UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

ESCOLA DE ENGENHARIA

TRABALHO DE CONCLUSÃO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Desenvolvimento de módulo de predição de comportamento para manutenção inteligente de atuador elétrico

Autor: Fabrício da Silva Stein

Orientador: Prof. Dr. Carlos Eduardo Pereira

Porto Alegre, 2014.

Sumário

Sumário ii
Agradecimentos iii
Resumo iv
Abstract iv
Lista de Figuras v
Lista de Tabelas vi
Lista de Símbolos vii
Lista de Abreviaturas e Siglas viii
1 Introdução 1
1.1 Objetivo 2
1.2 Estrutura do Trabalho 2
2 Revisão Bibliográfica 4
2.1 Manutenção 5
2.1.1 Manutenção Corretiva 6
2.1.2 Manutenção Preventiva 6
2.1.3 Manutenção Preditiva 6
2.1.4 Manutenção Proativa 6
2.2 Watchdog Agent™ 6
2.3 ARMA 8
3 Materiais e Métodos 9
3.1 Descrição do estudo de caso 9
3.2 Análise do Watchdog Agent™ para Matlab™ 12
4 Desenvolvimento do algoritmo 15
5 Simulações e resultados 27
6 Conclusões e Trabalhos Futuros 31
7 Referências 32

Agradecimentos

O agradecimento deve ser feito àqueles que nos ofereceram algum tipo de suporte durante uma jornada, seja ela acadêmica, na vida pessoal ou profissional. Dessa forma eu gostaria de agradecer primeiramente à minha família (meus pais, irmão e mascote) que, sempre que necessário, foram prestativos e não hesitaram em oferecer o que tinham de melhor para mim.

Gostaria de agradecer à minha namorada Ana Paula Culau, que sempre me apoiou, trazendo calma nos momentos de stress e alegria nos momentos de lazer. Quero agradecer também ao meu amigo Leonardo Faria, que me ofereceu um teto na volta da minha viagem e aos amigos Alexandre Andreoli e Marcos Zuccolotto que me ajudaram no final dessa caminhada rumo à graduação.

Resumo

Manutenção inteligente tem se mostrado crucial nos atuais sistemas de produção. Graças a recentes avanços na área de manutenção inteligente, é possível diagnosticar o estado de peças que compõem um sistema baseando-se na coleta de informações de sensores. O *Watchdog Agent™* é uma ferramenta para análise de degradação e predição de falhas, desenvolvida pelo *IMS Center*. O objetivo deste trabalho é fazer uso dessa ferramenta de diagnóstico para prever possíveis falhas e até a data de quebra de peças de um equipamento, utilizando como estudo de caso a bancada montada na UFRGS a partir da válvula elétrica CSR06, produzido pela empresa Coester. Para isso, foi desenvolvido um programa com a ferramenta Matlab™ que é capaz de diagnosticar a atual saúde do equipamento e, a partir do treinamento de um algoritmo de predição, apresentar o comportamento futuro deste. O que se espera deste trabalho é ter um algoritmo capaz de determinar uma provável data de quebra de uma peça ou equipamento baseando-se no seu comportamento prévio ou em alguma simulação deste comportamento, informação esta que é entregue para sistemas de otimização de cadeias de suprimento (peças de reposição), buscando permitir uma redução de custos do processo de manutenção.

PALAVRAS-CHAVE: Manutenção Inteligente, Algoritmo de Predição, Provável Data de Quebra

Abstract

Intelligent maintenance has shown itself as being crucial on today's production systems. Thanks to recent development in the intelligent maintenance field, it is possible to diagnose the health of a machine's part of a system based on the sensor's response. The Watchdog Agent™ is a toolbox approach for degradation assessment and failure prediction, developed by IMS Center. The aim of this work is to use this diagnose tool to forecast possible failures and even the breakdown of the parts, using as study case the test bench mounted at UFRGS from the electric valve CSR06, produced by Coester. For that, it was developed in Matlab™ a script that is capable of diagnose the actual health of the equipment and, from the training of a prediction algorithm, present the future behavior of the equipment. What it is expected from this project is having an algorithm capable of present a probable breakdown date of a determined equipment based on its past behavior or on some simulation of this behavior, this information can be delivered to supply chain optimization systems, aiming reduce costs in the maintenance process.

KEYWORDS: Intelligent Maintenance, Prediction Algorithm, Probable Breakdown Date

Lista de Figuras

Figura 1: Representação do conceito de Valor de Confiança. 7
Figura 2: Conjunto atuador-válvula 10
Figura 3: Bancada de testes. 11
Figura 4: Acelerômetros posicionados (a) na estrutura do freio, (b) no sem-fim e (c) dentro do compartimento do motor do atuador elétrico. 11
Figura 5: Interface gráfica do Watchdog Agent™ para Matlab™ 13
Figura 6: Diagrama de funcionamento do programa. 17
Figura 7: Curva dos CV's obtida no exemplo. 17
Figura 8: Perfil de degradação simulado. 18
Figura 9: Perfil de degradação utilizado na escolha da ordem do modelo. 20
Figura 10: Comparação entre sinal ruidoso e suavizado. 20
Figura 12: Perfil de degradação após diferenciação das amostras da série. 21
Figura 13: Gráfico de ACF e PACF após diferenciação das amostras da série. 22
Figura 14: Distribuição residual do modelo proposto. 23
Figura 15: Previsão de comportamento baseado no modelo proposto. 23
Figura 16: Representação da data de quebra no programa. 25
Figura 17: Escolha da função de probabilidade que apresenta o menor erro. 26
Figura 18: Perfil de CV para início da simulação. 27
Figura 19: Perfil de CV e perfil de degradação. 27
Figura 20: Vetor utilizado para treinamento do modelo. 28
Figura 21: Apresentação do modelo proposto no Matlab™. 28
Figura 22: Resultado da predição para o modelo proposto. 29
Figura 23: Aproximações da probabilidade de quebra à funções conhecidas. 29
Figura 24: Arquivo de resultados do ensaio. 30

Lista de Tabelas

Tabela 1: Descrição dos ciclos simulados no sistema atuador-válvula. 12

Lista de Símbolos

A	ampère(s)
Nm	newton(s)metro
kPa	quilopascal(is)
V	volt(s)
$v(t)$	variável de distúrbio no tempo t
$e(t)$	ruído branco, distúrbio no tempo t
λ	usado para denotar variância
q, q^{-1}	operadores de deslocamento de adiantamento e atraso na série
$a_{1,2,\ldots na}$	coeficientes do processo AR
$c_{1,2,\ldots nc}$	coeficientes do processo MA

Lista de Abreviaturas e Siglas

AR Autoregressive (autoregressão)

ARIMA Autoregressive Integrated Moving-Average

ARMA Autoregressive Moving-Average (autoregressão com média móvel)

CV Confidence Value (Valor de Confiança)

IEEE Institute of Electrical and Electronics Engineers

MA Moving Average (média móvel)

NBR Norma Brasileira Regulatória

1 Introdução

Manutenção inteligente é cada vez mais crucial nos sistemas atuais. A manutenção consiste em uma série de eventos, técnicas e medidas tomadas a fim de se ter um sistema operante em sua máxima eficiência. À medida que os equipamentos são utilizados, fatores como corrosão, infiltrações e acúmulo de sujeira fazem com que o funcionamento de determinadas peças fique comprometido, necessitando muitas vezes a troca da peça ou de todo o equipamento. Num momento em que o mercado exige grande demanda a baixos custos, o tempo gasto com manutenção de equipamentos deve ser o menor possível, de modo a garantir que a fábrica não terá sua linha de produção parada por muito tempo (LEE ET AL., 2006; LU, DUROCHER, STEMPER, 2009; NIU, YANG, 2010).

Tendo seu início durante a Revolução Industrial, a manutenção muitas vezes acabava sendo deixada em segundo plano no planejamento de custos e investimentos das empresas. Em meio a um maquinário simples do ponto de vista construtivo, a manutenção não trazia grande dificuldade para o operador, e esta acontecia apenas quando uma peça quebrava fazendo a máquina interromper seu funcionamento. A prevenção de falhas então não era um campo que atraía grande interesse ou que rendesse algum retorno, diferente do que se tem hoje (GONÇALVES, 2011).

Esta prática de trocar as peças assim que elas quebram é chamada de manutenção corretiva, é a primeira noção de manutenção que se tem conhecimento (MARÇAL, 2000). Na manutenção puramente corretiva, a máquina com defeito deve parar para que se faça a troca das peças e isto acarreta a interrupção da linha de produção à qual a máquina está inserida e, além disso, tem-se um grande desperdício de tempo útil na análise de qual peça da máquina é a defeituosa. À medida que a complexidade das máquinas foi crescendo e o custo com paradas inesperadas se tornou cada vez maior, surgiu a necessidade de se tomar medidas preventivas com relação às falhas (GONÇALVES, 2011).

Com a crescente mecanização dos processos industriais nas décadas de 50 e 60, resolveu-se realizar revisões gerais periódicas dos equipamentos em funcionamento, é nesse panorama que o conceito de manutenção preventiva começa a virar realidade (NUNES, 2001). Nesse tipo de manutenção, assume-se uma degradação das peças baseando-se no histórico de uso das mesmas, a troca planejada e realizada periodicamente visa diminuir o tempo parado das máquinas devido a falhas. Essa técnica resulta muitas vezes em perda de produtividade, uma vez que a peça ainda pode apresentar um bom nível de funcionamento ou porque a quebra pode acontecer antes do usual (LEE ET AL., 2003).

A quantidade de investimentos direcionados à área de manutenção teve seu crescimento significativo no início dos anos 70, foi quando a evolução dos computadores trouxe novas técnicas de manutenção (GONÇALVES, 2011). A partir de então, a necessidade de se ter máquinas operando continuamente sem falhas é cada vez mais crítica, o que justifica uma preocupação maior com a manutenção destas. Para se ter uma noção, um minuto com a linha de montagem parada no setor automobilístico pode custar

até $ 20,000. Surge então o conceito de manutenção preditiva, que vem com a ideia de detecção de um desempenho aquém do projetado para o sistema, implicando em um comportamento de falha para a máquina (LEE ET AL., 2003).

A manutenção é usualmente dividida segundo essa evolução histórica em três tipos: corretiva, preventiva e preditiva. Apesar de se ter essa divisão clássica, em meio ao grande desenvolvimento na área de sensoriamento e de atuadores, um novo conceito surge: a manutenção proativa.

Quando máquinas inteligentes – máquinas com sofisticados sensores e componentes capazes de entregar informação sobre o estado e desempenho do equipamento - são conectadas em rede e remotamente monitoradas e quando se tem informação analisada a partir delas, torna-se possível a realização de um serviço de manutenção inteligente, ou proativa. Isso inclui apontar exatamente o componente da máquina que está apresentando problemas e iniciar o processo de requisição de uma peça substitutiva. Na manutenção proativa pode-se monitorar o equipamento em tempo real, realizar diagnósticos a respeito da atual saúde das peças e até agir sobre o equipamento caso haja necessidade. Sendo assim, o comportamento de degradação de desempenho pode ser usado para antever um comportamento inaceitável para o sistema, oferecendo a possibilidade de troca da peça defeituosa antes que isso ocorra (LEE et al., 2004). É nesse cenário que o Centro de Sistemas de Manutenção Inteligente (IMS *Center*) desenvolveu a ferramenta de diagnóstico Watchdog Agent™, capaz de diagnosticar e quantificar a perda de desempenho de um equipamento em monitoramento.

1.1 Objetivo

O objetivo básico desse trabalho é ampliar as capacidades do Watchdog Agent™ desenvolvido até então, introduzindo um módulo capaz de estimar o tempo de vida útil de uma determinada peça, analisando dados recolhidos dos sensores de vibração acoplados à válvula elétrica CSR06, produzida pela empresa Coester, uma empresa gaúcha líder nacional no mercado de atuadores elétricos para válvulas e que possui forte inserção no setor de óleo e gás (especialmente fornecendo atuadores para a Petrobras) e saneamento. A partir da ferramenta de diagnóstico Watchdog Agent™, um histórico de diagnósticos ou uma simulação desse histórico será usado para predição do comportamento da peça utilizando algoritmos de séries temporais no ambiente Matlab™.

1.2 Estrutura do Trabalho

O trabalho está organizado da seguinte maneira:

No Capítulo 2 são apresentados alguns conceitos importantes para o entendimento do trabalho. Além disso, será feito o desenvolvimento do estado da arte baseando-se na literatura de manutenção inteligente.

No Capítulo 3 serão discutidas as ferramentas utilizadas para o desenvolvimento do trabalho, abordando a parte de *hardware* (válvula elétrica) de onde foram obtidas as medidas de vibração e a parte de *software* onde se desenvolveu a programação.

