



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Detecção e Diagnóstico de Agarramento em Válvulas Posicionadoras

Allan Robson Silva Venceslau

Orientador: Prof. Dr. Luiz Affonso Henderson Guedes de Oliveira

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Engenharia de Computação) como parte dos requisitos para obtenção do título de Mestre em Ciências.

Número de ordem PPgEEC: M383
Natal, RN, Janeiro de 2013

UFRN / Biblioteca Central Zila Mamede

Catálogo da publicação na fonte.

Venceslau, Allan Robson Silva.

Detecção e diagnóstico de agarramento em válvulas posicionadoras. / Allan Robson Silva Venceslau. – Natal, RN, 2012.

58 f. : il.

Orientador: Prof. Dr. Luiz Affonso Henderson Guedes de Oliveira.

Dissertação (Mestrado) – Universidade Federal do Rio Grande do Norte. Centro de Tecnologia. Programa de Pós-Graduação em Engenharia Elétrica e de Computação.

1. Agarramento - Dissertação. 2. Válvulas Posicionadoras - Dissertação. 3. Detectar - Dissertação. 4. Quantificar - Dissertação. 5. Redes Neurais. I. Oliveira, Luiz Affonso Henderson. II. Universidade Federal do Rio Grande do Norte. III. Título.

RN/UF/BCZM

CDU 621.3

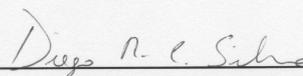
Detecção e Diagnóstico de Agarramento em Válvulas Posicionadoras

Allan Robson Silva Venceslau

Dissertação de Mestrado aprovada em 31 de janeiro de 2013 pela banca examinadora
composta pelos seguintes membros:



Prof. Dr. Luiz Affonso H. Guedes de Oliveira (orientador) DCA/UFRN



Prof. Dr. Diego Rodrigo Cabral Silva (Examinador Interno) ECT/UFRN



Vicente Delgado Moreira (Examinador Externo) ... PETROBRAS/UO-RNCE

Agradecimentos

Agradeço a toda a minha família pelo apoio, paciência, força e coragem, de forma especial, a minha mãe, Maria da Conceição, ao meu pai, João Venceslau e a minha avó, Maria das Dores, pelo incentivo em todos os aspectos.

Agradeço também à minha namorada, Sara Emanuelle, pelos momentos de incentivo e apoio incondicional, sem os quais não teria conseguido concluir este trabalho.

Ao meu orientador, professor Luiz Affonso, sou grato pela orientação.

Aos meus amigos de curso e do Laboratório de Informática Industrial, por todos os momentos que passamos desde a época de graduação.

Ao CNPq, pelo apoio financeiro.

Resumo

Agarramento, ou atrito estático, em válvulas posicionadoras é um problema muito comum nos processos industriais modernos. Recentemente, muitos estudos são desenvolvidos para tentar entender, modelar e detectar esse tipo de problema. Porém quantificar o agarramento ainda é um desafio. Uma vez que a posição da válvula (mv) é normalmente desconhecida em um processo industrial, o principal desafio é diagnosticar agarramento tendo conhecimento apenas dos sinais de saída do processo (pv) e o sinal de controle (op). Neste trabalho é apresentada uma proposta baseada em Redes Neurais Artificiais para detectar e quantificar o grau de agarramento em válvulas utilizando apenas as informações de pv e op . Diferentes métodos para o pré-processamento do conjunto de treinamento da Rede Neural são apresentados. Esses métodos são baseados no cálculo de Centróide e de Transformada de Fourier. A proposta é validada através de um processo simulado e os resultados obtidos foram satisfatórios.

Palavras-chave: Agarramento, Válvulas Posicionadoras, Detectar, Quantificar, Redes Neurais, Centróide, Transformada de Fourier.

Abstract

Valve stiction, or static friction, in control loops is a common problem in modern industrial processes. Recently, many studies have been developed to understand, reproduce and detect such problem, but quantification still remains a challenge. Since the valve position (mv) is normally unknown in an industrial process, the main challenge is to diagnose stiction knowing only the output signals of the process (pv) and the control signal (op). This paper presents an Artificial Neural Network approach in order to detect and quantify the amount of static friction using only the pv and op information. Different methods for preprocessing the training set of the neural network are presented. Those methods are based on the calculation of centroid and Fourier Transform. The proposal is validated using a simulated process and the results show a satisfactory measurement of stiction.

