

Métodos de Prognóstico de Falhas com a Rede Neo-Fuzzy Neuron ^{*}

José Hélio de Souza ^{*} Walmir Matos Caminhas ^{**}

^{*} Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos, 6627 31270-901, Belo Horizonte, MG, Brazil, (e-mail:josehelio@ufmg.br)

^{**} Departamento de Engenharia Eletrônica - Universidade Federal de Minas Gerais - Av. Antônio Carlos, 6627 31270-901, Belo Horizonte, MG, Brazil, (e-mail:caminhas@cpdee.ufmg.br)

Abstract: Intelligent systems for fault prognostics in industries have brought important contributions in terms of security and economy, which has made them indispensable, and motivated more and more research in the area. This article discusses and evaluates methods of analysis of historical data to estimate the remaining useful life in fault prognostics problems, using the Neo-Fuzzy Neuron (NFN). The methodology is applied in three well-known databases in the literature to assess prognostics problems, they are the lithium ion batteries, the wear of cutting tools of the Computer Numerical Control (CNC) and the wear of bearings extracted from the PRONOSTIA database.

Resumo: Os sistemas inteligentes em prognóstico de falhas nas indústrias têm trazido importantes contribuições em termos de segurança e economia, tornando-os indispensáveis, e motivado cada vez mais pesquisas na área. Este artigo aborda e avalia métodos de análise de dados históricos para estimar o tempo de vida útil remanescente em problemas de prognóstico de falhas, com o uso da *Neo-Fuzzy Neuron* (NFN). A metodologia é aplicada em três bases de dados bem conhecidas na literatura para avaliação de problemas de prognóstico, são elas: as baterias de íons de lítio, o desgaste de ferramentas de corte da Máquina de Comando Numérico (CNC) e o desgaste de rolamentos extraídos da base de dados PRONOSTIA.

Keywords: Neo-Fuzzy Neuron, Fault Prognostics, Remaining Useful Life.

Palavras-chaves: Neo-Fuzzy Neuron, Prognóstico de Falhas, Vida Útil Remanescente.

1. INTRODUÇÃO

O prognóstico de falhas é uma importante aplicação para as indústrias, tanto em economia como na segurança, pois com o prognóstico é possível, por exemplo, prever paradas de máquinas e realizar uma manutenção preventivamente antes que ocorra uma falha em um equipamento, ou seja, a partir da condição atual e dados anteriores é possível estimar quanto tempo de vida tem um certo equipamento. Na literatura esse tipo de prognóstico é denominado vida útil remanescente (RUL, do inglês *Remaining Useful Life*) (Jardine et al., 2006).

Os métodos de prognóstico de falhas podem ser divididos em três tipos (Liao and Köttig, 2014): o prognóstico baseado em modelos (Luo et al., 2003), ao qual utiliza-se modelos matemáticos para prever as condições futuras do equipamento; o baseado em experiência (Biagetti and Sciubba, 2004), que realiza a previsão a partir de modelos probabilísticos e experiências passadas; e o prognóstico

baseado em dados, composto de métodos que, em sua maioria utiliza-se de inteligência computacional.

O prognóstico baseado em dados tem ganhado grande atenção com a realização de diversos estudos e aplicações em problemas comuns da indústria como: o trabalho de Qu et al. (2019) que propõe uma arquitetura nomeada de PA-LSTM formada por uma rede neural de memória de longo prazo (*long short term memory* - LSTM) em conjunto com o algoritmo evolucionário PSO (*Particle swarm optimization*), para a predição do tempo de vida útil remanescente e o monitoramento do estado de saúde (*State of Health* - SOH) das baterias de íons de lítio; Javed et al. (2018) usa uma abordagem conexionista orientada a dados (*Summation Wavelet-Extreme* - SW-ELM) com aprendizagem incremental no monitoramento do desgaste da ferramenta de corte de uma Máquina de Comando Numérico (CNC); e na predição da degradação de rolamentos, Li et al. (2019) propõe uma rede neural profunda e Cosme et al. (2019) usa uma abordagem baseada no filtro IMM (*Interacting Multiple Model*) para o prognóstico de falha; e ainda nas bases de dados da CNC e rolamentos, Cosme et al. (2018) apresenta uma combinação do filtro de partículas com o algoritmo de evolução diferencial (*Diferencial Evolution* - DE).

