

# ABORDAGEM PARA APLICAÇÃO DE SOLUÇÕES DE ANALÍTICA PREDITIVA EM ATIVOS DE DINÂMICA RÁPIDA\*

Marcos de Oliveira Fonseca<sup>1</sup>  
Deusdedit Motta<sup>2</sup>  
Marlon Rosa de Gouvea<sup>3</sup>

## Resumo

A Transformação Digital é a palavra de ordem em todo o mercado mundial e na indústria não é diferente, principalmente no que se refere à Gestão de Ativos de produção. Dentre as diversas técnicas de Analítica Preditiva disponíveis, algumas se destacam pela sua capacidade de facilmente aprenderem o comportamento dos ativos a partir dos dados históricos, assim como monitorarem pequenos desvios que estejam relacionados aos mecanismos de falhas de interesse. O presente trabalho apresenta como estender uma das técnicas de Inteligência Artificial para Modelamento Baseado em Similaridade para aplicação em ativos que possuem uma dinâmica rápida de funcionamento ou de operação para seus estados estacionários. São demonstrados os resultados dessa abordagem em aplicações práticas que exemplificam como aumentar o resultado proporcionado por essa técnica na obtenção de ganhos para o desempenho dos ativos e resultados do negócio.

**Palavras-chave:** Transformação Digital; Analítica Preditiva; Gestão de Ativos e Confiabilidade; Indústria 4.0 e IOT.

## PREDICTIVE ANALYTICS SOLUTION APPROACH FOR FAST DYNAMIC ASSETS

### Abstract

Digital Transformation is the buzzword in the entire world market and in the industry is no different, especially regarding Asset Management. Among the various Predictive Analytics techniques available, some stand out for their ability to easily learn asset's behavior from historical data and being able to monitor small deviations that are related to the failure modes of interest. This paper presents how to extend the Similarity Based Modeling Artificial Intelligence's technique for application on assets that have a fast operation or working dynamics for their steady states. The results of this approach are demonstrated in practical applications that exemplify how to increase the outcomes provided by this technique for the performance of assets and the business.

**Keywords:** Digital Transformation; Predictive Analytics; Asset Management and Reliability; Industry 4.0 and IOT.

<sup>1</sup> Engenheiro Eletricista, M.Sc, GE Digital LatAm Services Delivery Leader, Belo Horizonte, MG, Brasil.

<sup>2</sup> Engenheiro de Controle e Automação, GE Digital LatAm Lead Service Engineer, Belo Horizonte, MG, Brasil.

<sup>3</sup> Engenheiro de Eletricista, M.Sc, Dr , Gerdau S.A, Brasil.