Keywords: Stiction, Control Loops, Detect, Quantification, Neural Network, Centroid, Fourier Transform.

Sumário

Sumário	i
Lista de Figuras	iii
Lista de Tabelas	v
Lista de Símbolos e Abreviaturas	vii
1 Introdução	1
1.1 Motivação	2
1.2 Objetivos	3
1.3 Divisão do trabalho	3
2 Detecção de Falhas	5
2.1 Características de um Sistema de Detecção de Falhas	6
2.2 Etapas do Processo de Detecção de Falhas	6
2.3 Classificação dos Métodos de Detecção de Falhas	7
2.4 Tipos de Falhas mais Comuns	10
3 Agarramento em Válvulas Posicionadoras	13
3.1 Modelagem de agarramento em válvulas posicionadoras	15
4 Estado da Arte	19
5 Proposta	21
5.1 Abordagem 01 - Centroide	22
5.2 Abordagem 02 - Análise Espectral	24
5.3 Abordagem 03 - Análise Espectral + Centroide	26
6 Resultados	29
6.1 Abordagem 01 - Centroide	29
6.1.1 Caso 1: Sem agarramento	29
6.1.2 Caso 2: Agarramento com apenas banda morta	30
6.1.3 Caso 3: Undershoot	30
6.1.4 Caso 4: Overshoot	31
6.1.5 Caso 5: Sem offset	32
6.1.6 Caso 06: Outras Situações	32

6.2	Abordagem 02 - Análise Espectral	32
6.3	Abordagem 03 - Centroide + Análise Espectral	34
7	Conclusões	39
7.1	Trabalhos Futuros	39
7.2	Publicações Associadas	40
	Referências bibliográficas	41

Lista de Figuras

1.1	Pirâmide da Automação Industrial.	1
2.1	Etapas do processo de detecção e diagnóstico de falhas.	7
2.2	Classificação dos algoritmos de diagnóstico.	8
2.3	<i>Thresholds</i> do sinal $Y(t)$	9
2.4	Representação do método de detecção de falhas por equações de paridade.	9
2.5	Esquema de blocos representando o método de detecção e classificação de falhas através de identificação de sistemas.	11
2.6	Classificação de falhas quanto a localização.	11
3.1	Falhas em válvulas posicionadoras	14
3.2	Diagrama de fase de uma válvula com agarramento.	14
3.3	Modelo proposto.	15
3.4	Algoritmo de modelagem de agarramento.	17
4.1	Defasagem dos Sinais.	19
4.2	Elipse.	20
5.1	Diagrama de fase.	22
5.2	centroide.	23
5.3	Diagrama de blocos da proposta.	24
5.4	Saída do Processo Para Diferentes Níveis Agarramento.	25
5.5	Diagrama de Blocos da Proposta Baseada em Análise Espectral.	26
5.6	Diagrama de Blocos da Proposta Baseada em Análise Espectral.	27
6.1	Agarramento com apenas Banda Morta para a abordagem 01.	30
6.2	Agarramento do tipo <i>Undershoot</i> para a abordagem 01.	31
6.3	Agarramento do tipo <i>Overshoot</i> para a abordagem 01.	31
6.4	Agarramento sem <i>offset</i> para a abordagem 01.	32
6.5	Configuração de Agarramento para a abordagem 01: $J = 2$ e $S = 4$	33
6.6	Configuração de agarramento para a abordagem 02: $J = 2$ e $S = 4$	34
6.7	Configuração de agarramento para a abordagem 02: $J = 4$ e $S = 4$	35
6.8	Configuração de agarramento para a abordagem 02: $J = 6$ e $S = 3$	35
6.9	Configuração de agarramento para a abordagem 03: $J = 2$ e $S = 4$	36
6.10	Configuração de agarramento para a abordagem 03: $J = 4$ e $S = 4$	37
6.11	Configuração de agarramento para a abordagem 03: $J = 3$ e $S = 6$	37

