

FILTRO DE PARTÍCULAS COM MÚLTIPLOS MODELOS APLICADO AO PROGNÓSTICO DE FALHAS

LUCIANA B. COSME*, MARCOS FLÁVIO S. V. D'ANGELO†, WALMIR M. CAMINHAS‡, REINALDO M. PALHARES‡

**IFNMG Campus Montes Claros*

Rua Dois, 300, Village do Lago I, 39404-058, Montes Claros - MG

*Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av.
Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil*

†Departamento de Ciência da Computação

Universidade Estadual de Montes Claros

Av. Rui Braga, s/n, Vila Mauricéia, CEP: 39401-089

Montes Claros - MG

‡Departamento de Engenharia Eletrônica

Universidade Federal de Minas Gerais

Av. Antônio Carlos, 6627, 31270-901, Belo Horizonte - MG

Emails: luciana.balieleiro@ifnmg.edu.br, marcos.dangelo@unimontes.br,
caminhas@cpdee.ufmg.br, rpalhares@ufmg.br

Resumo— This work proposes a hybrid approach based on multiple models particle filters and fuzzy sets to address the problem of fault prognostics of a computer numerical control tool. The main contribution of this paper is an alternative method to compute the individual probability model. The results indicate the effectiveness of the method presented and also it shows the need to automate the generation of the membership functions used.

Palavras-chave— Fault Prognostic, Particle Filters, Multiple Models, Fuzzy sets.

Resumo— Este artigo propõe uma abordagem híbrida para múltiplos modelos baseada em filtros de partículas e conjuntos nebulosos para tratar o problema de predição de falhas e de desgaste em máquinas CNC. A principal contribuição do trabalho é fornecer uma forma alternativa de computar a probabilidade individual de cada modelo. A solução encontrada pelo filtro de partículas proposto se mostrou superior aos métodos tradicionais. Os resultados deste estudo indicam a viabilidade da proposta bem como mostram a necessidade de propor métodos para geração automática das funções de pertinências utilizadas.

Palavras-chave— Prognóstico de Falhas, Filtros de Partículas (FP), Múltiplos Modelos, Conjuntos Nebulosos.

1 Introdução

Os filtros de partículas (PF) têm sido bastante empregados para as tarefas de estimação/predição em sistemas dinâmicos e, recentemente, em prognóstico de falhas (Sun et al., 2014; Jouin et al., 2016), devido principalmente a sua capacidade de avaliar os estados ocultos do sistema a partir de medições ruidosas. Em especial, é possível relacionar os filtros de partículas com prognóstico de falhas ao considerar que as predições sobre a evolução da condição da máquina/componentes pode ser representada como um sistema cujo espaço de estados, baseado nas observações de um dado parâmetro que pode indicar a condição interna de funcionamento de um equipamento/planta. Em Jouin et al. (2016) é possível encontrar uma extensa revisão sobre o assunto. Apesar de haver um conjunto razoável de abordagens, a literatura atual disponível tem adotado como praxe o uso de um único modo de evolução da falha. Entretanto, em algumas ocasiões, os sistemas são caracterizados por diferentes modos de falha e projetar filtros

baseados em diferentes hipóteses pode ser mais adequado. Na área de prognóstico de falhas, há poucos trabalhos que têm lidado com a temática de multimodelos (Tang et al., 2010; Butler, 2012), ao contrário, por exemplo, da literatura sobre *target tracking* que já investiga como os múltiplos modelos descrevem os diversos comportamentos dos sistemas (McGinnity and Irwin, 2000; Bar-Shalom et al., 2005; Blom and Bar-Shalom, 1988).