## 1. INTRODUÇÃO

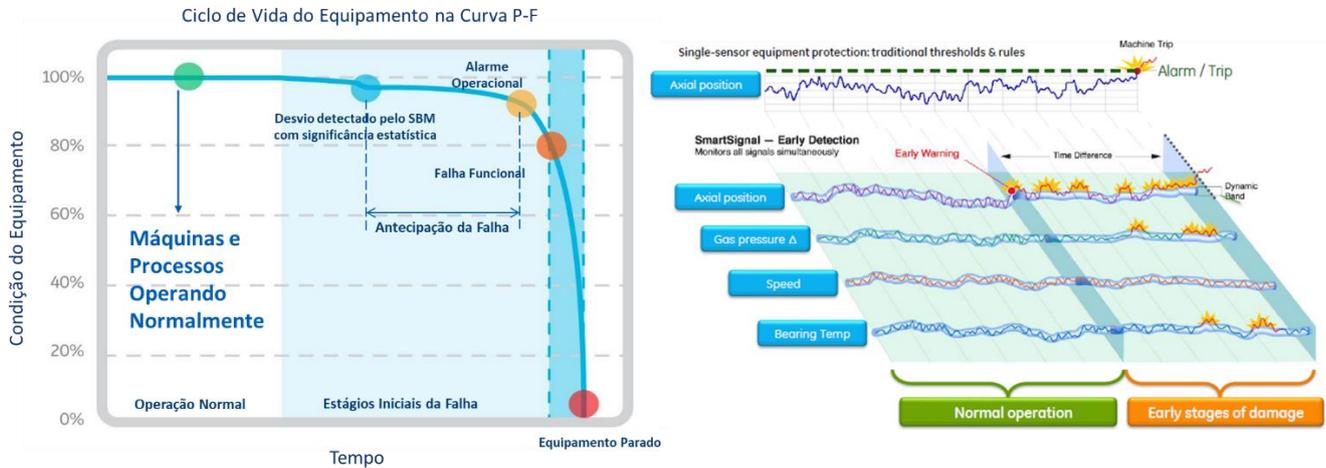
A Transformação Digital é um movimento que está bem adiantado em diversas áreas, devido principalmente ao desenvolvimento tecnológico e à disponibilização de produtos e soluções que permitem a aplicação em larga escala de técnicas até pouco tempo restritas aos centros de pesquisa ou a iniciativas de maior investimento. Nesse movimento, a Gestão do Desempenho de Ativos (*Asset Performance Management – APM*) tem uma grande relevância no foco de investimentos e expectativa de resultados para a indústria em geral. A maioria dos investimentos e retorno previstos em soluções de Internet das Coisas e Indústria 4.0 são esperados para soluções de APM [1].

De forma geral, a grande disponibilidade na indústria de sensoriamento e dados históricos de equipamentos e processos produtivos permite a alavancagem de muitas soluções para Transformação Digital e aumento de desempenho de seus processos e ativos [2]. Desde a simples estruturação e limpeza dos dados, passando pela uniformização de métricas e indicadores, assim como a aplicação de técnicas de Inteligência de Negócios e Inteligência artificial, até diferentes formas de visualização de informações. São várias as possibilidades de agregação de valor e obtenção de resultados para a indústria. O desenvolvimento tecnológico permitiu que tudo isso possa ser empregado em alta escala e custo acessível através das soluções de *Big Data* e processamento em nuvem. Diferentemente do passado recente, onde todos os dados e informações ficavam restritos aos ambientes de automação e TI industrial, com modesta capacidade de alavancagem de resultados. Um ponto muito importante a ser destacado está na qualidade dos dados gerados, que sofre influência dos sistemas de aquisição e comunicação de dados, assim como das diversas camadas de tratamento de dados. Cuidado especial deve ser tomado para garantir que a qualidade dos dados seja adequada para as necessidades das técnicas de análise empregadas, tendo em vista o paradigma “GIGO” (*Garbage In – Garbage Out*).

Historicamente, a indústria tem aplicado técnicas de analítica preditiva dentro das disciplinas de Confiabilidade de Ativos e Processos de Manutenção para a antecipação na identificação de falhas em seus equipamentos. Muitas dessas técnicas convencionais são baseadas em soluções e ferramentas que envolvem o sensoriamento ou medição de características que possam ser monitoradas e interpretadas de forma manual ou até automatizada. Entretanto, tais técnicas muitas vezes envolvem um processo de trabalho mais custoso e difícil de se fazer em alta escala, principalmente quando envolvem a interpretação de informações de forma individualizada (monovariável).

Por outro lado, novas técnicas que já estão disponíveis comercialmente há décadas [3], têm um enorme potencial de aplicação devido a sua capacidade de aprendizado relativa ao comportamento dos equipamentos, a partir de seus dados históricos, sem a necessidade de parametrizações (modelos não-paramétricos). Passando a identificar continuamente pequenos desvios no comportamento dos equipamentos, que possam estar associados a mecanismos de falhas. Essas técnicas normalmente utilizam inteligência artificial e conseguem fazer o tratamento simultâneo de todas as variáveis relacionadas entre si (multivariável), na geração de diagnósticos para predição de falhas. Portanto, com base nestas técnicas torna-se possível a obtenção de bons resultados na antecipação da ocorrência de Falhas. A curva PF apresentada na fFigura 1, ilustra graficamente o processo de antecipação de falhas proporcionado pelas técnicas com base em Inteligência artificial, tendo

como base comparativa o ponto de falha funcional do ativo. Desta forma, as equipes de confiabilidade e manutenção podem planejar as ações corretivas com calma e da forma economicamente mais viável para tomada de ações corretivas, maximizando a disponibilidade dos ativos para a produção, minimizando os custos de intervenção nos equipamentos, além do prolongamento da vida útil dos ativos.



