

Remaining Useful Life Estimation by Empirical Mode Decomposition and Support Vector Machine

Caio B. S. M., Márcio C. M., Isis D. L.

Center for Risk Analysis and Environmental Modeling, Department of Production Engineering, Federal University of Pernambuco, Recife, Brazil

Enrique L. P.

Center for Risk and Reliability, Mechanical Engineering Department, University of Maryland, College Park, USA

1. INTRODUÇÃO

Os impactos devido a falhas de sistemas trazem diversos pontos negativos, expondo malefícios que vão desde meras inconveniências e contratempos até lesões em pessoas, grandes perdas econômicas e até mesmo a morte. Ao perceber os benefícios que poderiam alcançar com o aumento da confiabilidade, as organizações passaram a dar mais importância a questões relacionadas à eficiência de sistemas e otimização de processos.

Num contexto mais específico, o estudo de confiabilidade pode associar-se à análise de manutenção, determinando um ponto ótimo em que a mesma deve ser realizada. Tal análise tem como objetivo evitar que a falha ocorra, ampliando o tempo de funcionamento da máquina e buscando reduzir os custos.

O tempo de vida útil remanescente (*Remaining Useful Life* – RUL) de determinado sistema, máquina ou componente é definido como a extensão do tempo atual até o final de sua vida útil [1]. Esta medida se relaciona com diversos fatores, como o estado de degradação atual, o ambiente no qual ele se encontra, o funcionamento do sistema, dentre outros.

Assim, o desenvolvimento de um plano de prognóstico que possa monitorar e administrar adequadamente o sistema, estimando o RUL de maneira precisa é de grande valia. Este plano visa permitir que as ações de manutenção sejam executadas antes que a falha ocorra, impactando positivamente a disponibilidade do sistema, evitando custos envolvidos com manutenção corretiva e relacionados com a indisponibilidade do sistema. O *Prognostic Health Management* (PHM) surge a partir desta ideia, com funções que incluem a detecção de falha, diagnóstico, prognóstico e monitoramento da saúde, entre outras [2]. O prognóstico permite avaliar a confiabilidade do sistema nas condições de ciclo atual e, ainda mais, busca prever quando e onde a falha vai ocorrer, dando a oportunidade de mitigar este risco [2]. Deste modo, o PHM representa importante pilar na busca de melhoria do sistema.

Há diversas maneiras de tentar se chegar a um modelo teórico que vise fornecer informações sobre a próxima falha ou tempos entre falhas, todavia muitos deles acabam não sendo viáveis na prática cotidiana, em virtude das simplificações impostas e que não acontecem na realidade. Estas simplificações podem acontecer tanto devido à falta de informações relevantes, como em razão de quais variáveis realmente afetam o comportamento do sistema, ou ainda devido à inviabilidade operacional de realizar complexos cálculos para sua estimação.

Uma alternativa são os modelos de aprendizagem, que podem ser utilizados quando há disponibilidade de uma série de dados sobre determinada variável para a qual se deseja realizar uma previsão, apesar se conhecer o mapeamento entre inputs e outputs de um sistema. A partir dos dados, cria-se um conhecimento implícito para determinação do comportamento futuro dessas variáveis.

Dentre os métodos de aprendizagem a partir de dados já bastante difundidos em diversos campos da ciência e que possuem sólida base, pode-se destacar o *Support Vector Machine* (SVM) [3] as Redes

Neurais Artificiais (RNA) [4]. No SVM, há a resolução de um problema de otimização quadrática e convexa, o que garante o ótimo global, não ficando preso em ótimos locais, como pode ocorrer nas RNA.

Adaptações de modelos de aprendizagem são utilizadas quando se busca melhorar qualidade dos dados de entrada, possibilitando ao modelo (por exemplo, SVM) fornecer previsões mais precisas. O *Empirical Mode Decomposition* (EMD) [5], aplicado antes do SVM é uma destas adaptações relevantes. A principal contribuição desse método é a possibilidade de analisar séries não estacionárias que apresentam tendência, já que a pura aplicação do SVM não faz uma previsão tão acurada deste tipo de série (por exemplo, o tempo entre as falhas de um componente que sofre degradação tende a diminuir com o passar do tempo). Assim, é possível decompor uma série complicada na soma de um pequeno número de outras séries, cada uma atendendo à condição de ser praticamente estacionária ou o resíduo. Mais especificamente, tem-se que para o EMD decompõe a série original, apresentando como output os vários *Intrinsic Mode Functions* (IMF), que são analisados separadamente pelo SVM para fornecer previsão mais adequada.

Portanto, combinar os dois métodos parece ser uma boa maneira para uma realizar previsão de séries não-estacionárias e com tendência. Neste contexto, [6] utiliza metodologia similar para realizar previsões de vazão em uma hidroelétrica. Em [7], a metodologia é aplicada na previsão de falhas em moinhos pesados. Já [8] utilizada este procedimento para investigar o comportamento de rolamentos e seus sinais vibratórios de falhas. A maior parte dos trabalhos presentes na literatura relacionada apenas utiliza a combinação dos dois métodos (EMD+SVM), sem verificar qual o real ganho fornecido pelo primeiro método. Sendo assim, combinar as duas métricas, comparando-a com a utilização de apenas SVM e fazendo uma análise da melhoria apresentada pelo EMD, pode trazer contribuição à análise de previsões em métricas de confiabilidade, com muito maior precisão para o RUL, por exemplo.