O propósito da modelagem com múltiplos modelos é permitir a execução de vários filtros em paralelo, cada qual descrevendo, em um certo tempo, um dos diversos comportamentos do sistema. Em especial, o estimador *Interacting Multiple model (IMM)* (Blom and Bar-Shalom, 1988) tem sido bastante utilizado em aplicações de estimação de estados. Neste artigo, é proposta uma versão modificada do IMM baseada nos conjuntos nebulosos para computar a probabilidade individual de cada modelo, considerando a possibilidade de haver também modelos de medição distintos. Adicionalmente, este trabalho apresenta uma aplicação de prognóstico de falhas em uma máquina

de comando numérico (*Computer Numerical Control - CNC*)(*PHM Society Conference Data Challenge*, 2010) utilizando a abordagem proposta.

O restante do artigo está organizado da seguinte maneira: a Seção 2 apresenta detalhes sobre a modificação proposta do IMM, na Seção 3 é apresentada a base de dados utilizada, os resultados e as discussões e, finalmente, na Seção 4 são apresentadas as conclusões do artigo.

2 Método proposto

Essa seção apresenta os detalhes sobre o método proposto e também introduz o referencial teórico necessário.

2.1 Filtros de partículas com múltiplos modelos

O objetivo principal dos filtros com múltiplos modelos é permitir a execução de vários filtros que caracterizam os modos distintos do sistema. Em especial, o método *Interacting Multiple Model (IMM)* (Blom and Bar-Shalom, 1988) tem sido bastante empregado na estimação de estados, especialmente em aplicações de rastreamento e, mais recentemente, na área de prognóstico de falhas.

Baseado no escopo de estimação de estados, o modelo é dado por:

$$x_k = f_k(x_{k-1}, \omega_{k-1}, m_k) , \quad (1)$$

$$y_k = h_k(x_k, v_k, m_k) , \quad (2)$$

sendo que $x_k, k \in \mathbb{N}$, representa o vetor de estados, f_k e h_k modelam a função de transição do estado x_{k-1} e a função de medição, respectivamente, ω_{k-1} é uma sequência i.i.d do ruído de processo, v_k é uma sequência i.i.d do ruído de medição e $m_k \in \{1, \dots, M\}$ é o parâmetro que indica o índice do modelo no instante atual. Além disto, x_0 , v_k e w_k são mutualmente independentes.

O problema de filtragem envolve a estimativa do vetor de estado no instante k , dado todas as medições disponíveis. Numa perspectiva Bayesiana, esse problema pode ser formalizado como o cálculo da densidade de probabilidade (pdf) $p(x_k | z_{1:k})$. Na presente proposta, cada filtro individual é executado como sendo um filtro de partículas (FP), que fornece uma aproximação discreta para a pdf desejada, executando simulações de um conjunto de variáveis aleatórias independentes chamadas de partículas. A principal vantagem é não requerer qualquer hipótese sobre a forma da pdf do vetor de estados, e por isso, são adequados para cenários não-lineares e não-Gaussianos. Para o leitor interessado em mais detalhes, sugere-se consultar Doucet and Johansen (2009) e Jouin et al. (2016). O filtro do tipo *bootstrap*, que consiste em sua versão mais simples (Chen, 2003), foi adotado neste trabalho.

Na abordagem com múltiplos modelos, a estrutura do estimador IMM consiste, resumidamente, em quatro etapas básicas (Bar-Shalom et al., 2005; Saucan et al., 2013):

1. interação entre as estimativas dos modelos no início de cada ciclo de estimação;
2. estimação do estado feita por cada modelo, de forma paralela;
3. predição e atualização da probabilidade de cada modelo;
4. estimativa do estado atual baseada na saída de todos os modelos.

A etapa de interação entre os modelos leva em consideração dois aspectos principais: a transição entre os modelos e a probabilidade individual de cada modelo. De acordo com McGinnity and Irwin (2000) e Saucan et al. (2013), a transição entre os modelos é governada por um processo de Markov com M estados. As probabilidades de transição da cadeia são descritas por uma matriz Markoviana, definida por:

$$[\Pi]_{ij} = \pi_{ij} \triangleq P(m_k = j | m_{k-1} = i), \quad \forall i, j \in \{1, \dots, M\}. \quad (3)$$