Lista de Tabelas

6.1	Comparação dos Valores Reais e Estimados de S e J para Várias Configuração de Agarramento para a Abordagem 01.	33
6.2	Comparação dos Valores Reais e Estimados de S e J para Várias Configuração de Agarramento para a Abordagem 02.	35
6.3	Comparação dos Valores Reais e Estimados de S e J para Várias Configuração de Agarramento para a Abordagem 03.	38

Lista de Símbolos e Abreviaturas

AEM:	<i>Abnormal Event Management</i>
CLP:	Controladores Lógicos Programáveis
DSS:	<i>Decision Support System</i>
EPS:	<i>Enterprise Production Systems</i>
ERP:	<i>Enterprise Resource Planning</i>
FFT:	<i>Fast Fourier Transform</i>
MSE:	<i>Mean Square Error</i>
PCA:	<i>Principal Component Analysis</i>
RNA:	Redes Neurais Artificiais
SAD:	Sistema de Apoio à Decisão
SCADA:	<i>Supervisory Control and Data Acquisition</i>

Capítulo 1

Introdução

Segundo o dicionário Aurélio de língua portuguesa [Aurélio 1993], automação (do inglês *Automation*) é um sistema automático de controle pelo qual os mecanismos verificam seu próprio funcionamento, efetuando medições e introduzindo correções, sem a interferência do homem. O conceito de automação foi instituído nos Estados Unidos apenas em 1946, nas fábricas automotivas e, atualmente, o termo significa qualquer sistema que utilize máquinas e que substitua o trabalho humano com o intuito, por exemplo, de aumentar a velocidade e a qualidade dos processos produtivos, a segurança dos funcionários, além de obter maior controle, planejamento e flexibilidade da produção. A automação foi, sem dúvida, uma das grandes revoluções tecnológicas do século XX, pois possibilitou otimizar processos antes realizados pela força humana e desempenhar tarefas antes impossíveis para o homem.

Um sistema de automação pode ser melhor compreendido se o dividirmos em níveis, como ilustra a Figura 1.1.

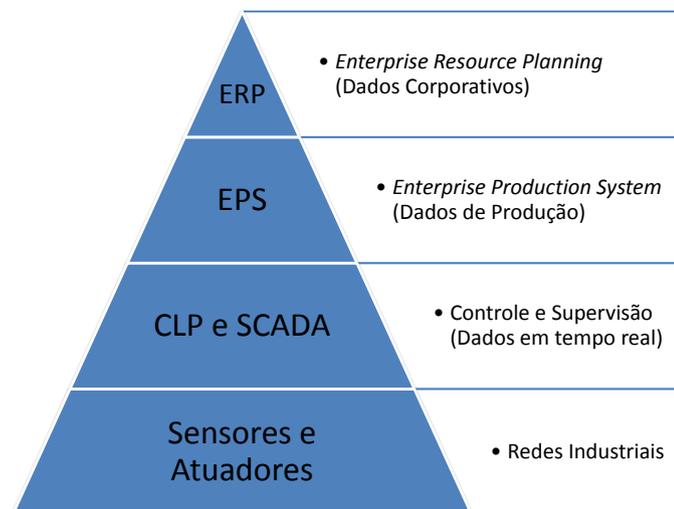


Figura 1.1: Pirâmide da Automação Industrial.

Na base da pirâmide encontra-se o nível de sensores e atuadores. Estes são responsáveis pela interação direta com o processo, fazendo a leitura das variáveis relevantes através dos sensores e interferindo no processo por intermédio dos atuadores. No ní-

vel imediatamente acima, encontram-se os controladores lógicos programáveis (CLP) e os SCADA (*Supervisory Control and Data Acquisition*), que são responsáveis por realizar o controle automatizado das atividades e a supervisão da planta, respectivamente. O terceiro nível, *Enterprise Production Systems* (EPS), é o responsável pela gerência de informação. Neste nível são armazenados dados referentes aos processos que podem ser utilizados como informação útil. No topo da pirâmide estão os sistemas responsáveis pela transformação desses dados em informação de negócio, *Enterprise Resource Planning* (ERP) [Leitão 2008].