**Figura 1.** Antecipação na curva P-F de pequenos desvios e falhas pelo tratamento multivariável  
Fonte: GE Digital

Essas novas técnicas estão por trás da maioria das soluções de Indústria 4.0 e Internet das Coisas Industrial (IIoT), no que se refere a *Digital Twin* para Análise Preditiva e APM. A técnica de Modelamento Baseado em Similaridade (*Similarity Based Modeling* - SBM), foco deste trabalho, tem se mostrado como uma das mais eficientes para a Análise Preditiva, conforme ampla aceitação do mercado e estudos recentes, [4]. Existem diversos exemplos em aplicações reais de diagnósticos de falhas em diversos tipos de equipamentos de vários segmentos industriais. Muito dos exemplos disponíveis mostram a capacidade da técnica no diagnóstico de falhas e ganhos expressivos obtidos, [5]. Novos segmentos de mercado, como manufatura, mineração e metalurgia, por exemplo, têm voltado sua atenção para o emprego desta técnica em seus processos de Transformação Digital com resultados muito satisfatórios para seus tipos de equipamentos e processos produtivos específicos, [6].

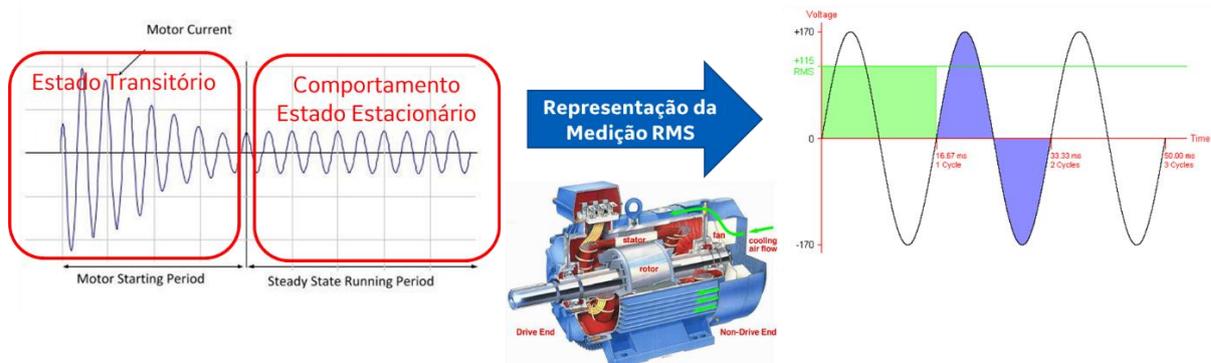
Nesse processo de adoção de novas tecnologias são encontrados desafios tanto do ponto de vista técnico, no que tange às características de funcionamento e operação dos equipamentos, assim como o nível de instrumentação e qualidade dos dados gerados, mas principalmente da Mudança de Cultura da organização. Não se pode subestimar a necessidade de investimentos e grande foco em iniciativas para ajudar as organizações no processo de Mudança da Cultura, em todas as camadas do negócio e em todos os processos de trabalho. Especificamente no que se refere à Análise Preditiva, a adoção de novas tecnologias com modernas soluções baseadas em nuvem, trazem um novo paradigma para as pessoas e processos de trabalho dentro das organizações. A falta de foco em relação às necessidades de Gestão de Mudança para ajudar na transformação da cultura das organizações coloca em risco todas as iniciativas e investimentos, assim como dificulta a obtenção de resultados. Também coloca o negócio em risco, tendo em vista o cenário cada vez mais competitivo entre as empresas e à velocidade como novos modelos de negócio surgem e empresas e negócios tradicionais sucumbem nesse processo. O

grupo Gartner em levantamento recente reconhece a necessidade das lideranças de tecnologia em dedicar maior foco e esforços junto ao RH para Mudança de Cultura das organizações. Soluções tecnológicas modernas sem a devida adoção tendem a cair em desuso e a causar frustração por parte dos investidores.