No Capítulo 4 será explicado o desenvolvimento do algoritmo, explicando como o modelo criado a partir de algoritmos de predição funciona e se aplica ao caso de estudo.

No Capítulo 5, abordam-se os resultados obtidos através do desenvolvimento do sistema computacional na ferramenta Matlab™.

No Capitulo 6 desta monografia são apresentadas as principais conclusões deste trabalho e perspectivas futuras.

2 Revisão Bibliográfica

Muitos trabalhos na área de manutenção preditiva e proativa vêm sendo desenvolvidos, principalmente a partir da década passada. Alguns de maior relevância para o presente trabalho foram separados e são apresentados neste Capítulo. Os casos de aplicação são os mais diversos e variam bastante na metodologia e modelagem de caso para caso, mas algumas ferramentas acabam tendo fins compartilhados e podem muitas vezes servir para um trabalho futuro. A seguir serão apresentados alguns trabalhos importantes relacionados com a presente monografia:

- No artigo de LEE e NI (2002), os autores trazem o inovador conceito da ferramenta de prognóstico Watchdog Agent™, que, segundo os autores, teria um impacto dramático no futuro da indústria. Nesse trabalho o IMS *Center*, um instituto norte-americano de pesquisa aplicada e vinculado à Universidade de Cincinnati, apresenta conceitos iniciais do que seria necessário para que a criação de tal ferramenta fosse realizada, desde a apresentação de métodos estatísticos até o conceito de índice de confiança – que mais tarde passou a ser chamado *Confidence Value* (CV), ou valor de confiança, que é a representação quantitativa da saúde ou estado do equipamento ou peça. Outro conceito importante apresentado remete às características do algoritmo de predição, é dito que para se capturar o comportamento dinâmico do índice de desempenho a fim de predizer a necessidade de manutenção, deve-se utilizar modelos dinâmicos, como o ARMA (*Autoregressive Moving Average).*
- Em LEE et al. (2004), a ferramenta de prognóstico Watchdog Agent™ vem formalizada através de conceitos matemáticos juntamente com a troca de paradigma, onde os autores propõem mudar do tradicional “falha e conserto” para “predizer e prevenir”. São apresentados métodos e referências utilizados para o desenvolvimento da ferramenta, assim como capacidades e resultados da mesma, provando sua eficiência.
- No trabalho de LEE et al. (2006), apresenta-se o contínuo desenvolvimento da ferramenta de prognóstico do IMS *Center*. O que este artigo traz como principal diferença para o anterior são os casos de aplicação do produto, exemplos de implementação como a previsão de desempenho de rolamentos e a detecção de falha em uma rede industrial são abordados.
- Em GONÇALVES (2007), abordou-se o uso de técnicas de processamento de sinais e métodos estatísticos como os utilizados no caso deste trabalho, mais especificamente a transformada *Wavelet Packet* e o método de Regressão Logística. O caso de estudo foi também uma válvula elétrica produzida pela Coester, porém foi feita a modelagem em simulação com os dados do fabricante, não se utilizando dados reais do atuador. O autor também desenvolveu um sistema de classificação de falhas usando mapas auto-organizáveis.
- FACCIN (2011) apresentou a metodologia desenvolvida por (LEE et al., 2004) aplicada à fusão de sensores na bancada de testes da válvula elétrica Coester

CSR06, localizada na UFRGS. São apresentados os métodos de extração de informação dos sensores espalhados pela bancada e que serviram de base para os ensaios realizados no presente trabalho. Na sua avaliação, quando projetada corretamente, uma arquitetura de fusão de sensores pode melhorar a qualidade do sensoriamento do processo.

- No trabalho de GONÇALVES (2011), abordou-se a implementação de um sistema de manutenção inteligente embarcado, comparando o uso de transformada *Wavelet Packet* e mapas auto-organizáveis com filtros adaptativos, na intenção de detectar, classificar e prever falhas em atuadores elétricos.
- Recentemente, LAZZARETTI (2012) abordou mais uma vez a válvula da Coester CSR06, utilizando os dados de vibração coletados para comparar a ferramenta Watchdog Agent™ nos ambientes Matlab™, LabVIEW™. A autora utilizou ferramentas de geração automática de código em conjunto com o código do IMS *Center* a fim de analisar o desempenho de cada uma das plataformas estudadas. Pode-se entender deste trabalho também que os gráficos de *Confidence Value* (CV) – saúde da peça - encontrados apresentam mudanças bruscas de CV ao longo do ensaio, isso se deve às injeções de falhas grosseiras no atuador (falhas estas referentes às leituras de comportamento da válvula funcionando com restrição de abertura e fechamento, engrenagens desgastadas e com dentes quebrados), numa situação real de degradação espera-se que a curva seja mais suave.

Dos trabalhos de LEE et al. (2002, 2004, 2006), pode-se observar uma clara evolução do produto Watchdog Agent™, desde a formulação da ideia a partir de *Workshops* até a escolha de métodos estatísticos para serem aplicados na ferramenta. Nos outros trabalhos abordados, os autores estudaram ou o comportamento da válvula CSR06 em si - como GONÇALVES (2007, 2011), ou o uso da válvula com o diagnóstico disponibilizado pelo programa do IMS *Center*. Este trabalho visa utilizar os dados de vibração extraídos por FACCIN (2011) do atuador a fim de aplicar um algoritmo de predição de comportamento baseado em séries temporais. Sendo este estudo direcionado para o desenvolvimento de um sistema de manutenção integrado, onde outros módulos de simulação de cadeias de suprimento possam fazer uso de informações (como a predição do comportamento do equipamento) provindas de equipamentos instalados. Este trabalho faz parte do projeto I2MS2C, desenvolvido pela UFRGS em colaboração com as universidades de Münster (Alemanha) e UFSC e FURG (Brasil) no âmbito do programa Bragecrim (Iniciativa Brasil-Alemanha para Pesquisa Colaborativa em Tecnologia de Manufatura financiada pelas agências CAPES e DFG), que tem como objetivo apoiar e financiar projetos conjuntos de pesquisa entre grupos de pesquisa brasileiros e alemães na área de tecnologia de manufatura avançada.

2.1 Manutenção

Manutenção é o processo de modificar um sistema ou componente a fim de corrigir falhas, melhorar desempenho ou outros atributos, ou ainda adaptá-lo a outro ambiente (IEEE, 1990). Qualquer equipamento que está em funcionamento está sujeito a fatores de

deterioração como poeira, corrosão, falta de lubrificação, entre outros. Estes fatores levam os componentes a apresentar menor eficiência até a sua ruptura ou quebra e são eles que devem ser monitorados a fim de se evitar paradas inesperadas no processo produtivo, evitando gastos desnecessários para a empresa.

Ao longo do desenvolvimento da indústria e de seus métodos, dois tipos principais de manutenção foram utilizados: a manutenção corretiva e a manutenção preventiva. Apesar disso, com o atual desenvolvimento tecnológico há dois novos enfoques nesse contexto: a manutenção preditiva e a manutenção proativa (LAZZARETTI, 2012).

A seguir são apresentados alguns conceitos sobre as principais técnicas de manutenção empregadas desde o início do seu uso até os dias atuais.

2.1.1 Manutenção Corretiva

Segundo a Norma Brasileira Regulatória (NBR) 5462, de 1994, entende-se por manutenção corretiva um reparo executado após a ocorrência de uma pane, destinado a recolocar um item em condições de executar uma função requerida.

2.1.2 Manutenção Preventiva

Manutenção preventiva é definida como sendo uma técnica executada especificamente para prevenir a ocorrência de falhas (IEEE, 1995).

2.1.3 Manutenção Preditiva

Conforme a ASSOCIAÇÃO BRASILEIRA DE NORMAS E TÉCNICAS (1994), a manutenção preditiva permite garantir uma qualidade de serviço desejada, com base na aplicação sistemática de técnicas de análise, utilizando-se de meios de supervisão centralizados ou de amostragem, para reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva.

2.1.4 Manutenção Proativa

A manutenção proativa é um avanço em relação às estratégias de manutenção preventiva e preditiva, pois além de se aplicar todos os conceitos referentes à manutenção preditiva, como o monitoramento do equipamento em função do desgaste ocorrido, pode-se diagnosticar e quantificar a perda de desempenho e atuar – de forma automática – sobre o sistema. No caso de uma falha ser detectada, o sistema pode automaticamente reconfigurar-se (atuar) de forma a continuar operando, ainda que de maneira degradada, até a ocorrência da manutenção. Essa monitoração, diagnóstico e predição de falhas podem ser alcançadas através do uso de sistemas embarcados, possibilitando a realização de análises em tempo real (GONÇALVES, 2011).

2.2 Watchdog Agent™

A ideia principal dessa ferramenta, desenvolvida pelo IMS *Center*, é coletar os dados de monitoramento do sistema a qual está inserida e usá-los para fins de manutenção inteligente. Com a extração de sinais dos sensores, segue-se os passos no algoritmo: aplica-se uma técnica de processamento de sinais a esses dados; talvez seja necessário também passá-los por uma etapa de redução de dimensionalidade, se o número de

amostras for muito grande; por fim, aplica-se um algoritmo para classificação das características, de onde se obtém um índice de desempenho (LAZZARETTI, 2012).

Da proposta de LEE et al. (2004), tem-se que a função de avaliação quantitativa da saúde do equipamento baseia-se na sobreposição entre as assinaturas mais recentes observadas e aquelas observadas durante o comportamento do produto em condições normais. Essa sobreposição é expressa através do chamado *Confidence Value* (CV), ou valor de confiança, que varia entre valores de zero a um, com CV's mais perto de um significando um desempenho normal e valores perto de zero significando falha ou desempenho pobre. Pode-se ver na Figura 1 um exemplo de uso do valor de confiança: no gráfico, à esquerda tem-se o comparativo entre o comportamento normal e o comportamento do ensaio – de um equipamento degradado, provavelmente – e à direita pode-se notar o decréscimo no CV, indicando um desempenho falho do sistema em questão.

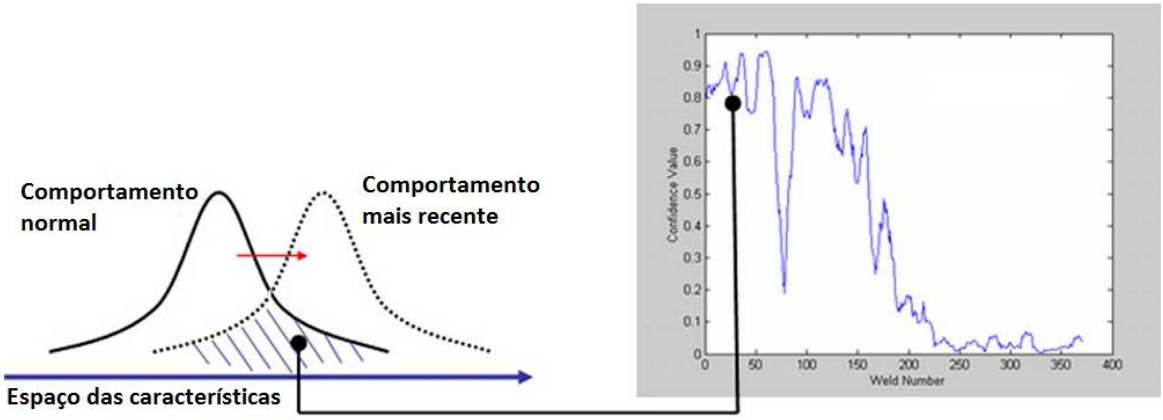

Figura 1: Representação do conceito de Valor de Confiança.
Fonte: LEE et al. (2004).

O Watchdog Agent™ Toolbox é um conjunto de ferramentas para a análise de desempenho e diagnóstico de falhas. Ele é composto por diversos módulos: Processamento de Sinal e Extração de Características, onde estão à disposição os métodos de Energia das bandas de frequência da Transformada de *Fourier*, de Momentos da Transformada Tempo-Frequência, de Momentos da Transformada *Wavelet* e de Energia da Transformada *Wavelet*; Avaliação de Desempenho, onde se tem os métodos de Regressão Logística e Reconhecimento Estatístico de Padrões; Detecção de Falhas, com os métodos de Mapa Auto-organizáveis, Redes Neurais e Clusterização Hierárquica; Predição de Saúde, composto pelos métodos de modelo ARMA (*Autoregressive Moving-Average*) e *Match Matrix* (LAZZARETTI, 2012). Infelizmente, para Matlab™ não se tem, até o momento, a disponibilidade do módulo de Predição de Saúde. A base para este trabalho será o código disponível para desenvolvimento no Matlab™, e o objetivo será acoplar este código a outro com função de previsão de falhas.

