

# Uma Proposta de Estrutura Variável para o Método IMMF Aplicada ao Problema de Estimação da Condição de Funcionamento de Baterias

Anne Caroline P. dos Santos<sup>1</sup>, Cauã R. da Costa e Aguiar<sup>1</sup>,  
Gabriel R. da Silva<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 (IFNMG) Campus Montes Claros

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

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

**Abstract.** *Industrial systems and their components can be characterized by different modes of operation and failures, mainly because various parts can suffer from different types of deterioration. Therefore, knowing the best time to start maintenance activities can prolong the equipment's useful life. To assist in the execution of maintenance activities for these equipment, this work proposes an approach to estimate the operating condition, using a variable structure for particle filters with multiple models, applied to estimate the state of a lithium-ion battery. Two approaches are proposed (IMMA and IMMAND), differing in the logic of selecting the most probable active models. To evaluate and validate the results obtained by the approaches, the metrics RMSE and MAPE are used, which showed good estimates of the proposed algorithms for the analyzed database and in the presence of many models without suffering significant interference from the choice of thresholds.*

**Resumo.** *Os sistemas industriais e seus componentes podem ser caracterizados por diferentes modos de funcionamento e falhas, principalmente porque várias partes podem sofrer com diferentes tipos de deteriorações. Por isso, saber o melhor momento para o início das atividades de manutenção pode prolongar a vida útil dos equipamentos. Para auxiliar a execução de manutenção desses equipamentos, o presente trabalho propõe uma abordagem de estimação da condição de funcionamento, utilizando uma estrutura variável para os filtros de partículas com múltiplos modelos, aplicado à estimação do estado de uma bateria de íon-lítio. Duas abordagens são propostas (IMMA e IMMAND), diferindo na lógica de seleção dos modelos ativos mais prováveis. Para avaliar e validar os resultados obtidos pelas abordagens, são utilizadas as métricas RMSE e MAPE, que mostraram boas estimativas dos algoritmos propostos, para a base de dados analisadas e na presença de muitos modelos sem sofrerem grandes interferências da escolha dos limiares.*

## 1. Introdução

A competição acirrada entre empresas e indústrias impulsiona a busca por produtos superiores, pela eficiência na produção e pela implementação de melhorias contínuas. Nesse cenário dinâmico, a manutenção desempenha um papel crucial, conforme destacado por [Xu and Saleh 2021, Kardec 2009], que ressalta a importância não apenas de reparar equipamentos, mas de estabelecer um processo de manutenção eficaz. A estimação da condição de funcionamento de equipamentos emerge como uma atividade essencial para otimizar custos e determinar o momento ideal para a manutenção, conforme sugerido por [Lan et al. 2011]. Vale ressaltar também, que diante da complexidade inerente aos sistemas industriais, com diferentes modos de funcionamento e possíveis falhas, as abordagens flexíveis na modelagem tornam-se imperativas, como salientado por [Cosme et al. 2019].

Nesse contexto, muitos trabalhos da literatura tem dedicado esforço para propor métodos e modelos capazes de contribuir para a manutenção eficiente dos ativos industriais [Jouin et al. 2016]. Como por exemplo, os filtros de partículas baseados em múltiplos modelos [Cosme et al. 2019], que emprega conjuntos nebulosos no método *Interactive Multiple Model Filter* (IMMF) para estimação e a predição da vida remanescente útil remanescente (RUL) dos equipamentos. Entretanto, abordagens do tipo IMMF não utilizam estrutura variável, o que poderia melhorar os resultados do método, visto a redução da carga computacional e da competição desnecessária entre os modelos. Outros trabalhos, tal como [Sun et al. 2020a], aplicam a uma estrutura variável aplicados ao diagnóstico de múltiplas falhas, no entanto, os autores utilizam Filtros de Kalman Estendidos (EKF), que além de fazer suposições de normalidade dos ruídos, também necessitam de modelos matemáticos. Já [Barbosa and Gomes 2008] propõe em seu trabalho uma estrutura variável (LMS), adaptando dinamicamente o conjunto de modelos, resultando em economia de complexidade computacional e melhoria nas estimativas. Este trabalho busca unir essas duas abordagens [Cosme et al. 2019, Barbosa and Gomes 2008] e propor uma estrutura variável de múltiplos modelos, fazendo uso de filtros de partículas, com o objetivo de aprimorar a estimação da condição de funcionamento de sistemas dinâmicos, sem o uso de modelos matemáticos. Essa abordagem de múltiplos modelos possibilita a execução em paralelo dos filtros, proporcionando uma representação mais precisa da situação em diferentes momentos, destacando-se especialmente na estimação da condição de funcionamento de baterias, como mostrado pelos resultados dos experimentos.