Este artigo está organizado da seguinte maneira: na Seção 2, é apresentada, de maneira direta, o objetivo do trabalho, na Seção 3 serão abordados os conceitos relacionados com PHM e uma breve fundamentação teórica sobre EMD e SVM. Na Seção 4, é apresentada a metodologia e a descrição do trabalho utilizado nas aplicações expostas neste artigo. Na Seção 5 há dois exemplos relacionados à previsão do tempo entre falhas, em que os desempenhos do EMD+SVM e do SVM puro são comparados, apresentando seus resultados. Finalmente, na Seção 5 serão apresentadas algumas relevantes conclusões.

2. OBJETIVOS DO TRABALHO

A finalidade é utilizar o método proposto de EMD+SVM para estimar o RUL, comparando os resultados de previsão fornecida por este modelo com a do SVM puro. Esses resultados podem auxiliar a resolução de problemas associados à confiabilidade de equipamentos, bem como colaborar para a elaboração de políticas de manutenção apropriadas.

3. FUNDAMENTAÇÃO TEÓRICA

3.1 *Prognostic Health Management*

Nos últimos anos, estudos sobre prognóstico de falhas têm recebido considerável atenção em trabalhos de pesquisa nas áreas de manutenção e confiabilidade. Muitas vantagens podem ser obtidas a partir dos sistemas de prognósticos, como a redução do tempo de parada na produção, aumento da disponibilidade e segurança, redução dos custos de manutenção e logísticos [9]. O sistema de prognóstico de equipamentos é utilizado para estimar o tempo de vida remanescente de componentes do maquinário baseado em vários métodos, tais como o método de distribuição tradicional, métodos baseados na aprendizagem a partir de dados, modelos de base física e métodos baseados na probabilidade [10].

Para entender a ideia de prognóstico e diagnóstico, é importante verificar os vários passos envolvidos na estimação do tempo de vida remanescente e seus limites de confiança. Um mesmo componente pode ter diversos tipos de falha, iniciados a partir de causas distintas e tendo um comportamento de deterioração diferente, mesmo quando são expostos às mesmas condições operacionais

e ambientais. Eventos anormais, como mudança nas condições de operação, ações de manutenção e outras falhas, também podem acelerar a progressão de um ou vários modos de falhas particulares [11].

Sendo assim, na determinação do tempo de vida remanescente, é necessário o conhecimento de algumas informações, tais como: qual o atual estado de degradação do componente, qual modo de falha iniciou a degradação e quão severo é o estado de degradação, ou seja, em que local o componente está na curva de degradação. Estas informações podem ser consideradas de diagnóstico. Por outro lado, questões sobre quão rápido é esperado o progresso da degradação do estado atual até a falha, que novos eventos irão alterar o comportamento esperado de degradação e como outros fatores podem afetar a estimação do tempo de vida útil remanescente, são questões associadas a prognósticos [11].

Então, é fácil ver que questões sobre diagnósticos estão relacionadas ao estado atual do componente, ou seja, ao que aconteceu no passado até o presente momento. Questões sobre prognósticos estão relacionadas ao que irá acontecer com o componente, ou seja, referentes ao futuro. Os diagnósticos precisarão ser acompanhados continuamente para a detecção de novos eventos para que então a estimação do prognóstico possa ser atualizada adequadamente. Para análise do processo e futura estimação de prognóstico, é necessário fazer a escolha adequada do modelo utilizado.

3.2 Empirical Mode Decomposition

A ideia principal do EMD é que qualquer dado derivado de uma série de tempo é constituído por uma composição de séries de oscilações. O objetivo é identificar empiricamente os IMFs a partir das características dos dados na escala de tempo [12].

$$x(t) = \sum_i^N c_i(t) + r(t) \quad (1)$$

Um importante comentário a se fazer é que cada IMF representa uma pequena faixa modulada de amplitude e frequência e que normalmente está associada a um processo físico específico [13]. Um IMF é uma função que satisfaz a duas condições: (1) em todo o conjunto de dados, o número de extremos e de cruzamentos pelo zero (eixo das abscissas) deve ser igual ou diferenciar-se por no máximo um; e (2) em qualquer ponto, o valor médio dos envelopes definidos pelo máximo local e pelo mínimo local deve ser igual a zero. [5] Os IMFs são obtidos a partir de um processo chamado de *sifting*. A decomposição é baseada nas seguintes suposições: (1) a série (sinal) apresenta, pelo menos, um máximo e um mínimo; (2) a escala de tempo característica é definida a partir do espaço de tempo existente entre os extremos; (3) se o sinal for completamente isento de extremos, mas apresentar apenas pontos de inflexão, deve-se diferenciar esse sinal uma ou várias vezes para que os extremos sejam então revelados [5]. A essência do método é identificar empiricamente os modos oscilatórios intrínsecos a partir das características dos dados da série de tempo e então decompor os dados de maneira adequada.