^{*} Este trabalho tem como parceiro e apoiador financeiro o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), a Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e o Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais (UFMG).

Além dessas estruturas, temos as redes *Neuro-Fuzzy* que têm sido utilizadas para o prognóstico de falhas (Razavi-Far et al., 2016) e apresentado bons resultados. Uma rede *Neuro-Fuzzy* que tem despertado interesse de alguns pesquisadores desde sua proposta é a *Neo-Fuzzy Neuron* (NFN) (Yamakawa et al., 1992), que tem uma arquitetura de fácil implementação e um bom desempenho computacional.

Com o uso da rede *Neo-Fuzzy Neuron* (NFN), este trabalho realiza a estimação de RUL com a análise de dados históricos e a predição de muitos passos a frente nas bases de dados de Baterias de íons de lítio (Saha and Goebel, 2007), das ferramentas de corte de uma Máquina de Comando Numérico (CNC) (PHM Society, 2010) e em uma base de dados de desgaste de rolamentos extraída da plataforma PRONOSTIA (Nectoux et al., 2012).

Em síntese, este artigo está organizado da seguinte forma: a Seção 2 apresenta uma revisão da rede *Neo-Fuzzy Neuron* (NFN), sua estrutura, funções de pertinência e método de aprendizagem; a Seção 3 apresenta o método de prognóstico de falha utilizado para estimar o tempo de vida útil remanescente; a Seção 4 apresenta os experimentos realizados e os resultados obtidos; e a Seção 5 apresenta a conclusão e as propostas de trabalhos futuros.

2. NEO-FUZZY NEURON

A estrutura da rede *neuro-fuzzy*, nomeada de *Neo-Fuzzy Neuron* (NFN), proposta por Yamakawa et al. (1992), é conhecida pela sua simplicidade de implementação e seu baixo custo computacional. Nesta rede (Figura 1) cada entrada x_{ti} é associada a um neurônio *fuzzy*. Quando usado a função de pertinência triangular complementar somente duas funções são ativadas a cada entrada x_{ti} . As funções ativas são indicadas pelas variáveis k_i e $k_i + 1$, desta forma, tem-se a saída dos neurônios:

$$f_{ti}(x_{ti}) = y_{ti} = \mu_{A_{ik_i}}(x_{ti})q_{ik_i} + \mu_{A_{ik_i+1}}(x_{ti})q_{ik_i+1}, \quad (1)$$

sendo que i é o índice da variável de entrada de n características da amostra t . A soma dessas saídas individuais, gera a saída da rede:

$$y_t = \sum_{i=1}^n y_{ti}. \quad (2)$$




Figura 1. Estrutura da NFN (Silva et al. (2014)).

Os neurônios *fuzzy* da NFN (Figura 2) são compostos pelas m_i regras *fuzzy* ($\mu_{A_{ij}}$) e os seus consequentes (pesos (q_{ij})).




Figura 2. Estrutura de um neurônio da NFN (Silva et al. (2014)).

2.1 Função de Pertinência Triangular Tipo I

As funções de pertinência triangulares igualmente espaçadas são geradas a partir da quantidade de regras m_i desejada e do valor mínimo e máximo de x_i , sendo $\min(x_i)$ o primeiro valor modal (a_{i1}) e os demais são definidos por:

$$\Delta_i = \frac{\max(x_i) - \min(x_i)}{m_i - 1}, \quad (3)$$

$$a_{ij} = \min(x_i) + (j - 1)\Delta_i, \quad (4)$$

onde j é o índice da função pertinência e Δ_i o espaço entre elas, como ilustra a Figura 3.




Figura 3. Funções de pertinência triangulares igualmente espaçadas.

A equação para encontrar o valor da função de pertinência da entrada x_i é dada por:

$$\mu_{A_{ij}}(x_i) = \begin{cases} \frac{x_i - a_{ir}}{\Delta_i} + 1, & a_{i(r-1)} \leq x_i \leq a_{ir} \\ -\frac{x_i - a_{ir}}{\Delta_i} + 1, & a_{ir} < x_i \leq a_{i(r+1)} \\ 0, & \text{Outro caso} \end{cases} \quad (5)$$

Caso ocorra algum valor fora dos intervalos máximo e mínimo da configuração de entrada da rede, uma alternativa é usar as funções de pertinência com as bordas trapezoidais conforme Figura 4.




