

# Uma abordagem evolutiva com filtro de partículas e sistemas nebulosos para o monitoramento da condição de equipamentos

Iarah G. de Almeida<sup>1</sup>, Gabriel R. da Silva<sup>1</sup>, Cauã R. C. e Aguiar<sup>1</sup>,  
Gabriel S. V. de Carvalho<sup>2</sup>, Luciana B. Cosme<sup>1</sup>

<sup>1</sup>Instituto Federal do Norte de Minas Gerais Campus Montes Claros (IFNMG)  
Montes Claros – MG – Brasil

<sup>2</sup>Programa de Pós-Graduação em Modelagem Computacional e Sistemas - UNIMONTES  
Montes Claros - MG - Brasil

iarahgda@gmail.com, {grs17, crdcea}@aluno.ifnmg.edu.br  
gsvc@outlook.com.br, luciana.balieiro@ifnmg.edu.br

**Abstract.** *This paper proposes an adaptive approach to representing degradation models in equipment, combining particle filter and fuzzy systems. Experiments with the NASA Ames Prognostics Center of Excellence (PCoE) database, which provides historical data on lithium-ion batteries, showed that the adaptive method improves real-time estimation of equipment condition compared to traditional approaches.*

**Resumo.** *Este artigo propõe uma abordagem adaptativa para representar modelos de degradação em equipamentos, combinando filtro de partículas e sistemas nebulosos. Experimentos com a base de dados da NASA Ames Prognostics Center of Excellence (PCoE), que disponibiliza dados históricos de baterias de íons de lítio, mostrou que o método adaptativo apresenta melhorias na estimativa em tempo real da condição dos equipamentos em comparação com abordagens tradicionais.*

## 1. Introdução

Diante dos dados de monitoramento em tempo real dos ativos físicos industriais, é possível criar indicativos de falhas e da saúde geral desses sistemas [Jouin et al. 2016]. Uma das maneiras de utilizar esses dados de monitoramento é através da estimação da condição do funcionamento do componente, cujo objetivo é identificar o estado atual do componente. Neste sentido, duas abordagens para o monitoramento são comumente utilizadas: a primeira é baseada na física do processo e exige um conhecimento matemático do sistema; já a segunda é baseada em dados e utiliza dados históricos do sistema coletados através de sensores. Dentre as técnicas utilizadas por abordagens baseadas na física do processo e também baseadas em dados, o filtro de partículas tem recebido destaque na literatura, conforme pontuado por [Jouin et al. 2016]. Esses autores também apresentam os filtros de partículas como uma técnica no estado da arte no campo do monitoramento de equipamentos, por serem capazes de modelar dados multivariados e processos dinâmicos, além de lidarem com ruídos não Gaussianos [Sikorska et al. 2011].

Uma outra técnica que pode ser empregada na rotina de monitoramento é o sistema de inferência nebulosa, que possui como vantagem a capacidade de lidar com entradas imprecisas, ruidosas e incompletas. Apesar de que a lógica nebulosa pode ser usada como método primário de monitoramento, é comum que seja utilizada para melhorar outras técnicas como, por exemplo, o filtro de partículas [Sikorska et al. 2011].

Alguns trabalhos da literatura para monitoramento e previsão de falhas [Cosme et al. 2018, Jouin et al. 2016] não apresentam capacidades de lidar com falhas com comportamentos inconstantes no decorrer do tempo e os algoritmos com poder de aprendizado e adaptação, que utilizam novas medições para alterar seus parâmetros, podem permitir a aquisição de melhores resultados. Assim, torna-se interessante unir um filtro de partículas, um método amplamente utilizado na literatura para o monitoramento de sistemas dinâmicos, com um sistema nebuloso que traga algum grau de adaptabilidade, de modo a permitir a adequação do sistema às mudanças do mundo externo.

Nesse contexto de adaptabilidade, é possível citar o sistema nebuloso eTS-LS-SVM desenvolvido por [Komijani et al. 2012], que utiliza técnicas de clusterização. Embora seja eficaz na evolução da estrutura do sistema nebuloso e na atualização dos parâmetros dos consequentes para minimizar o erro local, o método de clusterização empregado é sensível a outliers e requer uma janela deslizante maior para otimização, o que pode comprometer sua aplicação em online devido ao aumento do tempo de processamento. Portanto, neste trabalho, é utilizado o eTS-LS-SVM com uma janela deslizante menor para contornar esse problema.