Em um sinal, se existir um mínimo local maior que zero entre dois máximos locais sucessivos, ou se existir um máximo local menor que zero entre dois mínimos locais sucessivos, o segmento entre esses dois máximos locais (ou mínimos locais) é chamado de *riding waves* [13]. O objetivo do *sifting* é remover as *riding waves*, deixando o perfil de onda mais simétrico. O processo pode ser descrito a partir das seguintes etapas:

1. Identificar todos os extremos locais, incluindo os máximos e os mínimos da série $x(t)$.
2. Conectar todos os extremos locais com uma *cubic spline* para criar os envelopes superiores e inferiores, e_{sup} , e_{inf} , respectivamente.
3. Calcular a média dos envelopes por $m(t) = (e_{sup} + e_{inf})/2$.
4. Obter então $h(t) = x(t) - m(t)$, que é a subtração da série original pela média dos envelopes.

5. Verificar então se $h(t)$ satisfaz as duas características que definem um IMF. Se satisfizer, então um IMF foi gerado com o resíduo $m(t) = x(t) - h(t)$ sendo o novo substituto da função $x(t)$. Caso $h(t)$ não seja um IMF, então $h(t)$ irá substituir $x(t)$ e volta-se à etapa 1 do processo iterativo.

6. Quando a etapa 5 é atingida com sucesso, ou seja, chega-se a um IMF, tem-se então que $c_i(t) = h(t)$ é o i -ésimo IMF. Subtrai-se então este termo da série original $r(t) = x(t) - c_i(t)$. Guarda-se $c_i(t)$ como um IMF e começa-se novamente desde a etapa 1, agora com o $r(t)$ sendo o sinal inicialmente analisado.

O resultado desse processo é uma série de IMFs, mais um resíduo final, $r(t)$. De maneira simples, no *sifting* há um *loop* entre as etapas 1 e 5, e quando esta última é atingida, avança-se à etapa 6, com um novo *loop* criado no final da mesma, retornando a etapa 1. O processo tem dois efeitos: (1) eliminar as *ridings waves* e (2) suavizar as amplitudes desiguais. Enquanto a primeira condição é absolutamente necessária para que a frequência instantânea tenha significado físico, a necessidade da segunda acontece no caso em que as amplitudes das ondas vizinhas são muito dispersas. Infelizmente, o segundo efeito quando levado ao extremo, pode remover as flutuações de amplitudes físicas significantes [5].

Portanto, o processo de *sifting* deve ser aplicado com cuidado, uma vez que levar o processo ao extremo pode fazer do IMF resultante um puro sinal de frequência modulada de amplitude constante. Para garantir que o IMF guarde suficiente significado físico de amplitude e frequência, é necessário determinar um critério de parada. Isto pode ser conseguido limitando o tamanho do desvio padrão (SD) entre dois *siftings* consecutivos, com:

$$SD_k = \sum_{t=0}^T \left[\frac{|(h_{1(k-1)}(t) - h_{1k}(t))|^2}{h_{1(k-1)}(t)^2} \right] \quad (2)$$

onde k é o número de iterações de *sifting* que ocorrem até que seja encontrado um IMF e t representa cada dado. Então o processo de *sifting* é interrompido quando SD é menor que um valor pré-determinado. Após um grande número de testes, foi verificado que SD_k limitado entre 0,2 e 0,3 garante que o IMF obtido tenha suficiente significado físico [5].

Uma vez que o critério de parada é atingido, o primeiro IMF, $c_1(t)$, pode ser obtido, caracterizando o final da etapa 5. Em geral, $c_1(t)$ deve conter a melhor escala ou o componente de menor período do sinal. Pode-se então separar $c_1(t)$ do restante da série por meio da equação:

$$x(t) - c_1(t) = r_1(t) \quad (3)$$

Uma vez que o resíduo, $r_1(t)$, ainda contém informação de longos períodos (baixa frequência), ele é então tratado como um novo conjunto de dados (série) e é levado ao mesmo processo de peneiramento como acima mencionado. Este procedimento é então repetido para todos os r_j s subsequentes, e o resultado é:

$$r_1 - c_1 = r_2, \dots, r_{n-1} - c_n = r_n \quad (4)$$

O processo de *sifting* parar devido a qualquer um dos seguintes critérios predeterminados: se o componente, c_n , ou o resíduo, r_n , tornam-se muito pequenos (menores que o valor predeterminado dado como substancial) ou quando o resíduo, r_n , torna-se uma função monotônica da qual nenhum outro IMF pode ser extraído. Mesmo para a série com média zero, o resíduo final pode ser diferente de zero; para séries com tendências, então o resíduo final deve ser esta tendência. Finalmente, pode-se representar a série como:

$$x(t) = \sum_{i=1}^n c_i + r_n \quad (5)$$

Então, é alcançada a decomposição da série em n -intrinsic modes, e um resíduo, r_n , com o último sendo uma tendência média ou uma constante.