Figura 4. Funções de pertinência triangulares igualmente espaçadas com bordas trapezoidais.

2.2 Função de Pertinência Triangular Tipo II

As funções de pertinência triangulares também podem ser complementares sem necessariamente estarem igualmente espaçadas. Nesse caso, seus valores modais são gerados a partir de seu conjunto de dados, normalmente, verifica-se onde se encontra as maiores concentrações de dados para defini-los como o valor modal das funções, um exemplo, é o uso de algoritmos não supervisionados como demonstra Caminhas et al. (1999).




Figura 5. Funções de pertinência triangulares não igualmente espaçadas.

A Figura 5 ilustra um exemplo com m regras desse tipo de função. Neste caso, a equação para encontrar o valor da função de pertinência para cada entrada x_i é dada por:

$$\mu_{A_{ij}}(x_i) = \begin{cases} \frac{x_i - a_{ir}}{a_{ir} - a_{ir-1}} + 1, & a_{ir-1} \leq x_i \leq a_{ir} \\ \frac{x_i - a_{ir}}{a_{ir} - a_{ir+1}} + 1, & a_{ir} < x_i \leq a_{ir+1} \\ 0, & \text{Outro caso} \end{cases} \quad (6)$$

Assim como na Função Tipo I, também podem ser utilizado as bordas trapezoidais, como apresentado na Figura 6.




Figura 6. Funções de pertinência triangulares não igualmente espaçadas com bordas trapezoidais.

2.3 Aprendizagem da rede Neo-Fuzzy Neuron

O aprendizado da NFN se dá pela atualização dos pesos (q), de forma a encontrar os valores deste parâmetro que melhor representa o conjunto de dados e, conforme a Equação 1, na qual se usa funções de pertinência complementares para cada variável de entrada, somente os dois pesos das funções ativas são atualizados:

$$\begin{aligned} q_{ik_i}^{Atual} &= q_{ik_i}^{Anterior} - \alpha(y - \hat{y})\mu_{A_{ik_i}}(x_i), \\ q_{ik_i+1}^{Atual} &= q_{ik_i+1}^{Anterior} - \alpha(y - \hat{y})\mu_{A_{ik_i+1}}(x_i). \end{aligned} \quad (7)$$

A taxa de aprendizagem é definida por α , seu valor pode ser fixo ou adaptativo:

$$\alpha = \frac{\beta}{\sum_{i=1}^n \mu_{A_{ik_i}}(x_i)^2 + \mu_{A_{ik_i+1}}(x_i)^2}, \quad (8)$$

Caminhas e Gomide (2000) demonstra que, quando $\beta = 1$, proporciona uma taxa de aprendizagem com erro nulo para cada amostra no instante t calculado, $e_t = (y - \hat{y}) = 0$.

Aprendizagem offline: Nesta aprendizagem os dados são apresentados a rede diversas vezes para ajustar os parâmetros do modelo.

Aprendizagem online: Diferente da aprendizagem *offline*, onde os dados de treinamento passam por várias iterações para ajuste do modelo, no aprendizado *online* os dados são apresentados somente uma vez à rede, desta forma o ideal é utilizar o valor da taxa de aprendizagem com $\beta = 1$ (Equação 9), de forma a obter o α ótimo para ajuste dos dados.

$$\alpha = \frac{1}{\sum_{i=1}^n \mu_{A_{ik_i}}(x_i)^2 + \mu_{A_{ik_i+1}}(x_i)^2}. \quad (9)$$

O Algoritmo 1 detalha o processo de estimação da saída e atualização dos parâmetros da NFN.

Algoritmo 1 NFN

- 1: **Entradas:** x_t, y_t, n ;
 - 2: **Saída:** \hat{y}_t ;
 - 3: Inicializar a_{ij} ; // centro das funções de pertinência
 - 4: **for** $t = 1, 2, 3, \dots$ **do**
 - 5: Ler x_t, y_t ;
 - 6: **for** $i = 1 : n$ **do**
 - 7: Calcula $\mu_{A_{ik_i}}(x_{ti}), \mu_{A_{ik_i+1}}(x_{ti})$;
 - 8: Calcula y_{ti} ;
 - 9: **end for**
 - 10: Calcula \hat{y}_t ;
 - 11: Calcula e_t ;
 - 12: Calcula α ;
 - 13: Atualiza q_{ik_i}, q_{ik_i+1} ;
 - 14: **end for**
-

3. PROGNOSTICO DE FALHAS EM SISTEMAS DINÂMICOS

A Figura 7 ilustra um processo de estimação do tempo de vida útil remanescente (*Remaining Useful Life - RUL*), a parte inicial da série até um tempo (t_i) é usada para ajustar o modelo que melhor representa a tendência dos dados e iniciar a previsão de quanto tempo resta para o estado de degradação atingir o limiar de falha (y_{t+p}). A diferença entre o tempo em que a série atinge o limiar de falha (t_f) e o tempo inicial da predição (t_i) é o valor de RUL.

