dos valores RMS do sinal de vibração de uma máquina rotativa.

B. Seleção de Rolamentos

A acurácia de estimação da RUL depende das características do processo de degradação. De forma geral existem três estágios

que se apresentam em sequência (Fig. 2): saudável (vibração estacionária), degradação (vibração com crescimento moderado) e crítico (vibração com crescimento acentuado) [13]. Em situações de falhas abruptas, aquelas com curto período de estágio de degradação, como as decorrentes de estilhaçamento (quase-) instantâneo do rolamento, a RUL é de difícil predição. Por esse motivo, o presente trabalho analisa, exclusivamente, o desempenho dos métodos de estimação da RUL para sinais de vibração com estágio de degradação bem determinado.

Uma análise exploratória dos dois bancos de dados indica que grande parte dos sinais não se enquadra na condição prática de interesse, pois apresenta um valor RMS com período de degradação de muito curta duração. Um dos rolamentos que apresenta valor RMS com estágio de degradação de duração moderada a longa é o FEMTO 1.1 (nome da base de dados e referência do sinal). Utilizando esse rolamento como base, foi realizada uma aproximação do seu valor RMS por uma exponencial de segunda ordem [15] e selecionadas seis características: os coeficientes das duas exponenciais; o tempo de crescimento crítico [16]; o valor do erro médio absoluto (MAE); o instante médio ponderado no tempo [17]; e o erro percentual absoluto médio simétrico (SMAPE) [18].

A seleção dos rolamentos que representam a condição prática de interesse foi realizada através da repetição do processo de aproximação exponencial para cada sinal dos dois bancos de dados. O critério de seleção foi apresentar uma variação máxima de 30% em pelo menos três características em relação ao rolamento FEMTO 1.1, de forma a garantir um estágio de degradação de duração mínima. Com esse critério, foram selecionados os rolamentos FEMTO-1.3 e XJTU-1.3.

Além disso, foi verificado que o rolamento XJTU-3.2, em seu intervalo de medição original (sem interpolação), também se adequa aos critérios estabelecidos. Então, para aumentar o grupo de teste, foi incluído no grupo de rolamentos selecionados.

C. Dados Sintéticos

Os métodos baseados em aprendizado de máquina requerem quantidade considerável de dados para o processo de treinamento, o que não é comum em bancos de dados reais de rolamentos com degradação até a falha. Para superar essa restrição, o presente trabalho utilizou apenas sinais sintéticos para o treinamento dos métodos de Costa e Sánchez e de Berghout *et al.* Esses sinais foram gerados de forma a atender a existência de três estágios bem definidos (saudável, degradação e crítico) e implementados através da composição de um nível constante, compreendendo entre 500 e 1500 amostras, seguido de dois crescimentos exponenciais, com duração de 900 a 1500 amostras e 200 a 400 amostras, respectivamente, com diferentes taxas de crescimento (Fig. 3). Variações de amplitude de $\pm 30\%$ dos parâmetros de modelagem, identificados a partir do rolamento FEMTO 1.1, foram utilizadas. Ruído branco gaussiano foi adicionado de forma proporcional (entre 10% e 15%) à amplitude média de cada um dos estágios. Por fim, foram inseridas 20 amostras impulsivas em cada sinal, de maneira aleatória, com três valores distintos de amplitude (pequeno, médio e alto).

D. Configurações das Técnicas

A configuração dos parâmetros dos métodos de estimação de RUL foi realizada com base no sinal FEMTO-1.1. Pequenos ajustes posteriores foram realizados para permitir a

generalização para os demais sinais.

No método de Kong e Yang, um processo de análise exploratória foi realizado para determinar os tamanhos das janelas de tempo de predição, suavização e determinação do FPT. O limiar de falha foi estabelecido em 0,5.

Na técnica de Wang e Xiang, os parâmetros foram mantidos conforme descritos pelos autores, com exceção do limiar de falha, definido em 0,24, e do número de pontos necessários para a formação da curva, ajustado para 80 amostras.

O método de Costa e Sánchez foi originalmente desenvolvido para um banco de dados simulados de motores turbofan. Dessa forma, foi necessária uma adaptação na qual foram utilizados como entrada o valor de pico, a curtose e o RMS dos sinais de vibração.