3.3 Support Vector Machine

SVM é um método de aprendizado supervisionado que gera um mapeamento de funções de entrada-saída a partir de um conjunto denominado dados de treinamento $D = \{(x_1, y_1), \dots (x_n, y_n)\}$ [15]. O objetivo é encontrar a função $f(x)$ que apresente a menor penalização a partir dos desvios dos valores reais. Essa penalização ocorre quando a distancia entre o valor previsto e o valor real for maior que um valor ε predeterminado, para os dados de treinamento. Ao mesmo tempo, também é desejado que essa função seja a mais *flat* possível. O modelo pode ser usado para problemas de regressão, no chamado *Support Vector Regression* (SVR), resolvendo regressões não lineares e problemas de séries de tempo [15].

O SVM se baseia no princípio do risco mínimo estruturado (SRM) e tem seus conceitos fundamentados a partir da Teoria do Aprendizado Estatístico [3]. O problema resolvido a partir de SVM pode ser visto da seguinte maneira: existe um mapeamento $y = f(x)$ desconhecido, de valores reais e, possivelmente, não linear entre um vetor x de entrada e um escalar y de saída e a única informação disponível é um conjunto de dado D , usado para o processo de aprendizado, cuja solução é a função de regressão $f(x)$. Para o SVR, isto significa resolver um problema de otimização quadrática e convexa. Nesse caso, as condições de Karush-Kuhn-Tucker (KKT) são necessárias e suficientes para garantir um ótimo global.

O objetivo é encontrar o hiperplano que melhor representa o mapeamento de entrada e saída, a partir do conjunto de dados inicial. É importante citar que não se busca o perfeito alinhamento da função com os dados, mas sim a melhor representação deste mapeamento. É necessário fazer um *trade-off* entre a adaptação dos dados fornecidos e o poder de generalização desta função para novos dados, ou seja, encontrar a representação mais verídica possível da realidade. A equação do hiperplano de regressão pode ser representada por:

$$f(x) = w^T x + b \quad (6)$$

onde x representa os dados de entrada e w^T e b são os coeficientes a serem determinados. Eles são estimados a partir da seguinte função de risco regularizado:

$$R(C) = C \frac{1}{N} \sum_{i=0}^N \psi_\varepsilon(d_i, f_i) + \frac{1}{2} \|w\|^2 \quad (7)$$

com

$$\psi_\varepsilon(d_i, f_i) = \begin{cases} |d_i - f_i| - \varepsilon & \text{se } |d_i - f_i| \geq \varepsilon \\ 0 & \text{caso contrário} \end{cases} \quad (8)$$

onde d_i é o verdadeiro valor da variável, ou seja, o dado real e f_i é o valor estimado da mesma variável para o mesmo período. A equação (7) é a conhecida função ε -insensível de perda de Vapnik, que implica na não penalização enquanto os erros estiverem dentro do “tubo” de raio ε . Assim, ε mede a tolerância durante a execução do processo de treinamento. O segundo termo desta equação é usado como uma medida de suavização da função. Assim, C mede o *trade-off* entre o risco empírico e a suavidade do modelo e tanto ele como ε são parâmetros definidos pelo usuário. Por conveniência de cálculo, define-se também ξ_i quando os dados estão acima do tubo e ξ_i^{**} para dados abaixo do tubo.

Para encontrar o hiperplano de regressão ótimo, também é necessário minimizar o termo relacionado à capacidade da máquina, representado por $\mathbf{w}^T \mathbf{w}$, sendo entendido como a norma de \mathbf{w} . O problema primal é então definido:

$$\min_{\mathbf{w}, b, \xi, \xi^*} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=0}^l (\xi_i + \xi_i^*) \quad (9)$$

com l representando o número de pontos penalizados e sujeito às seguintes restrições:

$$y_i - \mathbf{w}^T \mathbf{x}_i - b \leq \varepsilon + \xi_i \quad (10)$$

$$\mathbf{w}^T \mathbf{x}_i + b - y_i \leq \varepsilon + \xi_i^* \quad (11)$$

$$\xi_i \geq 0 \quad (12)$$

$$\xi_i^* \geq 0 \quad (13)$$

Pode-se então determinar a função lagrangeana primal correspondente por meio da utilização dos multiplicadores de Lagrange. Também é possível criar o problema dual e a partir das condições de KKT, encontrar a solução global deste problema. É importante lembrar que a solução do dual é também solução do primal e que, efetivamente, o problema é resolvido na sua forma dual. Pode-se representar a função da seguinte maneira:

$$f(\mathbf{x}) = \mathbf{w}_0^T \mathbf{x} + b = \sum_{i=1}^N (\alpha_i + \alpha_i^*) \mathbf{x}_i^T \mathbf{x} + b \quad (14)$$

Uma maneira para resolver o produto interno é introduzindo as funções Kernel, que também é resolvida a partir do dual lagrangeano. A função de regressão é então dada:

$$f(\mathbf{x}) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \quad (15)$$

Neste trabalho, a função Kernel utilizada foi a *Radial Basis Function* (RBF), representada por $K(\mathbf{x}_i, \mathbf{x}) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}\|^2)$, onde γ também é um parâmetro do modelo. A resolução utilizando as funções kernel é quase idêntica à apresentada anteriormente.