2.3 ARMA

A família mais simples de séries temporais é a autoregressiva, a qual generaliza o conceito de regressão para representar a dependência linear entre uma variável e as suas antecessoras na série. A ordem de um modelo AR expressa quantos valores passados da série são incluídos no modelo (MEKO, 2013).

O modelo MA (*Moving-Average*) é uma forma de modelo ARMA em que a série temporal é considerada como uma média móvel (desigualmente ponderada) de uma série de "choques aleatórios" ao longo do tempo – e como esses "choques" impactam na tendência detectada pelo processo AR. A letra *q* geralmente é utilizada para expressar a ordem do modelo MA (MEKO, 2013).

As funções AR tem uma memória relativamente grande, uma vez que o valor atual é correlacionado com todos anteriores, sendo assim, os processos AR não podem representar séries de poucos valores. Uma família de processos que têm esta propriedade de "memória curta" são as de MA (*Moving-Average*), ou média móvel. Os MA são uma função de um finito, e geralmente pequeno, número de inovações passadas. Combinando-se as propriedades de processos AR e MA pode-se definir processos ARMA, que resulta em uma ampla e flexível família de processos úteis na representação de muitas séries temporais (ALONSO et al., 2012). Mais sobre processos ARMA será discutido no Capítulo 4.

3 Materiais e Métodos

3.1 Descrição do estudo de caso

O estudo de caso deste trabalho é o mesmo dos trabalhos de FACCIN (2011) e LAZZARETTI (2012): a bancada de testes composta por um atuador eletromecânico para válvulas, desenvolvida no âmbito de um projeto de pesquisa cooperativa entre o GCAR/UFRGS com as empresas Transpetro e Coester Automação Ltda.

Atuadores, elétricos ou pneumáticos, são dispositivos que permitem a motorização de válvulas, *dampers*, comportas e outros equipamentos similares. O atuador pode ser acoplado à válvula, por exemplo, através de unidades de adaptação ou redutores, tendo como função movimentar a haste da válvula, ou uma comporta. A abertura e fechamento de válvulas se dão a partir da ação desses atuadores (GONÇALVES, 2011). As válvulas estão presentes em diversas aplicações, sendo a sua principal finalidade o controle de fluxo de água, esgoto, petróleo, entre outros fluidos. Geralmente, o que define o modelo do atuador elétrico a ser usado é o tipo de válvula que se deseja controlar. Para válvulas utilizadas em tubulações maiores, se faz necessário um atuador com maior faixa de torque. Em válvulas gaveta e globo, usa-se um atuador elétrico multivoltas. Para válvula do tipo esfera ou borboleta, usam-se atuadores com ¼ de volta (FACCIN, 2011).

Como explica LAZZARETTI (2012), os atuadores elétricos são compostos de uma parte mecânica, que compreende uma série de engrenagens para transferir o movimento do motor para o eixo da válvula, e uma parte elétrica, composta do módulo de comando e de um motor para o acionamento. Os atuadores à disposição na bancada de teste são da linha CSR, modelo CSR06. Este atuador é específico para válvulas multivoltas, com capacidade de torque de 60 Nm e com o chamado controle inteligente, o qual possui uma unidade de processamento local, sensores e sistema de autodiagnose, além de capacidade de comunicação via uma rede *Modbus*. A Figura 2 mostra os principais componentes do conjunto atuador-válvula, indicando a nomenclatura de cada parte.

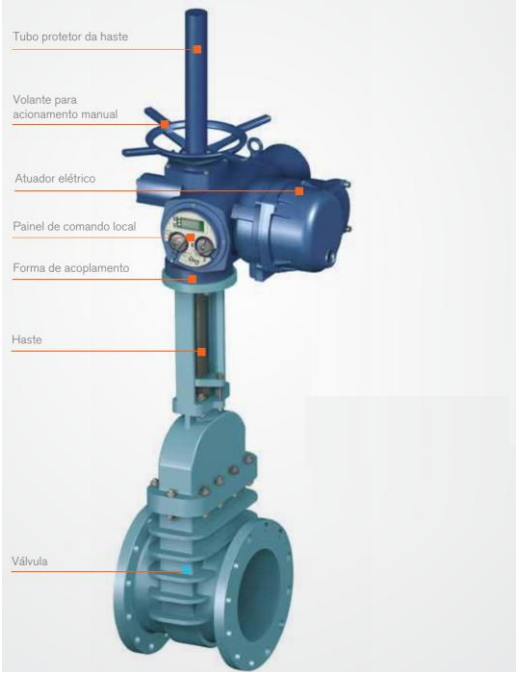

Figura 2: Conjunto atuador-válvula
Fonte: Coester Automação Ltda.

Esta válvula da empresa Coester (de mesmo modelo da Figura 2) conta com atuadores de comando inteligente, sendo assim possível detectar alguns problemas, como sobreaquecimento do motor, torque excessivo e falta de fase, e, além disso, possui a instrumentação necessária para medir valores de torque exercido na haste por percentual de abertura da válvula. Estes valores são armazenados na memória interna do atuador, que tem capacidade para registrar as últimas 500 operações realizadas (abertura ou fechamento). No entanto, estas medidas são disponibilizadas com resolução baixa (1 Nm sendo o fundo de escala de 60 Nm neste caso) e a cada 5% de abertura. Além disso, a fim de facilmente identificar o início e o fim do movimento do atuador, valores de torque inferiores a 10 Nm são registrados como 10 Nm e quando não há movimento o torque é registrado como sendo 0 Nm (LAZZARETTI, 2012).

Como é apresentado no trabalho de HENRIQUES et al. (2010), o âmbito de construir uma bancada com a válvula da Coester vem da necessidade de desenvolver um sistema de manutenção inteligente para este tipo de atuador. Esses sistemas precisam de dados de comportamento: normal, de degradação e de falha, que podem ser obtidos de forma estruturada através dos ensaios realizados. Com esta bancada se faz possível a realização de ensaios de esforços no atuador, inserção de defeitos e verificação do comportamento dinâmico do mesmo frente a diversas situações de degradação, tais como o surgimento de trincas e desgaste dos componentes.

Junto ao rolamento onde está conectada a haste da válvula, um freio a disco foi instalado com a finalidade de injetar falhas no sistema. Por exemplo, subidas bruscas de torque podem indicar um evento de falha como a quebra de alguma peça ou obstrução no fechamento da válvula. O freio é controlado por uma válvula proporcional que controla o fluxo de ar comprimido vindo de um compressor. Também está presente um segundo atuador conectado em paralelo com o primeiro, simulando uma rede tal como

em uma refinaria de petróleo. O atuador elétrico está ligado à alimentação trifásica de 380 V oriunda de um painel de distribuição, protegido por um disjuntor tripolar de 40 A (FACCIN, 2011). Na Figura 3 é apresentada uma visão geral da bancada, onde se tem o atuador instrumentado e o sistema de freio a disco.

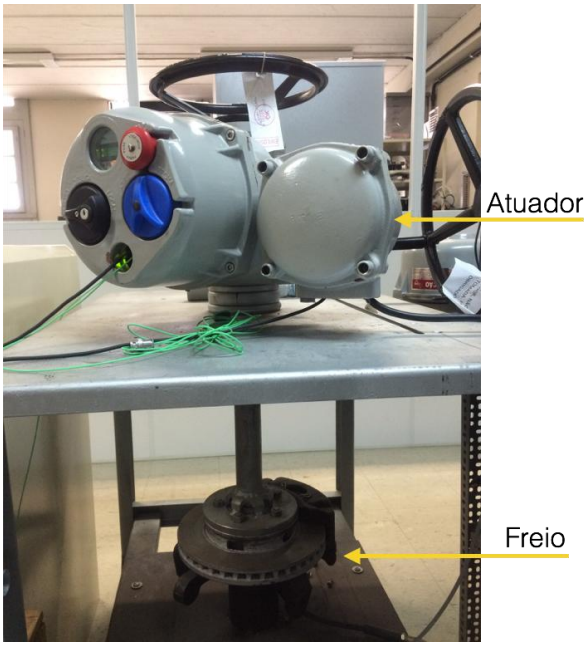

Figura 3: Bancada de testes.

Três acelerômetros piezoelétricos PiezoStar® *8705A* do fabricante Kistler foram posicionados em três locais distintos do sistema: no eixo do motor do atuador, na ponta do sem-fim e na pinça do freio. A Figura 4 mostra os acelerômetros posicionados no sistema.

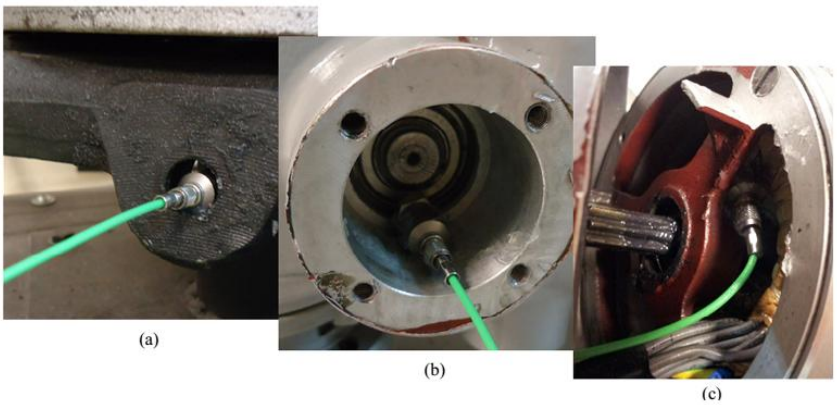

Figura 4: Acelerômetros posicionados (a) na estrutura do freio, (b) no sem-fim e (c) dentro do compartimento do motor do atuador elétrico.
Fonte: FACCIN (2011).

Segundo FACCIN (2011), para a aquisição de dados do atuador elétrico, utilizou-se o sistema CompactRIO® da empresa National Instruments™ no ambiente LabVIEW™. A taxa de aquisição usada foi 2048 amostras por segundo durante o movimento completo de abertura e fechamento, que para este atuador tem duração de, aproximadamente, 45 segundos. O registro da resposta de cada acelerômetro foi gravado em arquivos de texto.

Neste trabalho foram utilizados apenas dados coletados do acelerômetro acoplado junto ao motor do atuador, uma vez que foi o sensor que apresentou melhores resultados na detecção de degradações impostas ao sistema. Para mais informações sobre os ensaios realizados no atuador elétrico, sugere-se consultar o trabalho de FACCIN (2011).

Tem-se à disposição 25 ensaios de fechamento e 25 ensaios de abertura da válvula para cada uma das seis situações de funcionamento impostas ao sistema, totalizando 300 testes. Cada uma das situações é disposta na Tabela 1 (FACCIN, 2011).

Tabela 1: Descrição dos ciclos simulados no sistema atuador-válvula.

Condição	**Descrição**
Normal	Ciclo de operação a vazio
Falha 1	Ciclo com pressão no freio a disco equivalente a 300 kPa
Falha 2	Ciclo com pressão no freio a disco equivalente a 100 kPa
Falha 3	Ciclo executado com uma engrenagem desgastada e sem acionamento do freio
Falha 4	Ciclo executado com duas engrenagens desgastada e sem acionamento do freio
Falha 5	Ciclo executado com uma engrenagem com dentes quebrados e sem acionamento do freio

Fonte: Adaptado de (FACCIN, 2011).

3.2 Análise do Watchdog Agent™ para Matlab™

Atualmente o Watchdog Agent™ conta apenas com uma versão de demonstração para o Matlab™. Nessa versão, é possível fazer o Processamento do Sinal e a Extração das Características do mesmo, através dos métodos referidos anteriormente. Ainda é disponibilizado o módulo de Avaliação de Desempenho, onde é possível escolher entre os métodos de Regressão Logística e Reconhecimento Estatístico de Padrões.

Os módulos subsequentes na análise da saúde do equipamento seriam a Detecção de Falhas - com os métodos de Mapas Auto-organizáveis, Redes Neurais e Clusterização Hierárquica – e a Predição de Saúde, com os métodos de modelo ARMA (*Autoregressive Moving-Average*) e Match Matrix. A intenção deste trabalho é abordar o que seria o módulo de Predição de Saúde no Matlab™, a partir do uso de modelos ARMA, dando continuidade ao que já se tem da ferramenta.

