

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

FELIPE CARLOS FACCIN

**MANUTENÇÃO INTELIGENTE: FUSÃO DE SENSORES APLICADA NA
DETECÇÃO DE FALHAS EM ATUADORES ELÉTRICOS**

PORTO ALEGRE

2011

FELIPE CARLOS FACCIN

**MANUTENÇÃO INTELIGENTE: FUSÃO DE SENSORES APLICADA NA
DETECÇÃO DE FALHAS EM ATUADORES ELÉTRICOS**

Trabalho de conclusão de curso de graduação apresentado junto à disciplina de Projeto de Diplomação ENG 04029 como requisito parcial para obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Dr. Renato Ventura Bayan Henriques

PORTO ALEGRE

2011

FELIPE CARLOS FACCIN

**MANUTENÇÃO INTELIGENTE: FUSÃO DE SENSORES APLICADA NA
DETECÇÃO DE FALHAS EM ATUADORES ELÉTRICOS**

Trabalho de conclusão de curso de graduação apresentado junto à disciplina de Projeto de Diplomação ENG 04029 como requisito parcial para obtenção do título de Engenheiro Eletricista.

Aprovado pela Banca Examinadora em 20 de dezembro de 2011.

BANCA EXAMINADORA:

Prof. Dr. Renato Ventura Bayan Henriques – UFRGS
Orientador

Prof. Dr. Carlos Eduardo Pereira – UFRGS

Prof. Dr. Eduardo Luis Schneider – Universidade Feevale

PORTO ALEGRE

2011

AGRADECIMENTOS

Primeiramente, agradeço aos meus pais, Aldo Anversa Faccin e Vera Madalena Faccin, pela educação e valores transmitidos, e que, mesmo estando longe, sempre acreditaram em mim.

Agradeço também a minha irmã Aline Becker Faccin pelo apoio e incentivo.

Em especial, agradeço à minha namorada Gabriela Acco Dias pelo amor, companheirismo e compreensão nas dificuldades enfrentadas.

À Glessi Acco pelos conselhos e almoços no fim de semana.

Também agradeço ao pessoal que colaborou com a montagem e adequação da bancada no LASCAR ou que, de alguma forma, contribuiu com o sucesso do trabalho: Mateus Martini, Matheus Sena Poppl, Leonardo Piccoli, Klaus Boesch, Eduardo Luis Schneider, Luiz Fernando Gonçalves e, em especial, ao professor Renato Ventura Bayan Henriques pela orientação e atenção dedicada ao trabalho.

RESUMO

Os avanços na área de sensores e transdutores e na integração destes com softwares de aquisição de dados possibilitou que se reunissem dois elementos fundamentais para a elaboração de um sistema de manutenção inteligente: o monitoramento em tempo real dos parâmetros do sistema e a variedade de aplicações e técnicas matemáticas possíveis em uma ferramenta computacional. Tais sistemas de manutenção inteligente permitem diagnosticar as falhas de um determinado equipamento, determinar a origem e a causa da falha e até mesmo prever quando novas falhas acontecerão de acordo com os dados históricos do equipamento monitorado.

Surgiram, então, algumas iniciativas no desenvolvimento e padronização de sistemas de manutenção inteligente. Uma dessas iniciativas foi desenvolvida pelo *Intelligent Maintenance Systems Center* (ou simplesmente *IMS Center*), que desenvolveu uma metodologia para a abordagem sistemática em sistemas de diagnóstico, e tem como missão transformar as práticas tradicionais de manutenção de “falha e conserto” em uma metodologia de “prever e prevenir”.

Este trabalho apresenta a utilização desta metodologia, aplicando-se fusão de sensores e os pacotes computacionais desenvolvidos pelo consórcio *IMS* na detecção de falhas em uma bancada de testes composta por um atuador elétrico, onde é possível efetuar diferentes simulações de funcionamento nesta máquina e analisar o seu comportamento. Com a avaliação do desempenho deste sistema através dos pacotes computacionais, foi possível concluir que, quando projetada corretamente, uma arquitetura de fusão de sensores pode melhorar significativamente a qualidade do sensoriamento do processo.

ABSTRACT

The advances in sensors and transducers and their integration with data acquisition software allowed the gathering of two key elements for the development of an intelligent maintenance system: the real-time monitoring of system parameters and the variety of applications and techniques possible in a mathematical software tool. Such intelligent maintenance systems enable fault diagnosing of a particular piece of equipment, determining the root and cause of failures and even predicting when new failures will happen according to historical data from the monitored equipment.

Accordingly, some initiatives in the development and standardization of intelligent maintenance systems emerged. One such initiative was developed by the Intelligent Maintenance Systems Center (or simply IMS Center), which developed a methodology for the systematic approach in diagnosing systems, and aims to transform the traditional maintenance practices from "fail and fix" in a methodology "predict and prevent."

This work presents the use of this methodology, using sensor fusion and computational packages developed by the *IMS* consortium in the detection of faults in a test bench consisting of an electric actuator, where it's possible to perform different operating simulations on this machine and to analyze its behavior. By evaluating the performance of this system through the computational packages, it was concluded that, when properly designed, sensor fusion architecture can significantly improve the quality of the sensing of the process.

LISTA DE ILUSTRAÇÕES

Figura 1: Camadas do modelo OSA/CBM.....	19
Figura 2: Ferramentas de solução para os módulos funcionais do Watchdog Agent™.....	22
Figura 3: Árvore de decomposição de pacotes wavelets.....	26
Figura 4: Exemplo de curva de Valor de Confiança x Ciclos.....	28
Figura 5: Esquema de atuador elétrico.....	29
Figura 6: Forças presentes no sistema atuador-válvula.....	31
Figura 7: Representação da estrutura de camada de sensores de fusão de dados.....	37
Figura 8: Representação da estrutura central de fusão de dados.....	37
Figura 9: Representação de uma estrutura mista de fusão de dados.....	38
Figura 10: Representação de uma estrutura mista de fusão de dados.....	39
Figura 11: Representação de uma estrutura descentralizada de fusão de dados.....	39
Figura 12: Diagrama de fusão de características.....	41
Figura 13: Método de filtro.....	42
Figura 14: Método de invólucro.....	42
Figura 15: Exemplo de aplicação de PCA.....	44
Figura 16: Diagrama de combinação de classificadores.....	46
Figura 17: Hierarquia alternativa proposta por Dasarathy, caracterização de I/O.....	46
Figura 18: Modelo de fusão JDL.....	50
Figura 19: Representação do modelo de Thomopoulos.....	51
Figura 20: Diagrama representando o modelo cascata (<i>waterfall</i>).....	53
Figura 21: Painel frontal do atuador elétrico.....	55
Figura 22: Válvula de ar comprimido para o controle da pressão no freio.....	56
Figura 23: Acelerômetros posicionados.....	58
Figura 24: Componentes para a aquisição dos sinais.....	59
Figura 25: Rodas dentadas usadas nas falhas 3, 4 e 5.....	61
Figura 26: Exemplo de curva de amplitude vs. tempo dos sensores em ciclo normal.....	62
Figura 27: Transmissão do atuador elétrico com seus componentes e sensores.....	63
Figura 28: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 1.....	63
Figura 29: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 2.....	64
Figura 30: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 3.....	65
Figura 31: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 4.....	65
Figura 32: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 5.....	66
Figura 33: Fluxograma do algoritmo desenvolvido.....	73
Figura 34: Valor de confiança para o teste 1.....	74

Figura 35: Valor de confiança usando apenas o sinal de torque.	75
Figura 36: Teste 1 realizado com fusão dos sensores 1, 2 e 3.....	75
Figura 37: Curva do valor de confiança para o teste 2, com fusão dos quatro sensores.	76
Figura 38: Curva de valor de confiança para o sensor 4, no teste 2.	77
Figura 39: Curva de valor de confiança para a fusão do sensor 1 e 2, no teste 2.....	77
Figura 40: Valor de confiança calculado no teste 3, com fusão dos quatros sensores.	78
Figura 41: Valor de confiança calculado para o teste 3 com fusão dos acelerômetros.	79
Figura 42: Valor de confiança do sinal de torque (sensor 4) para o teste 3.	79
Figura 43: Valor de confiança obtido com o Watchdog Agent do Matlab.	80

LISTA DE TABELAS

Tabela 1: Tipos de manutenção e exigências técnicas.....	13
Tabela 2: Especificações do atuador elétrico modelo CSR6.....	55
Tabela 3: Especificações técnicas do acelerômetro 8705A.....	57
Tabela 4: Descrição dos ciclos simulados no sistema atuador-válvula.....	60
Tabela 5: Convenção utilizada no trabalho.....	61
Tabela 6: Resumo das características dos sinais.....	68

SUMÁRIO

1	INTRODUÇÃO	11
2	REVISÃO BIBLIOGRÁFICA.....	13
2.1	CONCEITOS SOBRE FALHAS E TIPOS DE MANUTENÇÃO.....	13
2.1.1	Manutenção Corretiva.....	14
2.1.2	Manutenção Preventiva.....	15
2.1.3	Manutenção Preditiva.....	16
2.2	SINAIS UTILIZADOS PARA DETECÇÃO DE FALHAS.....	17
2.3	MANUTENÇÃO INTELIGENTE – ARQUITETURA OSA/CBM	18
2.4	ANÁLISE DO SISTEMA WATCHDOG AGENT TOOLBOX™	20
2.4.1	Processamento de Sinais e Extração de Características	22
2.4.2	Ferramentas de Avaliação de Desempenho.....	26
3	ATUADORES ELÉTRICOS	29
3.1	Funcionamento do Atuador Elétrico	30
3.2	Forças Presentes no Atuador.....	30
3.3	Falhas Comuns em Válvulas e Atuadores Elétricos.....	31
4	FUSÃO DE SENSORES	33
4.1	Definição.....	33
4.2	Vantagens.....	34
4.3	Níveis de Fusão de Sensores	35
4.3.1	Nível de Fusão de Dados.....	36
4.3.2	Nível de Características.....	40
4.3.3	Nível de Decisão	44
4.3.4	Caracterização Baseada em Entradas/Saídas.....	46
4.4	Modelos de Fusão de Sensores.....	49
4.4.1	JDL.....	49
4.4.2	Arquitetura Thomopoulos	51

4.4.3	Modelo Cascata (<i>Waterfall</i>)	52
5	METODOLOGIA UTILIZADA	54
5.1	Descrição dos Equipamentos	54
5.1.1	Atuador Elétrico	55
5.1.2	Válvula de Ar Comprimido	56
5.1.3	Acelerômetros	57
5.1.4	Sistema de Aquisição: CompactRIO®	58
5.2	Descrição dos Testes Realizados	60
5.3	Avaliação dos Dados dos Sensores	61
5.3.1	Ciclo Normal	62
5.3.2	Falha 1	63
5.3.3	Falha 2	64
5.3.4	Falha 3	64
5.3.5	Falha 4	65
5.3.6	Falha 5	66
5.3.7	Resumo da Análise Primária	67
5.4	Desenvolvimento da Análise dos testes	69
5.4.1	Análise no Watchdog Agent para Matlab	69
5.4.2	Desenvolvimento da Fusão de Sensores no LabVIEW 2011	70
5.5	Análises e Resultados	74
5.5.1	Teste 1	74
5.5.2	Teste 2	76
5.5.3	Teste 3	78
5.5.4	Teste 4	79
6	CONCLUSÕES	81
7	REFERÊNCIAS BIBLIOGRÁFICAS	82
8	APÊNDICES	86

1 INTRODUÇÃO

Todo equipamento, quando utilizado regularmente para a execução de alguma tarefa, necessita estar em condições mínimas que assegurem seu pleno funcionamento durante esta atividade. Quando esta atividade está em um meio industrial, onde existe um processo produtivo dependente de seu funcionamento, é fundamental que essas condições mínimas sejam satisfeitas.

Portanto, para que uma máquina desempenhe suas funções adequadamente é necessário um conjunto de medidas que visem mantê-la em perfeito estado (ou, pelo menos, nas condições mínimas de operação). Esse conjunto de medidas denomina-se manutenção.

A manutenção surgiu durante a Revolução Industrial, quando os processos fabris passaram a substituir a mão de obra humana por máquinas. Naquele tempo, as funções desempenhadas pelas máquinas eram muito reduzidas, assim como a sua complexidade. Portanto, este conjunto de medidas não era exatamente organizado: ao quebrar uma peça, esta era imediatamente consertada ou trocada pelo próprio operador. Porém, com os desenvolvimentos tecnológicos dos anos seguintes e o surgimento das linhas de montagem, as máquinas e os equipamentos industriais começaram a ficar cada vez mais complexos e exigir mais cuidados.

Além disso, o processo produtivo das fábricas tornou-se mais dependente do total funcionamento do maquinário utilizado, exigindo menor tempo de paradas e menor número de falhas. As atividades de manutenção começaram a se tornar rotineiras e uma equipe especializada começou a ser designada somente para esta área.

A partir daí, a manutenção foi dividida em diferentes tipos de práticas e várias metodologias foram desenvolvidas para melhorar a execução de tais práticas, como será visto nas seções a seguir.

Uma das técnicas utilizadas dentro da manutenção preditiva, chamada manutenção baseada em condição, sugere a tomada de ações de acordo com o estado pontual do sistema (THURSTON; LEBOLD, 2001). A evolução dessa prática permitiu a elaboração de um sistema supervisorio que pudesse executar a inspeção do estado do sistema estudado com o mínimo de interferência em seu processo. Sendo assim, torna-se obrigatório, para essa nova abordagem, definir os parâmetros que melhor expressam o estado real do que se deseja monitorar e também estabelecer práticas padronizadas para a tomada de decisões e execução da manutenção.

A aquisição dos parâmetros que se deseja medir faz uso de transdutores como acelerômetros, torquímetros, dentre outros. Quando o diagnóstico deste equipamento estudado é proveniente de vários tipos de sensores e da correlação de seus sinais, denomina-se então arquitetura de fusão de sensores.

Este trabalho tem como objetivo principal avaliar uma estrutura de fusão de sensores, desenvolvida a partir do LabVIEW®, aplicada a uma bancada de testes composta por um atuador elétrico e um sistema de aquisição de dados. Injetando falhas no atuador, pretende-se simular diferentes situações e verificar se a arquitetura de fusão de sensores facilita a detecção de falhas. Para isto, foi instalado um freio a disco no sistema e peças da máquina foram substituídas por peças defeituosas. Finalmente, as análises foram executadas usando ferramentas computacionais disponibilizadas pelo *IMS Center*.

2 REVISÃO BIBLIOGRÁFICA

2.1 CONCEITOS SOBRE FALHAS E TIPOS DE MANUTENÇÃO

Manutenção é qualquer atividade que visa manter o bom funcionamento de um processo, máquina ou instalação. Todo equipamento necessita de alguma forma de manutenção: o tipo e periodicidade dessa manutenção dependem de qual equipamento se trata.

Existem muitas práticas diferentes de manutenção, cada uma com um custo, grau de confiabilidade e necessidades técnicas (BENEDETTI, 2002). Na Tabela 1, estão apresentados os principais tipos de manutenção em função de sua exigência técnica.

Tabela 1: Tipos de manutenção e exigências técnicas.

Tipo de manutenção	Exigência técnica
Corretiva	Bom orçamento para manutenção
Preventiva	Estoque de componentes e substituição dos mesmos em intervalos determinados
Preditiva	Qualidade do monitoramento dos sinais de interesse

Fonte: Benedetti (2002)

Antes de entrar em maiores detalhes sobre os tipos de manutenção, faz-se necessário definir os termos técnicos mais comumente utilizados nesta área.

- *Função*: é, basicamente, a função que o sistema ou equipamento desempenha. Por exemplo: a função de uma válvula é controlar o fluxo de um determinado líquido em uma tubulação (BENEDETTI, 2002).
- *Confiabilidade*: indica a capacidade de um sistema ou dispositivo de realizar sua função por um determinado período sob certas condições (BENEDETTI, 2002).
- *Falha*: evento que marca o término da capacidade do dispositivo ou sistema de desempenhar sua função (ABRAMAN, 2011).

- *Defeito*: desvio de uma característica normal do sistema ou equipamento em direção à degradação do mesmo podendo ou não interferir na sua capacidade de desempenhar sua função (ABRAMAN, 2011).
- *Mean Time Between Failures* (MTBF – ou, para o português, Tempo Médio Entre Falhas): tempo médio observado entre falhas consecutivas de algum dispositivo. Espera-se que este valor seja o mais alto possível para qualquer equipamento (ABRAMAN, 2011).
- *Mean Time To Repair* (MTTR – ou, para o português, Tempo Médio Para Conserto): tempo médio observado exigido para o retorno do sistema de volta à sua operação normal. Espera-se que este valor seja o menor possível (ABRAMAN, 2011).
- *Disponibilidade*: capacidade de um sistema ou dispositivo estar em condições de executar sua função em um determinado intervalo de tempo (ABRAMAN, 2011).

A seguir, serão descritos alguns fundamentos importantes sobre as principais estratégias de manutenção utilizadas atualmente: corretiva, preventiva e preditiva.

2.1.1 Manutenção Corretiva

Este tipo de prática de manutenção se resume ao conserto ou troca de uma peça (ou do equipamento) somente após a ocorrência de uma falha ou defeito. Como a falha em uma máquina é, na maioria dos casos, inesperada e a causa da mesma é desconhecida, o tempo para o reparo do equipamento é proporcional à experiência do profissional que executará as medidas corretivas (ABRAMAN, 2011).

Em alguns processos industriais, dependendo da função que a máquina desempenha, paradas críticas oriundas de falhas e defeitos podem ser inaceitáveis devido ao tempo de parada e ao estresse causado pela falha. Além disso, é importante ressaltar que o fato do equipamento ter sofrido dano suficiente ao ponto de interromper suas tarefas implica que o mesmo funcionou, por um período de tempo, em um estado de degradação, possivelmente causando danos em outras partes do equipamento e até mesmo em componentes indiretos do sistema.

Em contrapartida, a manutenção corretiva é preferível quando os custos da indisponibilidade do sistema são menores que os custos necessários para evitar que a falha ocorra. Basicamente, manutenção corretiva é indicada para equipamentos que não são essenciais ao processo produtivo ou onde o tempo de reparo não é prioridade.

2.1.2 Manutenção Preventiva

Manutenção executada com o propósito de prevenir problemas antes que eles ocorram (IEEE, 1990). Isso é feito realizando-se um reparo periódico em pontos críticos do sistema, geralmente aproveitando-se de paradas agendadas para sua execução. Esse tipo de medida impede que o equipamento venha a falhar em um momento inoportuno (necessitando, assim, de manutenção corretiva) e prolonga a sua vida útil, pois mantém o equipamento sempre em bom estado (BENEDETTI, 2002).

A manutenção preventiva é ideal para processos que sofrem degradação uniforme, pois é possível prever com grande precisão a ocorrência de falhas no sistema. Também é vantajosa em processos onde as falhas geram grande prejuízo para o processo produtivo e/ou para a segurança das pessoas envolvidas no mesmo (MARCORIN; LIMA, 2011). Exemplos de manutenção preventiva são a troca de óleo de um transformador de potencial e a limpeza de um filtro de ar condicionado.

Esta prática envolve algum estudo do sistema a ser monitorado, como por exemplo, quais são os equipamentos que necessitam de manutenção, qual a importância de cada um e a periodicidade de suas falhas. Feito isto, desenvolve-se um cronograma de manutenção composto por todos os componentes que precisarão de manutenção e a data e frequência na qual cada um deve ser vistoriado. Também é necessário manter um estoque de peças para a substituição dos componentes a serem trocados na execução da manutenção preventiva.

Apesar de reduzir a probabilidade da ocorrência de uma falha crítica, a manutenção preventiva é cara: além de exigir um estoque de componentes para reposição, peças que teriam um longo período de vida útil são muitas vezes substituídas durante a manutenção periódica, gerando enormes gastos com material (MARCORIN; LIMA, 2011). As paradas programadas também geram gastos desnecessários devido aos tempos de parada e, em algumas ocasiões, podem ser a causa de uma falha futura em um equipamento que se encontra em perfeito estado, devido a uma má execução da manutenção por parte do profissional

responsável. Por estes motivos, em algumas indústrias é raro observar-se práticas de manutenção preventiva.

2.1.3 Manutenção Preditiva

É a manutenção baseada na análise de algumas condições e variáveis do sistema para prever eventuais falhas (IEEE, 1990). Pode ser efetuada com desde uma simples inspeção visual até um sistema embarcado de aquisição de sinais. O ponto positivo da manutenção preditiva é, geralmente, a baixa intervenção no processo. Realizada a manutenção preditiva, é então feito um diagnóstico do estado atual do equipamento analisado e uma previsão do intervalo de tempo para a próxima falha (BENEDETTI, 2002).

As análises a serem aplicadas nas suas respectivas condições devem ser previamente estudadas e qualificadas para que a manutenção seja realmente efetiva. Por exemplo, a critério de manutenção, o que deve ser analisado em um motor que movimenta uma esteira em uma linha de produção? Quais são os pontos críticos e como estes devem ser avaliados? Poder-se-ia dizer que uma análise visual do seu estado é suficiente para prever que uma falha elétrica ocorrerá? Ou que uma análise do comportamento do torque no eixo do motor pode fornecer informações suficientes para detectar uma falha mecânica no mesmo? Este tipo de avaliação deve ser considerado, pois alguns sinais podem ou não auxiliar na identificação das falhas.

A eficácia da manutenção preditiva está diretamente relacionada à afinidade dos sinais adquiridos com o comportamento real da máquina e, portanto, às suas falhas de interesse. Antigamente, o problema dessa prática era que nem toda informação podia ser facilmente detectada. Entretanto, o avanço na área de instrumentação e softwares de manipulação e comunicação com sensores possibilitou o desenvolvimento de sistemas embarcados que, apesar de ainda exigirem grande investimento inicial, podem ser instalados em pontos críticos do processo produtivo para fornecer diagnósticos sobre os componentes e previsão de falhas com grande precisão (BENEDETTI, 2002).