## 2. Abordagem proposta

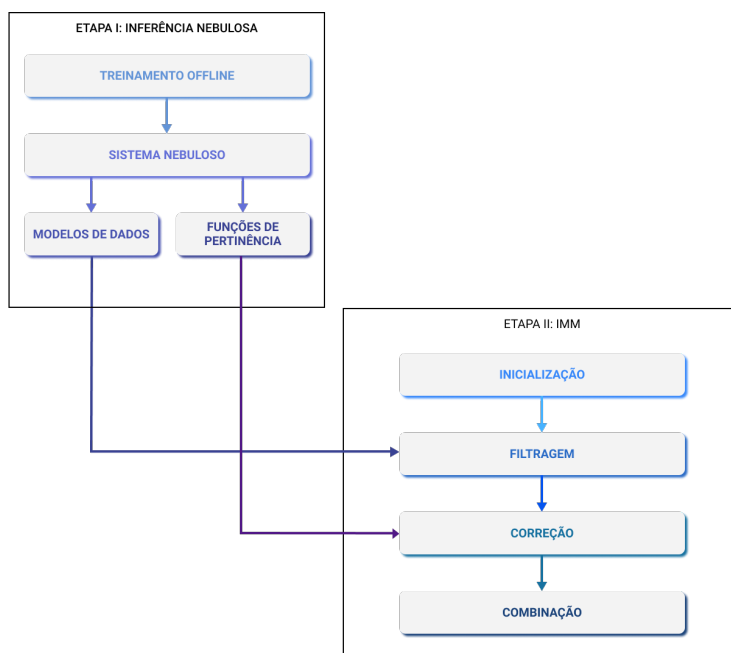
Nesta seção, são apresentados alguns detalhes sobre o método proposto, além de uma introdução ao referencial teórico, contribuindo para compreensão do tópico.

### 2.1. IMMF

O *Interactive Multiple Model* (IMM) possui algumas desvantagens para o prognóstico de falhas, como por exemplo, a complexidade e a difícil obtenção dos modelos matemáticos, o que pode dificultar na atualização da probabilidade dos modelos, especialmente quando esses modelos são difíceis de obter. Para contornar esse desafio, [Cosme et al. 2019] propõem um IMM, que utiliza os conjuntos nebulosos (IMMF), para a estimativa de estados, eliminando a necessidade de medições para calcular a probabilidade de cada modelo. O IMMF propõe treinamento offline do sistema nebuloso, fornecendo uma abordagem alternativa quando os modelos matemáticos não estão disponíveis.

O IMMF opera em duas etapas distintas. Na Etapa I, um sistema nebuloso é treinado offline para extrair modelos de dados e funções de pertinência. Esses modelos e funções são então utilizados na Etapa II, onde ocorre a interação e mistura dos modelos, permitindo a execução do algoritmo online.

Conforme mostrado na Figura 1, no passo de filtragem, é realizada a estimativa do estado (predição e atualização) para cada filtro de forma paralela. No entanto, nessa etapa o IMMF utiliza os modelos extraídos de um sistema nebuloso, previamente treinado.