Um processo estacionário é aquele o qual propriedades estatísticas não mudam ao longo do tempo (NASON, 2006). Como explica LAZZARETTI (2012), o sinal de vibração extraído dos sensores não é estacionário, logo, técnicas de processamento de sinal de tempo e frequência são as mais indicadas para que as características variantes no tempo sejam captadas. Dessa forma, o método mais indicado para extração das características do sinal é a análise da Energia da Transformada *Wavelet Packet* (WPE), o qual pode representar o sinal em bandas de frequência sem perder a sua localização temporal. Além disso, como se dispõe tanto de peças normais como peças defeituosas na bancada de

testes, pode-se distinguir comportamento normal de comportamento de falha, portanto, o método de Regressão Logística (LR) é o mais indicado para o caso de Avaliação de Desempenho, uma vez que neste método se necessita a referência dos dois estados do sistema – normal e falha.

Na Figura 5 pode-se observar a interface gráfica do Watchdog Agent™ para Matlab™: em primeiro plano são apresentadas as opções de métodos a serem escolhidos e o passo-a-passo de desenvolvimento da análise, que vai até a apresentação do Valor de Confiança; em segundo plano se tem o módulo de Processamento de Sinal, onde deve-se escolher o diretório de origem dos arquivos, a frequência do sinal e abaixo se tem o nome de cada uma das pastas contendo estes arquivos, separando o ensaio em Sinal Normal, Sinal de Falha e, por último, Sinal de Teste – esse é o ensaio mais recente, aquele que se quer diagnosticar, comparando os sinais anteriores.

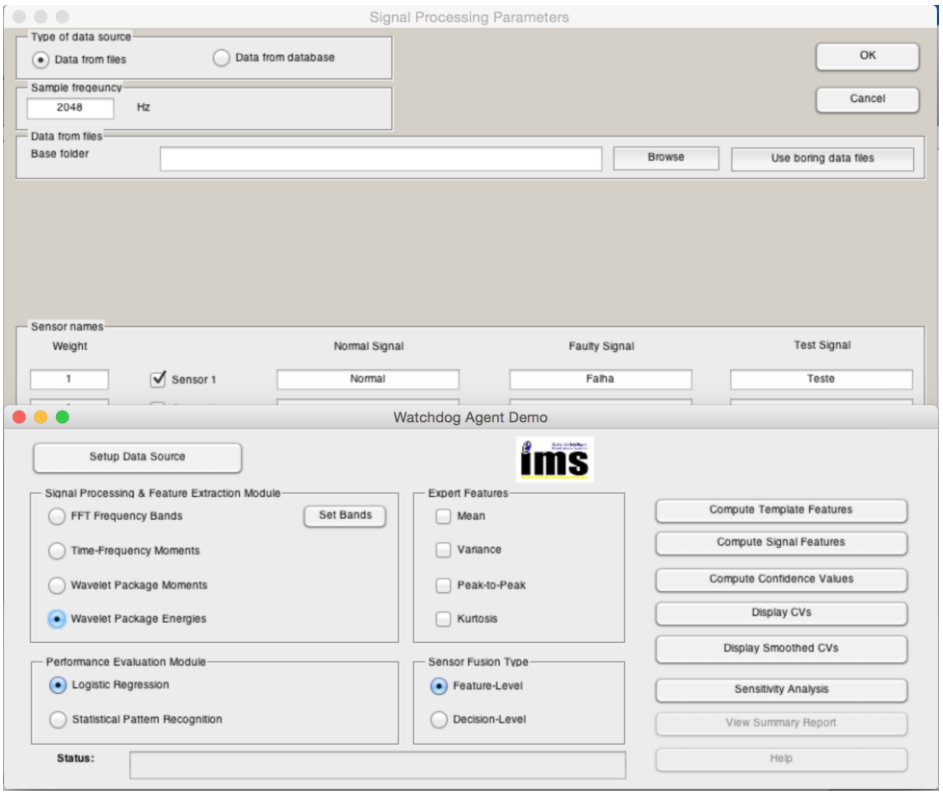

Figura 5: Interface gráfica do Watchdog Agent™ para Matlab™.

Considerou-se como referência de comportamento normal os testes extraídos do ensaio a vazio – sem acionamento do freio, e com todas as engrenagens em perfeitas condições. Para o caso de falha, utilizou-se dos dados referentes aos ensaios com uma ou duas engrenagens severamente desgastadas, ou com uma engrenagem com dentes quebrados, sendo todos os casos sem pressão no freio – operação a vazio.

Na extração das características do sinal utilizando a Transformada WPE, o código disponível possibilita a escolha de qual *Wavelet* mãe será utilizada e dos níveis de decomposição da análise, o que impacta na forma e número do vetor de características final dessa etapa. A opção escolhida foi a *Wavelet* mãe *Daubechies*, que já foi utilizada

com sucesso por trabalhos anteriores com o mesmo estudo de caso (LAZZARETTI, 2012; GONÇALVES, 2011; FACCIN, 2011). Para geração do vetor de características do sinal, utilizou-se 6 níveis de decomposição (gerando um vetor de 64 elementos), uma vez que tanto os gráficos de característica do sinal como os gráficos de CV apresentaram formas mais satisfatórias – do que com 4 níveis de decomposição, sendo que a diferença de esforço computacional em relação a 4 níveis de decomposição não foi significativa.

Para o algoritmo LR estipula-se um comportamento normal com um CV correspondente a 0,95, e o comportamento de falha como sendo 0,1. Esses valores são padrão do código, porém, foram escolhidos com base nos valores típicos encontrados nos exemplos de uso (apresentados nos artigos referenciados no Capítulo 2) das ferramentas e na documentação das funções tanto no ambiente Matlab™ quanto no ambiente LabVIEW™. Quanto mais próximos dos limites forem os valores de CV, melhor será a separação entre dois comportamentos, ficando mais evidente as alterações decorrentes da degradação do sistema (LAZZARETTI, 2012).

A fim de facilitar a verificação e a adequação dos algoritmos criados no Watchdog Agent™, fez-se toda uma análise de compreensão e domínio do código fonte disponibilizado pelo IMS *Center*. Dessa forma, foi possível incorporar as rotinas úteis para este trabalho a um novo algoritmo de testes para este projeto, capaz de executar a extração de CV e ao mesmo tempo servir de base para as novas rotinas que se necessitou criar. Sendo assim, algumas modificações foram necessárias a fim de tornar o algoritmo mais genérico, por exemplo, deixar de utilizar a interface gráfica, uma vez que para cada novo ensaio, os endereços dos arquivos deviam ser completados novamente, isto foi incorporado no novo algoritmo, agora pode-se utilizar um endereço padrão – que para o caso de repetidos ensaios facilita a análise – ou ainda há a possibilidade de entrada de endereço, caso necessário.

4 Desenvolvimento do algoritmo

É importante frisar que este trabalho foi desenvolvido a partir de um projeto de cooperação internacional, chamado Bragecrim (Iniciativa Brasil-Alemanha para Pesquisa Colaborativa em Tecnologia de Manufatura). O projeto é desenvolvido numa cooperação entre universidades do Brasil (UFRGS, UFSC e FURG) e da Alemanha (Universidade de Münster). O objetivo deste programa é apoiar e financiar projetos conjuntos de pesquisa entre grupos de pesquisa brasileiros e alemães na área de tecnologia de manufatura avançada. Dito isto, o código desenvolvido tem como objetivo, primeiramente, complementar as ferramentas já existentes do Watchdog Agent™ com a predição de comportamento, e também oferecer uma ponte entre a automação da manutenção de equipamentos e o desenvolvimento na área de produção, mais especificamente em cadeia de suprimentos – principal foco de estudo da universidade alemã.

Desta forma, organizou-se algumas metas a serem alcançadas pelo algoritmo, garantindo sua aplicabilidade. Este plano foi feito com a visão de que este programa seria instalado junto ao computador que recebe dados de todos os sensores do equipamento, onde haveria a análise destes dados. Após o término de todos os estágios da análise, as informações a respeito do equipamento seriam enviadas ao fabricante (central de cadeia de suprimentos, por exemplo), onde, baseado nesses dados, far-se-ia o planejamento adequado da produção da empresa. Essas metas são apresentadas a seguir:

- **Buscar e tratar a informação dos sensores:** a captura dos sinais extraídos dos acelerômetros pode ser realizada a partir de uma rotina do LabVIEW™, assim como foi o presente caso. Sendo assim, algumas adaptações talvez sejam necessárias a fim de adequar os ensaios ao padrão adotado pelo Matlab™. No caso deste trabalho, alguns detalhes como separação decimal dos valores por vírgula ao invés do ponto e ordem dos nomes tiveram um cuidado especial, são detalhes que, apesar de parecerem pequenos, podem travar a análise antes mesmo de começá-la.
- **Simulação de um padrão de degradação:** a fim de se validar a predição de comportamento, é preciso ter um histórico de degradação da peça em análise. Infelizmente, com a versão de demonstração do Watchdog Agent™, o que se tem com os dados disponíveis é um comportamento bem distinto em dois estados – normal e falha, não havendo possibilidade de se conseguir um perfil intermediário de degradação. Dessa forma, surgiu a necessidade de simular uma degradação que possibilita a análise de desempenho das predições de saúde da peça.
- **Módulo de predição de saúde:** baseando-se em séries temporais, o modelo ARMA é capaz de identificar tendências de comportamento ao longo do tempo e estimar o comportamento futuro do sistema. É possível ainda configurar um ponto de corte (*threshold*) que indique quando, provavelmente, a peça pode vir a quebrar, dessa forma, pode-se obter uma data para este evento. Aqui se insere o objetivo principal deste trabalho ampliando as funcionalidades da ferramenta Watchdog Agent™.

- **Função de distribuição de probabilidades:** com a intenção de aplicar a predição de saúde às simulações da área de cadeia de suprimentos, faz-se necessário o conhecimento de funções de probabilidade que descrevam a curva de probabilidade de quebra da peça. Assim, o programa deve aproximar a curva de probabilidade de quebra da peça a uma função conhecida, para que os parâmetros dessa função possam ser utilizados em estágios subsequentes do processo de manutenção.
- **Exportação dos resultados:** os resultados da análise devem ser exportados do Matlab™ a fim de serem utilizados por módulos subsequentes.
- **Execução cíclica e para várias peças:** A ideia de embarcar este programa em um computador é deixá-lo operando ininterruptamente. Então o código deve ter a capacidade de executar suas rotinas de maneira cíclica, lendo os valores extraídos dos acelerômetros e produzindo resultados continuamente até que lhe seja dada uma segunda ordem. Deve ainda fazer a procura pelo número de diretórios – sendo cada diretório referente à um ensaio ou uma peça, de modo a fazer a varredura em todo o equipamento.

Cada um destes pontos apresentados representa uma rotina do código, que são encadeados numa sequencia de chamadas. Sendo assim, há a possibilidade de aprimoramento de uma rotina sem necessidade de modificação de todo o programa. Por exemplo, se em determinada análise conclui-se que o modelo ARMA não é a melhor opção para a predição de valores no caso do atuador elétrico, pode-se fazer a troca para ARIMA (*Autoregressive Integrated Moving-Average*) – ou qualquer outro método – diretamente na rotina de predição sem que haja qualquer modificação nas demais rotinas, facilitando a busca e o isolamento de erros de programação, caso aconteçam.

Na Figura 6 pode-se observar o comportamento a ser seguido pelo código criado. Num primeiro estágio, acontece a coleta dos dados dos acelerômetros e, logo após, a extração das características do sinal, através da Transformada *Wavelet*. A seguir, é feito do diagnóstico da saúde da peça (note que pode haver a multiplicidade de peças). Tendo um gráfico de CV que degrada ao longo do tempo devido ao uso da peça, o próximo estágio trata da predição do comportamento da peça, responsável por apresentar valores futuros de CV. Por último, baseando-se em um determinado *threshold*, pode-se extrair uma provável data de quebra para a peça através da identificação do ponto no qual o gráfico da predição se cruza com o *threshold*. Note que este valor pré-determinado de CV de quebra deve ser escolhido adequadamente para cada tipo de processo e peça, o valor escolhido para este trabalho serve apenas para ilustração da capacidade do código.