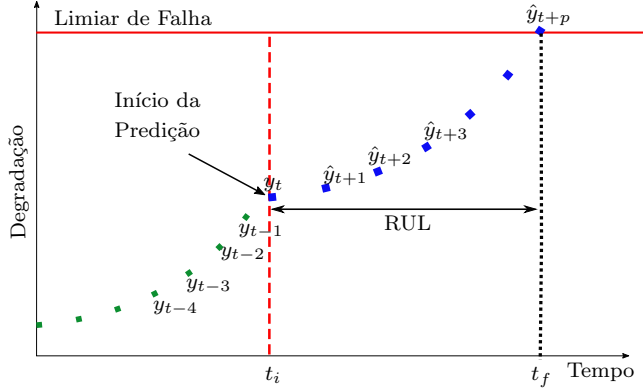


Figura 7. Processo de predição de RUL adaptado de Soualhi et al. (2020).

Uma característica das séries de degradação ou desgaste é ser crescente ou decrescente, a depender dos dados a serem analisados. E uma das formas de estimar a RUL, conforme a Figura 7, é realizar a previsão da série observando os valores passados, de forma a estimar essa evolução da degradação com o uso dos valores previstos, até chegar no limiar de falha. A equação:

$$\hat{y}_t = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-w}), \quad (10)$$

demonstra a predição de um valor futuro \hat{y}_t , utilizando os dados passados como sendo as *features* da rede, a quantidade de *features* utilizadas é determinada pelo tamanho da janela (w). A função f representa a rede que realiza o mapeamento de entrada e saída dos dados.

A Equação 11 detalha o processo de estimação dos valores até atingir o limiar de falha (y_{t+p}).

$$\begin{aligned} \hat{y}_{t+1} &= f(y_t, y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-(w-1)}), \\ \hat{y}_{t+2} &= f(\hat{y}_{t+1}, y_t, y_{t-1}, y_{t-2}, \dots, y_{t-(w-2)}), \\ \hat{y}_{t+3} &= f(\hat{y}_{t+2}, \hat{y}_{t+1}, y_t, y_{t-1}, \dots, y_{t-(w-3)}), \\ &\vdots \\ \hat{y}_{t+p} &= f(\hat{y}_{(t+p)-1}, \hat{y}_{(t+p)-2}, \dots, \hat{y}_{(t+p)-w}). \end{aligned} \quad (11)$$

Outra forma de extrair as características da série é usando a variação dos valores, ou seja, ao invés de usar os dados

brutos da série, é utilizado o valor atual e suas variações em relação aos dados anteriores como sendo as *features* da rede:

$$\hat{y}_t = f(y_{t-1}, y_t - y_{t-2}, y_t - y_{t-3}, \dots, y_t - y_{t-w}). \quad (12)$$

O processo de estimação do valor de RUL é realizado conforme segue:

$$\begin{aligned} \hat{y}_{t+1} &= f(y_t, y_t - y_{t-1}, y_t - y_{t-2}, \dots, y_t - y_{t-(w-1)}), \\ \hat{y}_{t+2} &= f(\hat{y}_{t+1}, \hat{y}_{t+1} - y_t, \hat{y}_{t+1} - y_{t-1}, \dots, \hat{y}_{t+1} - y_{t-(w-2)}), \\ \hat{y}_{t+3} &= f(\hat{y}_{t+2}, \hat{y}_{t+2} - \hat{y}_{t+1}, \hat{y}_{t+2} - y_t, \dots, \hat{y}_{t+2} - y_{t-(w-3)}), \\ &\vdots \\ \hat{y}_{t+p} &= f(\hat{y}_{(t+p)-1}, \hat{y}_{(t+p)-1} - \hat{y}_{(t+p)-2}, \dots, \hat{y}_{(t+p)-1} - \hat{y}_{(t+p)-w}). \end{aligned} \quad (13)$$

4. RESULTADOS NUMÉRICOS

Três conhecidas base de dados da literatura foram utilizadas para realização dos experimentos de previsão de vida útil remanescente (as baterias de íons de lítio, as ferramentas de corte da máquina de comando numérico (CNC) e a base de dados PRONOSTIA).