Após encontrar os parâmetros para a função de regressão, é necessário então fazer uma comprovação da exatidão desta função encontrada. São calculados então os erros comparando os valores reais com os valores previstos, sendo utilizado o MSE (*Mean Square Error*), que utiliza a seguinte fórmula para uma série com N elementos:

$$\text{MSE} = \left(\frac{1}{N} \right) \sum_{i=0}^N (y_i - \hat{y}_i)^2 \quad (16)$$

4. DESCRIÇÃO DO TRABALHO REALIZADO

A Figura 1 descreve a metodologia EMD+SVM aplicada em cada um dos dois exemplos apresentados na seção 5. Como a aplicação do EMD é caracterizada pela decomposição da série até que reste apenas um resíduo monotônico, utilizar-lo só fará sentido caso a série seja não-monotônica. Caso seja monotônica, não haveria decomposição alguma e a própria série já representaria o resíduo. Verificou-se através de um teste de Dickey-Fuller aumentado (Teste ADF) a veracidade do comportamento não estacionário dos exemplos expostos na seção 5. Os dados originais eram de tempo até a falha que, apesar de não estacionários, apresentavam comportamento monotônico. Sendo assim, optou-se por utilizar os tempos entre falhas (*Time Between Failure* – TBF) para medir o real efeito da utilização do EMD, uma

vez que esse tipo de dado apresentava comportamento não monotônico e não estacionário, verificado pelo teste conforme citado. Maiores detalhes serão expostos na seção 5.

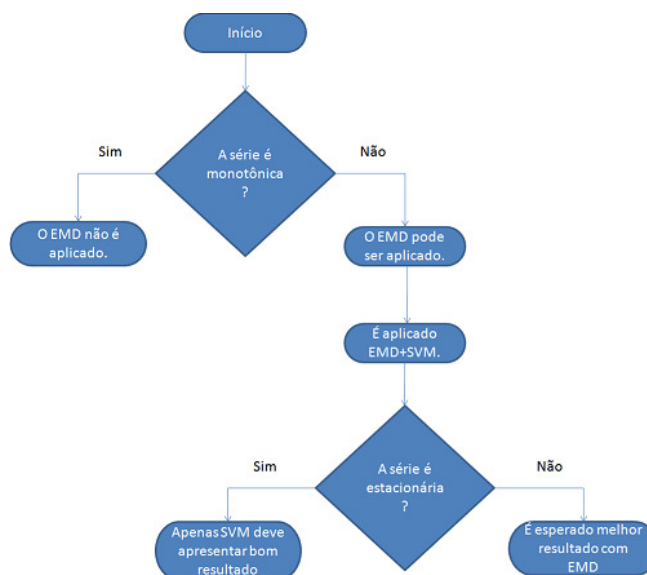


Figura 1 - Fluxograma da metodologia aplicada nos diversos exemplos

Os dados de TBF originais foram decompostos via EMD, gerando certo número de IMFs e um resíduo. Cada um destes alimentou um modelo de SVM, adotando-se um modelo autorregressivo de primeira ordem, com $y_t = f(y_{t-1})$, ou seja, a previsão futura depende do valor atual. Cada modelo pôde fazer a previsão de um passo à frente para o respectivo IMF ou resíduo. A soma das previsões dos IMFs com a previsão do resíduo retorna a previsão um passo a frente da série em sua escala original. Para o caso em que não se utiliza o EMD, a série original serviu de entrada para o SVM, que após o treinamento, resultou em um modelo autorregressivo de primeira ordem ajustado, capaz de fornecer a previsão da série um passo a frente diretamente em sua escala original.

Os parâmetros utilizados em cada modelo de SVM foram obtidos via *Particle Swarm Optimization* (PSO). O PSO é uma técnica de otimização com algoritmo baseado no comportamento social de alguns organismos biológicos que se movem em grupos, tais como pássaros e peixes [17]. Para maiores detalhes sobre aplicação do PSO, consultar [18]. Os dados então foram divididos em três categorias distintas:

- Treinamento: onde são utilizados para o treino propriamente dito da máquina, cerca 70% dos dados.
- Validação: onde são buscados os valores ótimos dos parâmetros, cerca 20% dos dados.
- Teste: onde, a partir da previsão do modelo, é possível calcular o erro entre os valores reais e a esta previsão, cerca de 10% dos dados.

. Para verificação de qual das previsões apresentava melhores resultados, os MSE foram então calculados por meio da equação (19), com um valor associado a cada categoria para cada previsão. Pôde-se então comparar a previsão com EMD e sem EMD em relação à série original e os menores valores foram determinados como mais adequados.