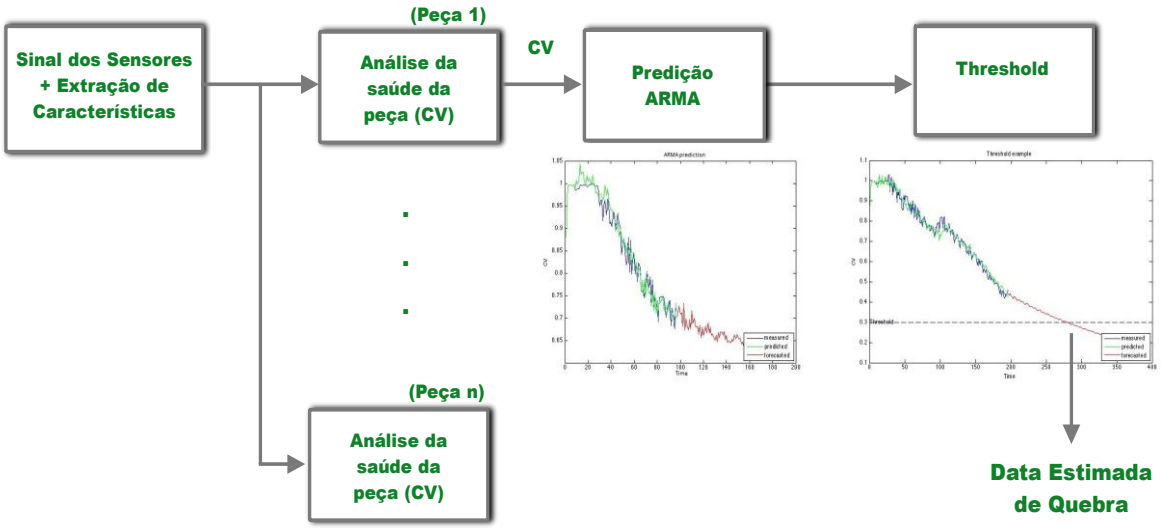

Figura 6: Diagrama de funcionamento do programa.

Para exemplificar a execução do cálculo do CV já acoplado ao algoritmo empregado neste trabalho, um ensaio foi organizado. Deve-se separar sinais de referência de comportamento normal e de comportamento de falha. Neste exemplo, utilizou-se 10 curvas (das 25 disponíveis para abertura da válvula) obtidas com todas as engrenagens em perfeito estado e sem pressão no freio como referência de funcionamento normal e 5 curvas obtidas com uma engrenagem quebrada como referência de funcionamento de falha. No teste, primeiramente foram utilizadas 10 curvas (das 15 restantes) de funcionamento normal, 20 curvas restantes obtidas com a engrenagem danificada e, por fim, as 5 curvas restantes do comportamento normal, totalizando 35 curvas de teste. Desta forma, das 35 curvas (ou ciclos), 20 correspondem a comportamento de falha. Esta separação foi feita a fim de que nos testes não houvessem dados idênticos aos utilizados no treinamento.

A Figura 7 mostra o gráfico de CV resultante com os arquivos de teste, onde se pode verificar o sucesso na classificação de cada ciclo de operação. Neste caso, um ciclo representa um movimento de abertura da válvula. Os 10 primeiros ciclos são correspondentes à curva de comportamento normal, assim como os cinco últimos, os 20 intermediários são de funcionamento degradado ou de falha.

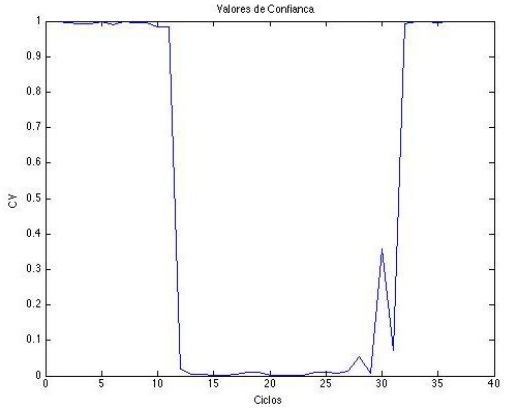

Figura 7: Curva dos CV's obtida no exemplo.

Pode-se notar na Figura 7 também que o comportamento da curva de CV é bastante abrupto, e a distinção de cada estado. Assim, apenas com este código disponível do Watchdog Agent™ não é possível traçar um perfil de degradação devido ao uso de uma peça, logo, não pode ser usado para predição de comportamento – com a intenção de se prever falhas. Pensou-se então em fazer uma simulação desse perfil de degradação, onde seria descrita a saúde da peça ao longo das horas (ou anos) de utilização da peça. Obviamente, o ideal seria que se tivesse à disposição um banco de dados com o CV da peça a cada período de tempo, como é mostrado à esquerda na Figura 8, assim sendo, uma previsão poderia ser realizada e validada. Como não se tem à disposição este histórico, se fez um código que interpola o CV final de um ensaio ao que seria o fim de uma peça, isto é, ao CV nulo. Isto é mostrado no lado direito da Figura 8, o intervalo de degradação é ajustável, o que na prática corresponderia à variação de características temporais de cada processo. Esta interpolação foi realizada no Matlab™ através de uma rotina simples que associa o passo de degradação necessário a um erro randômico (por isso essa característica não-suave do gráfico, simulando irregularidades na medição).

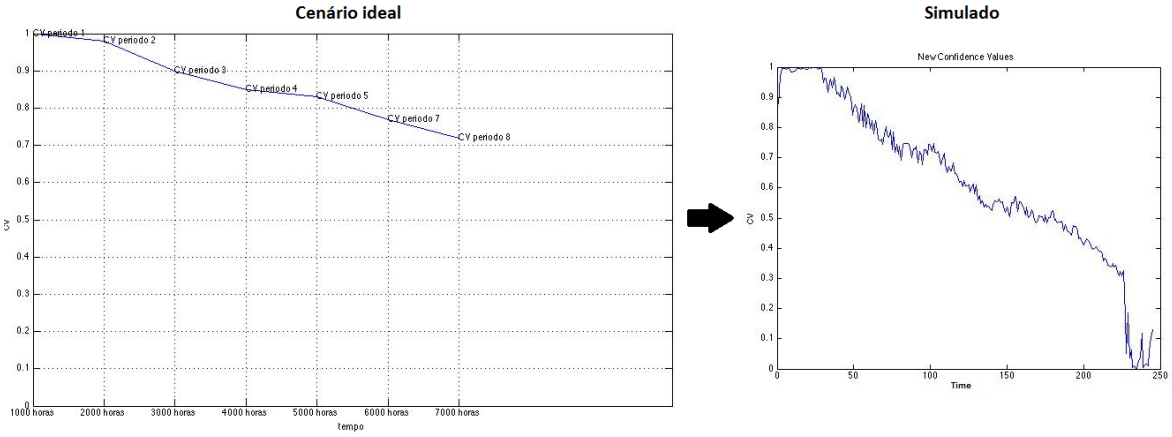

Figura 8: Perfil de degradação simulado.

Uma vez que se tem um perfil de degradação, pode-se partir para o módulo de predição em si. De LJUNG (1999), tem-se que um processo $\{v(t)\}$ pode ser representado por:

$$v(t) = R(q)e(t) \tag{1}$$

onde $\{e(t)\}$ é o ruído branco com variância λ. Aqui, $R(q)$ é uma função racional:

$$R(q) = \frac{C(q)}{A(q)}$$

$$C(q) = 1 + c_1 q^{-1} + \cdots + c_{nc} q^{-nc}$$

$$A(q) = 1 + a_1 q^{-1} + \cdots + a_{na} q^{-na}$$

então pode-se escrever:

$$v(t) + a_1 v(t-1) + \cdots + a_{na} v(t-na) =$$

$$e(t) + c_1 e(t-1) + \cdots + c_{nc} e(t-nc) \quad (2)$$

para a Equação (1). Tal representação de um processo estocástico é conhecida como modelo ARMA. Se $nc = 0$, tem-se um modelo AR:

$$v(t) + a_1 v(t-1) + \cdots + a_{na} v(t-na) = e(t) \quad (3)$$

e se $na = 0$, se tem um modelo média móvel (MA):

$$v(t) = e(t) + c_1 e(t-1) + \cdots + c_{nc} e(t-nc) \quad (4)$$

Segundo ALONSO et al. (2012), os processos ARMA tentam combinar as propriedades do modelo AR, onde se tem uma grande memória devido ao seu valor atual ser correlacionado com todos anteriores, com as propriedades do modelo MA, onde é possível representar séries de "memória curta". A escolha da ordem de um modelo AR pode ser feita através da direta verificação da função de autocorrelação parcial (PACF) – no Matlab™ tem-se "parcorr( )". O número de coeficientes não nulos (ou fora de um intervalo de tolerância) indica a ordem do processo AR. Para o caso dos processos MA, a análise é análoga, mas ao invés de ser feita com relação à PACF, é feita com relação à função de autocorrelação (ACF). Assim, um MA(1) (processo de média móvel de primeira ordem) terá só o primeiro coeficiente diferente de zero no gráfico ACF, o mesmo acontecerá no gráfico da PACF para um AR(1). Essa propriedade de dualidade entre estes dois processos é explicada em (ALONSO et al., 2012).

Há alguns métodos de escolha da ordem do modelo ARMA na atual bibliografia, sendo que não há um passo-a-passo definido para todos os casos. O método que se resolveu escolher para seguir, devido à fácil disponibilidade do mesmo no ambiente Matlab™ e também ao fácil acesso de material, foi o método de seleção de modelo Box-Jenkins.

Primeiramente, separou-se uma simulação do perfil de degradação da peça para se utilizar nesta etapa. Os dados podem ser observados na Figura 9: no início do período de medição se teria um CV referente a um comportamento normal, e ao longo do tempo a degradação desse valor, até o presente momento.

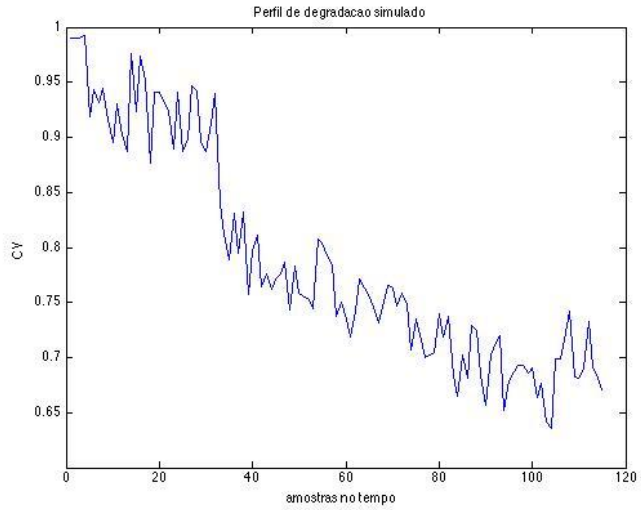

Figura 9: Perfil de degradação utilizado na escolha da ordem do modelo.

É possível notar um aspecto ruidoso nas amostras (isto foi feito intencionalmente na simulação de degradação mas serve para aproximar a simulação de um possível caso real onde inconsistências de medida dariam este aspecto ao gráfico). Fazer análises de comportamento em um sinal ruidoso pode trazer muitos erros de cálculo, trazendo tendências que talvez não retratem a característica do sinal que se queria captar. Sendo assim, optou-se por passar a curva de degradação utilizada por um filtro que suavizasse o aspecto ruidoso. No Matlab™, pode-se utilizar as *Smoothing Splines* (que são baseadas na função "csaps( )", do *Curve Fitting tool*) ou alternativamente um dos métodos específicos do programa para suavização de curvas (MATLAB, 2014). No caso, utilizou-se a função "smooth( )" que implementa um filtro de média móvel capaz de analisar todos os dados de uma só vez. A comparação das curvas de degradação antes e depois da suavização da curva é apresentada na Figura 10.

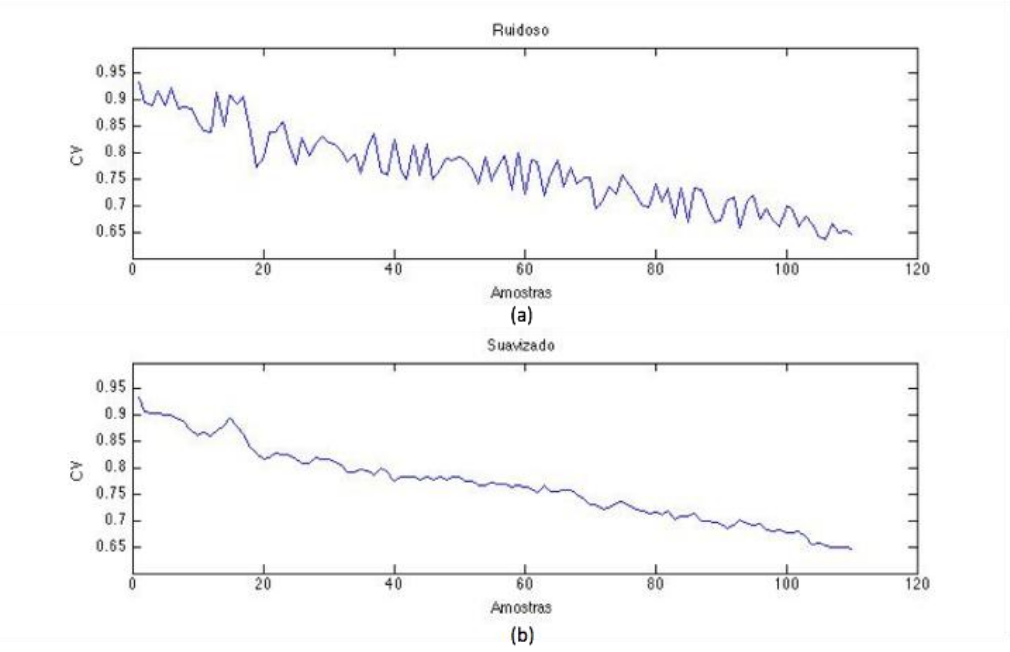

Figura 10: Comparação entre o (a) sinal ruidoso e o (b) suavizado.