Para cada *dataset* dois experimentos foram realizados, sendo submetidos da seguinte forma:

- (1) Separação de dados em treino e teste.
- (2) Treinamento *offline* com dados de treino.
- (3) Treinamento *online* com dados de teste até um ponto inicial de predição.
- (4) A partir do ponto inicial de predição, estima a série até o limiar de falha para encontrar a RUL.

4.1 Baterias de íons de lítio

Este *dataset* possui quatro baterias comerciais de íons de lítio tipo 1850 do Centro de Excelência em Prognósticos (PCoE), NASA (Saha and Goebel, 2007). Essas baterias são numeradas em B0005, B0006, B0007 e B0018, respectivamente, e suas classificações de capacidade são todas de 2.0Ah. Os dados obtidos dessas baterias, foram extraídos a partir de um experimento onde elas foram submetidas repetidamente a medidas de carga, descarga e impedância na temperatura de 25°, os valores de capacitância (Ah) por ciclo de descarga que serão utilizados neste artigo estão representados na Figura 8.




Figura 8. Trajetória de degeneração das baterias B0005, B0006, B0007 e B0018.

O limiar de falha para essas baterias normalmente é atingido em 70% de sua capacidade total, sendo assim, para uma capacidade de $2.0Ah$ o limiar de falha é definido em $1.4Ah$.

Na configuração do modelo nos dois experimentos com as baterias de íons de lítio foram utilizadas 2 regras, janela de tamanho 4 e 100 iterações no treinamento *offline*. O modelo treinado é submetido ao treinamento *online* nos primeiros 60 dados de teste e, a partir daí, é realizada a previsão dos dados subsequentes para a estimativa da RUL. A bateria B0006 foi separada para o treinamento *offline* da rede, e os testes de previsão de RUL foram realizados na bateria B0005 com extração de *features* pelo método apresentado na Equação 10, como pode ser visto na Figura 9 e também pelo método da Equação 12, na Figura 10, os resultados de RUL a partir do ponto inicial de previsão 60 e limiar em $1.4Ah$ são apresentados na Tabela 1.

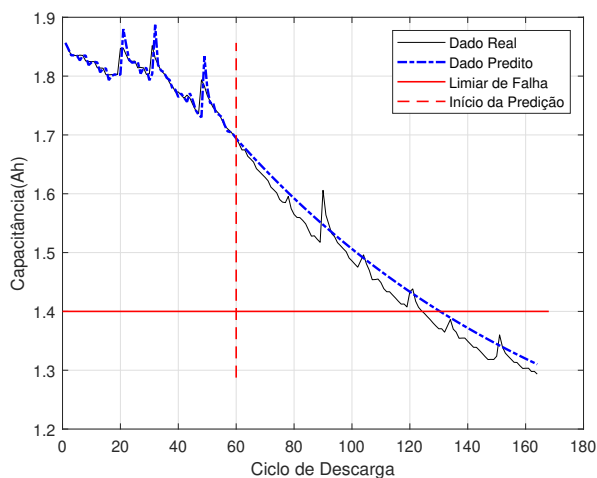


Figura 9. Predição de RUL da bateria B0005 com *features* extraídas pela Equação 10.

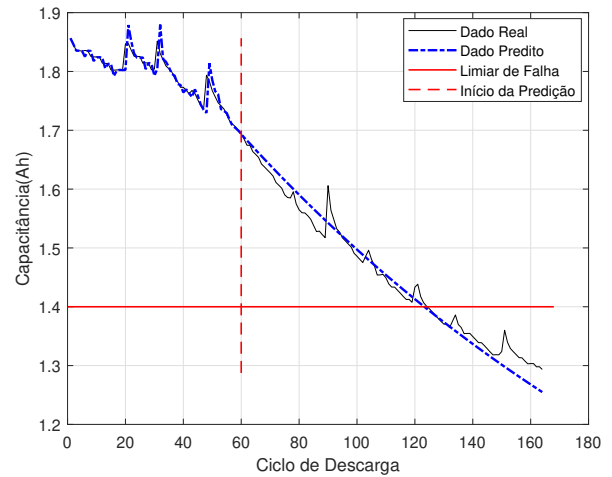


Figura 10. Predição de RUL da bateria B0005 com *features* extraídas pela Equação 12.