A automação industrial vem experimentando grande desenvolvimento nos anos recentes, muito em função dos desenvolvimentos tecnológicos nas áreas de eletrônica digital e informática, resultando em um ambiente cada vez mais preciso, eficiente, confiável e seguro. Além disso, torna possível o monitoramento dos produtos desde a sua fase inicial de produção, no chão de fábrica, até o seu contato com o mercado, o que possibilita um maior controle de tudo o que acontece no processo de fabricação de produtos industrializáveis dos mais diferentes setores.

Mesmo com todo esse aparato tecnológico, motivos para continuar aumentando o grau de automação dos processos ainda sobram. Além da concorrência cada vez mais acirrada em diversos setores da indústria, existe ainda o contínuo aumento das restrições econômicas, ambientais e de segurança sobre a operação de processos industriais. Toda essa demanda crescente por eficiência, qualidade dos produtos, redução de custos e a integração dos vários sistemas de controle no setor industrial, aliado aos preços elevados envolvidos em seus processos e à inquestionável necessidade de segurança, justificam a importância da supervisão (ou monitoramento) e dos sistemas de detecção e diagnóstico de falhas envolvendo tais processos [Isermann 2005, Silva 2008].

Com o advento de equipamentos de campo cada vez mais inteligentes e baratos, uma grande variedade de dados proveniente desses equipamentos pôde ser disponibilizada em tempo real para os sistemas supervisórios ou mesmo para outras aplicações. Assim, o grande desafio atual da engenharia é transformar essa grande quantidade de dados em informação útil à tomada de decisão, de modo que venha a contribuir efetivamente na melhoria da operação e planejamento do processo como um todo.

A detecção e o diagnóstico prematuro de uma falha, enquanto o processo ainda está operando em uma região controlável, pode ajudar a evitar um comportamento inesperado do sistema, que em última análise poderia ocasionar perdas bastante consideráveis como: paralização de processos, danos a equipamentos de custo elevado e principalmente, acidentes envolvendo vidas humanas, etc. O que se traduz, entre outras coisas, em perdas financeiras que podem chegar a valores bastante elevados, dependendo do tamanho e do setor da indústria em questão.

1.1 Motivação

Uma falha em um processo industrial pode ocorrer devido a inúmeros fatores. De acordo com Jelali (2006), os fatores que comprometem o desempenho de malhas de controle são de maneira geral: erros de projeto, mau-funcionamento de sensores e atuadores, estrutura ou sintonia de controles e falta de manutenção.

No que se referem aos atuadores em um processo industrial, os mais encontrados nas malhas de controles das plantas industriais são as válvulas posicionadoras. Essas válvulas apresentam características não lineares (histerese, banda-morta, agarramento, entre outras) provocadas pelo atrito entre as partes móveis da válvula. Estas não linearidades podem causar efeitos indesejáveis, como erros estacionários e comportamento oscilatório. Muitos pesquisadores consideram o agarramento em válvulas de controle um dos fatores mais relevantes para problemas de desempenho em malhas de controle [Romano 2010].

A rigor, o funcionamento de qualquer válvula é afetado por atrito, por menor que seja tal influência. Quando o atrito é muito elevado, um procedimento imediato de manutenção pode ser necessário. Por outro lado, em situações menos severas, é possível usar compensadores (baseados em modelos) para diminuir a perda de desempenho da malha, até que uma parada seja programada. Portanto, algoritmos para quantificação de atrito podem gerar uma classificação de prioridade de manutenção, de acordo com a intensidade da não linearidade apresentada pela válvula [Choudhury et al. 2006].

Estudos mostram que cerca de 30% das malhas de controle encontradas na indústria oscilam devido a problemas relacionados às válvulas de controle [Garcia 2008]. Dentre os vários tipos de não linearidade presentes em válvulas posicionadoras, o agarramento é o tipo mais comum [Choudhury et al. 2008]. Sendo assim, desenvolver técnicas que possam detectar e diagnosticar esse problema é bastante importante para a indústria.

É diante dessa realidade que este trabalho vem a contribuir com o estudo e análise de técnicas de detecção de falhas em válvulas posicionadoras. Neste trabalho é apresentada uma proposta baseada em Redes Neurais Artificiais (RNA) para detectar e quantificar o agarramento em uma válvula.

1.2 Objetivos

Em linhas gerais, o objetivo desse trabalho é contribuir para a área de detecção e diagnóstico de falhas, através de uma estratégia baseada em RNA para detecção de agarramento em válvulas posicionadoras, utilizando apenas informações de variáveis de processo e ações de controle.