2.2 SINAIS UTILIZADOS PARA DETECÇÃO DE FALHAS

Em primeiro lugar, é importante notar que os sinais utilizados para o estudo das falhas de um sistema variam de acordo com a sua característica e com o tipo de estratégia de manutenção que será empregada. Para tanto, faz-se necessário uma análise inicial de qual sinal fornecerá a resposta mais satisfatória e mais fiel ao comportamento do sistema.

Existem diversas maneiras de obter dados significativos sobre as condições de um sistema. Algumas delas serão brevemente descritas a seguir:

- *Observação direta:* nesta prática, o equipamento que se deseja diagnosticar é analisado através de uma inspeção visual de seus componentes críticos. É um método que garante pouco sucesso, considerando que muitos sinais de falha são imperceptíveis a olho nu (CARVAJAL, 2011).
- *Análise de óleo:* equipamentos e peças que utilizam óleo como lubrificante ou isolador podem ser diagnosticados através de sua análise. No caso de engrenagens, por exemplo, a força de atrito entre as mesmas desprende partículas de metais que se acumulam no óleo. Já em caso de transformadores a óleo, fatores adversos podem aumentar a concentração de gases presentes no isolador, proporcionando uma forma de diagnóstico. Segundo Carvajal (2011), cerca de 30% das falhas mais comuns em peças lubrificadas podem ser detectadas através da análise do óleo.
- *Análise de temperatura:* variações e picos de temperatura podem fornecer informações de falhas de um equipamento devido à falta de refrigeração. Problemas de superaquecimento são comuns em contatos de componentes elétricos, causando vários problemas como desgaste e carbonização de cabos e equipamentos (CHUDNOVSKY, 2006).
- *Análise da corrente elétrica:* o monitoramento do valor da corrente elétrica e de sua resposta em frequência pode ser utilizado como ferramenta de diagnóstico em vários componentes como máquinas rotativas, onde é analisada a sua interação com o torque (CARVAJAL, 2011).
- *Análise de emissão acústica:* trata-se de avaliar, através de sensores de emissão acústica, o comportamento dos sinais sonoros de acordo com a variação da carga. Um dos problemas no emprego dessa técnica é a presença de ruído no sinal, proveniente do ambiente em que se encontra o componente

estudado. A análise de emissão acústica tem demonstrado sucesso no desenvolvimento de peças para a indústria aeroespacial (RICE et al., 2003) e petrolífera (JACQUES, 2009).

- *Análise de vibração*: equipamentos rotativos apresentam ruído e vibração quando estão em funcionamento. É muito comum o sinal de vibração variar quando o nível de saúde do equipamento é alterado devido a uma falha, portanto tem-se na vibração uma assinatura de falhas muito útil tanto para regime permanente quanto para transitórios. O sinal de vibração pode ser analisado de diversas formas, dentre eles pode-se citar a análise da forma de onda e análise da frequência (BENEDETTI, 2002; MENNA, 2007).

2.3 MANUTENÇÃO INTELIGENTE – ARQUITETURA OSA/CBM

No desenvolvimento de um sistema de manutenção preditiva, os projetistas enfrentam desafios como desenvolver e integrar uma grande variedade de software/hardware e componentes para os mesmo, assim como estabelecer um fluxograma eficiente e que ofereça uma interface amigável para os operadores deste sistema (MIMOSA, 2011).

Para auxiliar a enfrentar estes desafios, uma arquitetura padrão foi desenvolvida para simplificar o fluxo de informação dedicado à manutenção baseada em condição (manutenção preditiva): a *Open Systems Architecture – Condition Based Maintenance* (OSA/CBM) que, traduzindo para o português, significa “Arquitetura de Sistema Aberto – Manutenção baseada em Condição” (MIMOSA, 2011).

O padrão OSA/CBM foi desenvolvido por um grupo fundado parcialmente pela Marinha Americana através de um programa conhecido como *Dual Use Science and Technology* (DUS&T) e financiado por indústrias como a Boeing, Caterpillar, Rockwell Automation, dentre outros.

Essa arquitetura auxilia na elaboração de um sistema de monitoramento baseado em condição estabelecendo padrões para o seu projeto, fornecendo assim meios para integrar os vários componentes desenvolvidos. O fluxograma padrão do OSA/CBM é composto por camadas, onde as entradas e saídas entre os componentes são especificadas. Em resumo, descreve o caminho que a informação percorre nesse sistema e como ela está sendo

processada (MIMOSA, 2011; DJURDJANOVIC, LEE, NI, 2003). As camadas do OSA/CBM estão apresentadas na Figura 1.

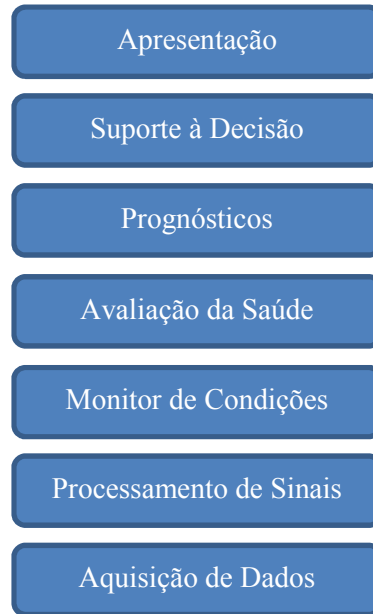


Figura 1: Camadas do modelo OSA/CBM
Fonte: Mimososa (2011)

Para um melhor entendimento deste modelo, será feita uma breve descrição de cada uma das camadas supracitadas:

- *Aquisição de Dados:* nesta camada, as informações do sistema são retiradas através de um sensor, onde sua entrada é uma medida de grandeza física e sua saída é uma grandeza elétrica (tensão ou corrente). Também estão incluídos nessa mesma camada o condicionamento do sensor e a conversão analógica para digital.
- *Processamento de Sinais:* etapa que consiste na manipulação dos sinais adquiridos pelos sensores. Nesta camada, são utilizadas ferramentas de processamento e análise de sinais para extrair características importantes sobre o comportamento do sistema. Os módulos de processamento executam funções que transformam os sinais adquiridos e fornecem saídas variadas, como dados filtrados digitalmente, espectros de frequência e características CBM.
- *Monitor de Condições:* com os sinais devidamente manipulados pelo módulo de processamento, nesta etapa são executadas várias comparações das características esperadas com as características obtidas para determinar os

valores dos indicadores de condição. Nesta camada, são arquivados os dados das duas primeiras camadas para uso das camadas posteriores.

- *Avaliação da Saúde*: é o módulo que determina se a saúde de um sistema, subsistema, ou parte de um equipamento degradou. Caso tenha sido constatada a degradação de um componente, o módulo gera um diagnóstico apontando possíveis falhas, considerando dados históricos da saúde, status de operação e carga, e o histórico de manutenção.
- *Prognósticos*: é nesta camada onde são feitas as previsões do comportamento e estado do sistema, baseado nas informações das camadas anteriores. Sua principal função é projetar a saúde atual do equipamento para o futuro levando em consideração as possíveis condições futuras e perfis de utilização.
- *Suporte à Decisão*: sua função principal é fornecer ações recomendadas e alternativas e as implicações de cada uma delas. As suas entradas vêm, principalmente, das camadas de avaliação de saúde e de prognósticos e suas saídas podem incluir planos de ação, modificando configurações operacionais a fim de atingir os objetivos do trabalho. Assim como as duas camadas anteriores, o módulo de suporte à decisão também mantém um histórico próprio.
- *Apresentação*: é, basicamente, a camada que faz a interface com o usuário e permite a ele o acesso às outras camadas. Pelo módulo de apresentação, é possível gerenciar alarmes e observar a fundo o funcionamento de cada módulo.

2.4 ANÁLISE DO SISTEMA WATCHDOG AGENT TOOLBOX™

Desenvolvido no Centro de Manutenção Inteligente (*Center for Intelligent Maintenance Systems*), ou simplesmente *IMS Center* na Universidade de Cincinnati em Ohio o *Watchdog Agent™* tem como objetivo estudar e validar as técnicas de manutenção inteligente. O *Watchdog Agent™* é uma ferramenta computacional baseada no modelo OSA/CBM que facilita a execução de algumas camadas do modelo de manutenção baseada em condição. Desenvolvida na plataforma *Matlab®*, o *Watchdog* é capaz de realizar várias técnicas de processamento de sinais, como Análise de Fourier, Transformada de *Wavelet*,

Wavelets Packets e ainda executar ferramentas de diagnóstico e prognóstico, como a Regressão Logística e os Mapas Auto Organizáveis, respectivamente (JOHNSON, 2006; DJURDJANOVIC, LEE, NI, 2003).

O método utilizado pelo Watchdog Agent™ para avaliar a degradação do sistema ou componente é baseado na leitura dos sinais de sensores instalados no equipamento que podem fornecer informações relevantes sobre as propriedades e comportamento do mesmo. Com a variação destes sinais, é possível fazer uma análise qualitativa e quantitativa do nível de degradação e, além disso, fazer uma previsão do seu estado futuro. Ainda, a utilização de dados históricos sobre o comportamento normal e de falha do processo, um modelo de processo similar ao avaliado e conhecimento prático do sistema podem ajudar em uma melhor descrição do processo de desgaste (DJURDJANOVIC, LEE, NI, 2003).

A função de prognóstico do Watchdog é realizada através da análise de tendência e modelagem das dinâmicas das assinaturas de desempenho do processo observado e/ou parâmetros do modelo. Isso permite prever o comportamento futuro desses padrões e, portanto, prever o comportamento do processo que está sendo considerado (DJURDJANOVIC, LEE, NI, 2003).

Além disso, o Watchdog Agent™ também é capaz de realizar diagnósticos precisos, memorizando as assinaturas padrões significativas do sistema a fim de reconhecer situações que foram observadas no passado ou alertar sobre situações que nunca foram observadas anteriormente. Assim, o Watchdog Agent™ tem elementos de comportamento inteligente que possibilitam saber quando o desempenho de um processo atingirá um nível inaceitável e o motivo dessa queda de desempenho (DJURDJANOVIC, LEE, NI, 2003).

Resumidamente, a funcionalidade do Watchdog Agent™ pode ser apresentada em três tarefas distintas (DJURDJANOVIC, LEE, NI, 2003):

- Avaliação quantitativa da degradação de desempenho
- Previsão da degradação
- Diagnóstico das razões da degradação atual ou futura

Algumas ferramentas de processamento e análise dos sinais serão brevemente descritas a seguir. Porém, o conteúdo abordado ficará restrito às camadas de processamento de sinais, extração de características e avaliação de desempenho, pois as camadas de diagnóstico e prognóstico não fazem parte do escopo deste trabalho. A Figura 2 apresenta um diagrama com alguns dos módulos funcionais disponíveis no Watchdog Agent (DJURDJANOVIC, LEE, NI, 2003).

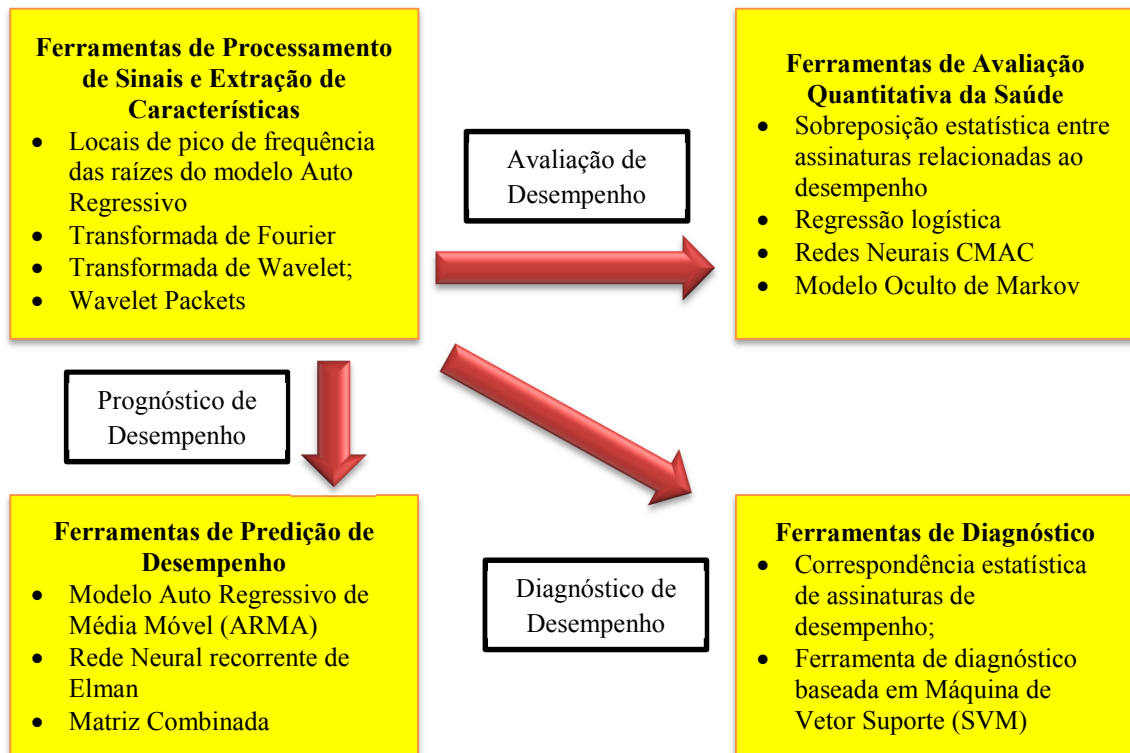


Figura 2: Ferramentas de solução para os módulos funcionais do Watchdog Agent™.
 Fonte: Djurdjanovic (2003).

2.4.1 Processamento de Sinais e Extração de Características

2.4.1.1 Transformada de Fourier

A Transformada de Fourier (FT) expressa um sinal em termos de suas funções sinusoidais, ou seja, como uma soma ou integral de funções seno e cosseno multiplicada por coeficientes constantes.

Entre suas vantagens, podemos citar que ela decompõe o sinal em suas componentes de amplitude e frequência, isolando componentes individuais de um sinal complexo para detecção e remoção de características indesejáveis. Particularmente, a Transformada de Fourier facilmente decompõe um sinal em componentes DC (média ou offset do sinal) e AC (senóides ou exponenciais complexas) (IMS CENTER, 2007).

As desvantagens da Transformada de Fourier são o fato de ela não preservar as características temporais do sinal e que o seu uso é restrito somente a sinais estacionários

(quando a frequência não varia), onde a variação de energia não interessa para a análise do sinal.

2.4.1.2 Discrete-Time Fourier Transform (DTFT)

É a ferramenta para análise de sinais discretos e não periódicos (sinal digital ou sinal analógico amostrado) (IMS CENTER, 2007). É expressa como na Equação 1:

$$X(\omega) = \sum_{n=-\infty}^{\infty} x[n] \cdot e^{-j\omega n} \quad (1)$$

Onde $X(\omega)$ é contínua com período 2π radianos e sua inversa é mostrada na Equação 2:

$$x[n] = \int_{2\pi} X(\omega) \cdot e^{j\omega n} \cdot d\omega \quad (2)$$

Também pode ser expressa como a multiplicação de suas componentes de módulo e fase, assim como na Equação 3:

$$X(\omega) = |X(\omega)| \cdot e^{j\varphi\omega} \quad (3)$$

2.4.1.3 Análise em Tempo-Frequência

Uma representação em tempo-frequência (TFR, do inglês *Time Frequency Representation*) é uma vista de um sinal (função do tempo) representada simultaneamente no tempo e na frequência. Sendo assim, a análise em tempo-frequência é a análise da TFR (IMS CENTER, 2007).

Como a TFR fornece informações temporais e espectrais, a análise da TFR é aplicável para sinais não estacionários e sinais de banda larga, que envolvem vários impactos e comportamentos transientes. Aplicações possíveis poderiam ser vibração ou monitoramento com som como diagnóstico de rolamentos, motores automotivos, etc. (IMS CENTER, 2007).

Porém, apesar de oferecer perfeita resolução temporal e espectral ao mesmo tempo, o cálculo necessário envolve termos cruzados que exigem alta capacidade computacional.

Portanto, a análise da TFR não é indicada quando se trata de uma grande quantidade de informação e a velocidade de processamento é um critério a ser considerado (IMS CENTER, 2007).

2.4.1.4 Short Time Fourier Transform (STFT)

Short Time Fourier Transform (Transformada de Fourier de Tempo Curto) é uma TFR linear que é uma combinação linear ou uma superposição das TFR das componentes do sinal assumindo que o sinal temporal possa ser expresso como uma superposição de algumas componentes do sinal (IMS CENTER, 2007).

A STFT é uma extensão da Transformada de Fourier. Na FT, faz-se a análise de todo o sinal, já que as componentes em frequência são assumidas constantes durante a aquisição do sinal temporal. No caso de sinais não estacionários, a STFT usa a FT para intervalos de tempo “janelados”. A STFT computa a FT de segmentos individuais de tempo e linearmente os combina para formar a TFR completa (IMS CENTER, 2007; JOHNSON, 2006).

2.4.1.5 Análise de Wavelets

A análise de wavelet, análise de pacotes wavelets (ou simplesmente WPA) e a transformada de wavelets se referem à representação de um sinal em termos de um comprimento finito ou uma forma de onda oscilatória e de rápido decaimento (mãe wavelet). Esta forma de onda é escalada e transladada para combinar com o sinal de entrada. Em termos formais, esta é uma série de wavelets, que é a representação de uma função com base em uma família completa ortonormal de funções básicas. Qualquer sinal, como na FT, pode ser representado como uma soma de componentes; neste caso, wavelets (IMS CENTER, 2007; JOHNSON, 2006).

Já que a análise de wavelet preserva as informações temporais e espectrais, ela é útil para a análise de sinais variantes no tempo e não estacionários. Também se podem incluir processos com impactos periódicos como aqueles que utilizam caixa de câmbio ou máquinas. Também possui processamento mais rápido que a FT e a TFR (IMS CENTER, 2007).

A Transformada de Wavelet Contínua pode ser descrita como na Equação 4:

$$CWT_x(\tau, a) = \int x(t) \cdot h_{a,\tau}^*(t) \cdot dt \quad (4)$$

Onde se tem que a função base é expressa como está apresentado na Equação 5:

$$h_{a,\tau}(t) = \frac{1}{\sqrt{a}} \cdot h\left(\frac{t-\tau}{a}\right) \quad (5)$$

Considerando que $h_{a,\tau}(t)$ é escalada por a e deslocada no tempo por τ e onde $h(t)$ é a mãe wavelet.

Enquanto a ortogonalidade e a suavidade da transformada de wavelets são mantidas, esta pode ser representada pela combinação linear de seus coeficientes, chamados de “pacotes wavelets” (*wavelet packets*). Um algoritmo recursivo é utilizado para combinar as wavelets para formar os pacotes wavelets (IMS CENTER, 2007).

O processo que representa um sinal $x(t)$ em uma soma de pacotes wavelets é chamado de “árvore de decomposição de pacotes wavelets”. Esta decomposição permite expor as componentes de alta frequência do sinal, atribuídos como detalhes, e componentes de baixa frequência atribuídos como aproximação do sinal em função do tempo. Este processo pode ser repetido até a resolução desejada (JOHNSON, 2006).

O processo de decomposição pode ser descrito matematicamente pelas seguintes funções básicas (Equações 6 e 7) (CHEN; CHUA; LIM, 2008; JOHNSON, 2006):

$$W_{2n}(2^{p-1}x - l) = \sqrt{2^{l-p}} \sum_m h(m - 2l) \sqrt{2^p} W_n(2^p x - m) \quad (6)$$

$$W_{2n+1}(2^{p-1}x - l) = \sqrt{2^{l-p}} \sum_m g(m - 2l) \sqrt{2^p} W_n(2^p x - m) \quad (7)$$

Onde p é o índice de escala, l é o índice de translação, h é um filtro passa baixas, e g é um filtro passa altas com $g(k) = (-1)^k h(1 - k)$. As duas primeiras funções que podem ser identificadas são a $W_0(x)$, que é a função passa baixas de escala φ , e $W_1(x)$, que é a mãe wavelet passa altas ψ . Os coeficientes dos pacotes wavelets em uma diferente escala e posição de um sinal $x(t)$ podem ser representados pela Equação 8 (JOHNSON, 2006):

$$C_{n,k}^p = \sqrt{2^p} \int x(t) W_n(2^p x - k) \cdot dx \quad (8)$$

A Figura 3 apresenta o fluxograma do processo de decomposição.

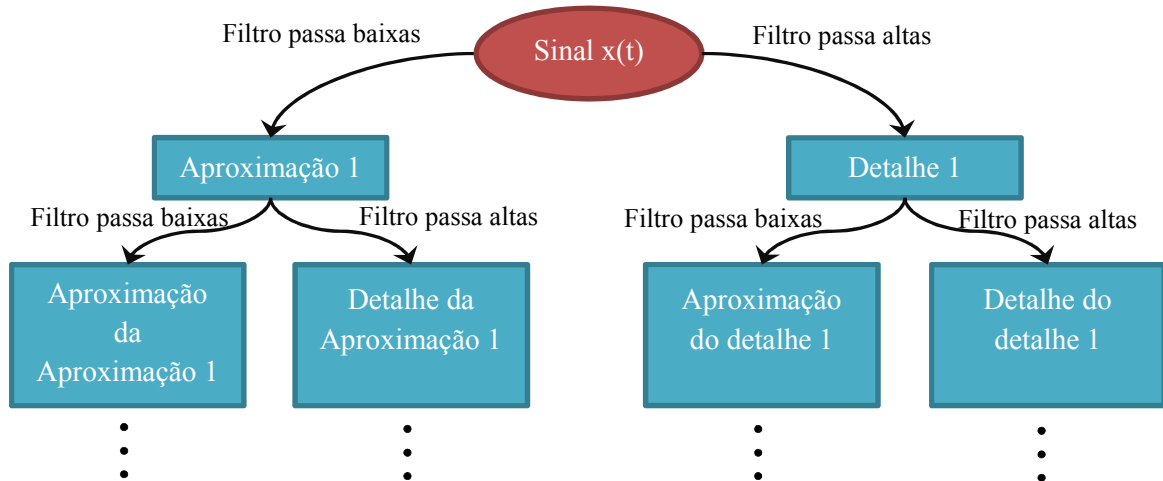


Figura 3: Árvore de decomposição de pacotes wavelets.
Fonte: Johnson, 2006.