Para a realização dos experimentos e análise das contribuições dessa proposta, foi utilizada uma base de dados de baterias de íons de lítio, disponibilizada pela NASA PCoE. Este trabalho realizou a estimação do estado dessas baterias a partir de uma abordagem baseada em dados, utilizando um filtro de partículas convencional em conjunto com um sistema de inferência nebulosa.

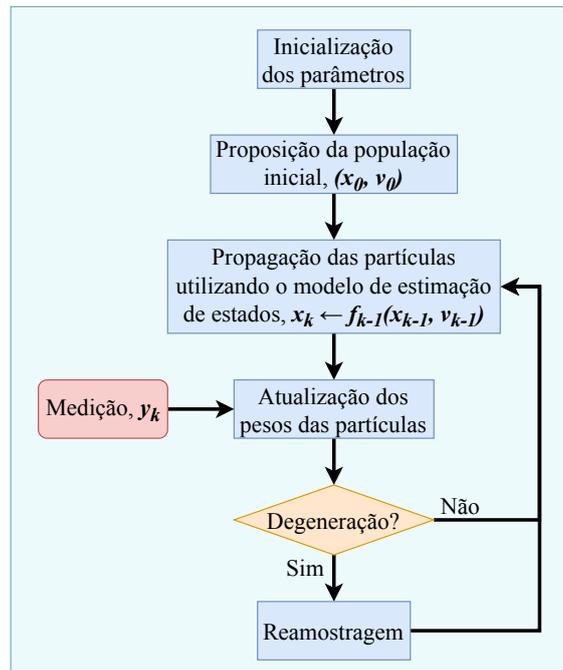
## **2. Abordagem Proposta**

### **2.1. Filtro de partículas e sistemas nebulosos**

O filtro de partículas é uma opção para estimar a distribuição posterior em modelos Bayesianos. Também são conhecidos como métodos de simulação de Monte Carlo e sua utilidade reside nos casos onde a distribuição posterior é multivariada e não padronizada [Sikorska et al. 2011].

Um fluxograma geral de um filtro de partículas é dado pela Figura 1. Inicialmente, a inicialização dos parâmetros do filtro de partículas deve ser realizado, seguido da definição da população inicial, que inclui o primeiro estado ( $x_0$ ) e o respectivo ruído ( $v_0$ ). Após as definições iniciais, temos o início da fase recursiva, em que é feita a propagação das partículas utilizando o modelo de estimação de estados seguido da atualização dos pesos das partículas utilizando os dados adquiridos pelo modelo de medição. Se houver degeneração, as partículas passam por um processo de reamostragem e, caso contrário, o fluxo retorna ao passo de propagação de partículas.

Um modelo matemático do sistema é fundamental para um filtro de partículas convencional. Contudo, quando esses modelos matemáticos não estão disponíveis, surge a necessidade de utilizar métodos alternativos para representar a dinâmica do sistema.



**Figura 1. Fluxograma de um filtro de partículas. Adaptado de [Saha and Goebel 2011].**

Nesse sentido, um conjunto nebuloso, introduzido por [Zadeh 1965], é um modelo matemático que lida com a incerteza e a imprecisão de dados, permitindo a representação de conceitos vagos em termos de conjuntos. Ao contrário dos sistemas convencionais que operam com lógica booleana, em que as variáveis são claramente definidas, um conjunto nebuloso permite que as variáveis tenham valores intermediários entre verdadeiro e falso, refletindo assim a natureza imprecisa e subjetiva de muitos problemas do mundo real.

Neste sentido, seja  $X$  uma coleção de objetos, em que cada objeto é denotado por  $x$ , portanto um conjunto nebuloso  $A$  em  $X$  é dado por:

$$A = \{(x, \mu_A(x)) | x \in X\}, \quad (1)$$

no qual  $\mu_A(x)$  é chamada de função de pertinência para o conjunto  $A$ .