A seguir será mostrado como a técnica de SBM pode ser estendida para ativos industriais com comportamentos específicos, com dinâmicas rápidas tais como máquinas alternativas, britadores, dispositivos de laminação, tesouras, etc; muito comuns em indústrias de manufatura, mineração e metalurgia. Esses ativos até então foram pouco explorados no que se refere à forma de preparar os dados que serão coletados para representar os estados estacionários que se deseja monitorar, com a finalidade de análise e previsão de falhas.

## 2. CARACTERIZAÇÃO E PRÉ-PROCESSAMENTO DE DADOS PARA ATIVOS DE DINÂMICA RÁPIDA

Nas aplicações da técnica de SBM para Analítica Preditiva é muito comum o modelamento dos estados de funcionamento dos equipamentos como forma de aprendizado dos comportamentos dos mesmos a partir de seus dados históricos. Essa abordagem se mostra muito eficiente e de rápida implementação para os produtos de mercado. Como estados de funcionamento, podemos simplificar como os estados estacionários para os quais um conjunto de dados relacionados entre si se mantêm sem variações relevantes dentro de um certo intervalo de tempo de observação. Isso se diferencia do estado transitório, Figura 2.



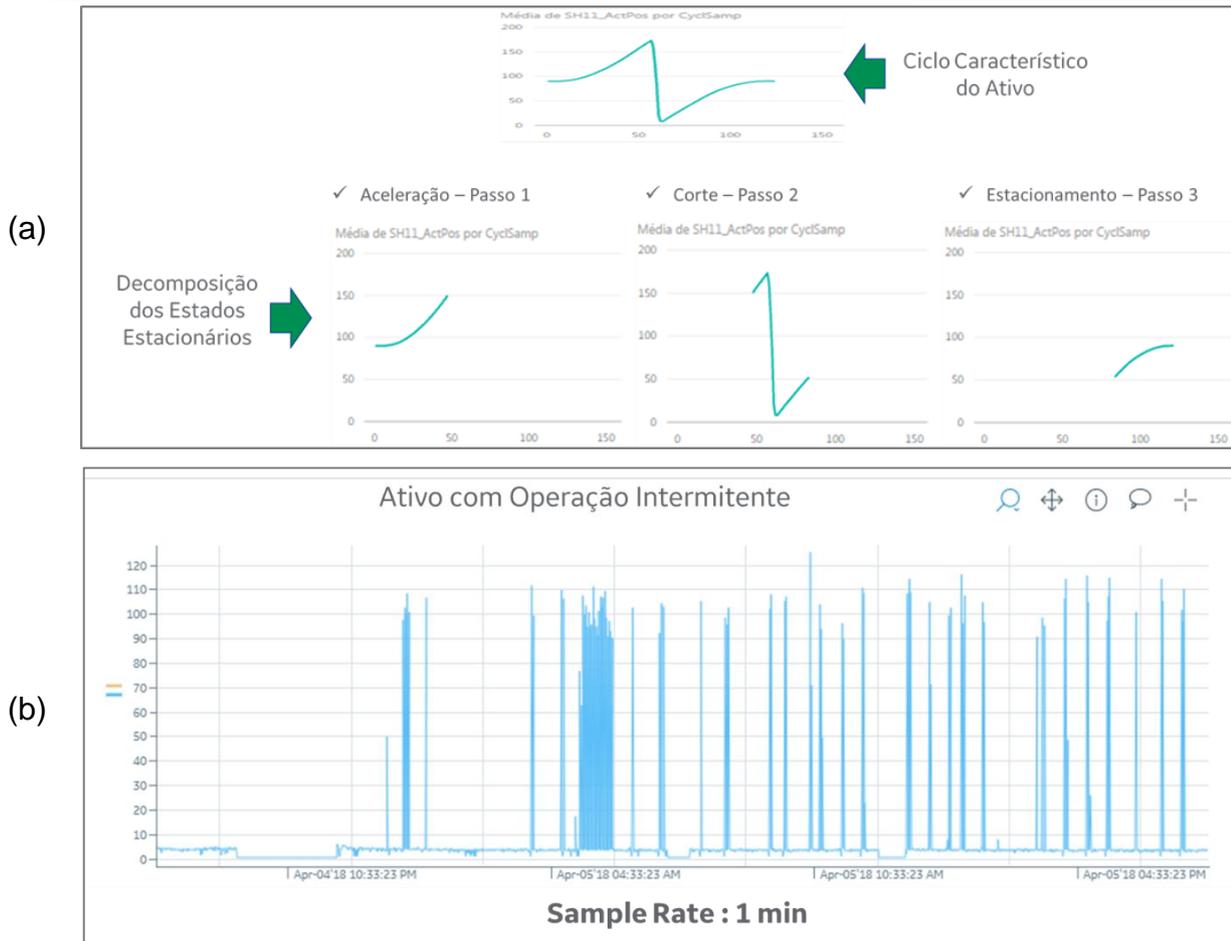
**Figura 2.** Representação dos estados de um motor a partir da medição de corrente