Um filtro é executado para cada um dos M modelos. Esses modelos possuem inicialmente uma probabilidade dada por $\eta_{k=0}^{(j)} (j = 1, \dots, M)$. Em cada instante, antes da execução dos filtros de partículas, a probabilidade de mistura $\eta^{(i|j)}$ é atualizada, de forma recursiva, com base na matriz de transição Π e na probabilidade de cada modelo $\eta_{k-1}^{(j)}$ (Schubert and Wanielik, 2009):

$$\eta^{(i|j)} = \frac{\pi_{ij} \eta_{k-1}^{(j)}}{\sum_{l=1}^M \pi_{lj} \eta_{k-1}^{(l)}} \quad (4)$$

Como resultado do processo de interação, $\eta^{(i|j)}$ representa a probabilidade do modelo i está ativo no instante $k-1$, dado que o modelo j está ativo no instante k . No caso do FP, a mistura das densidades para $m_k = j$ é obtida pela amostragem a partir da probabilidade $\eta^{(i|j)}$ do instante $k-1$, dado por:

$$p(x_{k-1} | m_k = j, y_{1:k-1}) = \sum_{i=1}^M \eta^{(i|j)} p(x_{k-1} | m_{k-1} = i, y_{1:k-1}). \quad (5)$$

Por fim, o estado do sistema é estimado pela soma ponderada das probabilidades individuais de todos os filtros e suas respectivas saídas:

$$x_k = \sum_{j=1}^M \eta_k^{(j)} \sum_{n=1}^{N_p} x_{k,n}^{(j)} W_{k,n}^{(j)} , \quad (6)$$

onde $N_p \in \mathbb{N}$ é o número de partículas, $W_{k,n}$ ($n = 1, \dots, N_p$) são os pesos associados a cada partícula e esses pesos podem ser atualizados a partir da probabilidade $p(y_k|x_{k,n})$.

A seção 2.2 apresenta as contribuições deste trabalho juntamente com o algoritmo IMM e as alterações propostas.

2.2 Filtro de partículas com múltiplos modelos proposto

Na literatura sobre IMM, é comum encontrar que a probabilidade de cada modelo seja computada com base na verossimilhança das medições. Como sugerido em Saucan et al. (2013), a verossimilhança do modelo, $L_k^{(j)}$, é dada pela média dos valores de cada partícula em cada modelo, de acordo com:

$$L_k^{(j)} = \frac{1}{N_p} \sum_{n=1}^{N_p} p(y_k|x_{k,n}^{(j)}). \quad (7)$$

O valor encontrado em (7) deve atualizar recursivamente a probabilidade normalizada de cada modelo:

$$\eta_k^{(j)} = \frac{\eta_{k-1}^{(j)} L_k^{(j)}}{\sum_{i=1}^M \eta_{k-1}^{(i)} L_k^{(i)}} \quad (8)$$

No entanto, a Eq. (7) assume que a equação de medição não é afetada pelo modelo m_k . O presente trabalho propõe uma abordagem alternativa baseada em conjuntos nebulosos (Zadeh, 1965), para computar a verossimilhança do modelo. De forma resumida, para o entendimento da proposta, um conjunto nebuloso e sua respectiva função de pertinência pode ser definida por:

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (9)$$

onde μ_A é a pertinência de x ao conjunto nebuloso A definido no universo de discurso X .

Assim, a etapa proposta de atualização de $L_k^{(j)}$ é baseada no grau de pertinência de um valor medido z_k . Esse valor pode ser diferente das medições necessárias y_k em cada modelo. A Figura 1 exemplifica a aplicação dessa proposta em que há uma função de pertinência para cada modelo.




Figura 1: Funções de pertinência representando os diversos modelos. Nesse exemplo, existem dois modelos e duas funções de pertinência

Sendo assim, $L_k^{(j)}$ é dado por:

$$L_k^{(j)} = \mu_{A_j}(z_k). \quad (10)$$

Note que, para $j = 1, \dots, M$, $L_k^{(j)} \geq 0$ e $\sum_{j=1}^M L_k^{(j)} = 1$. Vale ressaltar que a Eq. (8) permanece inalterada.