Os conjuntos nebulosos, como apresentado na Eq. 1, que permitem a atribuição de graus de pertinência, formam a base para os sistemas nebulosos, que são capazes de tomar decisões em ambientes imprecisos. Um sistema nebuloso é constituído, conforme [Sikorska et al. 2011], por uma base de conhecimento, uma base de regras nebulosas e algoritmos para aplicar a lógica do processo. Entretanto, os sistemas nebulosos mais convencionais possuem baixa capacidade de aprendizado e adaptação. Contudo, no caso em que o sistema nebuloso é integrado a uma rede neural, o primeiro oferece um mecanismo de inferência capaz de descrever graus de incertezas, enquanto a segunda contribui com poder de adaptação, generalização, aproximação e tolerância à falha. Um exemplo de integração de um sistema nebuloso com uma rede neural é o ANFIS, da condição de equipamentos. Segundo [Jouin et al. 2016], o ANFIS pode ser empregado em conjunto com um filtro de partículas na etapa de reconstrução de estado, em que os parâmetros são previamente estimados com base nos dados disponíveis até o momento, para prever

o estado atual do sistema. Esta abordagem permite potencializar os resultados obtidos, como em [Chen et al. 2012] e [Cosme et al. 2018]. Outra maneira de potencializar resultados é adicionando adaptatividade ao sistema nebuloso.

## 2.2. Adaptatividade

O monitoramento adaptativo consiste em utilizar a informação disponível no instante de tempo atual para atualizar o modelo de degradação. Dessa maneira, existem tanto sistemas evolutivos, que alteram tanto sua estrutura quanto seus parâmetros internos com o passar do tempo, bem como sistemas adaptativos, que apenas modificam seus parâmetros internos de acordo com o estado do sistema em questão. Ainda, se os parâmetros são atualizados a cada passo em que um novo dado fica disponível, temos o aprendizado online, definido por [Jang et al. 1997], em que os efeitos dos dados mais antigos devem decair na medida em que novos dados se tornam disponíveis. Essa abordagem de aprendizado é vital para sistemas cujas características se alteram no decorrer do tempo.

## 2.3. Solução proposta - Evolutivo

A solução proposta para o modelo evolutivo, utiliza o sistema nebuloso eTS-LS-SVM desenvolvido por [Komijani et al. 2012], em que a ideia é dividir os dados de entrada em regiões nebulosas e aproximar o sistema através de uma função de aproximação. O fluxograma geral do processo evolutivo do algoritmo pode ser visto na Figura 2.

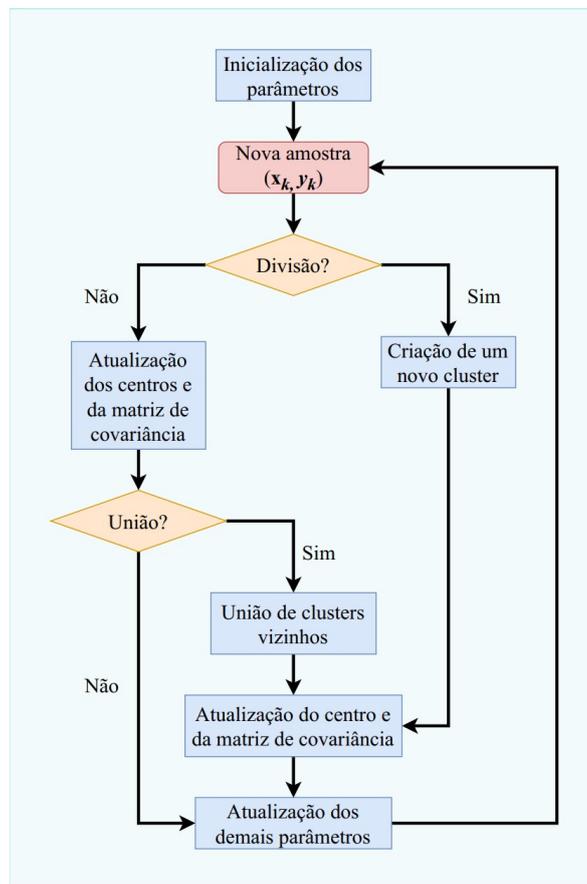
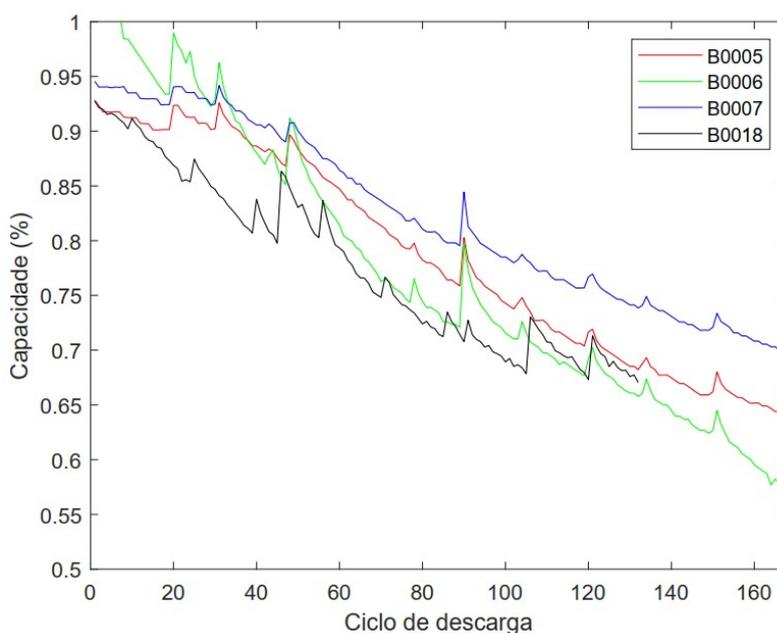