Pode-se observar nas figuras 9 e 10 que há uma clara tendência descendente no gráfico – como era de se esperar. Isto influencia em fatores como a média das amostras, que muda com o passar do tempo, indicando um comportamento de série não estacionária. O próximo passo do método é traçar o gráfico do ACF e PACF para esta série, que são apresentados na Figura 11.

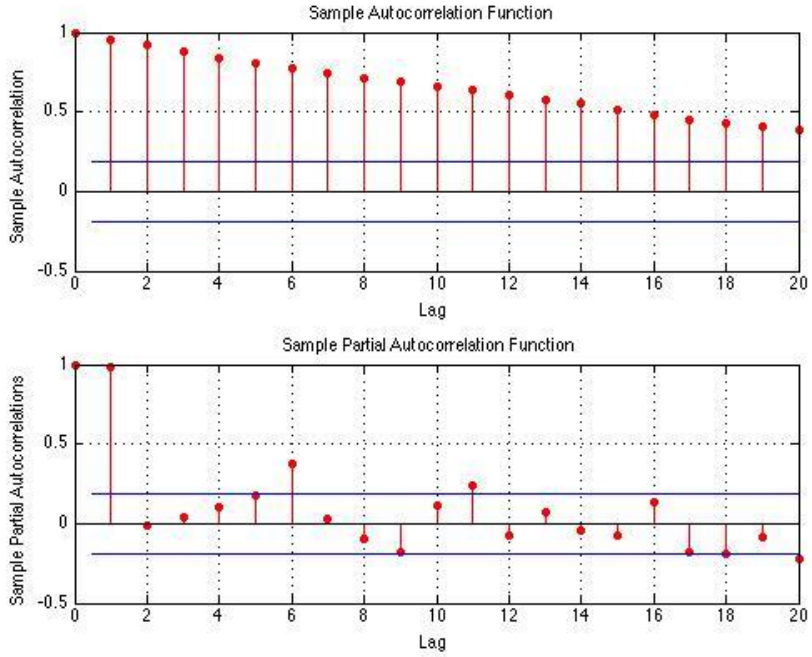

Figura 11: Gráfico de ACF e PACF para a série temporal.

Segundo o método de Box-Jenkins, a amplitude e o decaimento aproximadamente linear do ACF indicam um processo não estacionário. Dessa forma, o que deve ser feito a seguir é diferenciar esta série temporal a fim de "torná-lo" estacionário. O gráfico da série temporal diferenciada, após suavização do das amostras, é apresentado na Figura 12.

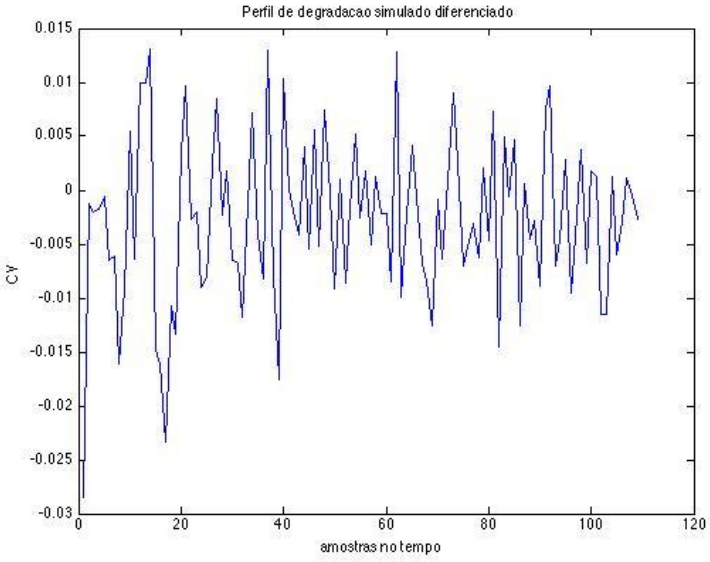

Figura 12: Perfil de degradação após diferenciação das amostras da série.

Diferenciando as amostras da série remove-se a tendência linear que a degradação carregava. Dessa vez, a série diferenciada mostra um aspecto estacionário, diferente da curva anterior (Figura 10). Novamente, deve-se traçar os gráficos de ACF e PACF da série temporal – agora diferenciada – para se observar o comportamento mais consistente com um processo estacionário. Os novos gráficos de correlação são apresentados na Figura 13.

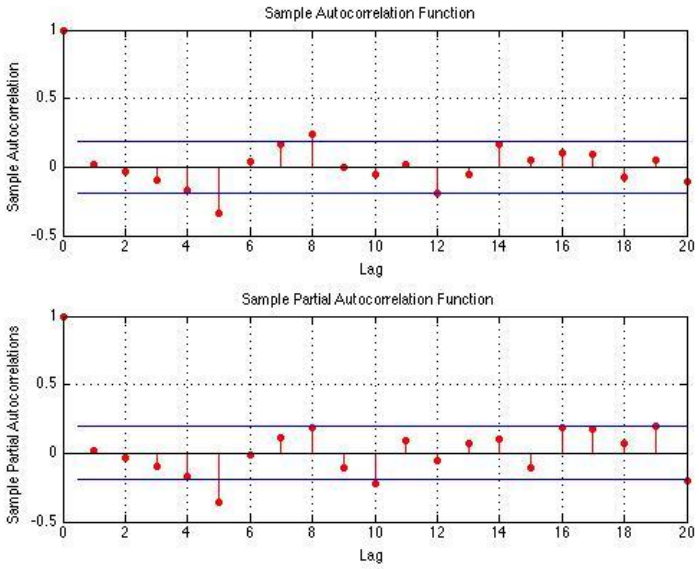

Figura 13: Gráfico de ACF e PACF após diferenciação das amostras da série.

As amostras do ACF com a série diferenciada decaem mais rapidamente. O gráfico de PACF "corta" após o atraso 5. Este comportamento é compatível com um modelo AR(5). Para o processo MA se utilizou ordem 5, uma vez que o comportamento obtido foi bastante similar ao caso do AR, sendo o atraso 5 o último de valor significativo. O último passo do método diz respeito a quão bom o modelo é (*goodness of fit*). Para isso, primeiramente deve-se inferir os resíduos (que são os erros de adequação associados ao modelo proposto) do modelo escolhido através da função "infer( )" do Matlab™. Como é possível observar na Figura 14, os resíduos do modelo são distribuídos de forma normal e, aparentemente, não há correlação entre eles. Sendo assim, pode-se afirmar que a ordem do modelo escolhida é uma boa candidata para representar o grupo de dados estudados, segundo o método Box-Jenkins.

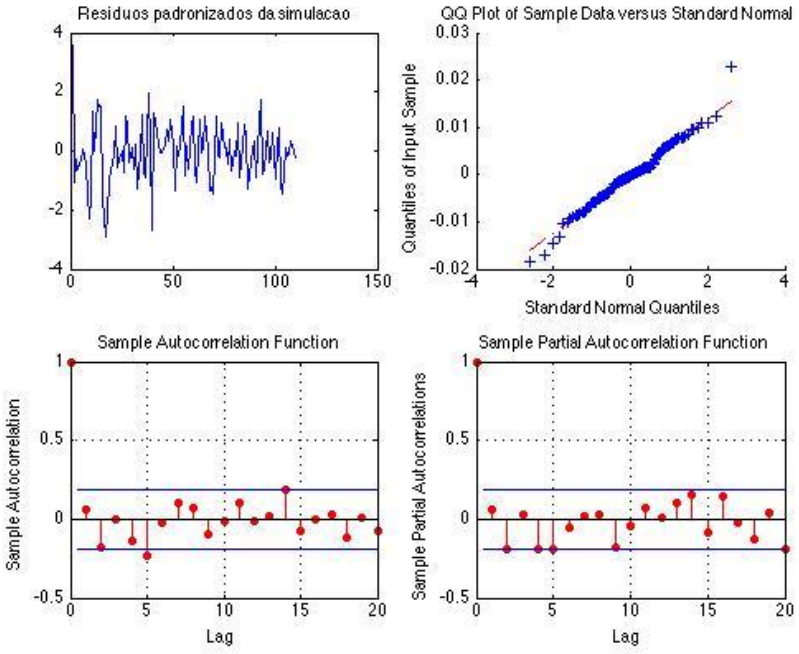

Figura 14: Distribuição residual do modelo proposto.

O último passo do método é a previsão dos valores futuros da série temporal. De Matlab (2014), tem-se que o uso da função “arima( )” com o parâmetro que se refere ao grau de integração não sazonal nulo, em outras palavras, a função “arima( )” pode ser utilizada para modelar processos ARMA. Com a combinação do modelo criado e a função “forecast( )”, pode-se extrair também o vetor de Erro Quadrático Médio (MSE – *Mean Square Error*) e, dessa forma, traçar o gráfico não só da predição de CV para amostras futuras, mas também um intervalo de confiança de 95% para estas amostras, como é apresentado na Figura 15.

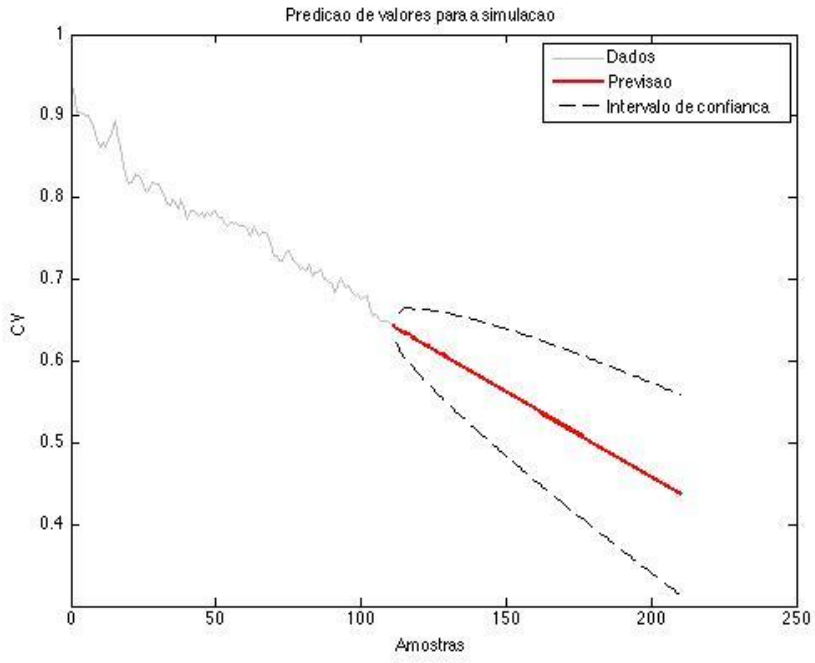

Figura 15: Previsão de comportamento baseado no modelo proposto.

Modelos ARMA são amplamente utilizados em hidrologia, econometria e outros campos. MEKO (2013) apresenta as conclusões supracitadas por ALONSO et al. (2012) e ainda comenta que a identificação de modelos ARMA a partir dos gráficos de ACF e PACF é difícil e requer muita experiência, com a exceção de casos de ordem reduzida. Maneiras diferentes de identificar ordens de modelos ARMA então são propostas, entre elas está a Predição Final de Erro de Akaike (FPE). O FPE está relacionado com a função variância do resíduo do modelo: quanto menor o resíduo, melhor a adequação. Assim, o FPE é computado para vários modelos candidatos, e o modelo com menor FPE é selecionado como o modelo mais adequado para o processo (MEKO, 2013). Assim, tentou-se combinar o método de Box-Jenkins com a observação do FPE para cada modelo proposto. O que foi possível notar, é que com o aumento da ordem do modelo, o FPE tende a diminuir até valores de ordens cada vez menores, mas, ao mesmo tempo, sabe-se que um modelo bom não é necessariamente aquele com maior ordem, o aumento da ordem resulta em um modelo mais tendencioso. Outro fator que muda com o aumento da ordem é o custo computacional, o código funcionando em computador pessoal é bastante rápido, mas no momento que o mesmo é embarcado em uma placa acoplada ao atuador, numa fase futura do projeto, o desempenho pode decair significativamente. Sendo assim, optou-se por utilizar uma ordem relativamente baixa de modelo, encontrada pelo método de Box-Jenkins.