**Figura 1. Diagrama de duas etapas: Etapa I - Inferência Nebulosa, onde o treinamento offline gera modelos de dados e funções de pertinência; Etapa II - IMM, com inicialização, filtragem e correção baseadas nos modelos e funções. Fonte: Adaptado de [Cosme et al. 2019]**

## 2.2. Estrutura Variável

Os algoritmos de Modelos Múltiplos de Estrutura Fixa (FSMM), que empregam um modelo fixo ao longo do tempo, revelam desvantagens em situações de estimação com conjuntos de modelos é muito grande. Para superar essas limitações e aprimorar os métodos de estimativa, a abordagem de Modelos Múltiplos com Estrutura Variável (VSMM) utiliza um conjunto variável de modelos. Os algoritmos VSMM oferecem benefícios significativos em termos de carga computacional e redução da competição desnecessária entre modelos, em comparação com os FSMM [Li and Bar-Shalom 1996, Sun et al. 2020b]. Além disso, a estrutura variável destaca-se pela adaptabilidade, sendo aplicáveis a problemas com espaços modais extensos ou pouco conhecidos.

## 2.3. IMMA

A primeira contribuição deste trabalho é o algoritmo IMMA que pertence ao conjunto de algoritmos de estrutura variável. O IMMA opera em dois passos principais: classificação dos modelos e cálculo da nova pertinência dos modelos ativos. A classificação baseia-se

no método proposto por [Barbosa and Gomes 2008], descartando modelos improváveis. O conjunto resultante, denominado  $mk$ , consiste nos modelos considerados significativos e prováveis, enquanto os demais são descartados. Em seguida, ocorre o ajuste da função de pertinência dos modelos ativos para manter a pertinência total do conjunto igual a 1.

## 2.4. IMMAND

A segunda contribuição deste trabalho é o algoritmo denominado IMMAND. A abordagem utiliza o IMMA, combinada com a lógica AND de descarte. A lógica AND exclui um modelo se sua probabilidade estiver abaixo de limiar  $t_1$  (igualmente no IMMA) e se o modelo não estiver entre os  $K$  maiores modelos. Ambos os parâmetros,  $t_1$  e  $k$  são definidos pelo usuário. Na sequência é realizado o cálculo das novas estimativas como é representado no IMMA.

## 3. Resultado e Discussões

A NASA Ames Prognostics Center of Excellence (PCoE) fornece uma coleção de conjunto de dados em seu repositório, dados esses doados por universidades, agências ou empresas e cujo processo de coleta é contínuo. Este repositório concentra suas bases de dados sobretudo no ramo do prognóstico de falhas e esses dados possuem registros de um estado nominal até o estado de falha do equipamento. Para este estudo, será utilizada a base de teste de baterias de íons de lítio. Essa base de testes compreende baterias recarregáveis de íons de lítio de tamanho 18650 do tipo comercial do Laboratório Nacional de Idaho. Como treinamento, será utilizado a base de dados B0006 e para os testes as bases, B0007 e B0018.

A base de estrutura variável proposta é a utilização de um subconjunto de modelos, obtido do conjunto de modelos totais para a estimação de estados, denominada de conjunto ativo. Esse conjunto ativo é definido por dois limiares  $t_1$  e  $t_2$ . Através desses limiares será analisada a função de pertinência (MF) de cada modelo que será classificado como:

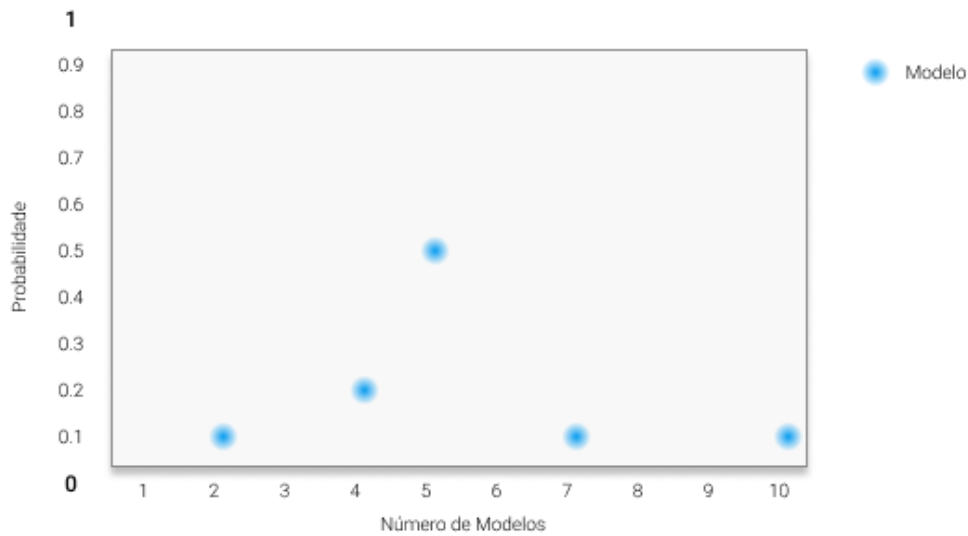
- **Improvável:** caso a MF seja menor que  $t_1$ .
- **Provável:** caso a MF seja maior que  $t_2$ .
- **Significativo:** caso MF seja menor que  $t_2$  e maior que  $t_1$ .