1.3 Divisão do trabalho

No Capítulo 2, encontra-se uma panorâmica da área de detecção de falhas, os principais conceitos e os tipos mais comuns de falhas encontradas em válvulas posicionadoras. No capítulo seguinte, encontra-se uma definição formal sobre agarramento em válvulas e é apresentado um modelo que simula esse tipo de falha. No Capítulo 4 é feito um levantamento bibliográfico das principais técnicas para diagnóstico de agarramento presentes na literatura. No Capítulo 5 é detalhada a proposta do trabalho para detecção e quantificação de agarramento em válvulas posicionadoras. No Capítulo 6 são mostrados os resultados obtidos, utilizando-se várias configurações de agarramento em uma planta simulada. E, finalmente, no Capítulo 7 encontram-se as conclusões do trabalho juntamente com algumas considerações para trabalhos futuros.

Capítulo 2

Detecção de Falhas

Em meados da década de 1970 [Isermann 2005], o grau de automação envolvido nos processos industriais aumentou drasticamente em consequência da disponibilidade dos microcomputadores, que eram capazes de resolver vários problemas da automação [Silva 2008]. Ações de controle ditas de baixo nível, como abrir e fechar válvulas, que antes eram realizadas por operadores humanos, são agora executadas de maneira automatizada.

No entanto, o dever de interpretar e realizar alguma ação quando a planta apresenta anormalidades ainda continua sendo uma tarefa bastante manual realizada pelo operador. Esta total confiança nas ações humanas para lidar com eventos anormais e de emergência tornou-se cada vez mais difícil devido ao tamanho e complexidade dos processos industriais modernos. Uma única unidade de processo de grande porte pode chegar a ter mais do que 1.500 variáveis do processo observadas a cada segundo [Bailey 1984]. Dessa maneira torna-se humanamente impossível analisar essa quantidade de dados em tão pouco espaço de tempo.

Além disso, a tarefa de diagnóstico de falha é dificultada pelo fato de que as medições de processo podem muitas vezes ser insuficientes, incompletas e/ou pouco confiáveis devido a uma variedade de causas, tais como má calibração ou falha nos sensores.

Dadas essas condições adversas, não é nenhuma surpresa que os operadores humanos tendem a tomar decisões erradas e realizar ações que tornam as coisas ainda piores. Estatísticas industriais mostram que cerca de 70% dos acidentes de trabalho são causados por erros humanos. Estes eventos anormais têm impacto significativo na segurança, na economia e no meio ambiente [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003].

Visando auxiliar o operador a detectar e diagnosticar falhas nos processos industriais, a área de Gerenciamento de Eventos Anormais, ou do inglês *Abnormal Event Management* (AEM), vem chamando bastante atenção nos últimos tempos. O desafio atual é a automatização da AEM utilizando sistemas de controle inteligentes, proporcionando assim auxílio aos operadores nas situações de emergência. Profissionais das indústrias de processo veem isso como o próximo grande marco na pesquisa de sistemas de controle e aplicação [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003].

O diagnóstico prematuro de uma falha enquanto o processo opera em uma região controlável, pode ajudar a evitar um comportamento inesperado do sistema, o que causaria perdas de produtividade, além de colocar em risco vidas humanas.

2.1 Características de um Sistema de Detecção de Falhas

Para que um Sistema de Detecção e Diagnóstico de Falhas possa cumprir com o que ele foi desenvolvido para fazer, é importante que ele possua algumas características principais [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003]:

- Detecção e Diagnóstico rápido: O sistema de detecção de falha deve detectar e diagnosticar uma falha de forma rápida. Conseguir obter uma resposta rápida e precisa em tempo real são dois fatores importantes para a confiabilidade do sistema.
- Robustez: O diagnóstico do sistema deve ser confiável mesmo na presença de ruído ou de incertezas. Seu desempenho deve decair de maneira suave ao invés de ter uma queda abrupta de confiabilidade.
- Adaptabilidade: O sistema de diagnóstico deve ser capaz de se adaptar a mudanças não apenas de perturbações externas, como também se adaptar a mudanças nas condições de operação no processo, tais como alteração na qualidade da matéria prima utilizada ou na quantidade de produto produzido.
- Facilidade de explicação: Além de ser capaz de identificar a causa da falha, o sistema de diagnóstico deve também explicar como o problema se originou e se propagou até a situação atual.
- Armazenamento e esforço computacional: Normalmente, soluções rápidas em tempo real requerem algoritmos com uma complexidade computacional baixa, mas isso requer um armazenamento em memória excessivo de informações. Para que o sistema de diagnóstico seja eficiente, é necessário ponderar essas duas características.