Tabela 1. Resultados do prognóstico de falhas na bateria B0005.

Equação	RUL real	RUL predito
10	64	70
12	64	63

4.2 Máquina de Comando Numérico Computadorizado - CNC

Os dados da CNC foram retirados do desafio “*prognostic data challenge 2010*”, disponibilizada pela *Prognostics and Health Management Society* (PHM Society, 2010), extraídos de uma plataforma como na Figura 11.




Figura 11. Máquina CNC de alta velocidade (Li et al., 2009).

O conjunto de dados da CNC é composto por 6 bases de corte, no entanto, somente as bases 1, 4 e 6 foram utilizados neste experimento, de forma que, a base 4 foi separada para treino e as bases 1 e 6 para teste. Na Figura 12 está ilustrado o desgaste das ferramentas de corte da máquina.




Figura 12. Desgaste das ferramentas de corte (*cutter 1*, *cutter 4* e *cutter 6*).

Com o modelo de predição da Equação 12 foi realizado a estimação do desgaste da ferramenta *cutter 1*, utilizando 4 regras, janela de tamanho 8 e 500 iterações no modo *offline* e com o treinamento *online* nos primeiros 150 valores. A Figura 13 ilustra o resultado de predição obtido.

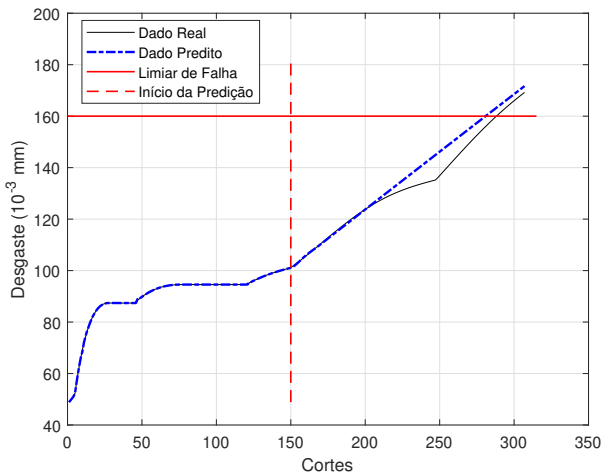


Figura 13. Predição de RUL da ferramenta *cutter 1* com *features* extraídas pela Equação 12.

E o experimento com o *cutter 6* foi realizado com o modelo de predição da Equação 10, a janela de dados foi de tamanho 3 e as outras configurações conforme o experimento anterior. Os resultados obtidos estão representados na Figura 14, e na Tabela 2 os resultados de RUL dos dois experimentos.

Tabela 2. Resultados do prognóstico de falhas para a ferramenta de Corte CNC.

Ferramenta	RUL real	RUL predito
<i>Cutter 1</i>	138	130
<i>Cutter 6</i>	79	84

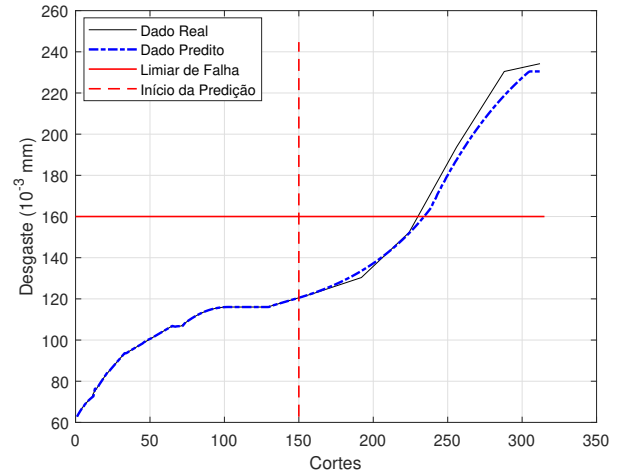


Figura 14. Predição de RUL da ferramenta *cutter 6* com *features* extraídas pela Equação 10.