Este processo é mostrado na Figura 2, na qual apresenta um gráfico de dispersão que mostra a probabilidade de diferentes modelos, em função do número de modelos. Cada ponto azul no gráfico corresponde a um modelo específico e sua respectiva probabilidade., e na Figura 3, em que há duas linhas horizontais pontilhadas: uma rosa para  $t_1$  (limite inferior) e outra roxa para  $t_2$  (limite superior). Além disso, quatro pontos azuis claros estão dispersos no gráfico, representando dados específicos ou observações.

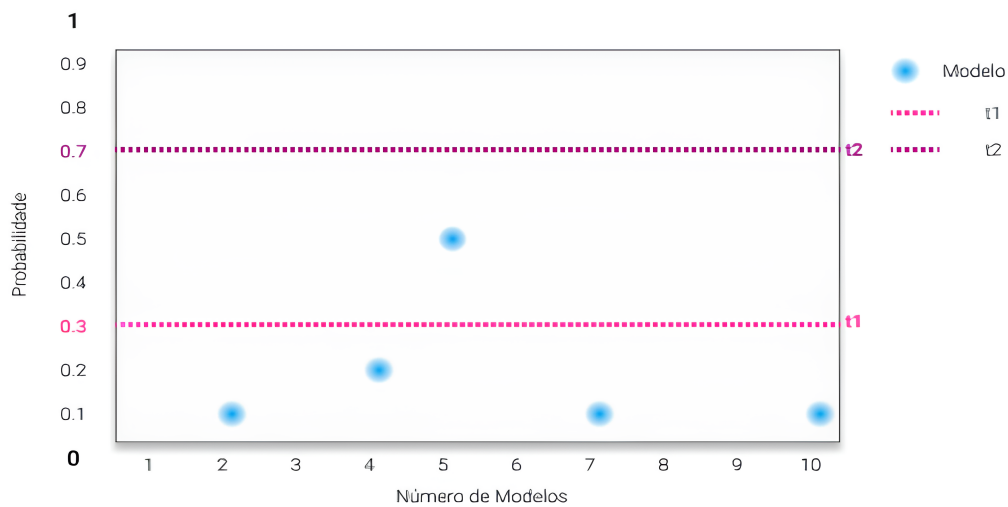
Para o parâmetro de seleção e classificação do conjunto ativos dos modelos, foi definido 3 duplas de limiares para os testes:

1. Experimento 1: limiares escolhidos  $t_1 = 0.4$  e  $t_2 = 0.6$ ;
2. Experimento 2: limiares escolhidos  $t_1 = 0.1$  e  $t_2 = 0.7$ ;
3. Experimento 3: limiares escolhidos  $t_1 = 0.3$  e  $t_2 = 0.5$ .

O último parâmetro adaptativo dos algoritmos,  $k$ , foi definido como o valor 3. Já com relação a função de pertinência, por simplicidade, escolheu-se as funções do tipo



**Figura 2. Gráfico de dispersão, probabilidade de diferentes modelos. Cada ponto azul no gráfico corresponde a um modelo específico e sua respectiva probabilidade.**



**Figura 3. Gráfico de probabilidade de diferentes modelos. As linhas pontilhadas representam os limites de probabilidade para os modelos T1 (rosa) e T2 (roxo). Os pontos azuis representam dados específicos.**

'gauss2mf' do MATLAB. Esses experimentos foram realizados com conjuntos de modelos de diferentes tamanhos, sendo eles 5, 10, 20 e 50. Cada algoritmo foi executado 30 vezes e os resultados obtidos nesses experimentos serão analisados de acordo com o RMSE.