No Matlab™, implementou-se a série temporal no modelo ARMA utilizando a função “armax( )”. Este modelo ainda conta com uma combinação linear dos últimos termos de uma entrada conhecida no sistema, além dos processos AR e MA. Se a função é utilizada com uma série temporal como parâmetro de dados, mas sem canal de entrada e um canal de saída, então “armax( )” calculará um modelo ARMA para esta série, neste caso, dois parâmetros são passados pela função (na e nc) (MATLAB, 2014). Ambas as funções “arima( )” e “armax( )” podem ser utilizadas para criação de um modelo ARMA, porém, resultados melhores foram obtidos com a função “armax( )” (possivelmente pelo algoritmo de resolução dos coeficientes utilizado em cada uma das funções) e, por esta razão, esta foi a função utilizada neste trabalho.

Logo após a previsão dos valores no modelo ARMA, usa-se o resultado da predição na comparação com um *threshold* (como é mostrado na linha tracejada na Figura 16). Também é mostrada a condição que diz que se o valor estimado for menor ou igual ao CV mínimo de quebra, ter-se-á a provável data de quebra do equipamento. É possível identificar no Matlab™ a data atual do ensaio, então somando-se a quantidade de amostras que se tomou para cruzar o *threshold* e contando que estas amostras tenham um espaçamento de tempo equidistante uma das outras, pode-se definir, por fim, a provável data de quebra do equipamento em questão.

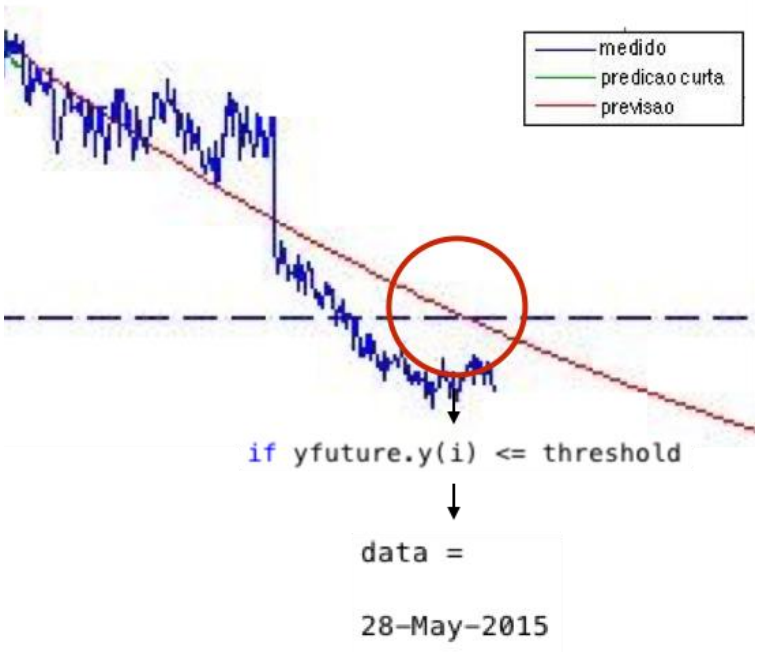

Figura 16: Representação da data de quebra no programa.

Com o intuito de exportar os resultados para permitir a integração entre o módulo de manutenção inteligente com o sistema de otimização de cadeia de suprimentos, surgiu a necessidade de descrever a curva de probabilidade de quebra (representada pela unidade menos a curva simulada em adição à de predição) através de uma função de probabilidade conhecida. Baseado na experiência prática de que a probabilidade de um equipamento vir a quebrar deve apenas crescer com o tempo, escolheu-se por funções de distribuição acumulada para descrever a probabilidade de quebra (essa função deverá variar de caso para caso, como pode ser observado no Capítulo 5). Dado que o gráfico de saúde de um equipamento tende apenas a cair ao longo do tempo (desconsiderando a possibilidade de reparos ou manutenções), o de probabilidade de quebra tende apenas a aumentar, então se usou o inverso do gráfico obtido após a predição como entrada para este módulo. Fez-se uso de uma função do Matlab™ (“allfitdist( )”) capaz de ajustar uma curva de entrada a uma função de probabilidade, assim, pode-se adequar essa curva a várias diferentes funções de probabilidade, sendo que o erro de adequação também é disponibilizado. A função que apresenta o menor erro (o erro pode ser de sinal positivo ou negativo, então aquela com a menor soma dos módulos do erro para cada ponto, será a melhor função) será passada como resultado da simulação para um módulo subsequente, juntamente com os parâmetros da função de distribuição acumulada que a descrevem. Na Figura 17 pode-se observar o que o programa desenvolvido em Matlab™ retorna no final da execução do código: no caso, a distribuição normal (Gaussiana) foi a que melhor descreveu a curva de probabilidade de quebra e seus parâmetros são apresentados.

```
Metodo com menor erro:


ans =

            DistName: 'normal'
               NLogL: -117.1928
                 BIC: -221.0516
                 AIC: -230.3856
                AICc: -230.3702
           ParamNames: {'mu'  'sigma'}
    ParamDescription: {'location'  'scale'}
              Params: [0.5084 0.2086]
             Paramci: [2x2 double]
            ParamCov: [2x2 double]
             Support: [1x1 struct]
```

Figura 17: Escolha da função de probabilidade que apresenta o menor erro.

5 Simulações e resultados

Através de uma simulação do comportamento do equipamento ao longo do tempo é possível avaliar o desempenho do modelo desenvolvido. Para a apresentação dos resultados, baseou-se no ensaio de CV já apresentado anteriormente como exemplo. Apresentado na Figura 18, o ensaio começa com 10 valores relativos a comportamento normal, depois se tem 20 ensaios relativos à falha e, por fim, mais cinco testes de comportamento normal.

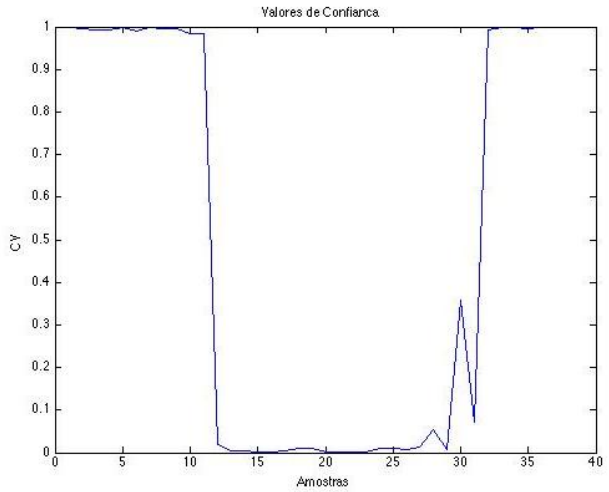

Figura 18: Perfil de CV para início da simulação.

Após a obtenção dos Valores de Confiança, o código parte para a simulação do perfil de degradação. Pode-se observar na Figura 19 que o programa parte do fim do ensaio de CV e simula um traçado de degradação em direção ao CV nulo. Este traçado muda de simulação para simulação – uma vez que se tem uma componente randômica somada a cada iteração, mas a rotina garante que o perfil resultante seja uma decrescente dos Valores de Confiança.

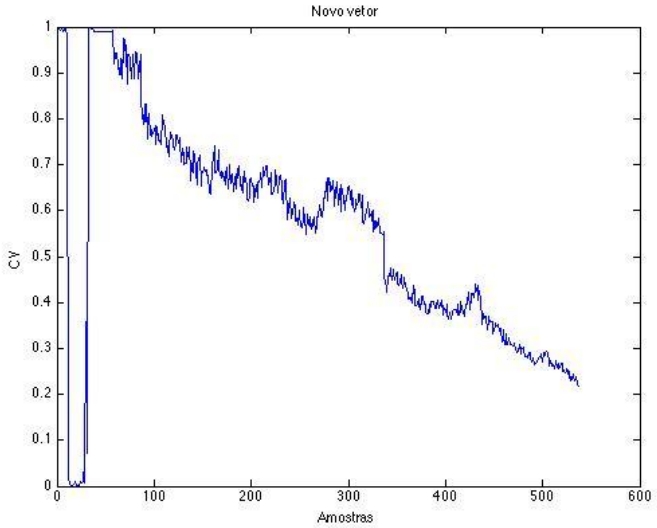

Figura 19: Perfil de CV e perfil de degradação.

Depois disso, o programa trunca o vetor de simulação de degradação, observado na Figura 20. Isto é feito a fim de se ter um resultado a ser comparado com a predição do modelo ARMA, assim, separa-se uma parte das amostras para uma possível validação da previsão de valores. Note que há também, neste caso, o truncamento de valores do início do vetor, uma vez que havia mudanças abruptas de CV e isto influenciaria de maneira negativa na adequação do modelo à curva. É possível observar o gráfico mais suavizado que o da Figura 19, a fim de diminuir erros no modelo.

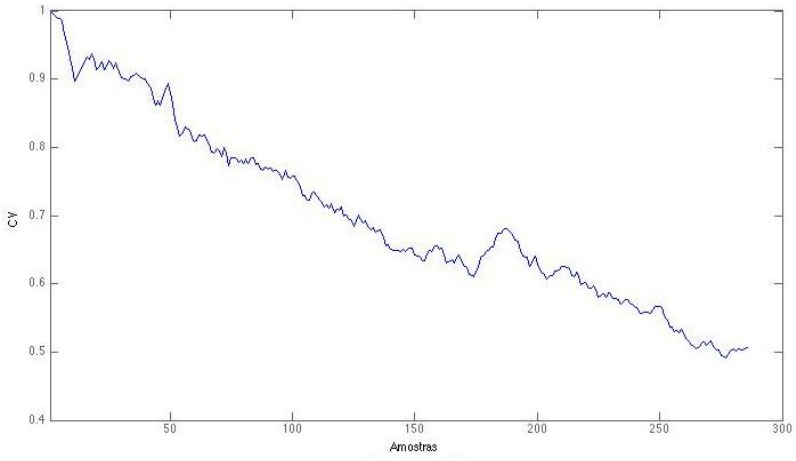

Figura 20: Vetor utilizado para treinamento do modelo.

Enfim, é feito o treinamento do modelo ARMA(5,5) (de ordem AR(5) e MA(5), neste caso). A Figura 21 mostra os dados de saída da modelagem da série temporal no Matlab™. Note que, por mais que a ordem do modelo seja relativamente pequena, os fatores de erro FPE e MSE apresentaram valores bastante pequenos, indicando um bom desempenho do algoritmo.

```
m =
Discrete-time ARMA model:  A(z)y(t) = C(z)e(t)
  A(z) = 1 - 1.11 z^-1 + 0.09688 z^-2 - 0.1231 z^-3 + 0.1425 z^-4 - 0.004798 z^-5

  C(z) = 1 + 0.1437 z^-1 + 0.1237 z^-2 + 0.09469 z^-3 + 0.07911 z^-4 - 0.8777 z^-5

Status:
Estimated using ARMAX on time domain data "y".
Fit to estimation data: 96.28% (prediction focus)
FPE: 2.601e-05, MSE: 2.411e-05
```

Figura 21: Apresentação do modelo proposto no Matlab™.

Utilizando este modelo e traçando o gráfico da sobreposição das amostras com os valores de predição, é apresentada a Figura 22. É possível notar que, no caso desta simulação, algumas amostras após o início da previsão do modelo (por volta da amostra 300, neste caso), houve uma pequena queda no perfil de degradação, o que distanciou um pouco os valores de previsão daquilo que seria o medido. Mesmo assim, o modelo ARMA proposto apresentou um desempenho bastante satisfatório, sendo capaz de capturar a tendência observada nas amostras anteriores e apresentando valores futuros de CV que parecem ser coerentes com o sistema observado. Vale também comentar que a previsão de valores foi feita para muitas amostras (500), o que não é usual para séries

temporais, mas, mesmo assim, apresenta um comportamento sem muitas discrepâncias daquilo que é o esperado.