Para aplicação do método EMD, utilizou-se o pacote “emd” do software R[®] [19] e o PSO+SVM foi aplicado via Matlab [18].

5. RESULTADOS OBTIDOS

Nesta seção são apresentados dois exemplos relacionados à confiabilidade, onde houve aplicação da metodologia EMD+SVM, com seus resultados comparados à aplicação do SVM isoladamente. Os dados originais do primeiro exemplo estão relacionados com a deterioração de turbocompressores em um motor a diesel, representados pelo *Failure Time (FT)*, ou seja, o tempo em que a falha ocorrerá a partir de um instante fixo de tempo [20]. No segundo exemplo, é exposta uma série de ações de manutenção não planejadas em um motor a diesel de um submarino, também com dados originais associado ao FT [21]. Os dados dos dois exemplos utilizam escala de 1000 horas de observação.

5.1 Turbocompressores em um Motor a Diesel

Como já citado na seção 4, devido ao comportamento dos FTs originais, é necessário fazer a estimação do tempo entre falhas (TBF), definido como a diferença de tempo entre duas falhas. Sendo assim, essa variável mostra como se desenvolve o comportamento do intervalo de tempo entre duas falhas sucessivas. Para este exemplo, a partir das 40 observações originais de falha (FT), são extraídos 39 dados entre falhas (TBF), utilizados no modelo.

Para esta análise, é utilizado tipo de previsão *single-step-ahead*, onde próximo termo y_t é função do termo anterior y_{t-1} , criando uma dependência entre previsão e histórico da variável. Neste caso, há perda de um dado da série original e utilização de apenas 38 dados. Neste modelo, os 26 primeiros foram utilizados para treinamento, os 7 seguintes na validação e os 5 últimos no teste.

O primeiro passo foi decompor por meio do EMD a série original nos vários IMFs e seu resíduo. Foram encontrados 4 IMFs além do resíduo (Figura 2). A Tabela 1 apresenta os parâmetros do SVM obtidos via PSO para cada um dos IMFs e resíduo.

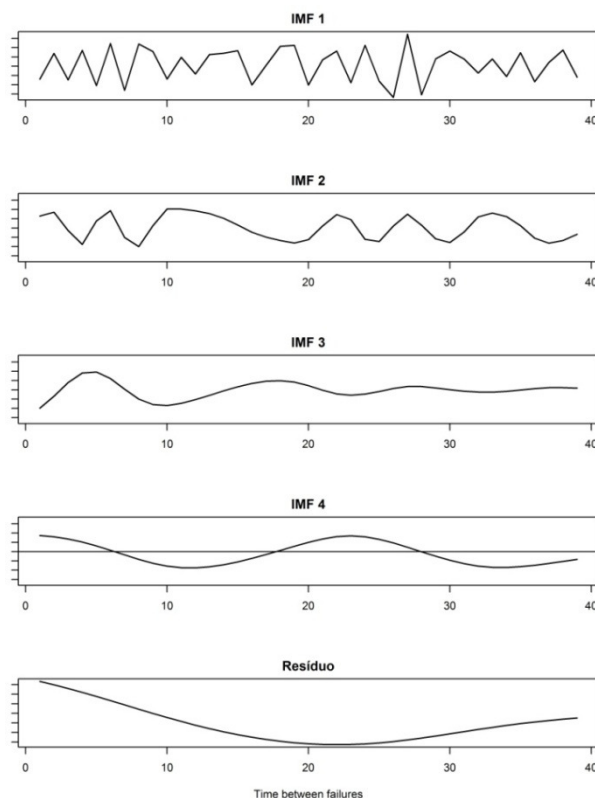


Figura 2 - Gráfico de cada IMF e resíduo da série de turbocompressores de um motor a diesel

Em seguida, aplicou-se o SVM à série original e compararam-se as duas previsões (EMD+SVM e SVM) com original. A Figura 4 apresenta em um único gráfico as três séries: a original, a previsão com EMD+SVM e a previsão de apenas SVM. É possível ver a melhor adaptação da série EMD+SVM ao longo das observações quando comparado com a série sem EMD. Ainda, os erros em cada uma das fases foram menores para o EMD+SVM em relação ao SVM puro, conforme a Tabela 2. Numa análise de erros agregada (Tabela 3) o erro médio do EMD+SVM é quase três vezes menor que o erro apresentado apenas pelo SVM, confirmando a proposta que EMD melhora a resposta para a previsão de séries não estacionárias.