É possível notar pela figura que para o tempo observado, um motor apresenta o estado estacionário de sua medição de corrente conhecido como regime permanente. Se quisermos coletar a medição de corrente de forma a reconstruir o sinal senoidal na sua forma original, teríamos de fazer a aquisição de dados numa frequência maior que 2 vezes a frequência fundamental (60 Hz), de acordo com o Teorema da Amostragem. Isso significa uma amostragem abaixo de 8 ms. Entretanto, o objetivo da Analítica Preditiva é de entender pequenos desvios no comportamento a partir do estado estacionário. Dessa forma, podemos nos abstrair da medição do sinal original (instantâneo e transitório) e utilizar uma medida auxiliar como o valor RMS (corrente eficaz). Esse valor é uma boa representação do estado estacionário que se quer analisar. Tendo essa analogia em mente, podemos coletar as medições que representam os estados estacionários de interesse, tais como valores ou métricas/indicadores (RMS, média móvel, medidas estatísticas,

decomposição espectral/eventos, etc.) para alimentar o SBM, sem perda de informação relevante para a predição de falhas. Isso permite um grande ganho do ponto de vista de aquisição e comunicação de dados, assim como otimiza a carga de processamento dos mesmos. Deve ficar bem entendido que os sistemas de Analítica Preditiva não são focados em “proteção instantânea” (relés de proteção e controle) de equipamentos, mas principalmente para identificar alterações de comportamento com tendência de evolução para falhas.

Em muitas aplicações, um motor ou outro equipamento tem seu comportamento em estado estacionário alterado por condições normais de funcionamento e operação, tais como dissipação térmica, mudanças de velocidade, alterações de carga, etc. Da mesma forma, tem seu comportamento afetado por problemas associados às falhas, tais como trincas, desbalanceamentos, problemas de enrolamentos, etc. A Analítica Preditiva busca identificar os mecanismos de falhas de interesse a partir das mínimas alterações de comportamento não relacionados às condições normais. Portanto, recomenda-se que sejam determinados os estados estacionários de interesse para todas as medições disponíveis, que sejam relacionados aos modos de falha, tendo em vista também a característica multivariável do SBM no modelamento do comportamento dos equipamentos.