Uma ferramenta importante na análise de wavelets, para extração de características, é a energia dos pacotes wavelets (WPE). É possível calcular uma assinatura de energia S_n para cada sequência de coeficientes dos pacotes wavelets $C_{n,k}^p$ para $n = 0, \dots, 4^p - 1$ com a Equação 9:

$$S_n = \frac{1}{N^2} \sum_{k=1}^N |C_{n,k}^p|^2 \quad (9)$$

Desta equação, é possível obter um vetor de características que pode ser usado para comparar as assinaturas de energias de diferentes sinais (JOHNSON, 2006).

2.4.2 Ferramentas de Avaliação de Desempenho

2.4.2.1 Regressão Logística

Regressão logística é um modelo linear generalizado que utiliza o logit como função de ligação. O logit de um número qualquer c é definido na Equação 10 (MENARD, 1995):

$$\text{logit}(c) = \log\left(\frac{c}{1-c}\right) \quad (10)$$

A função logística define a probabilidade $p(x)$ na Equação 11:

$$p(x) = P(y = 1|x) = \frac{1}{1 + e^{-(\alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)}} \quad (11)$$

Onde α e β são constantes e $x = (x_1, x_2, \dots, x_k)^T$ é o vetor de entrada com dimensão k e y é uma saída com valor binário (0 ou 1). A regressão logística tenta realizar um mapeamento desse vetor com dimensão k em um espaço unidimensional (MENARD, 1995). A Equação 12 pode ser reescrita em um formato de modelo linear, como a seguir:

$$g(x) = \log\left(\frac{p(x)}{1 - p(x)}\right) = \alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad (12)$$

Onde $g(x)$ é uma combinação linear do vetor de entrada x .

No modelo de regressão logística presente no Watchdog Agent se tem, na prática, um grupo de amostras $\{x\}$ de onde a probabilidade $\{p(x)\}$ é estimada a partir de estatísticas ou especificada subjetivamente de acordo com as necessidades (por exemplo, definir p igual a 0,95 para entradas normais e 0,10 para entradas anormais). Então, os parâmetros são obtidos resolvendo o modelo linear proposto na Equação 12 (IMS CENTER, 2007).

O algoritmo de regressão logística deve ser treinado para que possa apresentar o resultado esperado. Os dados de treinamento são compostos por características de funcionamento normal e de funcionamento anormal (falha). Sendo assim, as características aceitáveis e inaceitáveis devem ser previamente conhecidas. É possível realizar um método de ponderação através da correlação entre dados normais e anormais ou estes dados podem ser classificados arbitrariamente (determinados pelo usuário) (IMS CENTER, 2007).

Com os dados de treinamento inseridos no algoritmo, as características de teste (ou seja, os dados que se deseja avaliar) são computadas e o valor de confiança (ou *confidence value* - CV) pode então ser calculado, como está explícito na Equação 13.

$$CV(x) = \frac{1}{1 + e^{\alpha + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k}} \quad (13)$$

O valor de confiança apresenta um valor de 0 a 1, sendo que valores próximos de 1 correspondem a um “comportamento sadio” e valores próximos de zero correspondem a um “comportamento defeituoso”. A Figura 4 apresenta uma análise pelo valor de confiança do funcionamento de uma porta de elevador (YAN, CHEN, 2006).

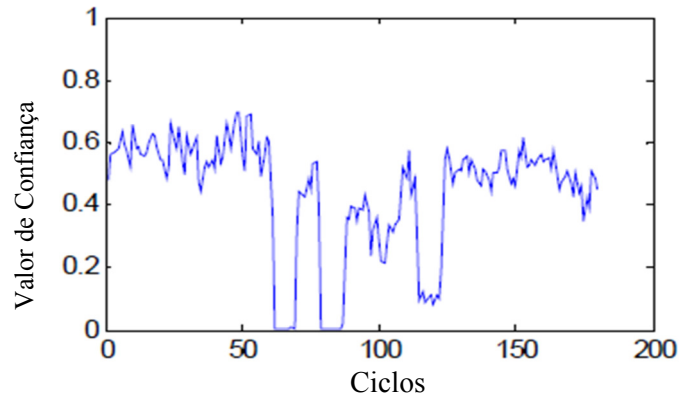


Figura 4: Exemplo de curva de Valor de Confiança x Ciclos.
Fonte: Yan e Chen (2006).

2.4.2.2 Reconhecimento Estatístico de Padrões

Compara analiticamente a distribuição de características. Calculando a sobreposição das características que estão sendo medidas com o modo normal ou com o modo de falha, obtém-se o CV do sistema ou a probabilidade de falha (IMS CENTER, 2007).

O cálculo desta sobreposição necessita que a distribuição das características seja aproximadamente gaussiana. Porém, somente é aplicado a distribuições que possam ser aproximadas por uma gaussiana, o que não ocorre em sistemas altamente dinâmicos (IMS CENTER, 2007).

O CV, neste caso, é como está apresentado na Equação 14:

$$CV(\tilde{x}) = 1 - F_{\chi_p^2} \cdot \sum_{i=1}^p \tilde{x}_i^2 \quad (14)$$

No procedimento computacional para o cálculo de CV, admite-se que as amostras r -dimensionais são armazenadas em uma matriz $X_{n \times r}$, cada linha na qual é uma amostra e há n amostras no total. É importante notar que uma amostra é um vetor linha (IMS CENTER, 2007).

3 ATUADORES ELÉTRICOS

Largamente utilizados em refinarias de petróleo e empresas de saneamento básico, os atuadores elétricos são dispositivos eletromecânicos capazes de controlar mecanicamente a posição da haste de válvulas, *dampers* e comportas com a finalidade de controlar remotamente o fluxo de gás ou líquido que passa por uma determinada tubulação.

Fisicamente, o atuador elétrico consiste de uma carcaça metálica em alumínio “Copper Free”, com um volante mecânico manual, um motor assíncrono de gaiola de esquilo, uma caixa de engrenagens, um compartimento para um circuito eletrônico (CPU) e um painel frontal com display e comando (ver Figura 5).




Figura 5: Esquema de atuador elétrico.
Fonte: Coester Automação S. A.

Existem diferentes modelos de atuadores elétricos. Geralmente, o que define o modelo de atuador elétrico a ser usado é a válvula que se deseja controlar. Para válvulas utilizadas em tubulações maiores, é necessário um atuador com maior faixa de torque. Em válvulas gaveta (como a da Figura 5) e globo, usa-se um atuador elétrico multivoltas. Para válvulas do tipo esfera ou borboleta, usam-se atuadores com $\frac{1}{4}$ de volta.

3.1 FUNCIONAMENTO DO ATUADOR ELÉTRICO

Instalado à haste de uma válvula, o atuador elétrico tem a função de abrir e fechar a mesma através de um conjunto de engrenagens acoplado ao motor de indução. Através do esforço exercido na haste, o atuador controla a abertura do obturador da válvula, controlando assim o fluxo de líquido ou gás que o percorre. A posição relativa do obturador é indicada através de um sensor potenciométrico de alta precisão e apresentada no display do atuador, onde “100%” significa que a válvula está totalmente aberta e “0%” totalmente fechada.

O atuador elétrico também pode conter um transdutor de torque, que consiste em uma célula de carga¹ que se deforma com o contra torque do motor sobre as engrenagens. Esse sinal, assim como o sinal de posição, é enviado para a CPU do atuador onde passa por um condicionamento e processamento sendo, finalmente, apresentado no display da máquina. O torque exibido no display varia de 0 a 100%, correspondendo respectivamente ao torque mínimo e máximo que o atuador suporta (esse valor de torque varia para diferentes modelos de atuadores).

Para proteger o motor de possíveis danos, o atuador elétrico é equipado com um sistema automático de proteção que age em eventos, como torque excessivo, alta temperatura, sobrecorrente no motor, oriundos de falhas críticas na válvula.

O controle do atuador pode ser executado localmente por um operador, ou remotamente através de um sistema supervisório. Caso o sistema de acionamento elétrico esteja indisponível, o atuador conta com um volante manual para operar a válvula.

3.2 FORÇAS PRESENTES NO ATUADOR

Como visto anteriormente, o motor do atuador elétrico aciona as engrenagens causando a rotação da haste que, por sua vez, abre ou fecha o obturador. A força que o atuador elétrico exerce deve superar as resistências individuais de cada parte do sistema para que ocorra o movimento esperado.

Dentre as forças resistentes presentes no sistema atuador-válvula, pode-se citar a força da mola (que é a peça responsável pelo retorno da gaveta da válvula à posição inicial, no

¹ Alguns atuadores elétricos não possuem uma célula de carga, mas ao invés disso medem a corrente elétrica no motor. O torque é, então, medido indiretamente a partir do valor desta corrente (LIMITORQUE QX, 2011).

caso de interrupção da alimentação), a força de atrito entre a haste e a gaxeta (peça que impede vazamento) e a força do fluido que passa pela válvula (GONÇALVES et al., [2007]). A Figura 6 apresenta as forças presentes no atuador elétrico.




Figura 6: Forças presentes no sistema atuador-válvula.
Fonte: Gonçalves et al. ([2007]).

3.3 FALHAS COMUNS EM VÁLVULAS E ATUADORES ELÉTRICOS

O sistema atuador-válvula sofre de inúmeras falhas que podem ser detectáveis ou não de acordo com os parâmetros que estão sendo observados. A maior parte dos problemas ocorridos em válvulas (como presença de detritos na tubulação) pode ser diretamente detectada durante a operação do atuador.

Segundo Gonçalves ([2007]), em um sistema atuador-válvula podem ocorrer as seguintes falhas:

- *Falha na caixa de reduções:* falha que ocorre na caixa de reduções do atuador; geralmente, está relacionada à quebra do sem-fim devido a torque excessivo.
- *Falha na mola:* relacionada à perda de elasticidade da mola, decorrente do desgaste da mesma com o tempo.

- *Falha por atrito excessivo*: decorrente do aumento da força de atrito entre a haste e a gaxeta, geralmente ocasionada devido a um vazamento de líquido e sua consequente cristalização na região de acoplamento.
- *Falha devido à densidade*: ocorre na variação da densidade do fluido presente na válvula.

Entretanto, existem outras falhas comuns que ocorrem diretamente no atuador elétrico. De acordo com Hayward Industrial Products Inc. (2011), é possível citar:

- *Torque excessivo*: a consequência direta dessa condição é a quebra da caixa de engrenagens do atuador. Pode ser causada por mau dimensionamento do atuador ao tipo de válvula. Situações de sobretorque ocorrem geralmente devido a obstruções excessivas na tubulação durante a abertura ou fechamento da válvula.
- *Ciclo de trabalho excessivo*: a definição de “ciclo de trabalho” é o tempo que o motor pode funcionar em relação ao tempo que o mesmo deve “descansar”. Todo motor de corrente alternada possui um ciclo de trabalho que deve ser respeitado. O excesso de trabalho no motor pode causar a sua queima. Dentre os possíveis agravantes para esta condição pode ser citados a exposição a altas temperaturas e sistemas de controle instáveis.
- *Proteção inapropriada*: em ambientes desfavoráveis, é possível que o atuador elétrico apresente problemas devido à deficiência de sua proteção². Esses problemas podem ser causados pela umidade, causando corrosão dos seus componentes (motor, placa, engrenagens).
- *Picos de tensão*: podem ser causados devido a diversas falhas elétricas no sistema de distribuição ou a descargas elétricas, causando queima dos componentes internos do atuador, em especial, a CPU.

² Índice de Proteção (IP), conforme NBR IEC 60529.

4 FUSÃO DE SENSORES

O estudo de fusão de sensores (ou “*sensor fusion*”) tem crescido muito nos últimos anos devido aos inúmeros avanços na área de instrumentação e de processamento de sinais. Em função do seu grande potencial na indústria civil e bélica, esse assunto tem sido cada vez mais abordado em congressos, jornais científicos e periódicos da área.

Apesar disso, a definição de fusão de sensores é geralmente incompreendida. Alguns autores se referem à fusão de sensores como “fusão de dados”: a combinação dos sinais de sensores para alcançar uma determinada melhoria em relação à análise individual dos sinais. Dessa forma, a melhoria depende do objetivo de cada aplicação. Entretanto, outros autores se referem à fusão de dados como “fusão de dados brutos”, ou seja, de sinais que não se encontram inicialmente preparados no momento de sua combinação (DASARATHY, 1997; ELMENREICH, 2011). Em vista disso, Dasarathy propôs o termo “fusão de informação” para se referir à fusão de qualquer tipo de dado, tornando a fusão de sensores em um subgrupo (LIU et al., 2007).

4.1 DEFINIÇÃO

Informalmente, pode-se dizer que fusão de sensores consiste em associar ou fundir informações que partem de várias fontes e usar essas informações associadas ou fundidas em variadas tarefas, tais como aumentar a confiabilidade dos dados, ajudar na tomada de decisões, detectar variações sutis de comportamento de um sistema ou realizar estimativas numéricas. Essa definição implica em dois conceitos principais: combinação da informação e objetivo da fusão (BLOCH; HUNTER, 2001).

Sendo assim, introduz-se a definição de fusão de sensores como a combinação de dados de sensores ou dados provenientes de sinais de sensores tal que a informação resultante é, de alguma forma, melhor do que seria possível se esses dados fossem analisados individualmente. É importante ressaltar que essa melhoria pode ser na forma de informações mais completas, mais precisas ou mais fáceis de computar e visualizar, e dependem do objetivo especificado para a fusão de sensores (ELMENREICH, 2011)

Talvez o melhor exemplo de fusão de sensores que se pode citar é o cérebro humano. Utilizando dos cinco sensores básicos do corpo humano (olhos, ouvidos, nariz, língua e pele), o cérebro “funde” os cinco sinais adquiridos pelos sensores (visão, audição, olfato, paladar e tato) e fornece o que se espera ser a melhor interpretação dos fenômenos presenciados. O cérebro, para esta comparação, demonstra ser uma arquitetura de fusão de sensores muito flexível já que, em geral, essa fusão ocorre em diferentes níveis para diferentes funções em diferentes combinações (DASARATHY, 1997).

4.2 VANTAGENS

Antes de apresentar as vantagens da fusão de sensores, devem-se citar os problemas mais comuns em sistemas que não utilizam múltiplos sensores. De acordo com Elmenreich (2011), são eles:

- *Perda do sensor*: um evento de falha em um sensor causa a perda de percepção do objeto observado. Exemplo: se o velocímetro quebra, perde-se a medida e, conseqüentemente, o controle do valor da velocidade do automóvel.
- *Cobertura espacial limitada*: sensores cobrem uma área restrita do fenômeno que se deseja observar e controlar. Exemplo: um único termômetro não consegue fornecer a temperatura média real de uma tubulação de etanol; a informação fornecida se restringe à área onde ele está instalado.
- *Cobertura temporal limitada*: a frequência na qual um fenômeno é medido pode ser limitada devido ao tempo de execução necessário para o sensor executar a medição.
- *Imprecisão*: a observação do fenômeno é limitada pela precisão do dispositivo de medição.
- *Incerteza*: um único sensor não consegue medir todos os parâmetros relevantes de um determinado sistema.

O uso de vários sensores e de sua eventual fusão gera inúmeras vantagens sobre o uso de sensores individuais. Segundo Henderson et al. (2011), Elmenreich (2011) e Esteban et al. (2005), destacam-se:

- *Mais informações:* o uso de vários sensores aumenta a quantidade de parâmetros que podem ser analisados. Isso pode significar uma maior abrangência geográfica (uma linha de distribuição de energia, por exemplo) ou uma maior variedade de aspectos do sistema (corrente, velocidade, pressão, etc.).
- *Maior robustez:* com o aumento da redundância dos dados, a robustez do sistema é melhorada já que o funcionamento do sistema ou do sistema de sensoriamento não é dependente de uma única fonte de dados.
- *Maior confiabilidade:* com a redundância de dados, pode-se confirmar a medida de um sensor com a medida de outro sensor que tenha a mesma abrangência geográfica ou que meça o mesmo parâmetro nas mesmas especificações.
- *Redução da ambiguidade e incerteza:* um maior número de dados e a combinação entre os mesmos reduz a possibilidade de múltiplas interpretações de uma observação.
- *Maior resistência à interferência:* decorrente do aumento da dimensionalidade do espaço de medida (ou seja, obtenção de múltiplos parâmetros), tem-se maior resistência à interferência e maior relação sinal-ruído.
- *Melhor resolução:* quando comparado à resolução de um único sensor, tem-se uma melhoria quando as leituras de vários sensores são fundidas.

4.3 NÍVEIS DE FUSÃO DE SENSORES

Existem diversas perspectivas pelas quais é possível definir a fusão de sensores. Segundo Dasarathy (1997), pode-se caracterizar um modelo de fusão pelo domínio de aplicação, pelo objetivo da fusão, pelo tipo do sensor, pela configuração dos sensores e pelo nível da fusão. Vale ressaltar que os métodos de caracterização de fusão são muito subjetivos e que ainda não existe um método fundamental.

De uma forma geral, a caracterização por níveis é a mais conhecida e visa subdividir o processo de fusão em três níveis principais: fusão de dados (*data fusion*), fusão de características (*feature fusion*) e fusão de decisões (*decision fusion*). Cada um desses níveis

será explicado nas subseções seguintes além de uma caracterização diferente de fusão de sensores, proposta por Dasarathy (1997), que se tornou globalmente aceita na comunidade científica.

Existem outros termos aceitos na comunidade acadêmica, tais como nível de fusão de classificação (*rank fusion*) e nível de fusão de *matching score*, mas esses termos são geralmente direcionados a uma área específica, tais como biométrica (MONWAR; GAVRILOVA, 2009).

4.3.1 Nível de Fusão de Dados

Também conhecida como fusão em baixo nível (*low-level fusion*) e fusão em nível de sensor (*sensor level*), é a camada da fusão que aborda o tratamento da informação bruta ou com baixo processamento vinda dos sensores (ELMENREICH, 2011), (DASARATHY, 1997).

A finalidade desse nível de fusão é a combinação entre os dados de várias fontes para produzir novos dados que forneçam maiores informações sobre o processo do que os dados individuais de entrada. Isto requer o uso de técnicas de avaliação não destrutivas que possam reduzir a incerteza, reduzir a quantidade de informação e, quando necessário, verificar a redundância dos dados obtidos. O produto da fusão de dados é a extração das características do processo, que então são enviadas para o nível de fusão de características (LIU et al., 2007), (ELMENREICH, 2011; MONWAR; GAVRILOVA, 2009).

Como em qualquer outro nível de fusão, a fusão de dados obedece a uma estrutura de processamento que depende muito da abordagem estabelecida. Nas subseções seguintes, serão brevemente descritos algumas estruturas de fusão de dados.

4.3.1.1 Estrutura Camada de Sensor

Essa estrutura está representada na Figura 7. A estrutura de camada de sensor utiliza um método centralizado de fusão de dados. Como cada sensor tem um processador de sinais independente que realiza a extração das características e a classificação e rastreamento do objeto, a unidade de processamento não sofre com sobrecarga de informações e pode utilizar

um único método aritmético para realizar a fusão dos dados. Porém, devido à camada de processamento de sensores, essa estrutura tem maior custo, maior complexidade e menor confiabilidade (XINHAN; MIN, 2003).

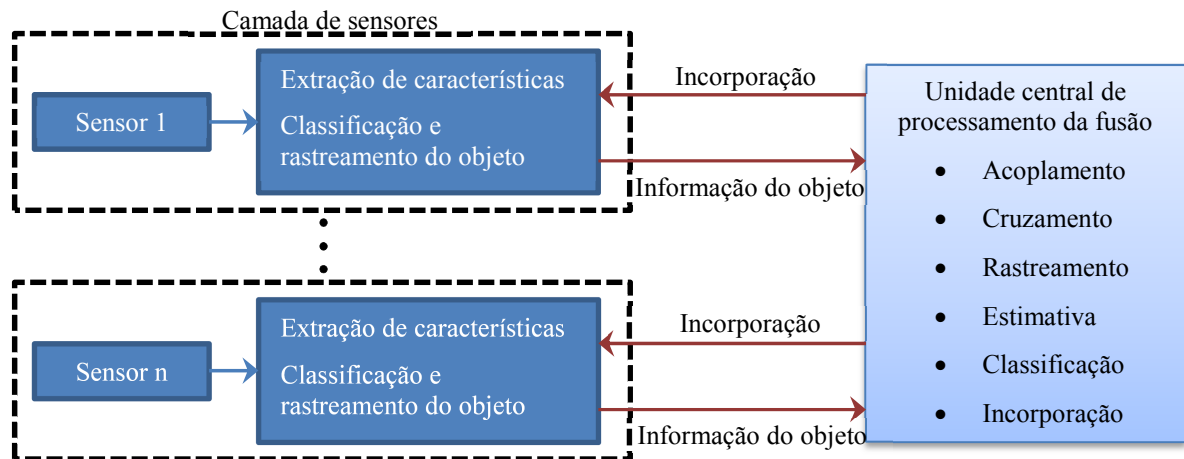


Figura 7: Representação da estrutura de camada de sensores de fusão de dados.
Fonte: Xinhan e Min (2003).