Figura 2. Fluxograma do eTS-LS-SVM. Adaptado de [Komijani et al. 2012]

Para o filtro de partículas do trabalho proposto, calculamos a maior diferença entre  $x_k$  e  $x_{k-1}$ , sendo  $k$  a variável de tempo e  $x_k$  e  $x_{k-1}$  o estado da partícula no instante atual  $k$  e anterior  $k - 1$  respectivamente, dos dados de treinamento e atribuímos à constante  $maxDiff$ , com  $k = 0 \dots t$ , em que  $t$  é o número máximo de instantes. Caso o  $x_k$  predito seja maior que  $x_{k-1} + maxDiff$ , então  $x_k = x_{k-1}$ .

### 3. Metodologia

A NASA PCoE disponibilizou um conjunto de dados de baterias de íons de lítio, utilizadas em diversas condições operacionais através de ciclos de carga e descarga até que atingissem o critério de fim de vida útil. Os ciclos de carga são realizados com um valor constante de 1.5A, até que a voltagem da bateria atinja o valor de 4.2V. Já os ciclos de descarga são feitos com valores constantes de 2A, até que a voltagem da bateria atinja o valor de 2.7V. Neste trabalho, utilizamos a capacidade restante da bateria após os ciclos de descarga de 4 experimentos: B0005; B0006; B0007 e B0018. Foi utilizado na base de dados apenas o valor da capacidade das baterias de íon-lítio no instante anterior, transformadas para porcentagem. Uma visualização da capacidade das baterias pode ser visto em Figura 3.

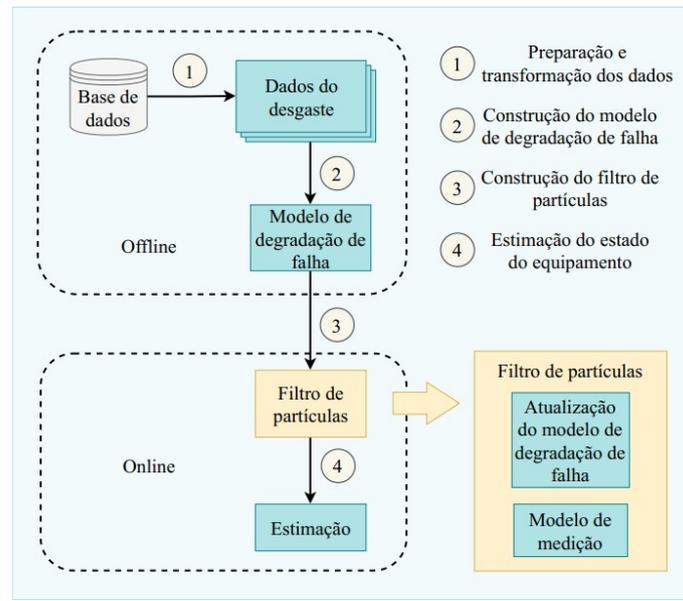


**Figura 3. Capacidade em porcentagem das baterias após cada ciclo de descarga. Adaptado de [Camargos et al. 2021].**

Um filtro de partículas empregado com sistemas de inferência neuro-fuzzy adaptativo foi desenvolvido para estimar o estado do equipamento referente às bases de dados supramencionadas. Para tanto, o desenvolvimento das atividades foi realizado com a linguagem de programação MATLAB.