Tabela 1 - Parâmetros do SVM para cada IMF e resíduo Separadamente

	IMF 1	IMF 2	IMF 3	IMF 4	RESÍDUO
C	1423.471455	196.1679725	848.4231021	100.3494646	1028.213695
epsilon	0.079736576	0.079200663	0.076391897	0.064475547	0.051926552
gamma	0.954023821	0.105252464	28.3565154	0.464516697	145.4114436




Figura 3 - Gráfico comparativo do TBF para turbo compressores em motor a diesel

Tabela 2 I- Erros para a série proposta com EMD+SVM e SVM

	Erros - MSE		
	Treinamento	Validação	Teste
sem EMD	0.023588321	0.014027118	0.007434
com EMD	0.009459695	0.005348058	0.00307

Tabela 3 – Erros agregados para a série proposta para turbocompressores em motor a diesel

Erros Agregados - MSE	
sem EMD	0.019702
com EMD	0.007862

5.2 Turbocompressores em um Motor a Diesel

Igualmente ao tópico anterior, a partir dos FT são extraídos os TBF como sendo a diferença entre duas falhas subsequentes, com a série representando o comportamento do tempo entre duas falhas sucessivas. Das 71 observações originais de FT, obtém-se 70 dados entre falhas (TBF) e devido ao *single-step-ahead*, 69 valores são utilizados, sendo os primeiros 48 para treinamento, os 14 seguintes para validação e 7 últimos para teste.

A série original é então decomposta em vários IMFs (5 para este caso) e seu resíduo por meio da aplicação do EMD. Na Figura 4, é apresentado o comportamento de cada IMF decomposto e na Tabela 4 são apresentados os parâmetros para cada IMF.

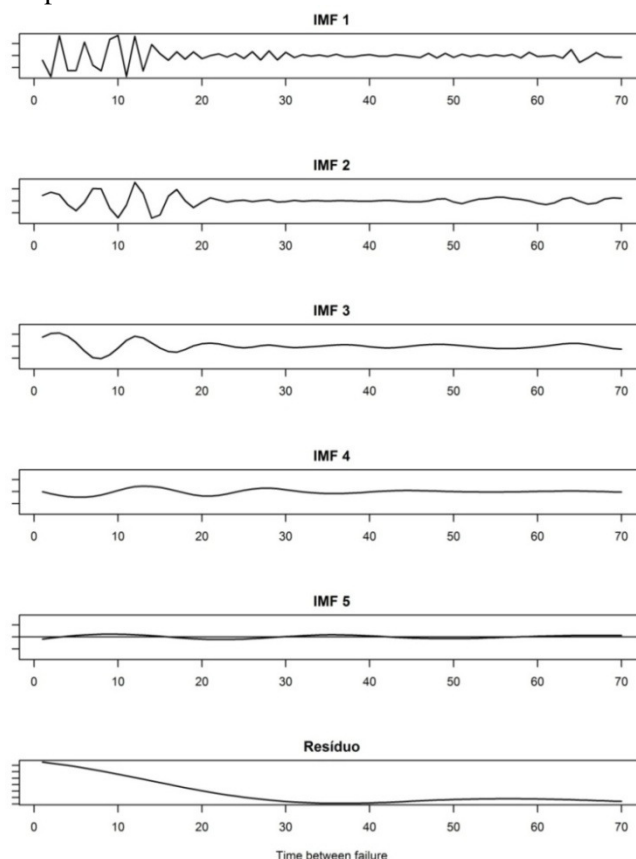


Figura 4 - Representação gráfica de cada IMF e resíduo da série de motor de submarino

Tabela 4 – Parâmetros do SVM para cada IMF e resíduo separadamente

	IMF 1	IMF 2	IMF 3	IMF 4	IMF 5	RESÍDUO
C	504.4579	1238.638	213.5289	706.9868	101.4028	1024.238
epsilon	0.000137	7.12E-05	0.002844	0.002031	0.000703	0.0279
gamma	0.388945	2.68088	10.28877	12.85873	0.100013	112.8476

Em seguida, o SVM é aplicado novamente, porém desta vez na série de dados sem decomposição nos diversos IMFs. Na figura 5 apresenta-se um gráfico único com as três séries (original, EMD+SVM, SVM) e, mais uma vez, observa-se que a aplicação do EMD melhora a capacidade preditiva do SVM. Nota-se que a previsão apenas com SVM aparentemente parece ser constante a partir da observação 18.

Na Tabela 5 são mostrados os erros de cada fase e, em cada uma delas, o EMD+SVM apresentou menor erro se comparado com SVM isolado. Os erros agregados apresentados na Tabela 6 demonstram que o erro médio do EMD+SVM é mais de duas vezes menor que o associado ao SVM.




Figura 5 - Gráfico do TBF para o motor de submarino

Tabela 5 – Erros para a série proposta com EMD+SVM e SVM

	Erros - MSE		
	Treinamento	Validação	Teste
sem EMD	0.370810154	0.008615683	0.063153197
com EMD	0.16008077	0.00673498	0.054314305

Tabela 6 – Erros agregados para as séries propostas para o motor de submarino

Erros Agregados - MSE	
sem EMD	0.26611
com EMD	0.118237

6. CONCLUSÕES (OU COMENTÁRIOS FINAIS)

A proposta do presente trabalho foi utilizar o método de EMD em conjunto com o SVM a fim de melhorar a capacidade preditiva em relação ao SVM isolado. Os desempenhos foram comparados em exemplos de aplicação envolvendo dados relacionados à confiabilidade como *Failure Time* e, especificamente, *Time Between Failure*. A partir deles, é possível estimar o *Remainig Useful Life* do sistema e tomar as ações de manutenção e de administrativas necessárias.