4.3.1.2 Estrutura Central

Essa estrutura utiliza um método centralizado de fusão de dados e pode ser visualizada na Figura 8. Percebe-se que nessa estrutura o nível de processamento de sensores foi retirado, fazendo com que essa estrutura seja mais simples, barata e apresente maior segurança. Em contrapartida, a unidade de processamento precisa computar uma carga maior de informações e precisa utilizar métodos aritméticos diferentes para cada tipo de sensor, tornando o sistema menos flexível (XINHAN; MIN, 2003).

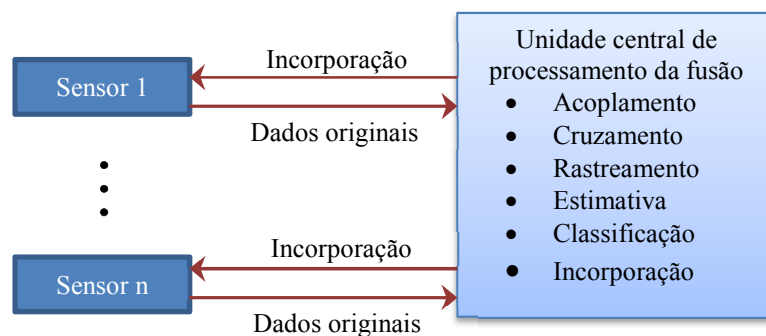


Figura 8: Representação da estrutura central de fusão de dados.
Fonte: Xinhan e Min (2003).

4.3.1.3 Estrutura Mista

Adotando um método centralizado de fusão de dados, esse tipo de estrutura é uma mistura entre as duas estruturas discutidas anteriormente. A estrutura mista apresenta melhor adaptabilidade e é, obviamente, mais complexa (XINHAN; MIN, 2003). A Figura 9 ilustra o seu diagrama de funcionamento.

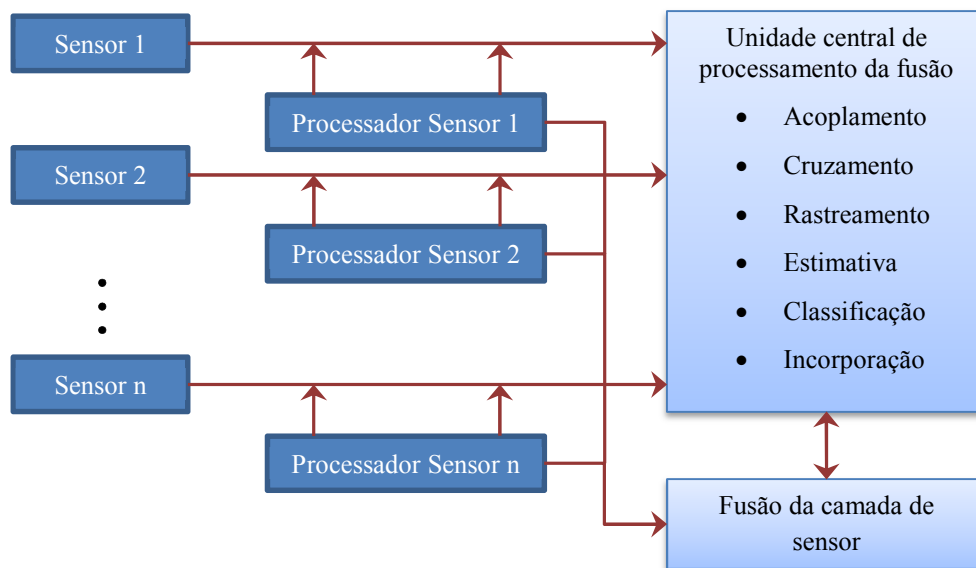


Figura 9: Representação de uma estrutura mista de fusão de dados.
Fonte: Xinhana e Min (2003).

4.3.1.4 Estrutura Distribuída

Diferente das estruturas anteriores, que utilizam um modelo centralizado de processamento de dados, a estrutura distribuída usa de “centros locais de fusão de dados” que, então, se conectam a uma unidade global. Cada centro local trata um conjunto diferente de informações baseado no tipo de sensores, objetos e requerimentos. O resultado dessa fusão parcial é, então, enviado para a unidade de processamento que finaliza o processo de fusão de dados (XINHAN; MIN, 2003). Essa estrutura pode ser vista na Figura 10.

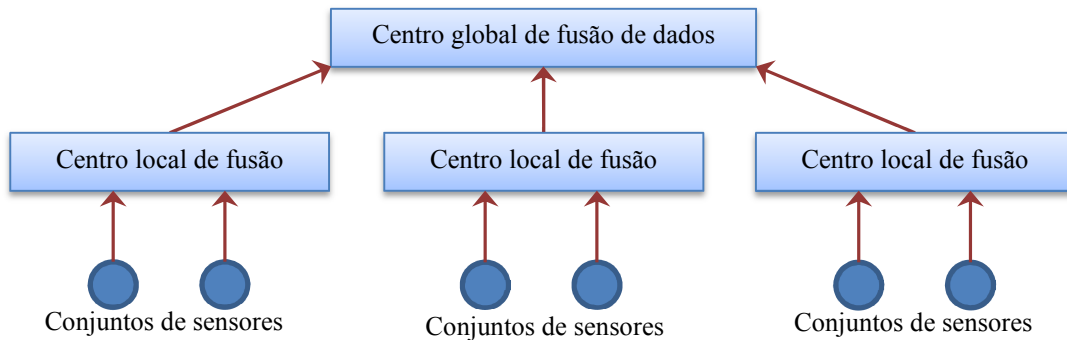


Figura 10: Representação de uma estrutura mista de fusão de dados.
Fonte: Xinhan e Min (2003).

4.3.1.5 Estrutura Descentralizada

Na estrutura descentralizada, os sensores são conectados a nós que recebem informações de outros sensores ou de fusões parciais de dados e realizam outras fusões parciais de dados. Devido à ausência de uma unidade central de processamento, o resultado final da fusão de dados pode partir de qualquer nó, tornando essa estrutura um tanto complicada em nível de computação e de comunicação. Entretanto, erros de sensores causam poucos danos ao resultado final da fusão de sensores, o que é uma grande vantagem desta estrutura (XINHAN; MIN, 2003). A Figura 11 ilustra um exemplo de estrutura descentralizada.




Figura 11: Representação de uma estrutura descentralizada de fusão de dados.
Fonte: Xinhan e Min (2003).

4.3.2 Nível de Características

Em aplicações onde o número de sensores é grande e variado, só o nível de fusão de dados não consegue tornar a fusão de sensores eficiente. Se dois sinais de sensores apresentam uma distribuição similar ou aproximada, então um deles é redundante. Se um sinal pouco se correlaciona com os sinais de outros sensores, então este é chamado irrelevante. No nível de fusão de dados, esse discernimento não é executado e não obstante toda essa informação é computada. Isso degrada o desempenho do sistema de fusão de sensores, tornando-o lento (MANGAI et al., 2010). Além disso, características que apresentem ruído ou dados contraditórios também devem ser evitadas, pois podem deteriorar o desempenho de um algoritmo classificador.

São pelas razões supracitadas que o nível de fusão de características (também conhecido como nível de fusão intermediário, ou *intermediate-level fusion*) é tão importante, principalmente em reconhecimento de padrões. Em fusão de sensores, entende-se por “característica” uma propriedade individual heurística e mensurável do fenômeno que está sendo observado.

Nesse nível, as informações provenientes da fusão de dados são analisadas e selecionadas. As características selecionadas são, então, fundidas gerando um vetor de características que certamente representa melhor o conjunto dos sinais adquiridos dos sensores. Sendo assim, o principal objetivo da fusão de características é a redução do número de características com a finalidade de reduzir a dimensionalidade do problema e a redução do ruído (MANGAI et al., 2010).

O processo de fusão de características pode ser subdividido em três métodos diferentes: seleção, extração e combinação de características (ver Figura 12). Nas subseções a seguir, serão apresentados os métodos mais conhecidos deste processo.

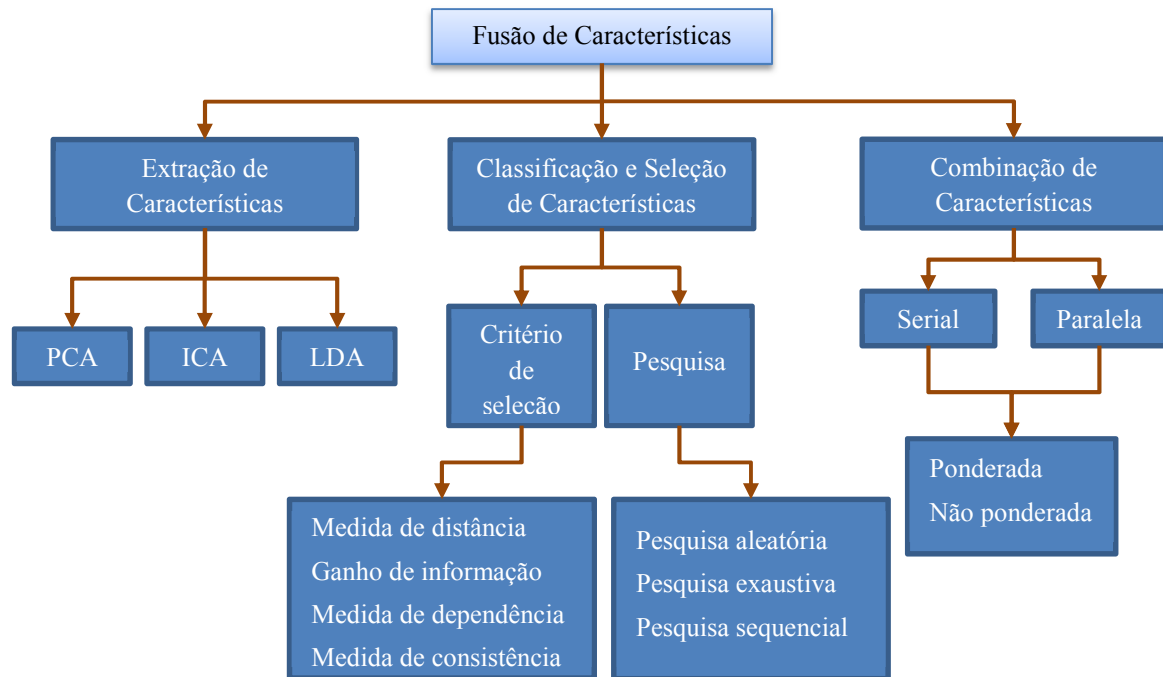


Figura 12: Diagrama de fusão de características.
Fonte: Mangai et al. (2010).

4.3.2.1 Seleção de Características

O método de seleção de características visa, em um dado conjunto de informações, encontrar um subconjunto de características apropriado para um domínio particular com a finalidade de melhorar a exatidão. Isto é, tem a finalidade de determinar um subconjunto mínimo que consiga representar todo o conjunto de características. Segundo Dash e Liu (1997) e Liu e Yu (2005), o processo de seleção de características pode ser dividido em método de filtro, método de envólucro e método híbrido.

No método de filtro, o conjunto de características é avaliado de uma só vez, independente do algoritmo de agrupamento ou classificador, fazendo com que este seja um método rápido e imparcial. No método de envólucro, o algoritmo de agrupamento ou classificador é utilizado em todos os subconjuntos de características até que se encontre o conjunto final de características. Isto é particularmente vantajoso na utilização de um algoritmo ou classificador específico. Esses dois métodos estão apresentados na Figura 13 e Figura 14. Já o método híbrido é uma mistura entre o método de filtro e o método de envólucro. É importante ressaltar que os métodos citados funcionam com qualquer algoritmo de seleção de características.

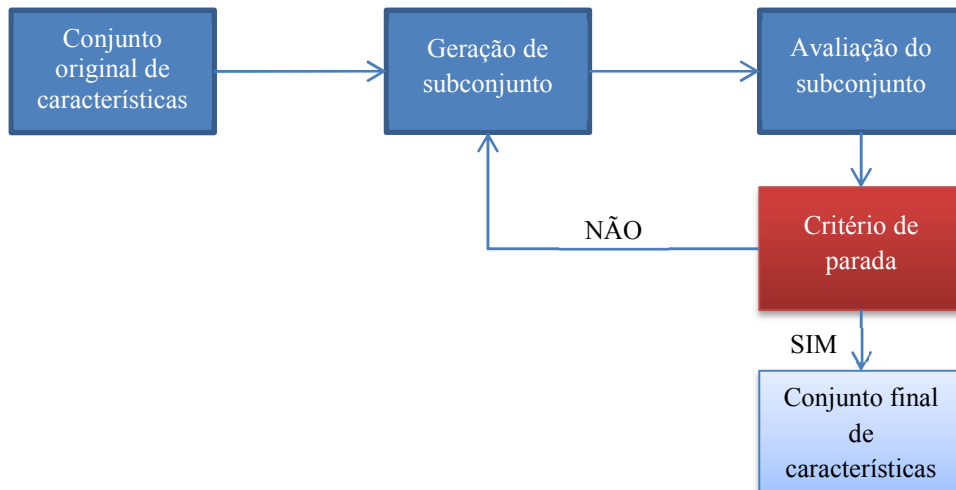


Figura 13: Método de filtro.
Fonte: Mangai et al. (2010).

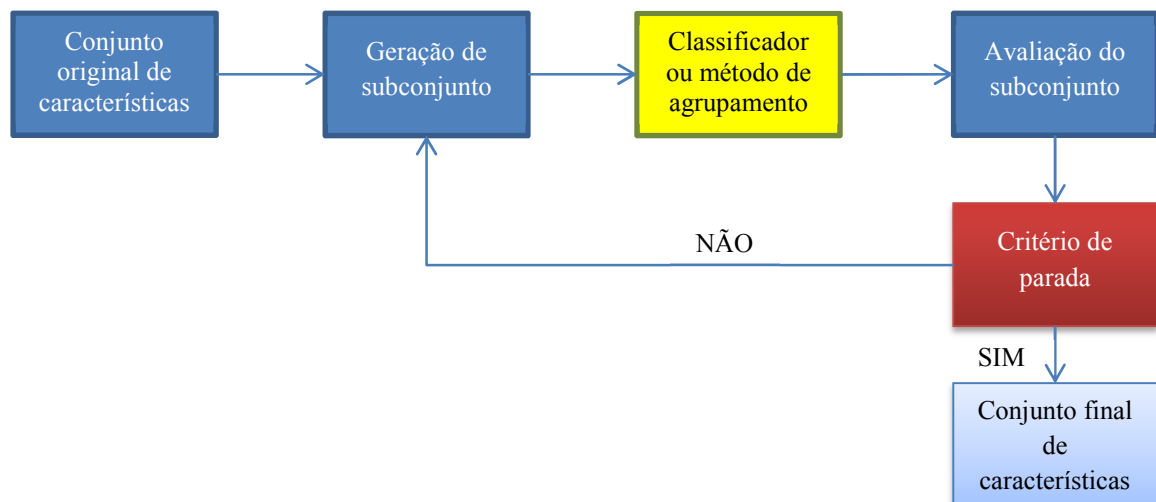


Figura 14: Método de envólucro.
Fonte: Mangai et al. (2010).

Independentemente do algoritmo utilizado, todos eles obedecem aos seguintes passos de seleção de características (MANGAI et al., 2010):

- *Geração do Subconjunto*: é basicamente um algoritmo de pesquisa que seleciona entre os N conjuntos principais de características um subconjunto de características.
- *Função de Avaliação da Seleção de Características*: nesse passo, o subconjunto é avaliado de acordo com o critério estabelecido. Liu e Yu (2005) classificaram todos os critérios de avaliação de subconjunto em quatro tipos: medida de distância, medida de dependência, medida de consistência e medida de ganho de informação. O critério estabelecido depende do tipo de

método que está sendo utilizado para a seleção das características (filtro ou invólucro).

- *Critério de Parada*: é o critério necessário para determinar quando o algoritmo encontrou a solução ótima.
- *Validação do Resultado*: quando o melhor conjunto de características é encontrado através do critério de seleção, ele é validado utilizando um algoritmo que verifica a exatidão dos resultados.

4.3.2.2 Extração de Características

O método de extração de características é muito utilizado devido à sua simplicidade e ao baixo impacto que impõe sobre o sistema de processamento de dados. Esse método funciona da seguinte maneira: o conjunto de características é projetado em outro espaço dimensional, ortogonal ou não ao espaço original, com a finalidade de “espalhar” os aglomerados de características, tornando-se mais fácil reconhecer os subconjuntos de características (MANGAI et al., 2010).

A ferramenta mais comum de extração de características é a chamada *PCA* (*Principal Component Analysis*). *PCA* é, formalmente, uma transformação linear cuja função é projetar os dados em um novo sistema de coordenadas tal que a maior variância do conjunto de dados se posicione no primeiro eixo, a segunda maior variância no segundo eixo e assim por diante (SHLENS, 2011). A matriz resultante terá colunas não correlacionadas umas com as outras, facilitando a eliminação de variáveis redundantes e ruído. A Figura 15 exemplifica o funcionamento da *PCA* (MANGAI et al., 2010).

Além da *PCA*, têm-se outras ferramentas matemáticas tais como a *ICA* (*Independent Component Analysis*), *LDA* (*Linear Discriminant Analysis*) e a *KPCA* (*Kernel Principal Component Analysis*). Em geral, essas ferramentas tem o objetivo de reduzir a dimensão da matriz de características e, assim, aumentar o desempenho do processo de fusão (MANGAI et al., 2010).




Figura 15: Exemplo de aplicação de PCA.
Fonte: Shlens (2011).

4.3.2.3 Combinação de Características

Uma vez obtido o melhor subconjunto de características do conjunto de dados originais percebe-se que, mesmo após a seleção das características, nem todos os elementos do subconjunto de características são úteis ou tem alguma importância. Portanto, o subconjunto selecionado é composto por algumas características que contribuem para mais e outras que contribuem para menos na qualidade da representação do fenômeno avaliado.

Sendo assim, o primeiro passo da combinação de características é ponderar os elementos do subconjunto, normalizando as características para que seja possível diferenciar as características “boas” das “ruins”. A partir daí, utiliza-se o método em série ou o método em paralelo. A explicação sobre esses dois métodos está fora do escopo deste trabalho, mas é válido afirmar que, segundo Yang et al. (2003), o método paralelo produz os melhores resultados.

4.3.3 Nível de Decisão

Fusão de decisão (também conhecida como fusão de alto nível, ou *high level fusion*) é o nível de fusão de sensores que tem como finalidade apresentar uma solução ou um parecer sobre o conjunto de informações adquiridas pelos sensores. Neste nível, são utilizados

algoritmos de classificação de características (ou classificadores) a fim de fornecer resultados melhores e imparciais (MANGAI et al., 2010).

Existem várias estratégias de fusão de decisão, tais como os algoritmos estatísticos (Teorema Bayesiano, Teoria de Evidência de Dempster-Shafer, Decisão Adaptável) e algoritmos teóricos de informação (Aprendizado Adaptável, Expert Systems).

SVM (Máquina de Vetores Suporte), Redes Neurais e GMM (Método Generalizado de Momentos) são alguns dos classificadores mais comumente utilizados. Para funcionar corretamente, o classificador selecionado deve ser “treinado”. Isto é, o classificador deve dispor de dados históricos dos sensores, informações ou conjuntos de características do fenômeno para que seja possível realizar a classificação (MANGAI et al., 2010).

O uso de apenas um classificador pode não ser adequado para um determinado caso. Por isso, um conjunto de classificadores é empregado e a saída de cada um deles é “fundida” através de vários métodos a fim de se obter a decisão final.

Segundo Mangai et al. (2010), existem três motivos principais que implicam na vantagem do uso de múltiplos classificadores sobre o uso de um único classificador:

- Muitas vezes um único classificador não consegue lidar com uma grande quantidade de dados, tornando o seu treinamento pouco prático. Em contrapartida, o uso de vários classificadores direcionados a subconjuntos limitados de dados ou características é mais eficiente, aumentando o desempenho do treinamento de dados.
- Nem sempre um único classificador apresenta um bom desempenho quando se trabalha com características de várias naturezas diferentes.
- É muito difícil encontrar um único classificador que, dado um conjunto limitado de dados de treino, tenha uma boa resposta para qualquer entrada. Sendo assim, o uso de vários classificadores pode melhorar a precisão da resposta final quando suas respostas individuais são combinadas.

O diagrama hierárquico da combinação de classificadores está apresentado na Figura 16. Existem dois tipos de estratégias de combinação de classificadores: fusão de classificadores e seleção de classificadores.