Para ilustrar os detalhes do algoritmo, sumariizado no Algoritmo 1, considere que para cada modelo $j \in \{1, \dots, M\}$, $\{x_{0:k,n}^{(j)}, W_{k,n}^{(j)}\}_{n=1}^{N_p}$ representam valores que caracterizam a função de densidade de probabilidade (*pdf*) $p(x_{0:k}|m_k=j, y_{1:k})$, onde $x_{0:k}^{(j)}$ é um conjunto de partículas com pesos associados $W_{k,n}^{(j)}$ e $x_{0:k} = x_l, l = 0, \dots, k$ é o conjunto de estados até o instante k .

Algoritmo 1: IMM Modificado

Data: $x_{0,n} \sim p(x_0)$, y_k , z_k ,

$W_{0,n}^{(j)} = \frac{1}{N_p}$, $n = 1, \dots, N_p$,

$\pi_{ij} = p(m_k = j | m_k = i)$, $\eta_{k=0}^{(j)}$.

Result: $\{\hat{x}\}$

begin

for $k = 1, 2, \dots, T$ **do**

for $j = 1, 2, \dots, M$ **do**

 Compute $\eta^{(i|j)} = \frac{\pi_{ij} \eta_{k-1}^{(j)}}{\sum_i \pi_{ij} \eta_{k-1}^{(i)}}$.

 Calcule $p(x_{k-1}|m_k = j, y_{1:k-1}) = \sum_i \eta^{(i|j)} p(x_{k-1}|m_k = i, y_{1:k-1})$.

 Gere N_p amostras $x_{k,n}^{(j)} \sim p(x_k|x_{k-1,n}, m_k = j)$, $n = 1, \dots, N_p$, de acordo com a Eq. (1).

 Calcule os pesos $W_{k,n}^{(j)} = W_{k-1,n}^{(j)} p(y_k|x_{k,n}^{(j)})$.

 Normalize os pesos $W_{k,n}^{(j)} = \frac{W_{k,n}^{(j)}}{\sum_{l=1}^{N_p} W_{k,l}^{(j)}}$.

 Execute a reamostragem.

 Atualize $L_k^{(j)} = \mu_{A_j}(z_k)$.

end

for $j = 1, 2, \dots, M$ **do**

 Calcule a probabilidade de cada modelo

$\eta_k^{(j)} = \frac{\eta_{k-1}^{(j)} L_k^{(j)}}{\sum_i \eta_{k-1}^{(i)} L_k^{(i)}}$.

end

 Estime o estado $\hat{x}_k = \sum_{j=1}^M \eta_k^{(j)} \sum_{n=1}^{N_p} x_{k,n}^{(j)} \omega_{k,n}^{(j)}$.

end

return $\{\hat{x}\}$

end

Também é importante ressaltar que a técnica de reamostragem foi utilizada para evitar a propagação de partículas que contribuem pouco para $p(x_k|y_{1:k})$. Uma revisão de literatura acerca dessas técnicas pode ser encontrada em Doucet and Johansen (2009).

3 Resultados e discussão

O objetivo desta seção é a previsão da condição de saúde de uma máquina de comando numérico (CNC). Essas previsões podem ser utilizadas para diminuir os custos de manutenção e aumentar a produtividade do equipamento. Para alcançar esse objetivo, é necessário que o desgaste das fresas seja previsto antes que os cortadores atinjam seu limite de desgaste. As seções 3.1 e 3.2 apresentam detalhes sobre a base de dados com suas características principais e o método de extração de características, respectivamente. Em seguida, as seções 3.3 e 3.4 mostram os modelos adotados nos experimentos e a avaliação do comportamento do filtro de partículas proposto para múltiplos modelos.

3.1 Base de Dados

Os experimentos utilizaram a base de dados *Prognostic Data Challenge 2010 (PHM Society Conference Data Challenge, 2010)*. Esses dados históricos pertencem a uma fresadora CNC de alta velocidade com três cortadores (Röders Tech RFM760) utilizados até um estágio de desgaste significativo.