O código disponibilizado por Berghout *et al.* não inclui o processo de *Transfer Learning* que foi adaptado de [19].

O treinamento por aprendizado de máquina foi realizado através de 90 sinais sintéticos gerados conforme a seção III.C.




Fig. 3. Sinais sintéticos utilizados para treinamento dos métodos baseados em aprendizado de máquina.

TABELA I. RESULTADOS QUANTITATIVOS DA ESTIMAÇÃO DA RUL

Rolamento	Técnica	MAE%	Score	PCC	MON
FEMTO 1.1	[12]	43%	0,05	0,80	0,25
	[6]	27%	0,14	0,96	0,66
	[1]	34%	0,11	0,42	0,45
	[13]	17%	0,25	0,81	0,61
FEMTO 1.3	[12]	33%	0,09	0,94	0,4
	[6]	24%	0,07	0,98	0,72
	[1]	21%	0,21	0,72	0,42
	[13]	19%	0,16	0,87	0,49
XJTU 1.3	[12]	27%	0,14	0,91	0,5
	[6]	34%	0,10	0,84	0,41
	[1]	14%	0,36	0,87	0,38
	[13]	17%	0,28	0,96	0,96
XJTU 3.2*	[12]	25%	0,17	0,85	0,47
	[6]	50%	0,03	0,32	0,04
	[1]	79%	0,00	0,44	0,46
	[13]	32%	0,18	0,39	0,65

*Rolamento com intervalo de medição original.

E. Métricas de Avaliação

As métricas de avaliação utilizadas foram: erro absoluto médio percentual (MAE%) [5]; *Score* para penalização de predições tardias [8]; coeficiente de correlação de Pearson (PCC), que avalia a correlação entre a RUL estimada e real; e monotonicidade (MON), que verifica a tendência de declínio ou crescimento da RUL ao longo do tempo [12]. Todas as métricas foram aplicadas somente às 500 amostras finais dos sinais analisados, como forma de padronização.

IV. RESULTADOS E DISCUSSÕES

A Tabela I apresenta os resultados quantitativos das quatro técnicas de estimação da RUL descritas na seção II. Os melhores resultados para cada rolamento estão destacados em negrito. Os valores de MAE% (quanto menor, melhor) obtidos no presente trabalho são compatíveis aos valores encontrados em [20]. Em geral, observa-se que, para um mesmo rolamento, o desempenho das diferentes técnicas não apresenta variações substanciais.

O Score (quanto maior, melhor) é uma métrica que penaliza as predições tardias. Análise de regressão indica correlação não-linear com o MAE%, na forma de um comportamento exponencial decrescente. Em decorrência da existência de diferentes definições [1] [8] [20], seu uso para comparações entre diferentes trabalhos é limitado.

Embora amplamente utilizados na literatura, PCC e MON podem ser considerados métricas secundárias, pois não retratam a diferença absoluta entre a RUL e sua estimativa, exigindo uma interpretação cautelosa de seus resultados.

Estimativas da RUL, ao longo do tempo, para o rolamento FEMTO 1.3, obtidas pelos quatro métodos sob análise são apresentadas na Fig. 4. As últimas 500 amostras das estimativas da RUL estão destacadas em azul escuro. A evolução do valor RMS do sinal de vibração ao longo do tempo é representada pela linha contínua cinza, enquanto a trajetória da RUL real é indicada pela linha tracejada vermelha. Analogamente, os resultados obtidos para o rolamento XJTU 1.3 são apresentados na Fig. 5.

Observa-se que a estimação da RUL durante o estágio saudável (até aproximadamente a amostra 1000 no FEMTO 1.3 e 400 no XJTU 1.3) exibe um comportamento característico para cada técnica. O método de Kong e Yang (Fig. 4(a) e Fig. 5(a)) apresenta variações bruscas na RUL estimada. A abordagem de Wang e Xiang (Fig. 4(b) e Fig. 5(b)) não fornece estimativas da RUL antes da detecção do FPT. O método de Costa e Sánchez (Fig. 4(c) e Fig. 5(c)) fornece uma estimativa aproximadamente constante.

No estágio de degradação, verifica-se um padrão de decaimento consistente na RUL estimada. O método de Costa e Sánchez se diferenciou, de maneira negativa, por apresentar comportamento substancialmente mais ruidoso. Durante o estágio crítico (após a amostra 2300 no FEMTO 1.3 e 850 no XJTU 1.3), observou-se uma tendência consistente da RUL estimada em direção ao valor nulo em todos os métodos avaliados.