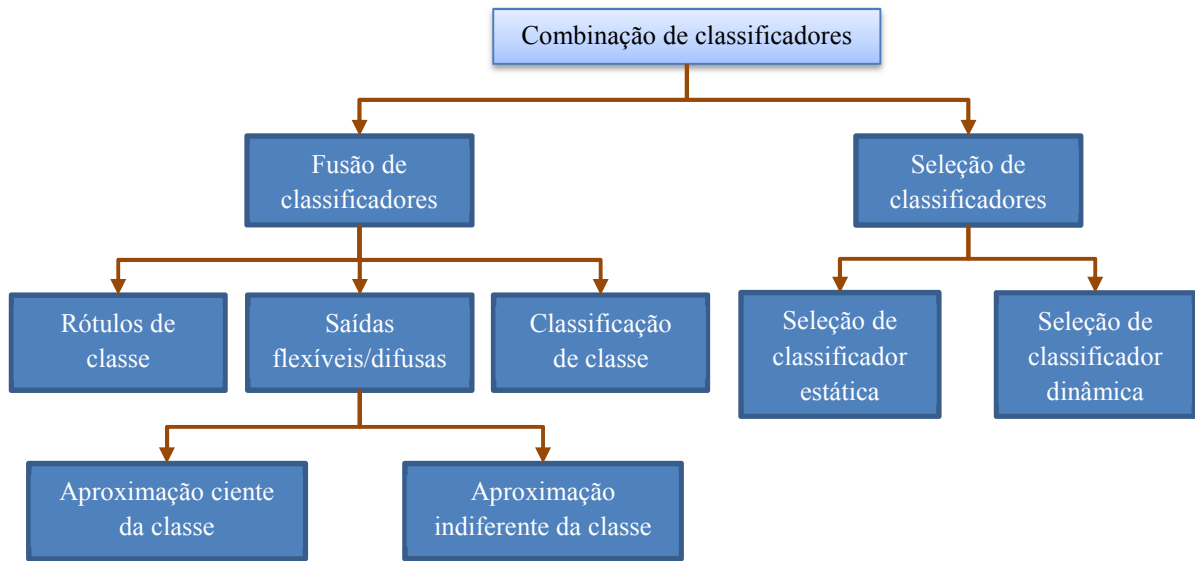


Figura 16: Diagrama de combinação de classificadores.
Fonte: Mangai et al. (2010).

4.3.4 Caracterização Baseada em Entradas/Saídas

Proposta por Dasarathy (1997), esse tipo de caracterização visa expandir a hierarquia dos três níveis descritos anteriormente em cinco processos de fusão dependentes das entradas e saídas (I/O) do sistema. Ao contrário da hierarquia dos níveis, este tipo de caracterização não apresenta ambiguidade, distinguindo um sistema de fusão de sensores de acordo com a natureza de suas entradas e saídas. A Figura 17 apresenta o diagrama desta caracterização alternativa.

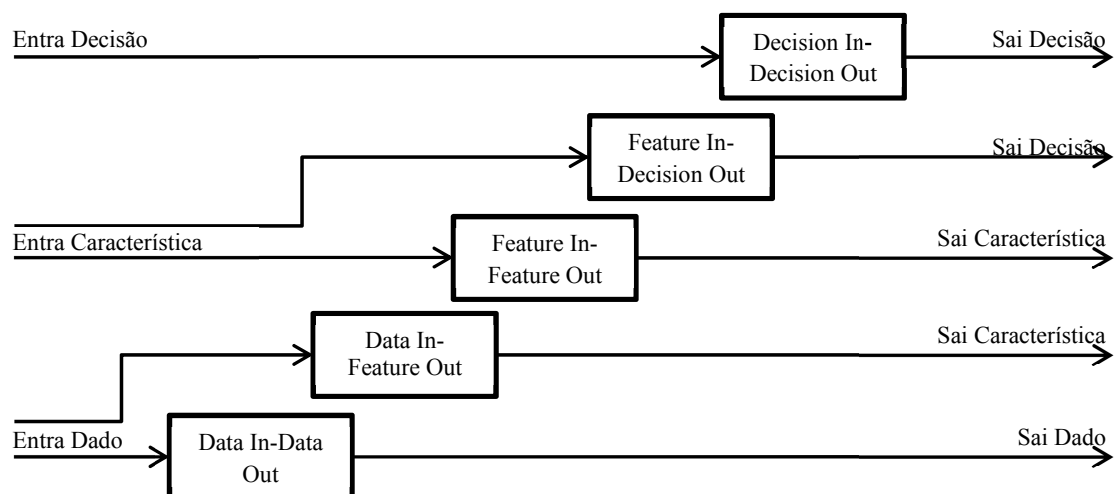


Figura 17: Hierarquia alternativa proposta por Dasarathy, caracterização de I/O.
Fonte: Elmenreich (2011).

Os passos estabelecidos para essa hierarquia serão brevemente descritos nas subseções a seguir.

4.3.4.1 *Fusão DAI-DAO (Data In-Data Out)*

É o nível mais baixo da hierarquia de I/O. Engloba o que foi descrito em fusão de dados, onde dados brutos dos sensores entram no sistema e são processados. Porém, neste tipo de caracterização, é importante notar a nova perspectiva dada à fusão de dados: nesse modo de fusão, as entradas são dados brutos e as saídas são dados processados ou filtrados. Nesta etapa da hierarquia, podem-se utilizar ferramentas de análise em domínio da frequência, tais como Transformada de Fourier e STFT.

Um paradigma típico de fusão nessa etapa é a forma que o olho humano funde as informações das cores.

4.3.4.2 *Fusão DAI-FEO (Data In-Feature Out)*

Nesta etapa, as entradas são os dados processados de diferentes sensores que, combinados, indicam as características do objeto avaliado ou algo que descreva o fenômeno observado. Comparando com a hierarquia de níveis, a categorização dessa etapa dependeria da perspectiva do usuário ou pesquisador: se levasse em consideração as entradas, seria fusão de dados; se levasse em consideração as saídas, seria fusão de características.

Um paradigma típico neste modo de fusão é a percepção de profundidade obtida pelos olhos humanos ao combinar as informações visuais adquiridas individualmente por cada um deles.

4.3.4.3 *Fusão FEI-FEO (Feature In-Feature Out)*

Essa etapa aborda o que é conhecido em hierarquia de níveis como fusão de características. Nessa perspectiva, deve-se atentar que a entrada é uma característica oriunda

da etapa anterior e a saída é um produto da fusão das características de entrada através de um método quantitativo ou qualitativo. Ferramentas utilizadas nessa etapa são os processos de extração e seleção de características.

Uma situação que pode servir como exemplo para esse modo de fusão é a detecção de um objeto por uma câmera de vídeo e um radar. Enquanto a câmera de vídeo fornece a informação das características visuais, o radar fornece a localização do objeto. A fusão das características detectadas por esses dois sensores permite a um sistema central obter ambas as informações ao mesmo tempo.

4.3.4.4 *Fusão FEI-DEO (Feature In-Decision Out)*

Em uma hierarquia de níveis, essa etapa apresentaria uma categoria ambígua dependente da perspectiva do usuário ou pesquisador, pois poderia ser considerada fusão de características (caso o problema fosse observado em relação às entradas) ou fusão de decisão (caso o problema fosse observado em relação às saídas).

Neste passo de fusão de sensores, as informações de vários sensores são fundidas para gerar uma saída na forma de decisão, ou seja, um rótulo de classe. Em essência, a maior parte das ferramentas de reconhecimento de padrões executa esse tipo de fusão na fase de reconhecimento, onde o vetor de características é classificado de acordo com o treinamento para formar um rótulo de classe.

4.3.4.5 *Fusão DEI-DEO (Decision In-Decision Out)*

O último passo dessa hierarquia é, na hierarquia dos níveis, conhecido como fusão de decisão. Aqui, tanto as entradas quanto as saídas são decisões. Nesta etapa, as decisões individuais, ou seja, os rótulos de classe resultantes de cada sensor são fundidos gerando uma decisão final baseada no treinamento especificado.

Este nível de fusão pode ser comparado à combinação de classificadores, descrita nas seções anteriores.

4.4 MODELOS DE FUSÃO DE SENSORES

Como a fusão de sensores é dependente principalmente da aplicação, não existe um modelo geral para o desenvolvimento de sistemas de fusão. Desse modo, surgiram vários quadros que auxiliam a elaboração da arquitetura mais adequada para cada tipo de problema. Nas subseções seguintes, os modelos mais conhecidos dentro de fusão de sensores serão brevemente discutidos.

4.4.1 JDL

Proposto em 1985 pelo *US Joint Directors of Laboratories*, JDL é o modelo mais conhecido de fusão de sensores (ESTEBAN et al., 2005). Suas principais finalidades são:

- Categorizar diferentes tipos de fusão;
- Fornecer uma estrutura comum para discussões sobre fusão;
- Facilitar o entendimento dos tipos de problemas para os quais fusão de dados é aplicada;
- Codificar a generalidade entre os problemas;
- Ajudar na extensão de soluções anteriores;
- Fornecer uma estrutura para investimento em automação.

O modelo JDL é formado por cinco níveis de processamento e um banco de dados, onde todos são interconectados por um barramento. Devido a essa interconexão, os níveis não precisam, necessariamente, ser executados em uma determinada ordem (ELMENREICH, 2011).

Os elementos desse modelo estão descritos a seguir (ESTEBAN et al., 2005; ELMENREICH, 2011):

- *Fontes*: fornecem os dados brutos do sistema. Podem ser sensores, bancos de dados externos, conhecimento do operador, etc.
- *Banco de dados*: armazena e fornece as informações internas para os níveis de fusão.
- *Interação Homem-Máquina*: etapa onde o operador realiza entrada de comandos e monitora o processo.

- *Nível 0 (Processamento de Fonte)*: o objetivo deste elemento é melhorar o desempenho computacional dos processos de fusão realizando funções simples de pré-processamento de dados e alocando os dados aos processos apropriados (filtragem, reamostragem, etc.).
- *Nível 1 (Refinamento de Objeto)*: este elemento desempenha funções de alinhamento de dados (transformação de dados em estrutura de referência e unidades), associação (métodos de correlação), rastreamento de objetos e identificação (métodos de classificação).
- *Nível 2 (Refinamento de Situação)*: este bloco tem a finalidade de contextualizar a relação entre os objetos e os eventos observados.
- *Nível 3 (Refinamento de Ameaça)*: executa a análise de dados históricos e sobre as futuras situações prováveis do processo possibilitando extrair informações sobre vulnerabilidade da operação.
- *Nível 4 (Refinamento de Processo)*: este nível faz o monitoramento do desempenho do sistema e controle dinâmico do processo, realocando o fluxo de dados para realizar tarefas específicas.

A Figura 18 apresenta a estrutura do modelo JDL.

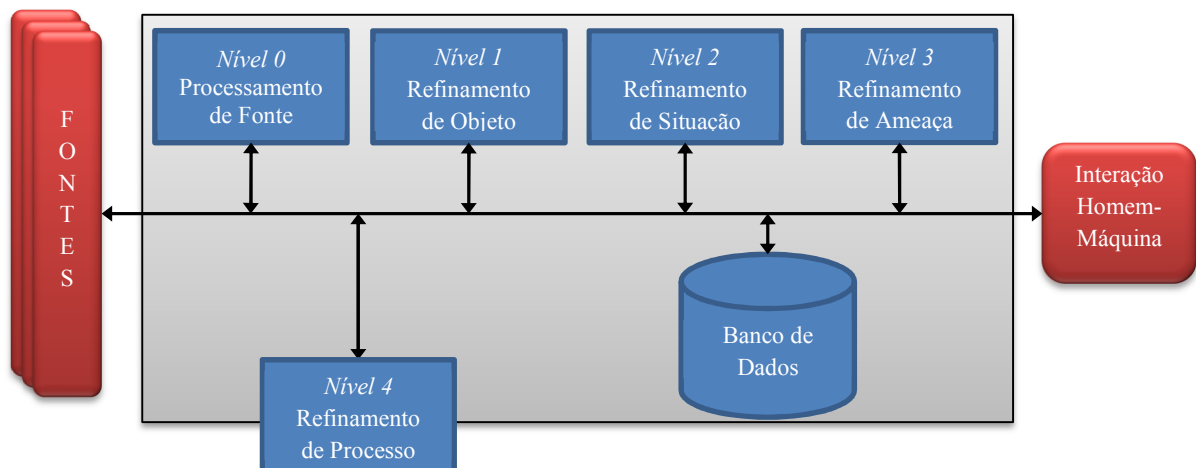


Figura 18: Modelo de fusão JDL.
Fonte: Elmenreich (2011).

Apesar de ser um dos modelos mais comuns para fusão de sensores, o modelo JDL apresenta algumas desvantagens, tais como a dificuldade em reutilizar as aplicações desenvolvidas (centralização dos dados), à dificuldade em apropriar o modelo a problemas específicos (muito abstrato) e o fato de não cooperar para a elaboração de uma arquitetura

para um sistema real (difícil identificação dos métodos que devem ser utilizados) (ELMENREICH, 2011). Por estes motivos, nos anos seguintes surgiriam várias propostas para revisar o modelo JDL com a finalidade de flexibilizá-lo a novos problemas a que este não está, originalmente, adaptado (STEINBERG; BOWMAN, 2011; WALTZ, 2011).

4.4.2 Arquitetura Thomopoulos

A arquitetura Thomopoulos se baseia em três níveis distintos (ESTEBAN et al., 2005):

- *Nível de fusão de sinal*: devido à falta de conhecimento matemático sobre o fenômeno medido, neste nível é utilizado correlação dos dados para proporcionar algum entendimento sobre o processo.
- *Nível de fusão de evidências*: onde os dados são combinados em níveis diferentes de inferência baseados em modelos estatísticos.
- *Nível de fusão de dinâmicas*: quando a fusão dos dados é realizada com a ajuda de um modelo matemático.

Nessa arquitetura de fusão, os níveis podem ser processados sequencialmente ou alternadamente dependendo da aplicação proposta. Por exemplo, a combinação dos dados pode ser realizada no nível de fusão de sinais, enquanto que as decisões sobre os resultados dessas combinações podem ser realizadas nos níveis mais avançados (evidência ou dinâmicas) (ESTEBAN et al., 2005). A Figura 19 apresenta a arquitetura de Thomopoulos.

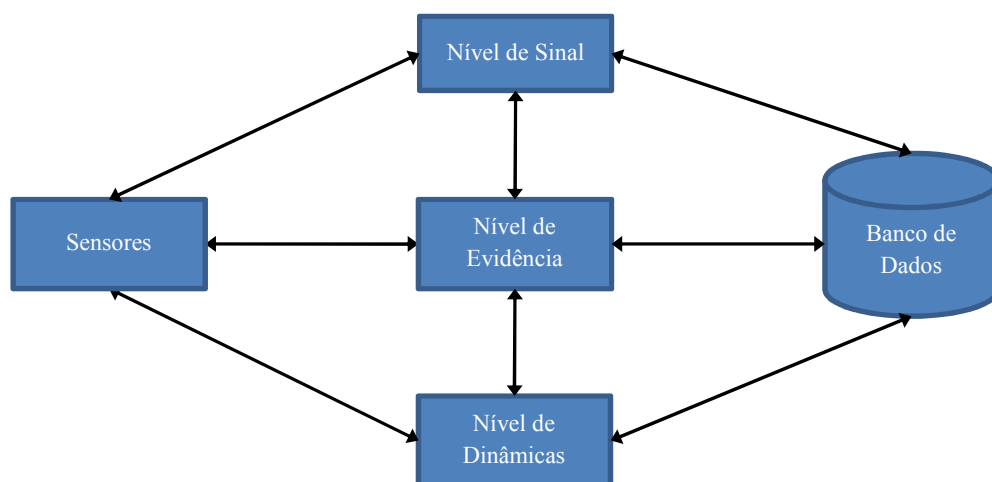


Figura 19: Representação do modelo de Thomopoulos.
Fonte: Esteban et al. (2005).

4.4.3 Modelo Cascata (*Waterfall*)

O modelo cascata é muito semelhante ao modelo JDL quando se trata dos níveis de fusão adotados (ELMENREICH, 2011). Esta estrutura enfatiza a fusão de baixo nível, ao nível de sensores e processamento. Na hierarquia dessa estrutura, existem seis estágios no processo de fusão (ESTEBAN et al., 2005; ELMENREICH, 2011):

- *Sensores*: camada dos sinais provenientes diretamente da medição do fenômeno, sem tratamento prévio.
- *Processamento de sinais*: camada relacionada ao processamento e adequação dos dados dos sensores para as camadas posteriores (filtragem, reamostragem, transformações, etc.).
- *Extração de características*: associada à transformação das informações processadas em um conjunto de características relevantes do processo.
- *Processamento de padrões*: estágio onde as características extraídas são fundidas a fim de obter um nível simbólico de inferência sobre os dados.
- *Avaliação de situação*: etapa que consiste na avaliação de uma lista de estimativas e probabilidades relacionadas às características fornecidas pela etapa anterior.
- *Tomada de decisão*: relaciona os objetos a eventos. Nesse estágio, uma rota de tomada de decisões é montada comparando os dados obtidos nos estágios anteriores com informações armazenadas em banco de dados, bibliotecas, etc.

A Figura 20 mostra a estrutura do modelo cascata e caracterização com os níveis de fusão. No diagrama é possível observar a analogia entre o modelo cascata e o modelo JDL. As camadas de sensores e processamento de sinais do modelo cascata correspondem ao nível 0 (processamento de fonte) do modelo JDL; extração de características e processamento de padrões ao nível 1 (refinamento de objeto); avaliação de situação ao nível 2 (refinamento de situação); e tomada de decisões ao nível 3 (refinamento de ameaça).

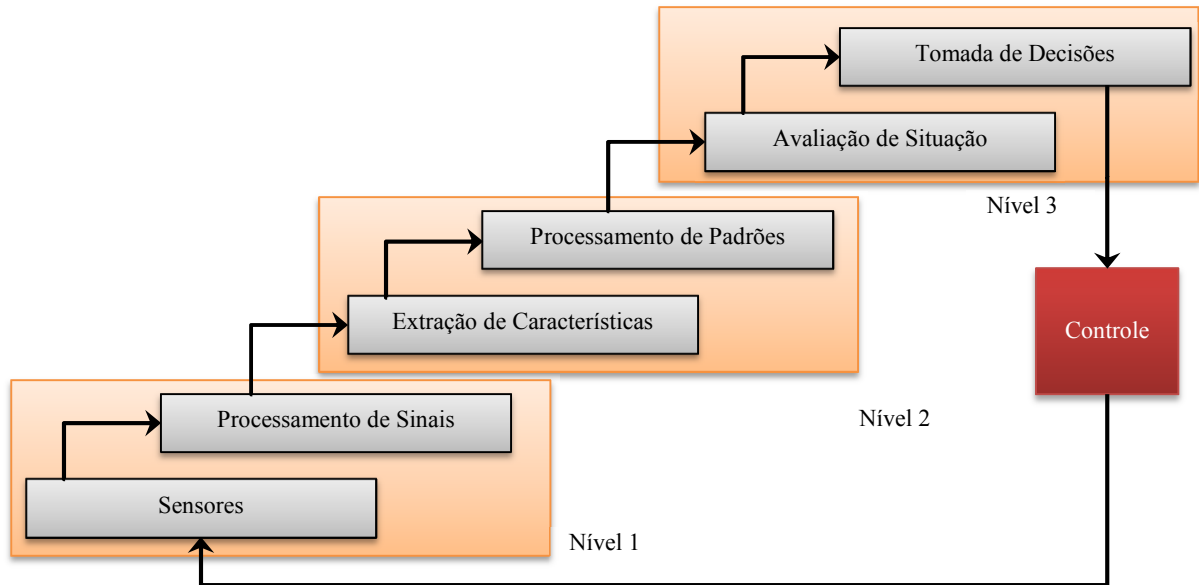


Figura 20: Diagrama representando o modelo cascata (*waterfall*).
 Fonte: Esteban et al. (2005).

Apesar de oferecer uma análise mais exata do processo de fusão, a grande desvantagem do modelo cascata é a carência de realimentação entre os níveis de sua hierarquia. Além disso, tal como o modelo JDL, o modelo cascata sofre dos mesmos inconvenientes (ELMENREICH, 2011).

5 METODOLOGIA UTILIZADA

O projeto de manutenção inteligente que está sendo desenvolvido no Laboratório de Sistemas de Controle, Automação e Robótica (LASCAR), da Universidade Federal do Rio Grande do Sul, conta com a participação da empresa fabricante de atuadores elétricos Coester Automação S.A.

Este projeto tem incentivo da Petrobrás e da Transpetro, que são grandes dependentes de atuadores elétricos em suas instalações. Estas empresas investem neste projeto porque são beneficiados diretamente pela modernização dos atuadores elétricos.

Nesta seção, serão descritos e discutidos todos os procedimentos experimentais desenvolvidos durante o trabalho de conclusão de curso.

5.1 DESCRIÇÃO DOS EQUIPAMENTOS

No laboratório, está montada e instrumentada uma bancada composta de um atuador elétrico e uma haste conectada a um rolamento. No rolamento, um freio a disco foi instalado com a finalidade de injetar falhas no sistema. 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 sistema remoto é controlado através de um computador industrial Advantech, contendo um sistema supervisório, Navegador STVM, desenvolvido pela própria Coester. Dentre as funcionalidades deste sistema, está o acionamento e gerenciamento remoto dos atuadores, análise das curvas de torque e acesso ao banco de dados do funcionamento dos atuadores (eventos de abertura e fechamento, erros, etc.).

Uma nova plataforma de aquisição de dados está sendo desenvolvida utilizando um controlador da National Instruments™. Os dados coletados pelo controlador podem ser analisados através de uma rotina feita em LabVIEW.

Nas subseções a seguir serão descritos individualmente os componentes supracitados com exceção do computador industrial, que não foi utilizado neste trabalho.

5.1.1 Atuador Elétrico

O atuador elétrico, modelo CSR6 da Coester Automação, está ligado à alimentação trifásica de 380V oriunda de um painel de distribuição, protegido por um disjuntor tripolar de 40 A. As especificações do atuador CSR6 estão resumidas na Tabela 2.

Tabela 2: Especificações do atuador elétrico modelo CSR6.

Especificação	Unidade	Valor
Torque máximo	N.m	60
Torque de trabalho	N.m	60
Tensão de operação	V	220
Tempo de operação	Segundos	46
Rotação	RPM	42
Potência do motor	KW	0,18
Rotação do motor	RPM	3600

Fonte: Coester Automação S.A.