Os arquivos da base de dados contém medições do nível de desgaste observado durante os cortes, além das medições dos sensores, a saber: dinamômetro, que mediram a força dos cortes nas três dimensões X, Y e Z; acelerômetros, que mediram a vibração também em três dimensões; e de emissão acústica para monitorar o estresse de alta frequência gerado pelo processo de corte (Li et al., 2009).

3.2 Extração de características

Apenas três experimentos (c_1 , c_4 e c_6), dos seis disponíveis, contém a medição do nível de desgaste. Para compor esses registros, as três fresas disponíveis na máquina realizaram os cortes em peças idênticas. Para o processo de treinamento, que consiste em obter os parâmetros dos modelos, dois experimentos c_4 e c_6 foram utilizados. Já c_1 foi fornecido aos métodos apenas como validação e, para este caso, o nível de desgaste foi considerado desconhecido.

Os dados dos sensores foram processados para verificar se eles representam a informação de desgaste dos cortadores, visto que essa informação não pode ser obtida diretamente em funcionamento normal. Dos dados brutos foram extraídas algumas características, tais como: *Root Mean Square* (RMS) dos acelerômetros e a média dos valores do sensor de emissão acústica.

Com o intuito de reduzir a dimensionalidade dos dados de entrada, a técnica *Principal Component Analysis* (PCA) (Jolliffe, 2002) foi aplicada às 4 características extraídas. Os parâmetros para

o método foram extraídos a partir de c_4 e c_6 . O conjunto de cortes c_1 , nesse caso, são novas observações, de forma a permitir o uso da proposta em tempo real. Para melhorar a confiabilidade da predição, optou-se por usar o valor máximo de desgaste entre as três fresas.

3.3 Múltiplos modelos

Com base nos dados de c_4 e c_6 , foram definidos três modelos para representar os estágios dos níveis de desgaste e para relacioná-los com as medições extraídas dos sensores:

$$\begin{aligned} x_k^{(j)} &= \exp(\alpha^{(j)})x_{k-1}^{(j)} + \omega_{k-1}^{(j)}, \\ y_k^{(j)} &= \beta_0^{(j)} + \beta_1^{(j)}x_k^{(j)} + v_k^{(j)}. \end{aligned} \quad (11)$$

onde $j = 1, \dots, M$ é o índice que indica o modelo e M indica o número de modelos disponíveis. x_k é o nível de desgaste e y_k é a medição (componente principal) obtidos no instante k , w_k e v_k representam o ruído de processo e de medição, respectivamente. Nesse caso, $z_k = y_k$, porém cada modelo de transição de estado possui um modelo de medição distinto.

Com relação aos parâmetros α , β_0 e β_1 , estes foram extraídos dos dados de treinamento. Utilizou-se a função *fit* do ambiente *MATLAB* para ajustar a curva $\exp(\alpha)x_{k-1}$ com os dados de cada modelo. Os valores encontrados foram $\alpha^{(1)} = 0.019$, $\alpha^{(2)} = 0.0032$, $\alpha^{(3)} = 0.0049$. Já os parâmetros β_0 e β_1 foram calculados por regressão linear simples, também para cada modelo:

$$\begin{aligned} \beta^{(1)} &= [-3.0 \quad 0.024] \\ \beta^{(2)} &= [-5.42 \quad 0.046] \\ \beta^{(3)} &= [-7.20 \quad 0.049] \end{aligned}$$

O ruído de processo para cada modelo é dado por $\omega_k \sim \mathcal{N}(0, \sigma_{\omega^{(j)}})$ sendo que $\sigma_{\omega^{(j)}}(j = 1, 2, 3) = [0.98 \ 0.29 \ 0.54]$. Da mesma forma, o ruído de medição é dado por $v_k \sim \mathcal{N}(0, \sigma_{v^{(j)}})$ sendo que $\sigma_{v^{(j)}}(j = 1, 2, 3) = [0.31 \ 0.45 \ 0.87]$. A condição inicial é dada por $x_0 \sim \mathcal{N}(50, \sigma_{\omega^{(1)}})$.