Ressalta-se que resultados semelhantes foram obtidos para os rolamentos FEMTO 1.1 e XJTU 3.2, mas eles não são graficamente apresentados devido à limitação de espaço.

A partir dos resultados, constata-se um processo de aprendizado bem-sucedido com sinais sintéticos, no qual os modelos de aprendizado de máquina exibem adequada

capacidade de generalização. Essa abordagem parece superar, pelo menos em parte, as limitações associadas à escassez de sinais reais.

É crucial relatar que, com exceção dos quatro rolamentos descritos (FEMTO 1.1, FEMTO 1.3, XJTU 1.3 e XJTU 3.2 sem interpolação) não foi possível obter configurações de parâmetros que permitissem generalização do aprendizado com estimações adequadas da RUL para os demais 15 sinais da base FEMTO e 13 sinais da base XJTU. Essa dificuldade decorre da natureza abrupta das falhas captadas nos sinais de vibração, resultando em erros de estimação significativamente elevados, como os valores de MAE% superiores a 400% reportados em [11].

Embora a magnitude do erro possa ser reduzida pela escolha de parâmetros específicos para cada sinal, os resultados obtidos neste trabalho evidenciam que as técnicas atuais de estimação da RUL ainda não estão adequadamente desenvolvidas para implementar sistemas genéricos de predição, demandando particularização de configuração para ativos específicos. Consequentemente, sugere-se, como boa prática em sistemas de gestão de manutenção industrial, a integração de estimadores de RUL com detectores de falha.

A análise comparativa dos quatro métodos demonstrou que, para a condição prática de interesse, na qual os sinais de vibração apresentam um estágio de degradação bem definido, a RUL pode ser estimada com erro limitado. No entanto, nenhum dos métodos avaliados apresentou desempenho consistentemente superior aos outros. A ausência de uma técnica dominante revela que a estimação da RUL ainda configura um problema de pesquisa em aberto.

V. CONCLUSÃO

Este trabalho apresentou uma avaliação comparativa de quatro métodos de estimação da vida útil remanescente de rolamentos de máquinas rotativas a partir de sinais de vibração com característica de degradação exponencial. Verificou-se a viabilidade do emprego de sinais sintéticos no treinamento de métodos baseados em aprendizado de máquina, mitigando o problema de escassez de dados reais que caracteriza esse tipo de aplicação. A análise quantitativa, através das métricas MAE% e Score, revelou que o desempenho das técnicas investigadas não apresenta diferenças substanciais. Este resultado, em conjunto com a dificuldade de generalização para a maioria dos sinais das bases de dados FEMTO e XJTU, devido aos rolamentos apresentarem falhas quase instantâneas, reforça a percepção de que a estimação robusta e universal da RUL em sistemas de gestão de saúde industrial de rolamentos ainda representa um desafio em aberto. Portanto, em muitos casos pode ser requerida a especificação *ad hoc* do modelo e de seus parâmetros, sendo recomendável a integração com detectores de falha.

REFERÊNCIAS

- [1] N. Costa e L. Sánchez, "Variational encoding approach for interpretable assessment of remaining useful life estimation", *Reliability Engineering and System Safety*, vol. 222, p. 109161, 2022.
- [2] M. Mishra *et al.*, "Bearing life prediction with informed hyperprior distribution: A Bayesian hierarchical and machine learning approach", *IEEE Access*, vol. 9, pp. 157002-157011, 2021.
- [3] R. K. Singleton II, E. G. Strangas e S. Aviyente, "The use of bearing currents and vibrations in lifetime estimation of bearings", *IEEE Transactions on Industrial Informatics*, vol. 13, n. 3, pp. 1301-1309, 2017.
- [4] X. Jin *et al.*, "Anomaly detection and fault prognosis for bearings", *IEEE*