Como já fora dito anteriormente, o atuador pode ser acionado localmente através do seu painel. No painel frontal do atuador, um display mostra a posição atual da válvula e o torque que está sendo medido pela célula de carga. A Figura 21 mostra a vista frontal do painel do atuador.



Figura 21: Painel frontal do atuador elétrico.

5.1.2 Válvula de Ar Comprimido

A válvula pneumática MPT40 da *Parker*TM é uma válvula proporcional que tem a finalidade de controlar eletronicamente o fluxo de ar que controla o freio mecânico acoplado ao atuador. Essa válvula funciona com alimentação de 24VDC mais um sinal de comando de 0 a 10V. A válvula proporcional pode ser vista na Figura 22.

O objetivo desta válvula, no referente projeto, foi o controle da pressão do freio a disco instalado no rolamento acoplado à haste da válvula do atuador.



Figura 22: Válvula de ar comprimido para o controle da pressão no freio.

Um circuito para regular o sinal de comando foi montado no laboratório contendo um potenciômetro para variar o valor de tensão. Devido à queda no resistor de entrada (que visa limitar a tensão máxima no controle da válvula), o sinal pode variar de 0 a 8,36V. Isso proporciona uma variação de até 8,36 bar de pressão no freio.

O freio foi instalado com a intenção de injetar falhas no sistema, causando variações no torque e na vibração do conjunto. Isto possibilita a simulação de várias situações comuns na operação real dos atuadores elétricos. Por exemplo, subidas bruscas de torque podem indicar um evento de falha como a quebra de alguma peça ou obstrução no fechamento da válvula. Uma condição de degradação também poderia ser simulada, mantendo uma pressão mínima no freio e gerando, assim, um pequeno torque constante na haste da válvula durante todo o processo de abertura ou fechamento.

5.1.3 Acelerômetros

Acelerômetros são largamente usados na indústria, principalmente quando é necessário medir vibração e variações bruscas de movimento. Por isso, são componentes indispensáveis em testes de colisão de automóveis e em biomecânica.

Um acelerômetro piezoelétrico é composto por uma massa crítica (PZT) que, quando deformada, desloca as cargas elétricas armazenadas no cristal em seu interior gerando uma diferença de potencial proporcional à força aplicada. A variável mecânica (aceleração) é, portanto, procedente de uma medida de força.

No projeto em estudo, foram empregados três acelerômetros piezoelétricos *PiezoStar® 8705A* do fabricante *Kistler*. As especificações mais importantes estão reunidas na Tabela 3.

Tabela 3: Especificações técnicas do acelerômetro 8705A.

Especificação	Unidade	Valor
Faixa (range)	g	±50
Sensibilidade	mV/g	101,5
Alcance em frequência	Hz	0,5 a 10000
Massa	g	8,4
Temperatura de operação	°C	-55 a 165
Diâmetro	mm	12,7
Alimentação	mA	2 a 20

Fonte: Kistler (2010).

O objetivo da utilização dos acelerômetros foi de avaliar a vibração do sistema atuador-válvula. Para isto, foram posicionados os três acelerômetros em três locais distintos do sistema:

- *Pinça do freio:* a motivação para a instalação neste local foi de medir o esforço transmitido da haste para a válvula. Também era esperado detectar melhor as falhas nos casos onde o freio fosse acionado.
- *Ponta do sem-fim:* foi instalado neste local com a finalidade de detectar vibrações no acoplamento entre o atuador e a haste.
- *Motor do atuador:* a finalidade da instalação neste ponto do sistema foi com a intenção de detectar vibrações no eixo do motor de indução.

Os acelerômetros foram colados em cada posição utilizando silicone. A cimentação usando silicone é adequada para realizar medições em alta frequência, além de oferecer melhor fixação ao componente medido e maior proteção à temperatura (KISTLER, 2010). A Figura 23 mostra os acelerômetros posicionados em seus devidos locais.




Figura 23: Acelerômetros posicionados (a) na estrutura do freio, (b) no sem fim e (c) dentro do compartimento do motor do atuador elétrico.

5.1.4 Sistema de Aquisição: CompactRIO®

Para a função de aquisição de dados do atuador elétrico, foi utilizado o CompactRIO®, da National Instruments™. O CompactRIO (ou, simplesmente, cRIO) é um sistema embutido de controle e aquisição em tempo real composto por um chassis, um controlador e módulos de I/O (input/output) com funções específicas (entrada digital, entrada analógica de tensão, temperatura, etc.). Os componentes desse sistema serão descritos abaixo.

- *Chassis:* o chassis serve como base para o controlador e os módulos de I/O fazendo, também, a comunicação entre eles através de um painel composto por portas serial montadas no mesmo. O chassis do laboratório é o modelo NI 9104 e possui 8 entradas para módulos de I/O.
- *FPGA:* o *Field Gate Programming Array* (FPGA) do CompactRIO, que se encontra no chassis e é conectado ao controlador através de um barramento PCI, tem a função de compilar o código enviado pelo usuário através do controlador para os respectivos módulos conectados ao painel serial.

- *Controlador:* o controlador do sistema CompactRIO tem a função de interagir com a plataforma externa (seja ela uma rede ou um computador ligado ao mesmo) através de um cabo RJ-45 e gerenciar a comunicação com o FPGA. O controlador utilizado no laboratório é o NI 9004.
- *Módulos de I/O:* conectados ao painel de portas serial do chassis, os módulos de entrada e saída tem a função de interagir com o sistema a ser controlado, enviando ou recebendo dados específicos de acordo com o tipo de sensor conectado. Na aquisição dos dados, foi utilizado um módulo de I/O específico para acelerômetros (com range de 5 V_{pp}) conectado ao CompactRIO; o NI-9233. Para a aquisição do sinal de torque foi usado o módulo de I/O portátil NI-6008, conectado ao computador do laboratório via porta USB. Este módulo possui range de entrada de 20 V_{pp} e resolução máxima de 12 bits.

Uma foto do sistema CompactRIO e do módulo portátil de tensão pode ser vista na Figura 24.




Figura 24: Componentes para a aquisição dos sinais. (a) CompactRIO com módulo de acelerômetro instalado e (b) módulo portátil de tensão NI-6008.

Na plataforma LabVIEW® foi desenvolvido um VI (*Virtual Instrument*) para controlar o sistema de aquisição. O algoritmo elaborado permite realizar a leitura dos quatro sinais de interesse do sistema atuador-válvula descrito acima, além de controlar algumas características dos módulos de aquisição, como taxa de dados e quantidade de amostras adquiridas. Também, através deste VI, os dados da leitura dos módulos são salvos no disco rígido do computador do laboratório. Uma imagem deste VI encontra-se no Apêndice A.

5.2 DESCRIÇÃO DOS TESTES REALIZADOS

Com o sistema de aquisição preparado, foi elaborado um plano de testes para serem simulados na bancada. Os testes tiveram como objetivo simular o maior número possível de aberturas e fechamentos da válvula sob condições normais e de falha.

Ao todo, foram realizados 300 testes, correspondendo a 150 aberturas e a 150 fechamentos. Desses 300 ciclos³, 50 deles são de comportamento normal (25 aberturas e 25 fechamentos) e os 250 restantes condizem a cinco falhas diferentes. A Tabela 4 resume a descrição de cada ciclo.

Tabela 4: Descrição dos ciclos simulados no sistema atuador-válvula.

Condição	Ciclos	Descrição
Normal	50	Ciclo normal a vazio e sem esforço externo sobre o sistema
Falha 1	50	Ciclo com pressão no freio equivalente a 3,0 bar
Falha 2	50	Ciclo com pressão no freio equivalente a 1,0 bar
Falha 3	50	Ciclo executado usando uma roda dentada desgastada
Falha 4	50	Ciclo executado usando duas rodas dentadas desgastadas
Falha 5	50	Ciclo executado utilizando uma roda dentada com dentes quebrados

A Figura 25 apresenta as rodas dentadas utilizadas no atuador elétrico. Essas rodas dentadas foram fornecidas pela empresa Coester Automação S. A. Da esquerda para a direita, é exibida uma roda dentada em boas condições, uma roda dentada gasta e uma roda dentada com os dentes quebrados⁴.

Cada ciclo foi adquirido a uma taxa de 2.048 amostras por segundo. De acordo com as especificações do tempo de operação do atuador, isto equivale a uma média de 94.208 amostras oriundas de cada sensor, correspondendo a um total de 376.832 amostras por ciclo. Essa alta taxa de aquisição de dados foi escolhida a fim de adquirir o maior número possível de informações sobre o sistema como, por exemplo, vibrações em alta frequência. Além disso, essa ampla faixa de amostras permite uma maior margem de experimentação com ferramentas de processamento de sinais.

³ Ciclo é uma operação qualquer de abertura ou fechamento.

⁴ A roda dentada com dentes quebrados foi propositalmente danificada com um moto esmeril. As rodas dentadas desgastadas sofreram danos devido ao desgaste natural de trabalho ao longo do tempo.




Figura 25: Rodas dentadas usadas nas falhas 3, 4 e 5.

Nas subseções a seguir, algumas características dos ciclos realizados serão apresentadas, além de um resumo com as principais características dos sinais obtidos utilizando diferentes métodos matemáticos com a finalidade de determinar as características dos sinais.

Após os testes, foi possível plotar as curvas de cada sensor e realizar uma análise inicial sobre o comportamento dos mesmos. Também foi possível utilizar ferramentas de processamento de sinais, tais como FFT, e métodos estatísticos para inferir algumas conclusões sobre os gráficos obtidos.

Para que não haja confusão, a terminologia descrita na Tabela 5 será utilizada daqui em diante para normalizar a notação no restante do documento.

Tabela 5: Convenção utilizada no trabalho.

Sensor 1	Acelerômetro do freio
Sensor 2	Acelerômetro do sem fim
Sensor 3	Acelerômetro do motor
Sensor 4	Sensor de torque

5.3 AVALIAÇÃO DOS DADOS DOS SENSORES

Antes de realizar as análises e seguir para o desenvolvimento da estrutura de fusão de sensores, foi feita uma análise inicial das informações coletadas pelo sistema de aquisição de dados. A seguir, serão apresentados as curvas de resposta dos sensores para cada situação simulada.

5.3.1 Ciclo Normal

O ciclo normal do atuador elétrico corresponde a um movimento completo, sem interrupção e sem esforço, de abertura ou fechamento. De acordo com as especificações do fabricante, este processo dura 46 segundos em operação normal e o atuador para automaticamente no momento em que a válvula abriu ou fechou completamente.

O primeiro fenômeno observado foi o pico de tensão captado pelo sensor 4 no arranque do motor. Outras características notadas foram as diferenças de amplitude entre os três acelerômetros. A Figura 26 abaixo mostra um ciclo de fechamento normal, com os respectivos sinais no tempo de cada sensor. É possível observar, pela Figura 26, que o sinal do sensor 3 possui a maior amplitude dos três sinais, seguido pelo sensor 2 e sensor 1. Já o sensor 4 é um tanto oscilatório devido à baixa resolução do dispositivo de aquisição.




Figura 26: Exemplo de curva de amplitude vs. tempo dos sensores em ciclo normal.

Quando está em operação, os esforços no atuador elétrico variam de um ponto para outro. Devido ao posicionamento dos acelerômetros, cada um deles medirá um nível diferente de vibração: o sensor 1 medirá vibrações na ponta inferior da haste e da pinça do freio, o sensor 2 medirá vibrações no eixo sem fim e da coroa, o sensor 3 detectará vibrações provenientes do motor e das engrenagens. A diferença de amplitude entre os acelerômetros pode ser explicada observando a Figura 27.




Figura 27: Transmissão do atuador elétrico com seus componentes e sensores.
Fonte: Coester Automação S.A.

5.3.2 Falha 1

Na falha 1, foram executados 50 ciclos (25 aberturas e 25 fechamentos) com pressão no freio do rolamento inferior a 3,0 bar. Nessa falha, esperava-se obter uma resposta mais visível do sensor 4, como pode ser visto na Figura 28.

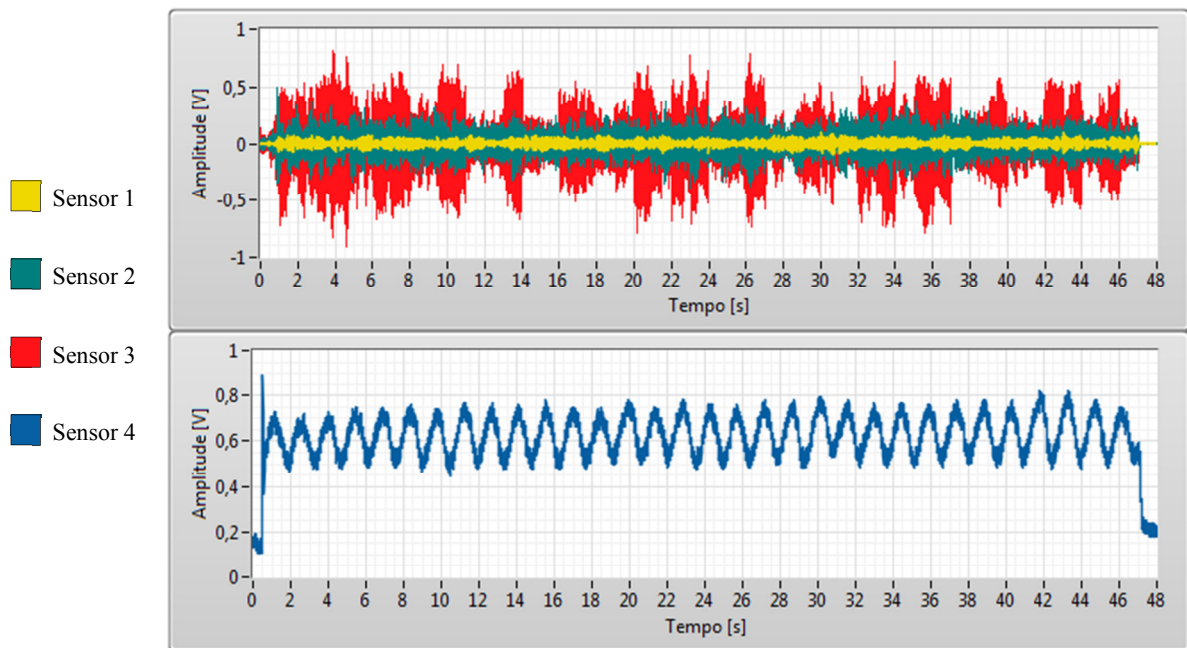


Figura 28: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 1.

5.3.3 Falha 2

Os ciclos de falha 2 têm, como motivação, simular um comportamento normal em operação em campo, ou seja, um fechamento ou abertura com alguma carga na válvula (como, por exemplo, um fluido), a qual exerce uma força de atrito na haste. Sendo assim, esperava-se observar uma mudança no sinal do sensor 4 (Figura 29).




Figura 29: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 2.

5.3.4 Falha 3

No ciclo de falha 3, uma das rodas dentadas da caixa de transmissão do atuador foi substituída por uma roda dentada desgastada. Com essa substituição, esperava-se uma variação expressiva em termos de vibração. Observando a Figura 30, à primeira vista é possível notar a diferença de amplitude do acelerômetro 1 em relação ao comportamento normal.

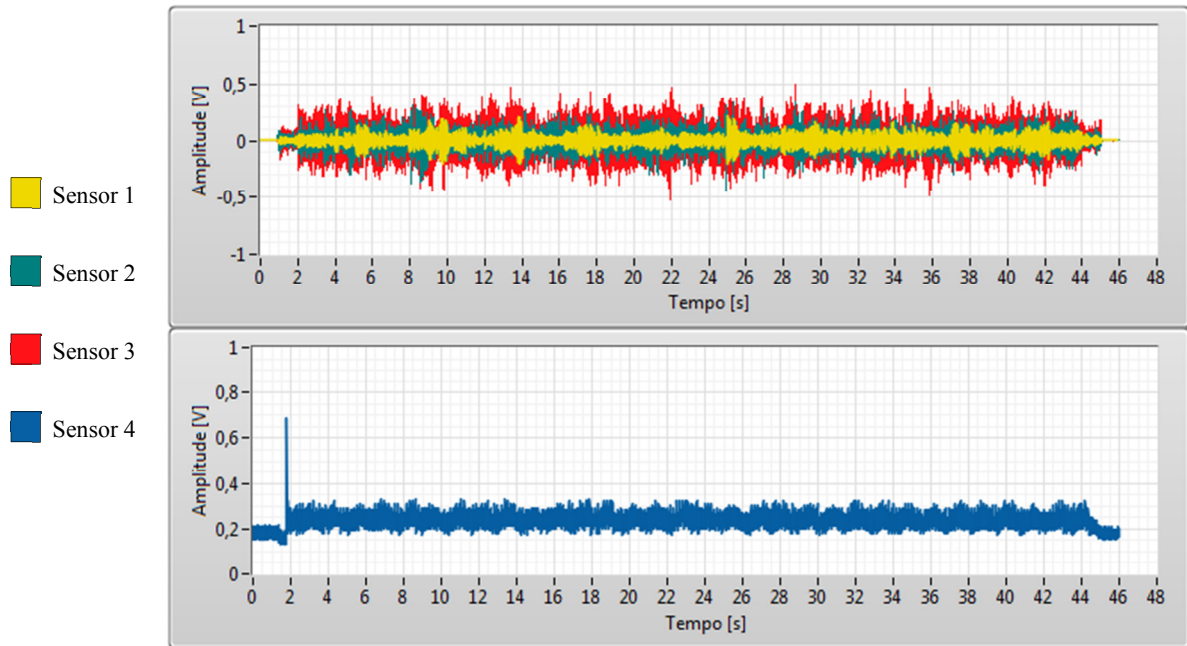


Figura 30: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 3.

5.3.5 Falha 4

A Figura 31 apresenta o ciclo de falha 4 no domínio tempo para os quatro sensores.

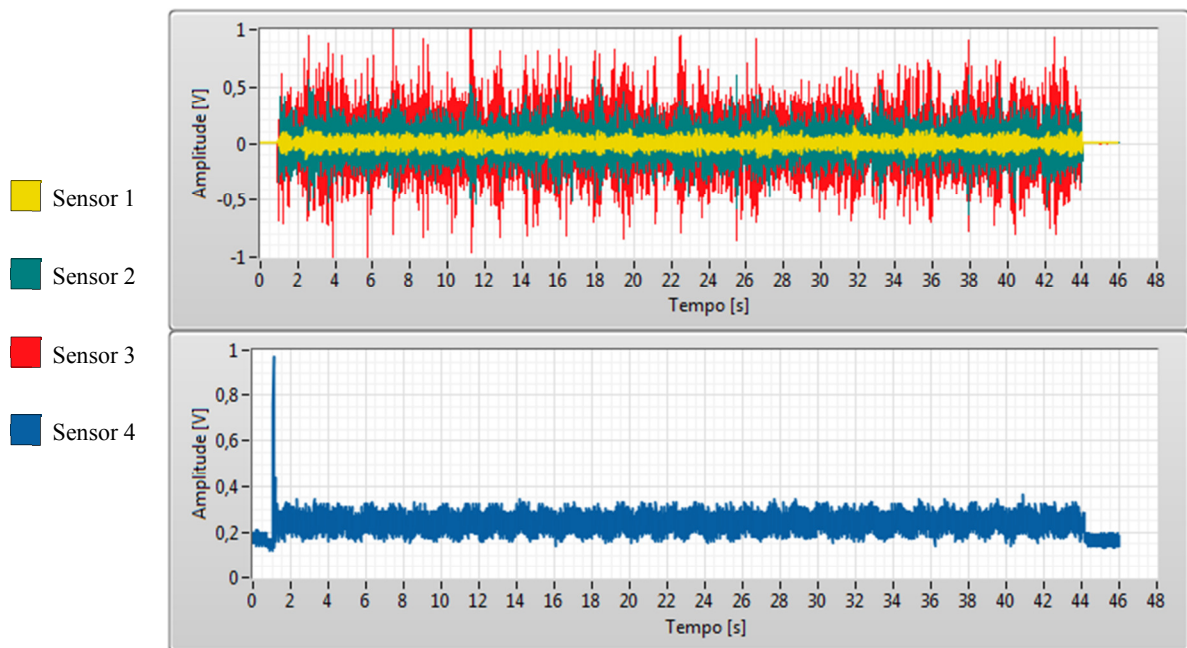


Figura 31: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 4.

Assim como a falha 3, a falha 4 consiste em ciclos com a presença de rodas dentadas desgastadas. Neste caso, porém, foram utilizadas duas rodas dentadas desgastadas. O resultado foi um expressivo aumento no ruído da máquina, somado à falta de lubrificação das peças envelhecidas, e maiores picos de vibração no acelerômetro 2 e 3.

5.3.6 Falha 5

Na falha 5, uma das rodas dentadas normais do atuador foi substituída por uma roda dentada com os dentes quebrados. No dia-a-dia, essa é uma condição perfeitamente possível para um caso crítico de falta de manutenção.

Com essa simulação, esperava-se observar um comportamento anormal na vibração detectada pelo acelerômetro 3, principalmente no momento da ausência de acoplamento da roda dentada com o eixo do motor. De fato, houve alguns picos de vibração próximos a 1,5V. O sinal de torque também apresentou um pico inicial relativamente alto (próximo a 0,8V).




Figura 32: Exemplo de curvas de amplitude vs. tempo dos sensores para a falha 5.

5.3.7 Resumo da Análise Primária

Com os ciclos descritos anteriormente, foi considerado conveniente adquirir algumas informações sobre as curvas obtidas. Para isto, foram utilizadas ferramentas matemáticas computacionais, como LabVIEW e Matlab.

Para cada categoria de ciclo, foi calculado o valor pico-a-pico, o pico máximo, o pico mínimo, o nível DC, o valor RMS e realizada uma média aritmética de cada categoria para cada sensor. Outros dados estatísticos, como a obliquidade⁵ e curtose⁶ também foram consideradas para esta avaliação.