A Figura 2 apresenta a evolução do nível de desgaste em cada conjunto de cortes (c_1 , c_4 , c_6) presentes na base de dados. O nível de desgaste foi dividido em três regiões e cada uma destas foi utilizada para definir um dos modelos. Levou-se em consideração que, inicialmente, há um crescimento maior do nível de desgaste, depois há um crescimento menor mas constante e, finalmente, há um crescimento mais acentuado. As regiões foram divididas da seguinte maneira: a primeira região começa do instante $k = 0$ até o instante $k = 20$, a segunda região parte do instante $k = 21$ até o instante $k = 240$ e, por fim, a terceira região se inicia no instante $k = 241$ até o final do experimento.

De forma análoga à Figura 2, a Figura 3 mostra a evolução da componente principal, no tempo,




Figura 2: Evolu  o do n vel de desgaste, ao longo do tempo, para cada conjunto de cortes (c_1 , c_4 e c_6)

de cada conjunto de cortes. Os modelos de medi  o foram divididos da mesma forma como os modelos do n vel de desgaste.




Figura 3: Evolu  o da componente principal, ao longo do tempo, para cada conjunto de cortes

Com rela  o  s fun  es de pertin ncia, foram selecionadas as fun  es do tipo trapezoidal¹ e triangular² e os par metros foram escolhidos de acordo com os valores de c_4 e c_6 , sendo eles: $M_1(z_1(k)) = \text{trapezoidal}(z_1(k), -10, -6, -2, -1)$, $M_2(z_1(k)) = \text{triangular}(z_1(k), -2, -1, 0.5)$ e $M_3(z_1(k)) = \text{trapezoidal}(z_1(k), -1, 0.5, 6, 10)$. A Figura 4 apresenta as fun  es geradas e z_1   a componente principal.

3.4 Experimentos

Para avaliar o desempenho do filtro de part culas proposto, do filtro IMM e do filtro de part cula convencional, utilizou-se a base de dados apresentada na se  o 3.1. De posse das informa  es dos sensores, foi extra  da a componente principal e inferido o valor do desgaste visto que esse valor n o pode ser obtido diretamente.

Os filtros foram executados com 50 part culas e com a reamostragem multinomial (Chen, 2003).

¹Utilizou-se a fun  o *trapmf*($x, [a \ b \ c \ d]$) do ambiente MATLAB.

²Utilizou-se a fun  o *trimf*($x, [a \ b \ c \ d]$) do ambiente MATLAB.




Figura 4: Fun  es de pertin ncia representando os modelos propostos

Os par metros do filtro convencional foram obtidos da mesma forma como no m todo proposto, por m apenas para um  nico modelo ($\alpha = 0.0044$ e $\sigma_\omega = 0.50$, $\beta = [-4.32 \ 0.035]$ e $\sigma_v = 0.68$).

Como crit rios de compara  o foram utilizados o erro quadr tico m dio (RMSE) e o desvio padr o desse erro. Os resultados correspondem   m dia de cada crit rio em 100 execu  es.

A Tabela 1 ilustra como o filtro de part culas com m ltiplos modelos proposto obteve melhores resultados que o filtro convencional (FP) e o filtro com m ltiplos modelos (IMM) original. De acordo com a tabela, a abordagem proposta alcan ou um erro em torno de 50% do valor encontrado pelos demais filtros.

Tabela 1: Resultados comparativos

	IMM Proposto	FP	IMM
RMSE	6.96	13.12	12.69
Desvio	0.57	0.69	0.49

A Figura 5 mostra o comportamento dos filtros executados, para predi  o do desgaste durante a valida  o com o conjunto de cortes c_1 .