A determinação dos estados estacionários normais está muito relacionada aos princípios de funcionamento dos equipamentos e à sua forma de operação. Tipicamente, equipamentos submetidos a regimes contínuos de operação (turbinas, ventiladores) tem seu estado estacionário alterado em função da dinâmica de cargas e pontos de operação, normalmente que acontecem no horizonte de alguns minutos, horas ou dias. Por outro lado, certos equipamentos têm seu princípio de funcionamento caracterizado por ciclos rápidos (máquinas alternativas, tesouras, máquinas operatrizes, etc.) ou pela forma de operação intermitente (cadeiras de laminação, britadores, por exemplo) ou mesmo uma combinação destes. Nestes casos, os estados estacionários normais sofrem alterações na faixa de poucos minutos, segundos ou ainda menos, Figura 3.



**Figura 3.** Exemplo de Ativos Rápidos e seus estados estacionários – (a) funcionamento cíclico com duração total de 1 segundo, (b) operação intermitente com alterações em cerca de 30 segundos.

Para aumentar a capacidade do SBM em diferenciar o comportamento dos estados estacionários afetados por condições normais e anormais, busca-se o tratamento da medição e coleta de dados de forma a obedecer a dinâmica dos ativos, sejam eles rápidos ou não. Para tanto, podem ser utilizadas técnicas de aquisição e pré-processamento de dados com o objetivo de representar os estados estacionários normais através de métricas/indicadores que possam refletir as alterações relacionadas aos modos de falha de interesse. A técnica mais apropriada depende principalmente dos modos de falhas de interesse, medições disponíveis, taxas de coleta consideradas pelo SBM e dinâmica dos estados estacionários a serem modelados. Em certos casos, faz-se necessária a decomposição das medições em relação aos eventos e seu sequenciamento, de forma a permitir o modelamento dos dados relacionados entre si. Se esses cuidados não forem observados adequadamente, os estados estacionários poderão ser confundidos com ruídos de medição e coleta, instabilidades do equipamento, mascaramento de comportamentos ou outro efeito indesejado que venha a limitar a capacidade de predição do SBM.

Considerando as novas soluções para Análise Preditiva em nuvem, em muitas aplicações o tempo de coleta das medições fica na ordem de 1 minuto, sendo considerado ativo de dinâmica rápida estados estacionários observados com dinâmica abaixo de 2 minutos. Dessa forma, a utilização da técnica adequada para

aquisição e pré-processamento de dados aumenta a capacidade do SBM para detecção de falhas, otimiza a comunicação e desempenho do sistema e potencializa a obtenção dos resultados esperados. É importante observar que a qualidade dos dados pode estar associada aos dados em si (ruídos, erros grosseiros, defeitos, etc.) assim como à não utilização da técnica de aquisição e pré-processamento adequadas, que podem minimizar a ocorrência de alarmes falsos.

Outro ponto muito interessante no que se refere aos ativos rápidos está na estabilização, retenção/persistência e sincronização das medições dos estados estacionários, que são importantes para que o SBM possa identificar de forma precisa os mecanismos de falhas que estejam ocorrendo.

### 3. EXEMPLOS PRÁTICOS

O uso de técnicas de pré-processamento de dados, em soluções que empreguem o SBM, se faz necessário para garantir que o estado operacional avaliado pelo modelo apresente a persistência adequada para detecção de desvios que antecedam potenciais falhas no equipamento. A estabilização dos dados do estado estacionário deve ser considerada em casos em que o equipamento apresente intermitência de operação ou transientes importantes para detecção dos modos de falha.