A metodologia pode ser ilustrada pela Figura 4, em que, primeiramente, os dados históricos coletados são transformados e, na segunda fase, utilizados para a construção do sistema nebuloso de forma offline. A terceira fase consiste em construir um filtro de

partículas que empregue o sistema nebuloso para a estimação de estados, e um instrumento adaptativo online será construído na etapa de atualização. A partir da abordagem desenvolvida, a quarta fase se trata de realizar a estimação do estado da bateria. A métrica de erro absoluto da estimação foi utilizada para a comparação dos resultados com um sistema de inferência neuro-fuzzy adaptativo e o teste de hipótese ANOVA foi conduzido sob esses resultados.



**Figura 4. Ilustração da metodologia proposta.**

Um sistema de inferência neuro-fuzzy foi desenvolvido, em que os conjuntos e regras nebulosas foram definidos de acordo com a análise dos dados históricos e os parâmetros de pertinência ajustados no treinamento de forma offline. Um filtro de partículas convencional foi implementado, em que o sistema de inferência neuro-fuzzy foi empregado como modelo de degradação de falha para estimar os estados do sistema [Cosme et al. 2018] e a etapa de atualização ajusta os parâmetros de pertinência e estrutura do modelo de forma online. Para a etapa de comparação de resultados obtidos pelo método desenvolvido neste trabalho, um filtro de partículas tradicional [Cosme et al. 2018] foram utilizados. Ainda, a métrica de erro absoluto da estimação foi empregada como meio de comparação nesta etapa, dado por:

$$\sum_{i=1}^N |y_{real}^i - y_{predito}^i| \quad (2)$$

em que  $N$  é a quantidade de amostras disponíveis na base de dados,  $y_{real}^i$  é o valor real do desgaste do componente no instante  $i$  e  $y_{predito}^i$  é o valor estimado da condição da saúde do equipamento dado pelo modelo proposto no instante  $i$ .

#### 4. Resultados

Para testar o método implementado, 12 experimentos foram propostos. Cada experimento conta com um conjunto de treinamento, utilizado para construção do modelo de forma

offline, e um conjunto de validação, utilizado pela aprendizagem online e para o cálculo da métrica de erro absoluto da estimação. O filtro de partículas foi configurado com  $x_0 = 1$ ,  $\sigma_X = 2 \times 10^3$ ,  $\sigma_V = 1 \times 10^2$ ,  $N = 50$  e  $\gamma = 0.9$ . Por sua vez, o sistema nebuloso foi configurado com 5 épocas. Já o modelo evolutivo foi definido usando os parâmetros  $\rho = 0.003$ ,  $\tau = 0.002$ ,  $\sigma_0 = 0.001$ ,  $\sigma_1^1 = 0.09$ ,  $\gamma = 1000$  e  $N = 4$ .

Os comparativos entre os resultados obtidos pelos 12 experimentos podem ser visualizados a partir da Tabela 1, que mostra a média de 30 execuções dos valores do erro absoluto de estimação obtidos por cada algoritmo para dado experimento. Os valores da primeira coluna mostram os respectivos conjuntos de treinamento e validação utilizados em cada experimento, a segunda coluna é referente ao método sem adaptação online e os da terceira coluna em relação ao algoritmo evolutivo. Para cada linha, os melhores resultados foram marcados em negrito, e os piores com a cor vermelha.

**Tabela 1. Médias de 30 execuções dos métodos avaliados, com relação aos erros absolutos de estimação para os experimentos.**

Experimento \ Algoritmos	Sem adaptação	Evolutivo
1 (B0005 - B0018)	0.0183	0.0183
2 (B0006 - B0018)	0.0140	0.0140
3 (B0007 - B0018)	0.0277	<b>0.0200</b>
4 (B0005 - B0007)	0.0078	<b>0.0069</b>
5 (B0006 - B0007)	0.0087	<b>0.0059</b>
6 (B0018 - B0017)	0.0119	<b>0.0060</b>
7 (B0005 - B0006)	0.0164	<b>0.0110</b>
8 (B0007 - B0006)	0.0235	<b>0.0121</b>
9 (B0018 - B0006)	0.0261	<b>0.0158</b>
10 (B0006 - B0005)	0.0096	<b>0.0077</b>
11 (B0007 - B0005)	0.0149	<b>0.0108</b>
12 (B0018 - B0005)	0.0126	<b>0.0076</b>
<b>Média da média</b>	0.0145	<b>0.0109</b>