Em ambos os exemplos, a utilização do EMD para decompor a série original em diversas séries e a posterior aplicação SVM mostrou resultado satisfatório esperado já que este, isoladamente, apresenta bom desempenho para séries estacionárias (cada IMF) e séries monotônicas (resíduo). Ainda comparado com o SVM isolado, o EMD+SVM teve desempenho superior para cada fase (treinamento, validação e teste) e de forma agregada. Os resultados encontrados indicam que a metodologia EMD+SVM pode ser usada como ferramenta de auxílio a decisões de manutenção, prevenindo falhas e reduzindo custos.

7. REFERÊNCIAS

- SI, XS *et. al.*; Remaining useful life estimation – A review on the statistical data driven approaches; European Journal of Operational Research; Vol. 213; Ed. 1; p: 1-14; 2011.
- PECHT, M. G.; Prognostics and Health Management of Electronics; New York, NY, USA: Wiley-Interscience, 2008
- VAPNIK, V. N.; CHAPELLE, O. Bounds on error expectation for support vector machines, Neural Computation, v. 12, n. 9, p. 2013–2036, 2000.
- HAYKIN, S. Neural networks. 2ed. Upper Saddle River: Prentice Hall, 1999.
- HUANG, N. E, SHEN, Z., LONG, S.R., WU, M.L.C., SHIH, H.H., ZHENG, Q.N., YEN, N.C., TUNG, C.C., LIU, H.H., The empirical mode decomposition method and the Hilbert spectrum for non-stationary time series analysis. Proc. R. Soc. A-Math. Phys. Eng. Sci. 454A: 903-995, 1998.
- HUANG, S. Z; CHANG, J. S.; HUANG, Q. CHEN, Y. T., Monthly streamflow prediction using modified EMD-based support vector machine , Journal of Hydrology, Vol.: 511; Pag.: 764-775, 2014.
- LIU, JF et al. Remote Fault Diagnosis System Based on EMD and SVM for Heavy Rolling-mills; Engineering Solutions for Manufacturing Processes IV, PTS 1 and 2, Vol. 889-890; p. 681-686; 2014.
- YANG, Y., YU, D., CHENG, J. A fault diagnosis approach for roller bearing based on IMF envelope spectrum and SVM, Measurement: Journal of the International Measurement Confederation, vol. 40, p. 943-950, 2006.
- LIAO, Linxia & KOTTIG, Felix; Review of Hybrid Prognostics Approaches for Remaining Useful Life Prediction of Engineered Systems, and an Application to Battery Life Prediction; IEEE TRANSACTIONS ON RELIABILITY, Vol. 63, N. 1, P. 191- 207, March 2014;
- WIDODO, A & YANG, BS, Machine health prognostics using survival probability and support vector machine, Expert Systems with Applications, Volume 38, Ed. 7, 2011.
- SIKORSKA, J.Z., HODKIEWICZ, M. and MA, L.; Prognostic modelling options for remaining useful life estimation by industry; MECHANICAL SYSTEMS AND SIGNAL PROCESSING; Vol. 25, Ed. 5, P. 1803-1836; 2011.
- HUANG, N. E., WU, Z. A review on Hilbert-Huang transform: Method and its applications to geophysical studies. Reviews on Geophysics, 46: RG2006, 23p. 2008.
- YANG, Z. *et al.* An Improved Empirical AM/FM Demodulation Mode Method. 2007 INTERNATIONAL CONFERENCE ON WAVELET ANALYSIS AND PATTERN RECOGNITION. Páginas: 1049-1053, 2007.
- WANG, Y. H.; On the computational complexity of the empirical mode decomposition algorithm; PHYSICA A-STATISTICAL MECHANICS AND ITS APPLICATIONS; Vol. 400; P. 159-167; 2014.
- WANG, L. Support Vector Machines: Theory and Applications. Warsaw, 2005.
- SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. Statistics and Computing, vol. 14, p. 199–222, 2004.
- KENNEDY J & EBERHART R. Particle swarm optimization. IEEE International Conference on Neural Networks, Perth, Australia, 1995
- LINS, I. D. ; MOURA, M. C. ; ZIO, E. ; DROGUETT, E. A. L. . A particle swarm-optimized support vector machine for reliability prediction. Quality and Reliability Engineering International (Print), v. 28, p. 141-158, 2012.
- KIM, D & OH, H.-S., EMD: A Package for Empirical Mode Decomposition and Hilbert Spectrum, The R Journal, vol. 1, p. 40-46, (2009)
- XU, K., XIE, M., TANG, L. C., & HO, S. L, Application of neural networks in forecasting engine systems reliability. Applied Soft Computing Journal, 2, 255–268, 2003.
- ASCHER, H.; FEINGOLD, H. Repairable Systems Reliability: modeling, inference, misconceptions and their causes. New York: Marcel Dekker, 1984.