No cálculo da frequência, esta foi aproximada usando um algoritmo que calcula a densidade espectral de potência: o valor correspondente é a média entre os testes do valor máximo de frequência onde 90% da potência do sinal está concentrada.

Observando os dados da Tabela 6, é possível estabelecer várias relações entre cada característica com os sinais e as falhas:

- *Valor pico-a-pico*: demonstrou ser bem característico quando se trataram dos acelerômetros, apresentando valores bem específicos para cada tipo de simulação. Porém, no caso do sensor 4, o comportamento normal e a falha 3 apresentaram um valor pico-a-pico muito aproximado.
- *RMS*: para o sensor 1, diminui para as falhas com o freio (falhas 1 e 2) e aumenta para as falhas com rodas dentadas (falhas 3, 4 e 5). O contrário ocorreu com o sensor 4.
- *Nível DC*: é irrelevante para os acelerômetros e redundante para o sensor 4 (o valor RMS apresenta o mesmo comportamento), podendo ser descartado.
- *Obliquidade*: foram observadas variações significativas na obliquidade. Para os sensores 1 e 4, o sinal da obliquidade se altera de acordo com o tipo de situação (falha com o freio ou falha com rodas dentadas desgastadas).

⁵ Obliquidade mede a assimetria da distribuição de probabilidade de uma variável aleatória. Valores negativos indicam que o lado esquerdo da função densidade de probabilidade é mais longo que o lado direito, enquanto valores positivos indicam que o lado direito da função densidade de probabilidade é mais longo que o lado esquerdo. Valores próximos de zero indicam simetria.

⁶ Curtose mede o achatamento de uma determinada distribuição de probabilidade. Valores próximos de 3 indicam distribuição normal. Valores menores que 3 indicam maior achatamento que a distribuição normal e maiores que 3 indicam caráter mais “pontagudo” que a distribuição normal.

- *Curtose*: no caso da curtose, não houveram variações visíveis de comportamento das curvas de acordo com cada sensor, apesar de haver variações significativas em seus valores.
- *Frequência*: foi notado grande variação de frequência, principalmente no caso dos acelerômetros. No caso de falhas simuladas com o freio, a frequência do sensor 1 aumentou, enquanto que no sensor 2 e 3 diminuiu. Em falhas com rodas dentadas problemáticas, o contrário aconteceu.

Tabela 6: Resumo das características dos sinais.

Ciclo	Sensor	PP	Pico +	Pico -	Freq. (Hz)	DC	RMS	Obliquidade	Curtose
Normal	1	0,2935	0,1470	-0,1465	80	0,0006	0,0332	-0,0110	3,5880
	2	0,9046	0,4927	-0,4119	430	0,0007	0,0778	0,1629	4,0138
	3	1,1781	0,6019	-0,5762	60	0,0006	0,1802	0,0346	2,5622
	4	0,4832	0,5928	0,1096	0,4	0,2346	0,2361	0,1047	7,4752
Falha 1	1	0,1735	0,0875	-0,0861	105	0,0007	0,0192	0,0136	3,8506
	2	0,7511	0,3796	-0,3715	180	0,0007	0,0790	0,0010	3,6022
	3	1,4358	0,7346	-0,7012	65	0,0005	0,2095	0,0383	2,8498
	4	0,7815	0,8840	0,1025	0,7	0,5542	0,5644	-1,5968	7,0612
Falha 2	1	0,1416	0,0708	-0,0708	90	0,0006	0,0151	0,0315	3,7444
	2	0,8129	0,4049	-0,4080	150	0,0007	0,0986	-0,0538	3,1453
	3	1,3445	0,7018	-0,6426	60	0,0006	0,1913	0,0591	2,8479
	4	0,7086	0,8190	0,1104	0,6	0,3601	0,3633	-1,2992	8,5243
Falha 3	1	0,4153	0,2081	-0,2072	70	0,0006	0,0389	-0,0038	5,0031
	2	0,7770	0,3804	-0,3966	500	0,0007	0,0716	-0,0254	3,7315
	3	0,9662	0,5063	-0,4599	350	0,0006	0,1036	0,1472	3,0885
	4	0,4824	0,5979	0,1155	0,6	0,2283	0,2295	0,4664	11,8808
Falha 4	1	0,2883	0,1442	-0,1441	70	0,0006	0,0328	-0,0190	3,2679
	2	0,9593	0,4707	-0,4887	230	0,0007	0,0895	-0,0238	3,6299
	3	2,1838	1,2058	-0,9780	270	0,0005	0,1716	0,0459	3,8601
	4	0,6864	0,7900	0,1037	0,7	0,2277	0,2294	1,1730	24,8803
Falha 5	1	0,3515	0,1748	-0,1766	80	0,0006	0,0381	-0,0038	3,5617
	2	1,3964	0,6899	-0,7064	480	0,0007	0,0769	-0,0213	8,4352
	3	2,8650	1,6218	-1,2433	220	0,0004	0,1471	0,0952	6,3151
	4	0,6552	0,7491	0,0939	0,5	0,2165	0,2185	0,9085	18,2830

Apesar dos valores da Tabela 6 terem pouco valor quantitativo (pelo fato dos mesmos serem oriundos de médias aritméticas entre cada tipo de ciclo), eles são válidos do ponto de vista de avaliação da variação entre os sinais dos sensores e as diferentes falhas.

Nas seções seguintes, será visto que a Tabela 6 tem uma função importante na definição do método que foi usado para avaliar o sistema.

5.4 DESENVOLVIMENTO DA ANÁLISE DOS TESTES

Para realizar a análise dos testes com fusão de sensores foi utilizado um VI desenvolvido na plataforma LabVIEW®, com a ajuda do pacote Watchdog Agent™ Toolbox para LabVIEW 2011. A elaboração deste VI teve como referencial o Watchdog Agent para Matlab®, que foi brevemente descrito na seção 2.4.

Portanto, antes de entrar em maiores detalhes quanto ao procedimento utilizado para realizar a análise dos dados, alguns conceitos e funcionalidade do Watchdog devem ser esclarecidos.

5.4.1 Análise no Watchdog Agent para Matlab

Existem três categorias de dados que são computadas pelo Watchdog: dado normal, dado de falha e dado de teste. Dados normais e de falha são as informações históricas (as quais já se tem conhecimento) do processo que será avaliado. Também podem ser chamados de “dados de treinamento”. Neste trabalho, os dados normais e de falhas são os próprios resultados obtidos dos testes realizados. Dados de teste é o conjunto de dados que se deseja avaliar, os quais não se tem nenhum conhecimento prévio.

Os conjuntos de dados que compõe cada uma dessas categorias são definidos pelo próprio usuário. Portanto, este deve ter muito cuidado ao rotular cada conjunto (por exemplo, o usuário pode equivocadamente definir um dado normal como dado de falha, gerando um erro de análise que poderá passar despercebido).

Para a análise, o usuário escolhe as ferramentas de processamento de sinais, extração de características e avaliação de desempenho que estão disponibilizadas no Watchdog Agent™ (as mesmas que foram descritas na seção 2.4). O programa faz então a extração das

características dos dados de treinamento, dos dados de teste e então, finalmente, calcula o valor de confiança.

5.4.2 Desenvolvimento da Fusão de Sensores no LabVIEW 2011

O procedimento de fusão de sensores foi baseado no modelo proposto por Dasarathy (1997). A análise inicia com o processamento de sinais (Fusão DAI-DAO), parte para a extração de características (Fusão DAI-FEO) e, finalmente, para a avaliação de desempenho através de regressão logística (Fusão FEI-DEO). Cada etapa citada será descrita nas subseções a seguir.

5.4.2.1 Processamento de sinais

Antes de iniciar, é importante esclarecer como funciona a estrutura dos arquivos que contém os dados de cada ciclo. Cada arquivo tem o formato de uma planilha e corresponde a um ciclo de abertura ou fechamento contendo quatro colunas (uma para cada sensor) e m amostras adquiridas a uma taxa de 2048 Hz. Um exemplo da estrutura dos arquivos está apresentado na Equação 15, contendo uma matriz S com n sensores genéricos e m amostras. No caso deste trabalho, o valor de n é igual a 4.

$$S = \begin{bmatrix} S_{1,1} & S_{1,2} & \cdots & S_{1,n} \\ S_{2,1} & S_{2,2} & \cdots & S_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ S_{m,1} & S_{m,2} & \cdots & S_{m,n} \end{bmatrix} \quad (15)$$

Como já foi mencionado anteriormente, a quantidade de dados adquirida é excessiva tornando necessário um pré-processamento desses sinais. Como ferramenta para reduzir essa quantidade excessiva de dados, foi utilizado um processo de reamostragem. Um processo de filtragem foi inicialmente proposto, mas infelizmente a filtragem não traria melhorias em termos de desempenho computacional.

Considerando que a densidade espectral de potência da maior parte dos dados dos sensores não passou de 500 Hz, a taxa de reamostragem selecionada foi de 1024 Hz. O

resultado da reamostragem foi a obtenção de um sistema computacionalmente mais rápido e mais estável, com mínima perda de informação.

Algebricamente, agora a matriz de dados da Equação 15 continua com a mesma quantidade de colunas, porém $m/2$ amostras.

5.4.2.2 Extração de Características

Para a extração de características, foi proposto o cálculo da energia dos pacotes wavelets (WPE) dos sinais. Esse método foi selecionado porque reduz enormemente a quantidade de informação presente no processo, além de manter as informações temporais e espectrais (JOHNSON, 2006).

Nesta etapa, os quatro vetores coluna da matriz da Equação 15 foram separados e calculados individualmente. Para o sensor n , a Equação 16 representa a operação realizada utilizando um algoritmo de WPE com wavelet do tipo Daubechies⁷-6 e ordem 6, gerando um vetor unidimensional C_n com 64 elementos⁸.

$$C_n = [E_1 \ E_2 \ \dots \ E_{64}] \quad (16)$$

Onde $\{E_1 \dots E_{64}\}$ são as energias dos pacotes wavelet. Como esses valores representam as características de um sensor para um dado ciclo, o vetor C_n é o vetor de características do sensor n . Deve ser ressaltado que para a análise completa dos dados é necessário obter os vetores de características de todos os sensores para todos os ciclos.

Além das energias dos pacotes wavelets, é possível selecionar outras características que sejam consideradas relevantes. A Tabela 6 apresentou vários candidatos a esse grupo. Portanto, foram adicionados ao vetor de características da Equação 16 o valor RMS, o valor pico-a-pico, a obliquidade, a curtose, o ponto de máximo e o ponto de mínimo. Tem-se, então, o vetor da Equação 17, contendo agora 70 componentes.

$$C_n = [E_1 \ E_2 \ \dots \ E_{64} \ V_{RMS} \ V_{pp} \ g_1 \ g_2 \ V^+ \ V^-] \quad (17)$$

Onde V_{RMS} é o valor RMS, V_{pp} é o valor pico-a-pico, g_1 é a obliquidade, g_2 é a curtose, e V^+ e V^- são os pontos de máximo e mínimo, respectivamente.

⁷ Daubechies-6 é uma família de wavelets ortogonais e assimétricas (WASILEWSKI, 2011).

⁸ A ordem da árvore de decomposição determina o número de iterações executadas no sinal (ver seção 2.4.1.7, Figura 3).

5.4.2.3 Avaliação de Desempenho

Nesta etapa, foi escolhido o bloco de Regressão Logística, presente no Watchdog Agent Toolbox para LabVIEW. Esse bloco possui os seguintes terminais:

- *Training Data (Dado de Treinamento)*: são os dados de treinamento do bloco de regressão logística. Neste terminal devem entrar as características de comportamento normal e de falha. O terminal aceita matrizes com dimensão de m amostras (que, neste caso, serão os ciclos) por n características.
- *Training Label (Rótulo de Treinamento)*: trata-se de um vetor unidimensional de m amostras contendo valores de 0 a 1 que deve ser incluído no terminal a fim de “rotular” os dados de treinamento. Para este trabalho, foram usados 0,95 para as características normais e 0,10 para as características de falhas.
- *Testing Data (Dado de Teste)*: são os dados de teste que se desejam avaliar. Consiste de uma matriz com p amostras e n características. Como os dados de teste devem ter o mesmo número de características que os dados de treinamento, fica implícito que os dados de teste devem passar pelo mesmo processo de extração de características que os dados de treinamento.
- *Confidence Value (Valor de Confiança)*: é um terminal de saída que apresenta o resultado da regressão logística em um valor de confiança de 0 a 1, sendo “1” totalmente saudável e “0” totalmente defeituoso. Em termos de fusão de sensores, essa saída representa um valor em decisão.
- *Sum of Squared Errors (Soma dos Erros Quadráticos)*: terminal de saída que apresenta o erro da regressão.

Para calcular o valor de confiança, é necessário organizar os vetores de características em uma matriz m por n como é exigido pelo terminal de dados de treinamento. Essa matriz de características está apresentada na Equação 18.

$$C = \begin{bmatrix} C_{1,1} & C_{1,2} & \cdots & C_{1,n} \\ C_{2,1} & C_{2,2} & \cdots & C_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ C_{m,1} & C_{m,2} & \cdots & C_{m,n} \end{bmatrix} \quad (18)$$

Note que, considerando os sensores referentes a este trabalho, cada linha da matriz C possui cerca de 280 elementos. Apesar de este número parecer exagerado, ele é irrisório se for comparado com os dados brutos adquiridos pelos sensores (mesmo depois de reamostrados).

Também é necessário montar o vetor unidimensional de rótulos para os dados de treinamento. Este vetor foi gerado no LabVIEW de acordo com a origem dos dados inseridos na matriz característica (0,95 para normais; 0,10 para falhas).

A matriz característica dos dados de teste também foi montada e ela tem a mesma estrutura da matriz expressa na Equação 18, com a diferença que o número de amostras não precisa ser necessariamente igual ao número de amostras da matriz característica dos dados de treinamento.

Todo este processo de aquisição, tratamento de sinais e avaliação foi resumido em um fluxograma simplificado com a finalidade de fornecer uma visão geral do algoritmo elaborado. Este fluxograma está apresentado na Figura 33.

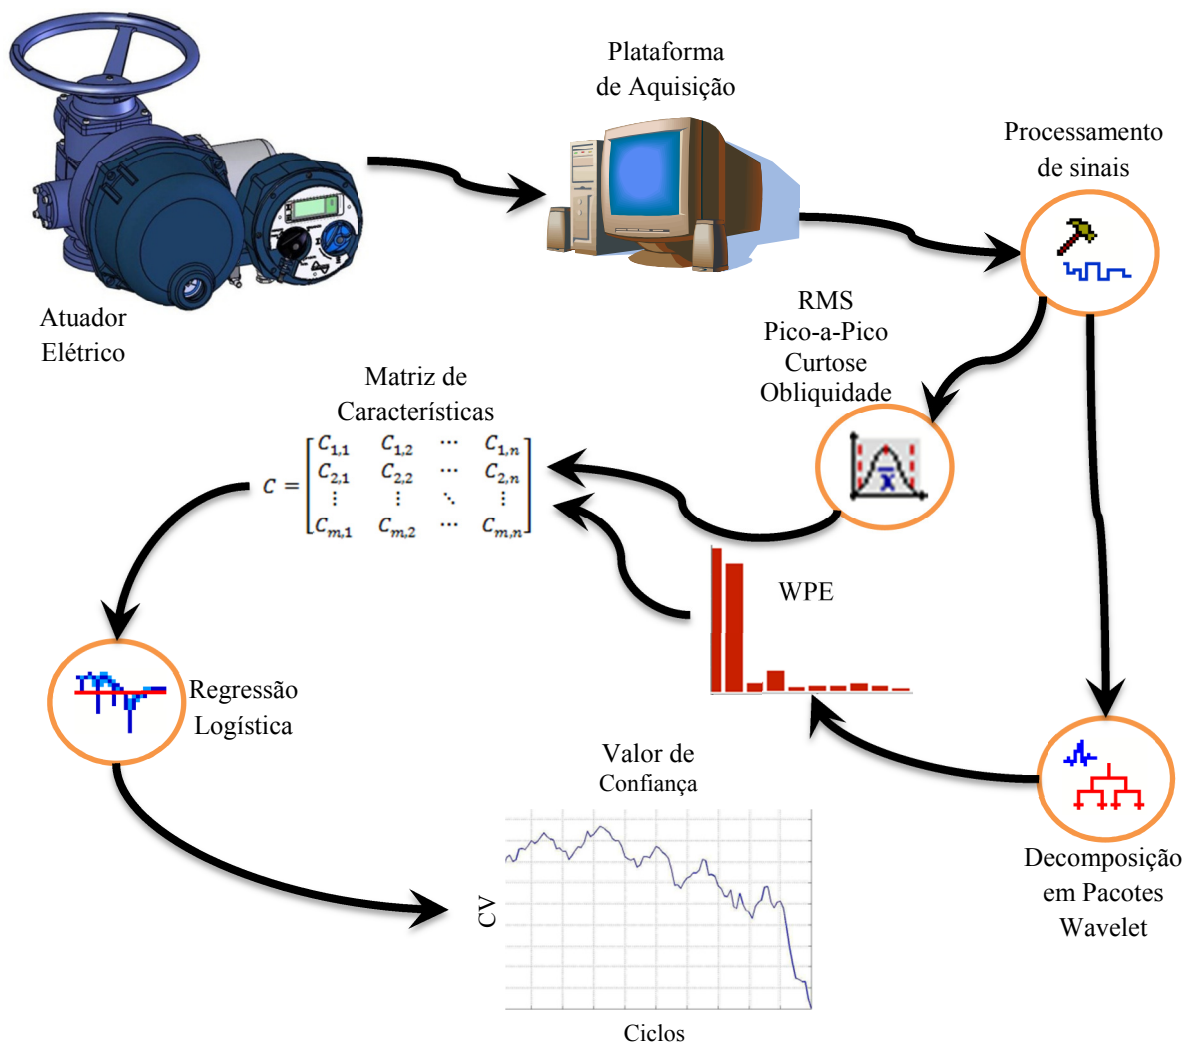


Figura 33: Fluxograma do algoritmo desenvolvido.
Fonte: Coester Automação S. A., LabVIEW 2011®.

5.5 ANÁLISES E RESULTADOS

Nesta seção serão apresentados e discutidos os resultados obtidos com a rotina empregada no LabVIEW. Adiante, uma breve comparação dos resultados com o Watchdog Agent do Matlab também será abordada, com a finalidade de definir qual o melhor método para utilização de fusão de sensores.

Além das curvas que estão presentes neste trabalho, foram levantados cerca de 200 gráficos de valor de confiança para avaliar o comportamento do sistema de fusão, tanto no Matlab quanto no LabVIEW. De todas elas, foi possível tirar uma série de conclusões sobre a aquisição dos dados do atuador, sobre a análise realizada e sobre as duas plataformas abordadas.

5.5.1 Teste 1

O bloco de regressão logística foi treinado com 30 ciclos normais mais 20 ciclos de cada tipo de falha (100, no total). Como dado de teste, foram executados 20 ciclos normais, todos os 250 ciclos de falhas e, finalmente, os 30 ciclos normais restantes. A curva de valor de confiança esperada nesse teste é uma curva que se mantém perto de 1 até o ciclo 20 e depois disso cai para um valor próximo de zero, se mantendo ali até o ciclo 270; onde ela volta a oscilar próximo de 1. O resultado está apresentado na Figura 34.

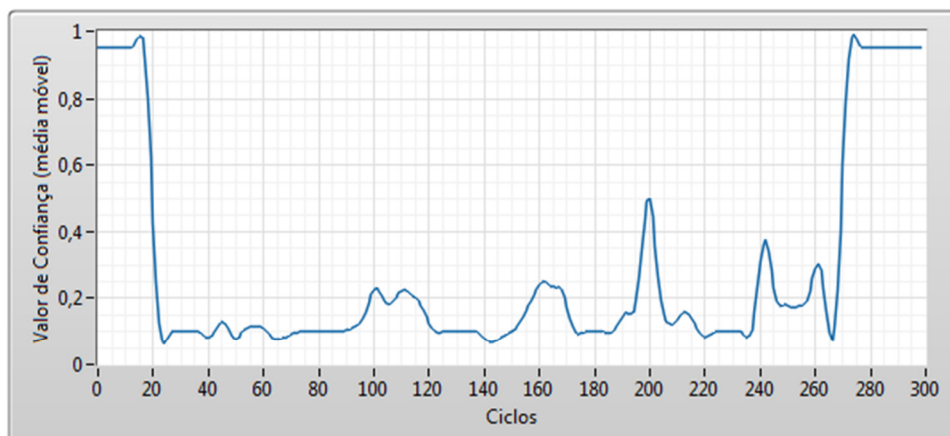


Figura 34: Valor de confiança para o teste 1.

O teste acima foi executado com os dados de todos os sensores. É possível notar que o teste foi satisfatório, exibindo o comportamento esperado.

Utilizando somente o sensor 4, o valor de confiança apresenta a seguinte característica (Figura 35):




Figura 35: Valor de confiança usando apenas o sinal de torque.

Neste caso, quando a avaliação de desempenho depende apenas do torque, é possível verificar que existe discrepância entre o resultado esperado com o resultado obtido. Enquanto que com todos os sensores o erro de regressão foi em torno de 10^{-15} , com apenas o sensor 4 obteve-se um erro de 0,2206.

Também foi realizado um teste usando somente a fusão dos acelerômetros (sensores 1 a 3), apresentado na Figura 36. Apesar do valor de confiança apresentar um comportamento próximo do que é esperado, o erro de regressão foi de 0,001185; consideravelmente maior do que o erro com quatro sensores.




Figura 36: Teste 1 realizado com fusão dos sensores 1, 2 e 3.