A Tabela 1 exibe os resultados obtidos pelos algoritmos IMMF, IMMA e IMMAND para conjuntos de modelos de tamanhos 5, 10, 20 e 50, respectivamente. Cada conjunto de resultado inclui o RMSE, com desvio padrão, marcando os melhores resultados em negrito.

**Tabela 1. Resultados encontrados para os métodos IMMF, IMMA e IMMAND para as bases de dados B0007 e B0018 para 5,10,20,50 modelos**

		IMMF	IMMA	IMMAND
5 Modelos	Experimento 1 : Limiares 0.4 e 0.6			
	Base B0007	<b>0.0011/0.0002</b>	0.0015/0.0003	0.0012/0.0002
	Base B0018	<b>0.0016/0.0002</b>	0.0018/0.0003	0.0016/0.0003
	Experimento 2 : Limiares 0.1 e 0.7			
	Base B0007	<b>0.0011/0.0002</b>	0.0012/0.0003	0.0012/0.0002
	Base B0018	<b>0.0016/0.0002</b>	0.0016/0.0003	0.0016/0.0003
	Experimento 3: Limiares 0.3 e 0.5			
	Base B0007	<b>0.0011/0.0002</b>	0.0014/0.0003	0.0012/0.0002
Base B0018	<b>0.0016/0.0002</b>	0.0018/0.0003	0.0016/0.0003	
10 Modelos	Experimento 1 : Limiares 0.4 e 0.6			
	Base B0007	0.0043/0.0011	<b>0.0034/0.0016</b>	0.0038/0.0009
	Base B0018	0.0041/0.0013	<b>0.0033/0.0014</b>	0.0042/0.0010
	Experimento 2 : Limiares 0.1 e 0.7			
	Base B0007	0.0043/0.0011	0.0041/0.0009	<b>0.0038/0.0009</b>
	Base B0018	0.0041/0.0013	<b>0.0037/0.0013</b>	0.0042/0.0010
	Experimento 3: Limiares 0.3 e 0.5			
	Base B0007	0.0043/0.0011	0.0041/0.0009	<b>0.0038/0.0009</b>
Base B0018	0.0041/0.0013	<b>0.0038/0.0012</b>	0.0042/0.0010	
20 Modelos	Experimento 1 : Limiares 0.4 e 0.6			
	Base B0007	0.0033/0.0009	<b>0.0021/0.0005</b>	0.0031/0.0007
	Base B0018	0.0033/0.0009	<b>0.0023/0.0005</b>	0.0030/0.0009
	Experimento 2 : Limiares 0.1 e 0.7			
	Base B0007	0.0033/0.0009	<b>0.0021/0.0005</b>	0.0031/0.0007
	Base B0018	0.0033/0.0009	0.0032/0.0011	<b>0.0030/0.0009</b>
	Experimento 3: Limiares 0.3 e 0.5			
	Base B0007	0.0033/0.0009	<b>0.0020/0.0004</b>	0.0031/0.0007
Base B0018	0.0033/0.0009	<b>0.0023/0.0006</b>	0.0030/0.0009	
50 Modelos	Experimento 1 : Limiares 0.4 e 0.6			
	Base B0007	0.0122/0.0017	<b>0.0102/0.0016</b>	0.0117/0.0013
	Base B0018	0.0106/0.0015	<b>0.0091/0.0025</b>	0.0103/0.0017
	Experimento 2 : Limiares 0.1 e 0.7			
	Base B0007	0.0122/0.0017	<b>0.0102/0.0016</b>	0.0117/0.0013
	Base B0018	0.0106/0.0015	<b>0.0099/0.0019</b>	0.0103/0.0017
	Experimento 3: Limiares 0.3 e 0.5			
	Base B0007	0.0122/0.0017	<b>0.0102/0.0018</b>	0.0117/0.0013
Base B0018	0.0106/0.0015	<b>0.0091/0.0022</b>	0.0103/0.0017	