- Transactions on Instrumentation and Measurement*, vol. 65, n. 9, pp. 2046-2054, 2016.
- [5] R. Wang *et al.*, "Remaining useful life prediction of rolling bearings based on multiscale convolutional neural network with integrated dilated convolution blocks", *Shock and Vibration*, vol. 2021, p. 1-11, 2021.
- [6] G. Wang e J. Xiang, "Remain useful life prediction of rolling bearings based on exponential model optimized by gradient method", *Measurement*, vol. 176, p. 109161, 2021.
- [7] R. K. Singleton II, E. G. Strangas e S. Aviyente, "Discovering the hidden health states in bearing vibration signals for fault prognosis", *Proceedings of the IEEE*, pp. 3438-3444, 2014.
- [8] B. Wang *et al.*, "A hybrid prognostics approach for estimating remaining useful life of rolling element bearings", *IEEE Transactions on Reliability*, vol. 69, n. 1, pp. 401-412, 2020.
- [9] J. S. L. Senanayaka, H. V. Khang e K. G. Robbersmyr, "Autoencoders and recurrent neural networks based algorithm for prognosis of bearing life", *International Conference on Electrical Machines and Systems (ICEMS)*, Jeju, Coreia do Sul, pp. 1-6, 2018.
- [10] W. Mao, J. He e M. J. Zuo, "Predicting remaining useful life of rolling bearings based on deep feature representation and transfer learning", *IEEE Transactions on Instrumentation and Measurement*, vol. 69, n. 4, pp. 1594-1608, 2020.
- [11] E. Sutrisno *et al.*, "Estimation of remaining useful life of ball bearings using data driven methodologies", *Proceedings of the IEEE*, pp. 1-6, 2012.
- [12] X. Kong e J. Yang, "Remaining useful life prediction of rolling bearings based on RMS-MAVE and dynamic exponential regression model", *IEEE Access*, vol. 7, pp. 169705-169714, 2019.




Fig. 4. Resultados para o sinal FEMTO 1.3. (a) Kong e Yang, (b) Wang e Xiang, (c) Costa e Sánchez, e (d) Berghout *et al.*. (i) RMS (linha contínua cinza), (ii) RUL real (linha tracejada vermelho) e (iii) estimacão da RUL (linha contínua azul).

- [13] T. Berghout *et al.*, "A semi-supervised deep transfer learning approach for rolling-element bearing remaining useful life prediction", *IEEE Transactions on Energy Conversion*, vol. 37, n. 2, pp. 1200-1210, 2022.
- [14] D. An, J.H. Choi e N.H. Kim, "Prognostics 101: A tutorial for particle filter-based prognostics algorithm using Matlab", *Reliability Engineering & System Safety*, vol. 115, pp. 161-169, 2013.
- [15] MathWorks, "Exponential Models", *MATLAB Curve Fitting Toolbox Documentation*, 2023. Disponível em: <https://www.mathworks.com/help/curvefit/exponential.html>.
- [16] N. He e Q. Q. Chen, "A novel event triggered model predictive control method for VAV air conditioning System", *Chinese Control Conference (CCC)*, Shanghai, China, pp. 2680-2685, 2021.
- [17] Q. Soares *et al.*, "Developing a machine learning pipeline for predicting neurological outcomes in comatose cardiac arrest survivors using continuous EEG data", *Computing in Cardiology Conference*, 2023, pp. 1-4.
- [18] G. -m. Bak, E. -s. Lee e Y. -c. Bae, "PNP-lightweight model for predicting remaining useful life of Lithium-Ion battery to applying embedded Systems", *International Conference on System Reliability and Safety (ICSRS)*, Bologna, Italy, 2023, pp. 53-60.
- [19] T. Berghout e M. Benbouzid, "Diagnosis and prognosis of faults in high-speed aeronautical bearings with a collaborative selection incremental deep transfer learning approach", *Applied Sciences*, vol. 13, pp. 10916, 2023. Available at <https://github.com/TBdevelloper/CSIDTL>.
- [20] C. Li, W. Zhai e Z. Yan, "Remaining useful life prediction of rolling bearings based on CAGRU-HF", *Data Driven Control and Learning Systems Conference (DDCLS)*, Kaifeng, China, 2024, pp. 2139-2144.




Fig. 5. Resultados para o sinal XJTU 1.3. (a) Kong e Yang, (b) Wang e Xiang, (c) Costa e Sánchez, e (d) Berghout *et al.*. (i) RMS (linha contínua cinza), (ii) RUL real (linha tracejada vermelho) e (iii) estimacão da RUL (linha contínua azul).