Figura 5: Predi  o da evolu  o do n vel de desgaste pelo filtro proposto e demais filtros

Diante dos resultados apresentados na Tabela 1 e na Figura 5, os autores acreditam que a estrat gia de utilizar o m todo IMM juntamente com os conjuntos nebulosos melhorou o desempenho do algoritmo baseado no filtro de part culas

convencional, para o experimento proposto, o que sugere uma melhor capacidade de capturar as características e as incertezas presente em cada modelo. Na construção dessa proposta, entretanto, os parâmetros das funções de pertinência foram selecionados manualmente, o que nem sempre é viável para aplicações práticas. O desafio da proposta é, então, a geração das funções de pertinência que dependem do conhecimento específico da base de dados. Utilizar uma geração automática dessas funções baseada, por exemplo, nos *clusters* encontrados nos dados de entrada, z_k , pode não ser suficiente pois o sistema depende também de como os modelos de transição de estados se comportam.

4 Considerações finais

O presente trabalho apresentou uma nova abordagem híbrida baseada nos filtros IMM e nos conjuntos nebulosos, para fazer a predição das condições de desgaste de uma máquina CNC. Os resultados comparativos com a abordagem tradicional mostraram a melhor capacidade do filtro de partículas proposto em prever o valor desconhecido de desgaste do equipamento, a partir dos dados disponíveis de sensores. Para trabalhos futuros, pretende-se investigar e propor alternativas para geração automática dos parâmetros e, assim, tornar o processo mais automatizado.

Agradecimentos

Os autores agradecem o suporte financeiro da FAPEMIG e CNPq (processos 157280/2014-4 e 303812/2014-1).

Referências

- Bar-Shalom, Y., Challa, S. and Blom, H. A. P. (2005). IMM estimator versus optimal estimator for hybrid systems, *IEEE Transactions on Aerospace and Electronic Systems* **41**(3): 986–991.
- Blom, H. A. P. and Bar-Shalom, Y. (1988). The interacting multiple model algorithm for systems with markovian switching coefficients, *IEEE Transactions on Automatic Control* **33**(8): 780–783.
- Butler, S. (2012). *Prognostic Algorithms for Condition Monitoring and Remaining Useful Life Estimation*, PhD thesis, National University of Ireland.
- Chen, Z. (2003). Bayesian filtering: From kalman filters to particle filters, and beyond, *Technical report*, McMaster University.
- Doucet, A. and Johansen, A. M. (2009). A tutorial on particle filtering and smoothing: fifteen years later, *Handbook of Nonlinear Filtering* **10**: 656–704.
- Jolliffe, I. T. (2002). *Principal Component Analysis*, Springer-Verlag.
- 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.
- 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, *Annual Conference of the Prognostics and Health Management Society*, PHM Society.
- McGinnity, S. and Irwin, G. W. (2000). Multiple model bootstrap filter for maneuvering target tracking, *IEEE Transactions on Aerospace and Electronic Systems* **36**(3): 1006–1012.
- PHM Society Conference Data Challenge* (2010). <https://www.phmsociety.org/competition/phm/10>.
- Saucan, A. A., Chonavel, T., Sintès, C. and Caillec, J. M. L. (2013). Interacting multiple model particle filters for side scan bathymetry, *OCEANS - Bergen, 2013 MTS/IEEE*, pp. 1–5.
- Schubert, R. and Wanielik, G. (2009). Unifying bayesian networks and IMM filtering for improved multiple model estimation, *Information Fusion, 2009. FUSION '09. 12th International Conference on*, pp. 810–817.
- Sun, J., Zuo, H., Wang, W. and Pecht, M. G. (2014). Prognostics uncertainty reduction by fusing on-line monitoring data based on a state-space-based degradation model, *Mechanical Systems and Signal Processing* **45**(2): 396 – 407.
- Tang, L., DeCastro, J., Kacprzyński, G., Goebel, K. and Vachtsevanos, G. (2010). Filtering and prediction techniques for model-based prognosis and uncertainty management, *2010 Prognostics and System Health Management Conference*, pp. 1–10.
- Zadeh, L. A. (1965). Fuzzy sets, *Information and control* **8**(3): 338–353.