Ao considerar 5 modelos, o método IMMAND apresentou resultados semelhantes ao IMMF original, enquanto o IMMA teve desempenho inferior. Já os resultados para conjuntos de 10, 20 e 50 modelos, consistentemente, IMMA e IMMAND superaram o IMMF. Mesmo com um número limitado de modelos ativos, os métodos propostos não aumentaram a complexidade computacional. Observando os resultados, à medida que o número de modelos aumenta, as abordagens propostas demonstram uma melhoria

contínua. Embora em conjuntos menores não se observe uma diferença tão significativa, os algoritmos de estrutura variável mantêm uma estimativa comparável ao IMM, indicando que não há perda de desempenho mesmo nesses cenários, conforme evidenciado na Figura 4.



**Figura 4. Comparação entre os diferentes métodos de propostos, IMMA e IMMAND, com a literatura, IMM, bem como os dados reais para a base B0018 para 50 modelos, no experimento 1.**

#### 4. Conclusão

Este trabalho propôs duas abordagens de estrutura variável para lidar com múltiplos modelos no IMM, visando uma estimação da condição de funcionamento de máquinas e equipamentos, em meio a uma ampla gama de modelos. A contribuição central é a introdução de dois limiares ao IMM para adaptativamente selecionar um conjunto ativo de modelos, assegurando que apenas modelos considerados significativos contribuam para a estimação de estado. A abordagem busca mitigar interferências de modelos não significativos que poderiam prejudicar a estimativa geral, especialmente em conjuntos com um grande número de modelos. Os algoritmos demonstraram baixa sensibilidade às escolhas dos limiares, exibindo consistência em relação aos resultados em diferentes intervalos de faixas de limiares testados. Comparando IMMA e IMMAND com IMM, destaca-se que a melhoria das abordagens propostas torna-se mais evidente com o aumento do número de modelos. Mesmo em conjuntos menores, essas abordagens não mostraram perdas nos resultados. Embora os resultados sejam promissores, existem oportunidades de aprimoramento, como a determinação dinâmica de limiares ideais, evitando escolhas intuitivas que possam prejudicar a estimação. Outra área de melhoria inclui a análise do impacto do possível descarte de modelos em cada instante na estimativa do estado. Além disso, mais testes com diferentes bases de dados de máquinas e equipamentos são cruciais para validar e generalizar os resultados altamente promissores obtidos até o momento.

#### 5. 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

- Barbosa, J. and Gomes, B. (2008). *An Overview on Target Tracking Using Multiple Model Methods*. Dissertação (Mestrado) - Instituto Superior Técnico, Universidade Técnica de Lisboa, Lisboa, 2008, Portugal. Acesso em 16 maio 2024.
- 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.
- 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.
- Kardec, A. N. J. (2009). Manutenção - função estratégica. 3ª edição. Rio de Janeiro: *Qualitymark: Petrobrás*, pages 1–440.
- Lan, J., Li, X. R., and Mu, C. (2011). Best model augmentation for variable-structure multiple-model estimation. *IEEE Transactions on Aerospace and Electronic Systems*, 47(3):2008–2025.
- Li, X.-R. and Bar-Shalom, Y. (1996). Multiple-model estimation with variable structure. *IEEE Transactions on Automatic Control*, 41(4):478–493.
- Sun, X., Wang, X., and Lin, S. (2020a). Multi-fault diagnosis approach based on updated interacting multiple model for aviation hydraulic actuator. *Information*, 11:410.
- Sun, X., Wang, X., and Lin, S. (2020b). Multi-fault diagnosis approach based on updated interacting multiple model for aviation hydraulic actuator. *Information*, 11(9):410.
- Xu, Z. and Saleh, J. H. (2021). Machine learning for reliability engineering and safety applications: Review of current status and future opportunities. *Reliability Engineering System Safety*, 211:107530.