4.3 PRONOSTIA

Esse conjunto de dados é gerado a partir da plataforma PRONOSTIA (Figura 15) que realiza uma degradação acelerada de rolamentos (*bearings*) (Nectoux et al., 2012). Os dados utilizados foram transformados para um valor conforme (Javed et al., 2015), de forma a obter uma série monotônica, como ilustra a Figura 16.




Figura 15. Plataforma PRONOSTIA (Pan et al., 2020).

Este *dataset* é composto de dados de 17 rolamentos em três diferentes condições de operação, porém, para o experimento foram extraídos somente dados de 3 rolamentos (*Bearing 1-1*, *Bearing 1-3* e *Bearing 1-5*), que foram submetidos as condições operacionais de 1800 rpm e 4000 N. O Rolamento 1 foi utilizado para treino e os rolamentos 3 e 5 para teste.




Figura 16. Trajetória $\sigma(atan)$ cumulativa dos rolamentos 1-1, 1-3 e 1-5.

Os experimentos nesta base de dados foram realizados extraíndo as *features* conforme a Equação 12 e com a NFN configurada com 4 regras, janela de tamanho 5 e 100 iteração na aprendizagem *offline* utilizando o rolamento 1. Os primeiros 500 dados foram utilizados no treinamento *online* e o limiar de falha foi definido como sendo um valor de $\sigma(atan)$ cumulativa de 20. A Figura 17 ilustra a predição do rolamento 3, a Figura 18 do rolamento 5 e na Tabela 3 os resultados de RUL dos dois.

Tabela 3. Resultados do prognóstico de falhas para a plataforma PRONOSTIA.

Rolamento	RUL real	RUL predito
Bearing 1.3	776	752
Bearing 1.5	957	903




Figura 17. Predição de RUL do rolamento 3.

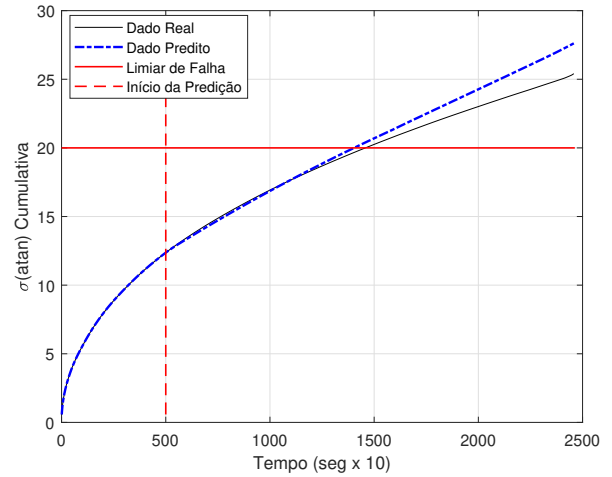


Figura 18. Predição de RUL do rolamento 5.

5. CONCLUSÃO

O trabalho aborda e avalia técnicas de predição do tempo de vida útil remanescente (*Remaining Useful Life* - RUL) com a rede *Neo-Fuzzy Neuron* (NFN), com ajuste do modelo em modo *offline* e iniciando a predição com aprendizado *online*. Os experimentos são realizados em três conhecidas base de dados de problemas de prognóstico, são elas as baterias de íons de lítio, o desgaste de ferramentas de corte da máquina de comando numérico (CNC) e no desgaste de rolamentos extraídos da base de dados PRONOSTIA.

O uso da rede NFN, se mostrou eficiente para os problemas em que foram realizados os teste, tanto ao utilizar os dados históricos brutos ou com a variação delta. Os resultados de RUL, em sua maioria, indicou um prognóstico conservador, ao atingir o limiar de falha antes da sua ocorrência, o que facilita uma manutenção antecipada.

Para trabalhos futuros pretende-se adicionar um intervalo de confiança que demonstre qual seria o valor de RUL pessimista e o valor otimista, pelo fato, da dificuldade de encontrar um valor exato em problemas de previsão.