5.5.2 Teste 2

No primeiro teste, foram utilizados dados repetidos para o treinamento e para o teste (ou seja, dados que foram usados para treinar a regressão também entraram no teste). Sendo assim, o objetivo do segundo teste é realizar uma medição do valor de confiança com informações diferentes das que foram usadas para treinar a regressão logística.

Para o treinamento, foram usados 20 ciclos normais além de 10 ciclos para cada falha (totalizando 50 ciclos de falha). A entrada para os dados de testes usados foram somente os ciclos que foram excluídos do treinamento na seguinte ordem: 20 ciclos normais, 200 ciclos de falhas, 10 ciclos normais. A forma da curva do valor de confiança esperada é como a do teste 1, com a pequena diferença nos pontos onde o valor cai para próximo de zero (agora deve ser aproximadamente no ciclo 20) e sobe para próximo de 1 (espera-se que seja aproximadamente no ciclo 220).

À primeira vista, o resultado da Figura 37 pode parecer desanimador devido a divergência com o resultado esperado. Porém, analisando o gráfico cuidadosamente é possível perceber alguns fatores interessantes. De acordo com o ordenamento dos dados de teste, os primeiros 20 ciclos são comportamentos normais, do 20 ao 60 são ciclos de falha 1, do 60 ao 100 são ciclos de falha 2, e assim sucessivamente, até o 220 ao 230, que são ciclos normais.




Figura 37: Curva do valor de confiança para o teste 2, com fusão dos quatro sensores.

Apesar de o gráfico da Figura 37 ter um comportamento diferente daquele que seria o correto, no teste 2 a transição entre as falhas é mais visível. A causa da divergência provável é devido à falta de correlação entre os ciclos do mesmo tipo e/ou a influência negativa de algum sensor no resultado final da fusão.

A influência negativa pode ser provada calculando o valor de confiança para os sensores individualmente. Foram calculados os valores de confiança para os quatro sensores, mas somente o valor de confiança do sensor 4 será mostrado aqui (ver Figura 38). Como comparação, foi plotado também a curva de valor de confiança da fusão entre o sensor 1 e 2 na Figura 39. A partir daí, é possível perceber que a fusão de sensores nem sempre tende a fornecer um resultado 100% correto, pois vários fatores afetam a eficiência da fusão, tais como a afinidade entre as amostras de mesmo tipo (normal, falha 1, etc.), a afinidade indesejada com amostras de outro tipo (ciclos normais que parecem falhas, e vice-versa) e ainda um algoritmo que possa ponderar relativamente a influência de cada sensor.

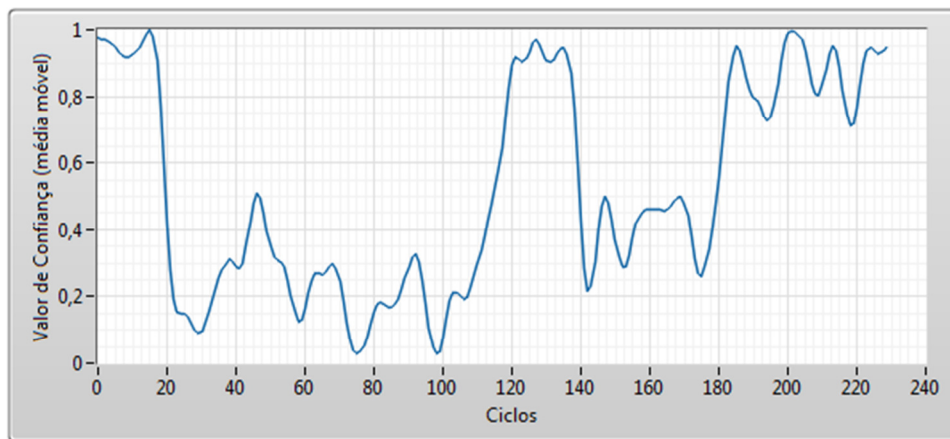


Figura 38: Curva de valor de confiança para o sensor 4, no teste 2.




Figura 39: Curva de valor de confiança para a fusão do sensor 1 e 2, no teste 2.

5.5.3 Teste 3

Neste teste, foram selecionados para o treinamento do algoritmo 30 ciclos normais, mais 20 ciclos de falha 1 e 20 ciclos de falha 4. Os arquivos testados usados para testes foram todos os 300 ciclos. O objetivo desta configuração é avaliar se a rotina desenvolvida tem capacidade de indicar a ocorrência de falhas mesmo que ela não tenha sido treinada para a detecção da mesma.

O ordenamento dos ciclos foi o seguinte: falhas 1, 2 e 3 em sequência até o ciclo 150, ciclos normais de 151 a 200, falhas 4 e 5 de 201 até 300. Sendo assim, o comportamento esperado é de valores próximos a zero até 150, próximos de 1 até 200 e próximos de zero novamente até 300. Foi realizado um teste com fusão dos quatro sensores, o resultado segue na Figura 40.




Figura 40: Valor de confiança calculado no teste 3, com fusão dos quatro sensores.

O gráfico apresentado na Figura 40 apresentou resultados interessantes. Como era de se esperar, a falha 1 (ocorrida entre o ciclo 1 e 50) e a falha 4 (ocorrida entre os ciclos 200 e 250) foram visivelmente detectadas. Já a falha 2 (51 e 100) foi indicada como um comportamento próximo do normal. A falha 3 (101 e 150) foi apresentada como ciclo normal e a falha 5 (251 a 300) apresentou oscilações, tendendo para um comportamento de falha.

Novamente questiona-se o efeito negativo da medição de algum sensor. Alguns testes foram realizados e foi constatado que a curva de valor de confiança sem o sensor 4 (torque) apresentou uma resposta mais coerente com o que se esperava (Figura 41).




Figura 41: Valor de confiança calculado para o teste 3 com fusão dos acelerômetros.

Surpreendentemente, plotando somente a curva de torque para o teste 3, tem-se um resultado mais expressivo do que utilizando a fusão de sensores. Apesar disso, o erro de regressão é alto em relação às duas fusões executadas anteriormente ($0,0071$ contra 10^{-14}). A curva está apresentada na Figura 42.




Figura 42: Valor de confiança do sinal de torque (sensor 4) para o teste 3.

5.5.4 Teste 4

O último teste apresentado neste projeto usa dos mesmos dados de treinamento e de teste que o teste 1. Porém, foi executado no Watchdog Agent do Matlab a fim de comparar com o VI que foi desenvolvido neste trabalho.

A curva de valor de confiança com fusão dos quatro sensores pode ser visualizada na Figura 43. Observa-se que o comportamento da curva é muito diferente do que foi visto no

LabVIEW, apresentando um comportamento mais amortecido. Apesar de indicar corretamente a tendência do sistema, o valor de confiança não varia expressivamente durante os ciclos de falha ou na transição entre os tipos de falhas, tornando difícil a identificação do que é um ciclo normal e o que é um ciclo defeituoso.




Figura 43: Valor de confiança obtido com o Watchdog Agent do Matlab.

6 CONCLUSÕES

A respeito dos dados coletados do atuador, foi constatado que alguns dos dados obtidos apresentavam baixa afinidade entre ciclos do mesmo gênero (normal com normal, falha com falha), diminuindo drasticamente a precisão do modelo desenvolvido. Essa baixa afinidade foi decorrente de vários fatores, dentre eles a falta de sincronia na aquisição de diferentes operações de abertura e fechamento da válvula e a falta de uniformidade das simulações.

Em vista dos problemas supracitados, algumas simulações apresentaram valores totalmente discrepantes com o que seria esperado. Porém, este problema foi superado aumentando a quantidade de dados de treinamento e de testes. A maior parte das simulações com mais de 150 ciclos de teste e 50 ciclos de treinamento apresentou resultados interessantes.

Sobre as duas plataformas utilizadas no trabalho, além de apresentar uma série de problemas, tais como dificuldades na interface e pequenos erros nos algoritmos que impediam a extração das características de todos os ciclos, o Watchdog Agent para Matlab exibiu resultados piores na maioria dos processos que envolviam a fusão dos sensores (em especial, com os acelerômetros). Portanto, o Watchdog Agent para LabVIEW é mais indicado para este tipo de situação, pois fornece melhor compatibilidade com hardware de aquisição de dados e permite monitoramento do sistema em tempo real de forma descomplicada (comparado ao Matlab).

Sendo assim, verificou-se que a aplicação de um sistema de fusão de sensores é eficiente devido ao *insight* adicional que proporciona sobre o processo. Uma arquitetura bem projetada de sensores pode, facilmente, fornecer informações de diversas falhas sobre o processo monitorado, o que não seria possível com um sistema dependente de um único sensor.

Porém, para que possa fornecer a melhor resposta possível sobre os sinais do processo, uma arquitetura de fusão de sensores deve ser projetada observando alguns fatores, tais como a uniformidade na aquisição dos dados e a adequação do hardware aos sinais de entrada. Caso contrário, a propagação dos erros gerada pode vir a prejudicar a análise, minando a precisão dos resultados e reduzindo sua confiabilidade; o que seria inadmissível em uma situação real.

7 REFERÊNCIAS BIBLIOGRÁFICAS

ABRAMAN. **A Situação da Manutenção no Brasil**. Disponível em:

<<http://eventos.abraman.org.br/pesquisa/glossario.php>>. Acesso em: 20 set. 2011.

BENEDETTI, Julinho Alberto. **Manutenção Centrada em Confiabilidade e Análise de Vibração**. 2002. 127 f. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2002.

BLOCH, I.; HUNTER, A. (Ed.). Fusion: General Concepts and Characteristics. **International Journal Of Intelligent Systems**, [S. l.], p. 1107-1134. Dec. 2001.

CARVAJAL, Ricardo Enrique Gutiérrez. **Sobre Técnicas para Manutenção e Diagnóstico Inteligente de Dispositivos Mecatrônicos**: Estudo de Caso utilizando Cálculo de Ordem Fracionária. 2011. 221 f. Tese (Doutorado) - Unicamp, Campinas, 2011.

CHEN, H. X.; CHUA, Patrick S. K.; LIM, G. H.. Fault Degradation Assessment of Water Hydraulic Components by Noise Signal with Wavelet Packet Analysis. **Journal Of Testing And Evaluation**, [s. l.], p. 1-9. Apr. 2008.

CHUDNOVSKY, Bella H.. Electrical Contacts Condition Diagnostics Based on Wireless Temperature Monitoring of Energized Equipment. **IEEE Institute Of Electrical And Electronics Engineers**, [S. l.], p. 73-80. May 2006.

COESTER AUTOMAÇÃO. **Manual Linha CSR: CSR6 – CSR16**. Rev. 0, p.1-28. Julho, 2009

DASARATHY, Belur V.. Sensor Fusion Potential Exploitation: Innovative Architectures and Illustrative Applications. **IEEE Institute Of Electrical And Electronics Engineers**, [S. l.], p. 24-38. Jan. 1997.

DASH, M.; LIU, H.. Feature Selection for Classification. **Intelligent Data Analysis**, [S. l.], p. 131-156. Mar. 1997.

DJURDJANOVIC, D.; LEE, J.; NI, J. Watchdog Agent™ - an Infotronics-Based Prognostics Approach for Product Performance Degradation Assessment and Prediction. **Advanced Engineering Informatics**. [S. l.] v. 17, p. 109-125, Jul.-Out. 2003.

ELMENREICH, Wilfried. **An Introduction to Sensor Fusion**: Research Report 47/2001.

Disponível em:

<http://www.vmars.tuwien.ac.at/documents/intern/805/elmenreich_sensorfusionintro.pdf>.

Acesso em: 19 out. 2011.

ESTEBAN, Jaime et al. A Review of Data Fusion Models and Architectures: Towards Engineering Guidelines. **Neural Computing And Applications**, Springer-verlag London, Uk, p. 273-281. Dec. 2005.

GONÇALVES, Luiz Fernando et al. **Um Método de Classificação de Falhas em Atuadores Elétricos Baseado em Mapas Auto-Organizáveis**. Porto Alegre: UFRGS - PPGEE, [2007].

HAYWARD INDUSTRIAL PRODUCTS INC.. **Most Common Electric Actuators Problems**.

Disponível em: <<http://pdf.directindustry.com/pdf/hayward-flow-control/electric-actuator-problems-solutions/16511-47554.html>>. Acesso em: 23 out. 2011.

HENDERSON, Thomas C. et al. **Sensor Fusion**. Disponível em:

<<http://www.cs.utah.edu/~tch/publications/pub191.pdf>>. Acesso em: 29 out. 2011.

IEEE. **IEEE Standard Computer Dictionary: A Compilation of IEEE Standard Computer Glossaries**. Institute of Electrical and Electronics Engineers. New York, NY. 218p. 1990.

IMS CENTER. **Watchdog Agent™ Toolbox Documentation**. p. 1-22. Mai. 2007.

JACQUES, Ricardo Callegari. **Avaliação de Parâmetros de Emissão Acústica para Monitoramento de Risers Flexíveis**. 2009. 129 f. Tese (Doutorado) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

JOHNSON, K. **Watchdog Agent™ Toolbox – Project Report**. [S. l.] p. 1-94. Ago. 2006

KISTLER. **Instruction Manual**. K-Shear and PiezoStar® Accelerometers. [S. l.]. 2010.

LIMITORQUE QX. **Maintenance and Spare Parts**. Disponível em:

<<http://www.flowserve.com/files/Files/Literature/ProductLiterature/FlowControl/Limitorque/LMENIM3314.pdf>>. Acesso em: 10 dez. 2011.

LIU, H.; YU, L.. Toward Integrating Feature Selection Algorithms for Classification and Clustering. **IEEE Trans, Knowledge And Data Engineering**, [S. l.], p. 491-502. Apr. 2005.

LIU, Zheng et al. Survey: State of the Art in NDE Data Fusion Techniques. **IEEE Transactions On Instrumentation And Measurements**, [S. l.], p. 2435-2451. Dec. 2007.

MANGAI, Utthara Gosa et al. A Survey of Decision Fusion and Feature Fusion Strategies for Pattern Classification. **IETE Technical Review**, [S. l.], p. 293-307. July 2010.

MARCORIN, Wilson Roberto; LIMA, Carlos Roberto Camello. **Análise dos Custos de Manutenção e de Não-manutenção de Equipamentos Produtivos**. Disponível em: <<http://www.unimep.br/phpg/editora/revistaspdf/rct22art03.pdf>>. Acesso em: 20 set. 2011.

MENARD, Scott W.. **Applied Logistic Regression Analysis**. [S. l.]: Sage, 1995.

MENNA, Alexandre Ribeiro. **Deteção de Falhas em Mancais de Rolamento por Análise de Vibrações em Banda Larga: Um Caso Prático de Aplicação em uma População de Equipamentos Rotativos**. 2007. 186 f. Dissertação (Mestrado) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

MIMOSA. **OSA-CBM 3.1L**. Disponível em:

<<http://www.mimosa.org/?q=resources/specs/osa-cbm-31l>>. Acesso em: 19 ago 2011.

MONWAR, Md. Maruf; GAVRILOVA, Marina L.. Multimodal Biometric System Using Rank-Level Fusion Approach. **IEEE Transactions On Systems, Man, And Cybernetics**, [S. l.], p. 867-878. Aug. 2009.

RICE, Trevor et al. Fiber Optic Distributed Strain, Acoustic Emission, and Moisture Detection Sensors for Health Maintenance. **Institute Of Electrical And Electronics Engineers**, [S. 1], p. 505-514. July 2003.

SHLENS, Jonathon. **A Tutorial on Principal Component Analysis**. Disponível em: <<http://www.sn1.salk.edu/~shlens/pca.pdf>>. Acesso em: 07 nov. 2011.

STEINBERG, Alan N.; BOWMAN, Christopher L.. **Rethinking the JDL Data Fusion Levels**. Disponível em: <http://www.infofusion.buffalo.edu/tm/Dr.Llinas'stuff/Rethinking%20JDL%20Data%20Fusion%20Levels_BowmanSteinberg.pdf>. Acesso em: 11 nov. 2011.

THURSTON, Michael; LEBOLD, Mitchell. Standards Developments for Condition-Based Maintenance Systems. In: MEETING OF THE SOCIETY FOR MACHINERY FAILURE PREVENTION TECHNOLOGY, 55., 2001, Virginia Beach, Virginia. **Proceedings**. Virginia Beach, Virginia: Integrated Diagnostics And Prognostics, 2001. p. 1 - 11.

WALTZ, Ed. **The Principles and Practice of Image and Spatial Data Fusion**. Disponível em: <<http://dsp-book.narod.ru/HMDF/2379ch04.pdf>>. Acesso em: 21 Oct. 2011.

WASILEWSKI, Filip. **Wavelet Daubechies 6**. Disponível em: <<http://wavelets.pybytes.com/wavelet/db6/>>. Acesso em: 1 dez. 2011.

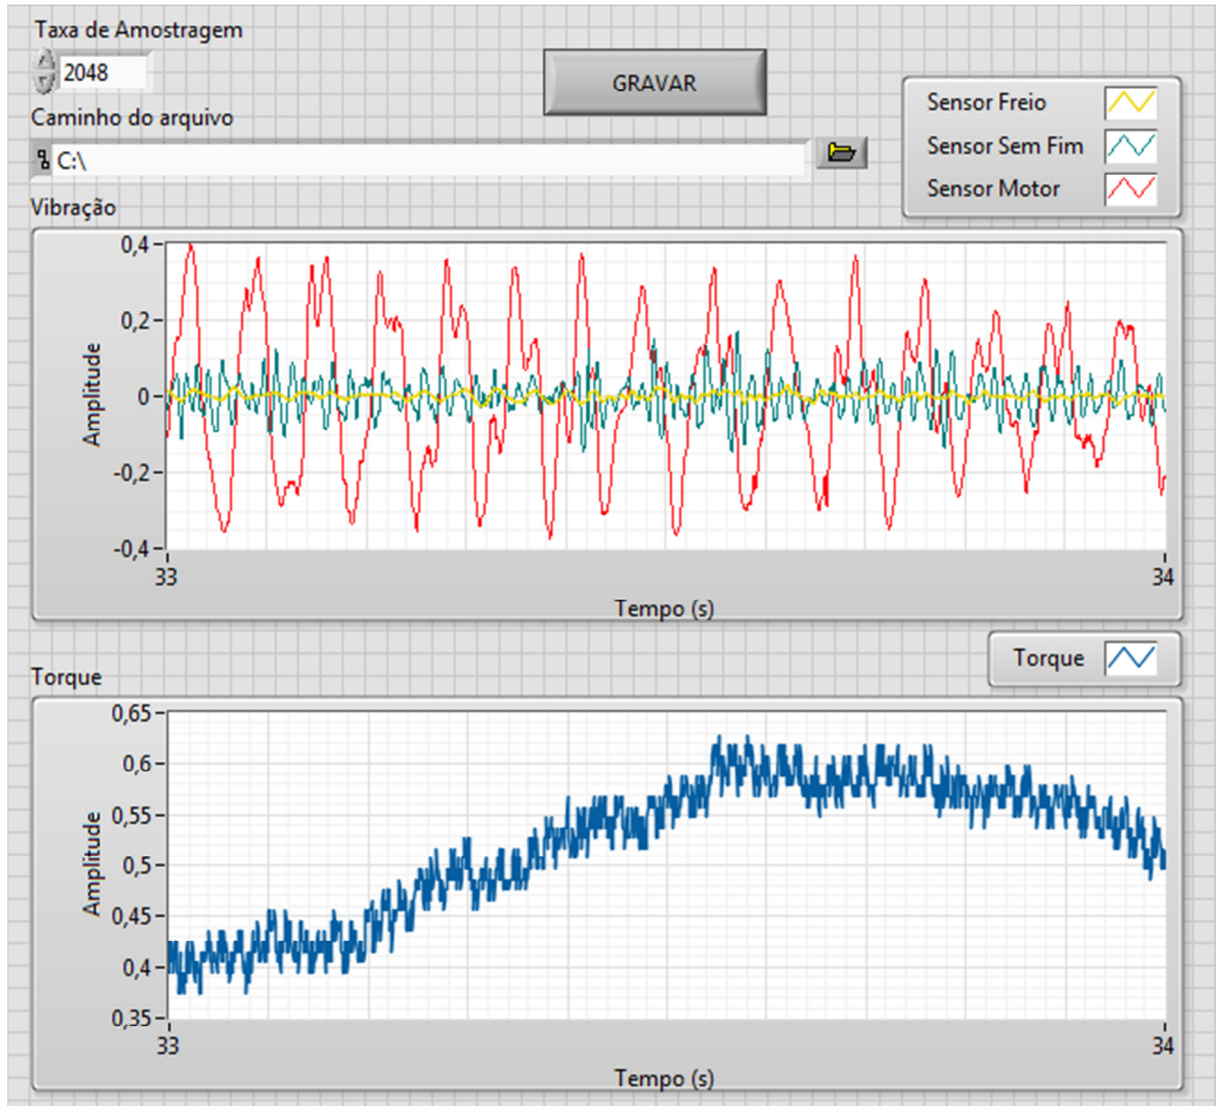
XINHAN, Huang; MIN, Wang. Multi-sensor Data Fusion Structures in Autonomous Systems: A Review. **Proceedings of The 2003 IEEE: International Symposium on Intelligent Control**, Houston, TX, Usa, p. 817-821. 5 Oct. 2003.

YAN, J; CHEN, Z. **Project Name: KONE Elevator Door**. [S. 1.] p. 1-13. Ago. 2006

YANG, J. et al. Feature Fusion: Parallel Strategy vs. Serial Strategy. **Pattern Recognition**, [S. 1.], p. 1369-1381. June 2003.

8 APÊNDICES

APÊNDICE A – VI de aquisição de dados



APÊNDICE B – VI de Regressão Logística