Ao observar os valores encontrados, o algoritmo evolutivo, de forma consistente, apresenta erros absolutos de estimação mais baixos que o algoritmo sem adaptatividade online. Em especial, o método proposto não teve desempenho superior nos experimentos 1 e 2 com a validação dos dados da bateria B0018. Nesse caso, o erro de estimação foi maior que nos demais experimentos também. Ao observar melhor a Figura 3, é possível ver que a bateria B0018 tem comportamento bem diferente das demais, portanto, somente os dados utilizados no processo evolutivo não foi suficiente para adaptar à tamanha diferença. Entretanto, para os demais experimentos, os resultados do método proposto se mostraram melhores, com erro de estimação menor, se apresentando como uma alternativa para melhoria da estimação.

## 5. Considerações Finais

O objetivo deste trabalho foi desenvolver um sistema inteligente evolutivo para monitoramento da condição do equipamento, de forma que os dados de medição disponíveis até o instante atual sejam incorporados no modelo extraído na etapa de treinamento, na tentativa

de melhorar o processo de estimação do estado do componente. As contribuições deste trabalho visaram comparar os métodos de estimação da degradação do equipamento realizados de forma offline e online. Foi proposta uma abordagem evolutiva para a estimação online que foram comparadas com a abordagem offline sem adaptatividade. Com base nos experimentos realizados, a métrica de erro absoluto da estimação mostra a potencialidade do método proposto, em que se utiliza da adaptatividade de forma online. A predição da *Remaining Useful Life* (RUL), próximo passo após a estimação, poderá ser investigada em trabalhos futuros, bem como outras abordagens evolutivas.

## 6. Agradecimentos

Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), além do suporte do Instituto Federal do Norte de Minas Gerais (IFNMG) Campus Montes Claros e da Fundação de Apoio e Desenvolvimento do Ensino Tecnológico (FADETEC).

## Referências

- Camargos, M., Bessa, I., Junior, L. A. Q. C., Coutinho, P., Leite, D. F., and Palhares, R. M. (2021). Evolving fuzzy system applied to battery charge capacity prediction for fault prognostics. In *Joint Proceedings of the 19th World Congress of the International Fuzzy Systems Association (IFSA), the 12th Conference of the European Society for Fuzzy Logic and Technology (EUSFLAT), and the 11th International Summer School on Aggregation Operators (AGOP)*.
- Chen, C., Vachtsevanos, G., and Orchard, M. E. (2012). Machine remaining useful life prediction: An integrated adaptive neuro-fuzzy and high-order particle filtering approach. *Mechanical Systems and Signal Processing*, 28:597–607.
- Cosme, L., D'Angelo, M., Caminhas, W., Yin, S., and Palhares, R. (2018). A novel fault prognostic approach based on particle filters and differential evolution. *Applied Intelligence*, 48:834–853.
- Jang, J. S., Sun, C. T., and Mizutani, E. (1997). *Neuro-fuzzy And Soft Computing: A Computational Approach To Learning And Machine Intelligence*. Prentice-Hall, 1th edition.
- Jouin, M., Gouriveau, R., Hissel, D., Péra, M.-C., and Zerhouni, N. (2016). Particle filter-based prognostics: Review, discussion and perspectives. *Mechanical Systems and Signal Processing*, 72-73:2–31.
- Komijani, M., Lucas, C., Araabi, B., and Kalhor, A. (2012). Introducing evolving takagi-sugeno method based on local least squares support vector machine models. *Evolving Systems*, (3):81–93.
- Saha, B. and Goebel, K. (2011). Model adaptation for prognostics in a particle filtering framework. *International Journal of Prognostics and Health Management*, page 61.
- Sikorska, J., Hodkiewicz, M., and Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25(5):1803–1836.
- Zadeh, L. (1965). Fuzzy sets. *Information and Control*, 8(3):338–353.