REFERÊNCIAS

- Biagetti, T. and Sciubba, E. (2004). Automatic diagnostics and prognostics of energy conversion processes via knowledge-based systems. *Energy*, 29(12), 2553 – 2572.
- Caminhas, W. and Gomide, F. (2000). A fast learning algorithm for neofuzzy networks. In *Proc. Information Processing and Management of Uncertainty in Knowledge Based Systems*, 1, 1784–1790.
- Caminhas, W.M., Tavares, H., Gomide, F.A., and Pedrycz, W. (1999). Fuzzy set based neural networks: Structure, learning and application. *JACIII*, 3(3), 151–157.
- Cosme, L.B., Caminhas, W.M., D’Angelo, M.F.S.V., and Palhares, R.M. (2019). A novel fault-prognostic approach based on interacting multiple model filters and fuzzy systems. *IEEE Transactions on Industrial Electronics*, 66(1), 519–528.
- Cosme, L.B., D’Angelo, M.F., Caminhas, W.M., Yin, S., and Palhares, R.M. (2018). A novel fault prognostic

- approach based on particle filters and differential evolution. *Applied Intelligence*, 48(4), 834–853.
- Jardine, A., Lin, D., and Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20, 1483–1510. doi:10.1016/j.ymssp.2005.09.012.
- Javed, K., Gouriveau, R., Zerhouni, N., and Nectoux, P. (2015). Enabling health monitoring approach based on vibration data for accurate prognostics. *IEEE Transactions on Industrial Electronics*, 62(1), 647–656.
- Javed, K., Gouriveau, R., Li, X., and Zerhouni, N. (2018). Tool wear monitoring and prognostics challenges: a comparison of connectionist methods toward an adaptive ensemble model. *Journal of Intelligent Manufacturing*, 29(8), 1873–1890.
- Li, X., Lim, B., Zhou, J., Huang, S., Phua, S., Shaw, K., and Er, M. (2009). Fuzzy neural network modelling for tool wear estimation in dry milling operation. In *Annual conference of the prognostics and health management society*, 1–11.
- Li, X., Zhang, W., and Ding, Q. (2019). Deep learning-based remaining useful life estimation of bearings using multi-scale feature extraction. *Reliability Engineering & System Safety*, 182, 208 – 218.
- Liao, L. and Köttig, F. (2014). Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction. *IEEE Transactions on Reliability*, 63(1), 191–207.
- Luo, J., Namburu, M., Pattipati, K., Qiao, L., Kawamoto, M., and Chigusa, S. (2003). Model-based prognostic techniques [maintenance applications]. In *Proceedings AUTOTESTCON 2003. IEEE Systems Readiness Technology Conference.*, 330–340. Ieee.
- Nectoux, P., Gouriveau, R., Medjaher, K., Ramasso, E., Chebel-Morello, B., Zerhouni, N., and Varnier, C. (2012). PRONOSTIA : An experimental platform for bearings accelerated degradation tests. In *IEEE International Conference on Prognostics and Health Management, PHM'12.*, 1–8. IEEE Catalog Number : CPF12PHM-CDR, Denver, Colorado, United States.
- Pan, Z., Meng, Z., Chen, Z., Gao, W., and Shi, Y. (2020). A two-stage method based on extreme learning machine for predicting the remaining useful life of rolling-element bearings. *Mechanical Systems and Signal Processing*, 144, 106899.
- PHM Society (2010). PHM data challenge 2010. <https://www.phmsociety.org/competition/phm/10>. Accessed: 2020-04-30.
- Qu, J., Liu, F., Ma, Y., and Fan, J. (2019). A neural-network-based method for rul prediction and soh monitoring of lithium-ion battery. *IEEE Access*, 7, 87178–87191.
- Razavi-Far, R., Farajzadeh-Zanjani, M., Chakrabarti, S., and Saif, M. (2016). Data-driven prognostic techniques for estimation of the remaining useful life of lithium-ion batteries. In *2016 IEEE International Conference on Prognostics and Health Management (ICPHM)*, 1–8.
- Saha, B. and Goebel, K. (2007). Battery data set. *NASA Ames Prognostics Data Repository*. URL <https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository>.
- Silva, A.M., Caminhas, W., Lemos, A., and Gomide, F. (2014). A fast learning algorithm for evolving neo-fuzzy neuron. *Applied Soft Computing*, 14, 194–209.
- Soualhi, A., Medjaher, K., Celrc, G., and Razik, H. (2020). Prediction of bearing failures by the analysis of the time series. *Mechanical Systems and Signal Processing*, 139, 106607.
- Yamakawa, T., Uchino, E., Miki, T., and Kusanagi, H. (1992). A neo fuzzy neuron and its applications to system identification and predictions to system behavior. *Proceedings of the International Conference on Fuzzy Logic and Neural Networks*, 1, 477–483.