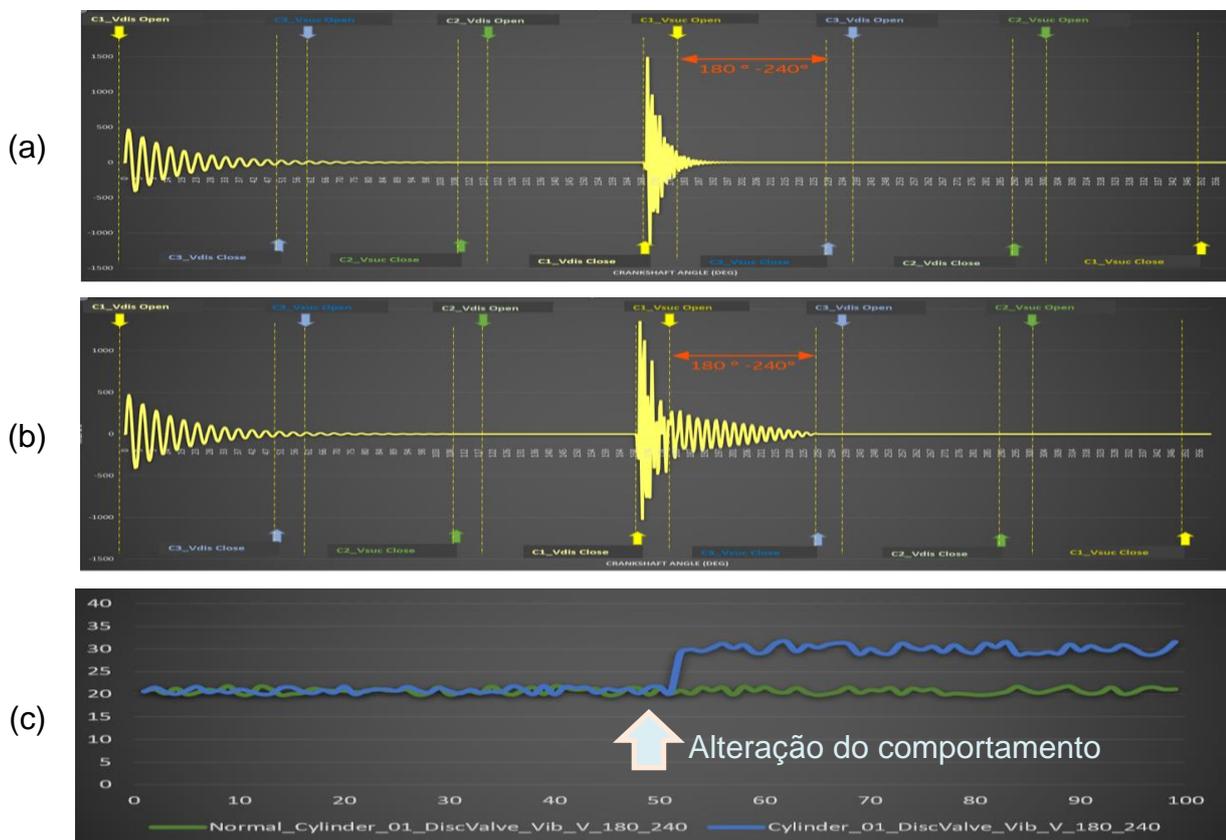
Na Figura 4 é apresentado um exemplo de estabilização do sinal de corrente de uma cadeira de laminação. A operação deste tipo de equipamento é caracterizada por ciclos intermitentes de carga enquanto o produto laminado sofre a conformação termomecânica. A intermitência está associada à passagem de segmentos de material pelo equipamento em função do ritmo de produção e necessidades de conformação requeridos. Os sinais intermitentes, que compõem um dado estado operacional avaliado pelo SBM, são então estabilizados pelo pré-processamento através da medida de média móvel filtrada enquanto o produto laminado passa pela cadeira. Nota-se, na Figura 4, que o sinal pré-processado estabiliza e retém os estados estacionários de interesse – neste caso, estados representativos do equipamento sob carga. Outras medidas estatísticas podem ser utilizadas, dependendo das características de operação, para refinamento do comportamento associado à cada variável do processo: cálculos de máximos, mínimos, variância e etc. Importante observar que a aplicação de medidas estatísticas lineares preserva as relações e correlações entre os dados associados ao comportamento do ativo, desde que todos os dados dinâmicos sejam submetidos aos mesmo pré-processamento. Principalmente para técnicas multivariáveis, como no caso do SBM.