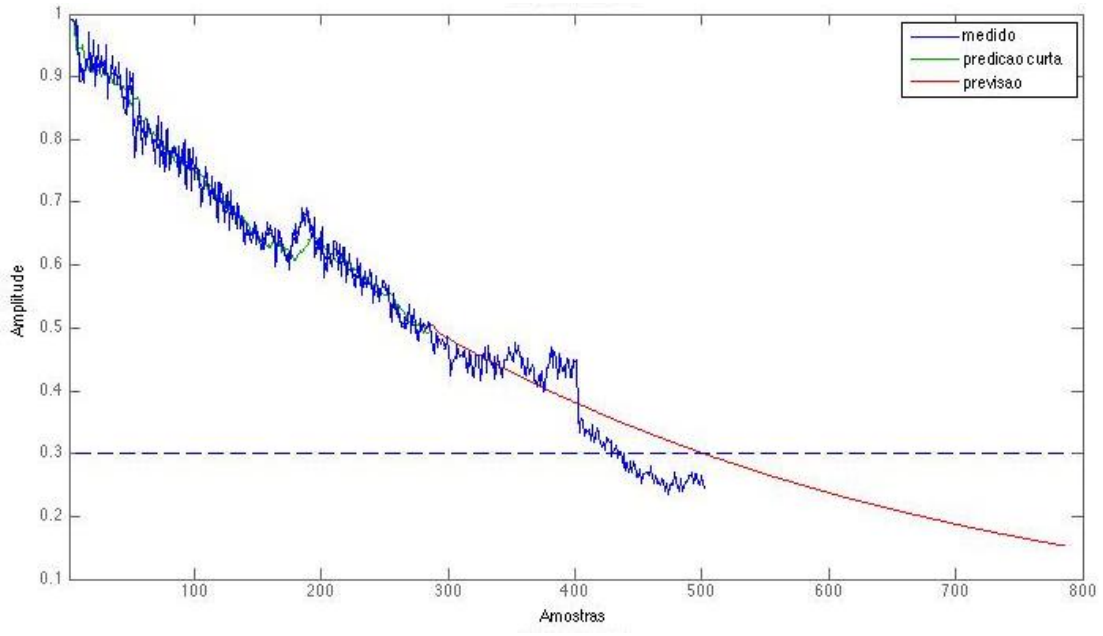

Figura 22: Resultado da predição para o modelo proposto.

Na Figura 23 é possível observar as funções de probabilidade utilizadas na adequação destas à curva de probabilidade de quebra extraída do gráfico anterior. A curva de probabilidade de quebra apenas crescerá com o passar do tempo, como as curvas descrevem.

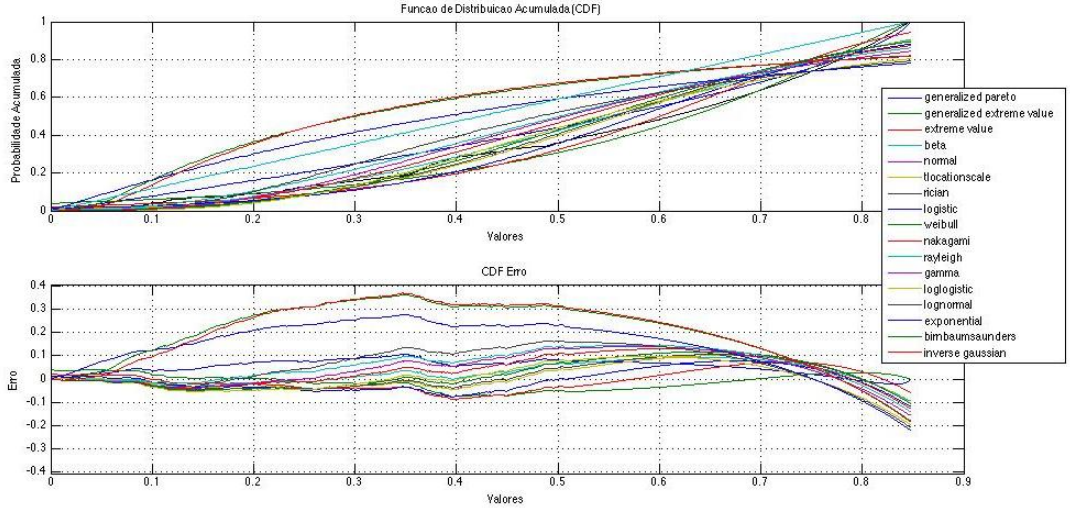

Figura 23: Aproximações da probabilidade de quebra à funções conhecidas.

Através da soma dos módulos dos erros apresentados na Figura 23, pode-se obter a curva que descreve a curva de probabilidade de quebra de forma mais adequada. Os resultados deste ensaio são apresentados na Figura 24, sendo a data provável de quebra, neste caso, o dia 12 de junho de 2015. Este arquivo poderá ser passado para um módulo

subsequente na hierarquia de manutenção inteligente, enriquecendo a gama de informações que a empresa tem sobre os seus produtos instalados.

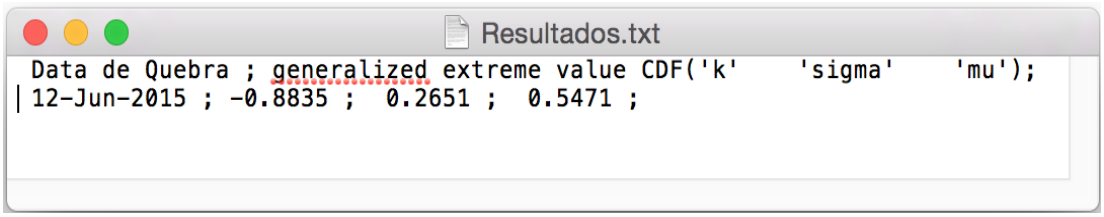

Figura 24: Arquivo de resultados do ensaio.

6 Conclusões e Trabalhos Futuros

O presente trabalho buscou desenvolver um módulo de predição de saúde de um equipamento, visando a implementação deste integrado à ferramenta de diagnóstico já existente Watchdog Agent™. O desenvolvimento do código se deu a partir da extração do CV, considerando um perfil de degradação simulado e, por fim, o modelo de predição de comportamento ARMA.

O algoritmo desenvolvido tem cada uma de suas funcionalidades separadas por rotinas isoladas, sendo que, se necessária alguma modificação, isto não influencie no resto do código. A simulação do sistema em degradação e, principalmente, o desempenho do módulo de predição de saúde se mostraram bastante satisfatórios. O modelo ARMA foi capaz de capturar a tendência de degradação da série temporal e prolongar este efeito para os períodos subsequentes de forma bem sucedida.

Também se desenvolveu uma rotina para ajustar a curva de probabilidade de quebra a uma função de probabilidade conhecida, a fim de fazer a ponte entre este projeto e simulações na área de cadeia de suprimentos. Entretanto, esse projeto carece de dados experimentais obtidos em situações reais de operação, a fim de prover a adequada validação do modelo proposto. Dessa forma, o código ainda não se encontra apto para um possível uso comercial. Para continuidade desse trabalho, sugere-se o desenvolvimento dos seguintes tópicos:

- Coleta de mais dados, tanto de mais estágios de degradação de determinada peça, como peças com conhecimento a respeito de seu tempo de utilização, isto ajudaria na validação do modelo proposto por este trabalho. Nesse aspecto, estudos em na área de ensaios acelerados de tempo de vida de equipamentos (¨*Accelerated life tests*¨) já estão sendo desenvolvidos em parceria com outras instituições.

- O código ainda precisa de um maior amadurecimento e de diferentes testes para ver como ele se comporta e como pode ser melhorado. A principal intenção deste código é o módulo de predição em si, mas um aperfeiçoamento da extração de CV com valores intermediários (que não sejam ou zero ou um) seria de grande uso no desenvolvimento de mais testes.

- Um módulo de comunicação dos resultados de saída do módulo de predição com os módulos subsequentes, visando uma integração completa do projeto Bragecrim a nível de sistema.

7 Referências

ALONSO, Andrés M.; GARCÍA-MARTOS, Carolina. Time Series Analysis. Autoregressive, MA and ARMA processes. 2012. Universidad Carlos III de Madrid e Universidad Politécnica de Madrid. Disponível em < http://www.etsii.upm.es/ingor/estadistica/Carol/TSAtema4petten.pdf >. Acesso em: 26 de outubro de 2014.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. NBR-5462: confiabilidade e mantenabilidade. Rio de Janeiro, 1994. 37p.

FACCIN, F. C. Manutenção Inteligente: fusão de sensores aplicada na detecção de falhas em atuadores elétricos. 2011. 89 p. Projeto de Diplomação (Graduação em Engenharia Elétrica) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

GONÇALVES, Luiz Fernando et al. Um método de classificação de falhas em atuadores elétricos baseado em mapas auto-organizáveis. 2007. Universidade Federal do Rio Grande do Sul - PPGEE, Porto Alegre, 2007.

GONÇALVES, Luiz Fernando. Desenvolvimento de um sistema de manutenção inteligente embarcado. 2011. f.Tese (Doutorado em Engenharia), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

HENRIQUES, R. V. B. et al. Detecção de falhas em atuadores nas linhas de transporte de petróleo e/ou derivados, In: CONGRESSO INTERNACIONAL E EXPOSIÇÃO SUL AMERICANA DE AUTOMAÇÃO, SISTEMAS E INSTRUMENTAÇÃO, 14, 2010, São Paulo. Anais. São Paulo: International Society of Automation, 2010.

IEEE. IEEE Standard Computer Dictionary: a compilation of IEEE standard computer glossaries. Washington: Institute of Electrical and Electronics Engineers, 1990. 217 p.

IEEE. IEEE Standard Glossary of Computer Hardware Termonilogy. Washington: Institute of Electrical and Electronics Engineers, 1995. 109 p.

LAZZARETTI, Elisandra Pavoni. Avaliação de desempenho de implementações em hardware e software de algoritmos para aplicações de manutenção inteligente. 2012. f.Dissertação (Mestrado em Engenharia), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012.

LEE, J.; NI, J. An Introduction of Embedded Infotronics Agent for Tether-Free Prognostics. NSF Industry/University Cooperative Research Center on Intelligent Maintenance Systems (IMS) Univ. of Wisconsin-Milwaukee and Univ. of Michigan-Ann Arbor, 2002.

LEE, J. et al. Watchdog – Information Technology for Proactive Product Maintenance and Its Implications to Ecological Product Re-Use, invited paper in Proc. of the Symposium on Ecological Manufacturing in Berlin, Germany, 2003, pp. 101-110.

LEE, J. et al. Watchdog Agent—an infotronics-based prognostics approach for product performance degradation assessment and prediction. Elsevier Ltd. 2004.

LEE, J. et al. Intelligent prognostics tools and e-maintenance**.** Computers in Industry, Amsterdam, v. 57, n. 6, p. 476-489, 2006.

LJUNG, Lennart. System Identification – Theory for the User. Prentice-Hall. Upper Saddle River, N.J., 2nd Edition. 1999.

LU, B.; DUROCHER, D.; STEMPER, P. Predictive maintenance techniques, IEEE Industry Applications Magazine, New York, v. 15, n. 6, p. 52-60, Nov.-Dec. 2009.

MARÇAL, R. F. M. Um método para Detectar Falhas Incipientes em Máquinas Rotativas Baseado em Análise de Vibração e Lógica Fuzzy. 2000. 111 f.Tese (Doutorado em Engenharia), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

MATLAB. **mathworks.com** 2014. Disponível em: < http://www.mathworks.com/help/ident/ref/armax.html >. Acesso em: 29 de outubro de 2014.

MATLAB. **mathworks.com** 2014. Disponível em: < http://www.mathworks.com/help/econ/specify-arimap-d-q-models.html >. Acesso em: 29 de outubro de 2014.

MATLAB. **mathworks.com** 2014. Disponível em: < http://www.mathworks.com/help/curvefit/smoothing-data.html >. Acesso em: 29 de outubro de 2014.

MEKO, David M. Applied Time Series Analysis Notes. Autoregressive-Moving-Average Modeling. 2013. Disponível em < http://www.ltrr.arizona.edu/~dmeko/notes_5.pdf >. Acesso em: 26 de outubro de 2014.

NASON, G.P. Stationary and non-stationary time series. Chapter 11 of Statistics in Volcanology, (Mader, H. and Coles, S.C., eds), Geological Society of London, 2006.

NIU, G.; YANG, B.-S. Intelligent condition monitoring and prognostic system based on datafusion strategy. Expert Systems with Applications, New York, v. 37, n.12, p. 8831-8840, Dec. 2010.

NUNES, E. L. Manutenção Centrada em Confiabilidade (MCC) - Análise da Implantação em uma Sistemática de Manutenção Preventiva Consolidada. 2001. 146 f. Dissertação (Mestrado em Engenharia Elétrica), Universidade Federal de Santa Catarina, Florianópolis, 2001.