**Figura 4.** Exemplo de pré-processamento para medições de equipamento com operação intermitente.

Outro exemplo que podemos considerar para emprego de pré-processamento são os efeitos/eventos rápidos associados a modos de falha específicos. O emprego de bombas alternativas é bastante difundido na indústria de mineração para bombeamento de fluidos com características reológicas especiais: poupa de minérios, rejeito e lamas em geral. Os eventos observados durante o ciclo de revolução do virabrequim destas bombas são de fundamental importância na caracterização de modos de falha desta classe de equipamento.

A Figura 5 apresenta a simulação de um exemplo de pré-processamento para sinal de vibração associado à uma válvula de retenção de descarga de uma bomba alternativa.



**Figura 5.** Exemplo de pré-processamento para sinal de vibração associado à uma válvula de uma bomba alternativa – (a) Efeito da vibração durante comportamento normal, (b) Efeito da vibração para falha de vazamento durante o fechamento da válvula, (c) Sinal RMS da faixa angular de 180° a 240° da revolução do virabrequim, indicando comportamento normal – antes da alteração – e comportamento quando da existência da falha de vazamento da válvula – após alteração do comportamento.

Deve-se enfatizar que máquinas alternativas como as mostradas no exemplo anterior tem funcionamento cíclico com período da ordem de 1 segundo e eventos e efeitos manifestados na casa dos milissegundos, que exigem coleta de dados na faixa de microssegundos. Portanto, o não pré-processamento desses sinais exigiria uma alta capacidade de aquisição/comunicação e maior custo para utilização de soluções em nuvem, devido ao alto volume dados a serem processados.

#### 4. CONCLUSÕES

A abordagem apresentada tem como foco a técnica de SBM para aplicações de Analítica Preditiva. Entretanto, esta abordagem pode ser aplicada para técnicas similares. Seu objetivo consiste em segregar os dados que sejam relacionados entre si para os estados estacionários que descrevem o comportamento normal do equipamento. Desta forma, facilita a aplicação das técnicas de modelamento, aumenta a capacidade de predição dos modelos e, conseqüentemente, a precisão dos diagnósticos para aplicações de Analítica Preditiva.

Os principais benefícios esperados pela utilização da abordagem apresentada são:

- Estender a aplicação de técnicas de Analítica Preditiva para ativos de dinâmica rápida, muito comuns em determinados seguimentos industriais
- Aumentar a capacidade de predição dos sistemas de Inteligência Artificial através da segregação de dados relacionados a estados estacionários
- Melhoria do desempenho dos sistemas de Analítica Preditiva através do pré-processamento de dados e redução do volume de dados enviados para a nuvem
- Aumento dos ganhos proporcionados pela Analítica Preditiva
- Aumento dos resultados proporcionados para o negócio das empresas

A determinação das necessidades de aquisição e pré-processamento dos dados dependerá da técnica de modelamento e características dos produtos utilizados, assim como o correto entendimento do funcionamento e forma de operação dos equipamentos considerados.

O domínio das técnicas e tecnologias envolvidas são requisitos para maximização de cada benefício proporcionado.

#### REFERÊNCIAS

1. World Economic Forum “Industrial Internet of Things: Unleashing the Potential of Connected Products and Services”, 2015.
2. Fonseca, M. O; “Aplicação de Técnicas de Data Analytics para Melhoria do Desempenho de Processos”, XVIII Seminário de Automação e TI Industrial, ABM, São Paulo, 2014.
3. Doan, D. S; “Predictive Analytics in Equipment Reliability Programs”, Focus on Nuclear Power Generation, November 2009.
4. Marins, M. A; Ribeiro, F. M. L; Netto, S. L; Silva, E. A. B; “Improved Similarity-Based Modeling for the Classification of Rotating-Machine Failures”, Journal of the Franklin Institute, July 2017.
5. Relatórios semanais de casos reais de diagnósticos de falhas do site <http://www.geautomation.com/catch-of-the-week>.
6. Gouvêa, M. R; Eleutério, F. A; Abreu, M. V; Pires, A. V; Yano, F. I; Pereira, V. G; “Indústria 4.0: Gestão de Ativos na Era Digital”, ABMWeek, São Paulo, 2018.