2.2 Etapas do Processo de Detecção de Falhas

Para entender melhor como um sistema de detecção e diagnóstico de falhas funciona, é importante identificar as várias transformações que são realizadas durante o processo antes que o diagnóstico final seja feito [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003]. A Figura 2.1 mostra as várias etapas de processamento da informação para que o diagnóstico final seja realizado.

A primeira etapa de um sistema de diagnóstico de falhas é chamado de Espaço de Medição. É nessa etapa onde são obtidos os valores das variáveis de processo que serão analisadas para gerar o diagnóstico final. Nenhum conhecimento *a priori* do processo é necessário nesta etapa.

O Espaço de Características é onde os valores medidos são analisados e combinados com o auxílio de algum conhecimento *a priori* para que sejam extraídas informações úteis sobre a dinâmica do processo, para auxiliar no diagnóstico.

A etapa seguinte é chamada de Espaço de Decisão. Nesta etapa é formado um conjunto de pontos $d = [d_1, \dots, d_k]$ onde k é a quantidade de variáveis de decisão, obtidas através de transformações do espaço de características. O mapeamento do Espaço de Características para o Espaço de Decisão geralmente é designado para atender alguma função objetivo (como minimizar o erro de classificação) [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003].

Por fim, temos o Espaço de Classes que é a etapa final de um Sistema de Diagnóstico. Esta última etapa é representada por um conjunto de características $c = [c_1, \dots, c_M]$, onde cada elemento c_i representa diferentes falhas que o sistema pode diagnosticar.

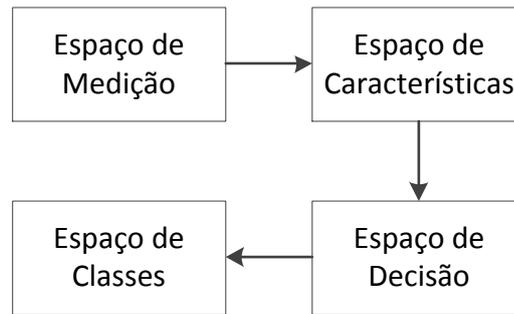


Figura 2.1: Etapas do processo de detecção e diagnóstico de falhas.

Fazendo um comparativo com Redes Neurais, os nós de entrada da rede representam o Espaço de Medição. Os neurônios ocultos correspondem ao Espaço de Características. Os neurônios de saída da rede mapeiam o Espaço de Característica para o Espaço de Decisão. Por fim, a interpretação da saída da Rede Neural nos dá o Espaço de Classes.

2.3 Classificação dos Métodos de Detecção de Falhas

Devido à abrangência do problema de diagnóstico de falha em processo e às dificuldades na sua solução em tempo real, várias abordagens computacionais foram desenvolvidos ao longo dos anos. Elas cobrem uma ampla variedade de técnicas, como as primeiras tentativas usando árvores de falhas e grafos, abordagens analíticas e sistemas baseados em conhecimento e redes neurais em estudos mais recentes [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003].

Há diversas técnicas já utilizadas na construção de ferramentas com o objetivo de detectar falhas em processos industriais. Vale destacar que cada autor tem a sua visão particular de como categorizar essas técnicas. Em especial, podemos destacar a classificação feita por Venkatasubramanian, Rengaswamy, Yin & Kavuri (2003) e por Isermann (2005).

No trabalho desenvolvido por Venkatasubramanian, Rengaswamy, Yin & Kavuri (2003), os métodos de diagnóstico de falhas são classificados em três categorias gerais. Eles são métodos quantitativos baseados em modelos, métodos qualitativos baseados em modelos e métodos baseados em histórico. Os diferentes tipos de classificação podem ser visualizados na Figura 2.2.

Os métodos baseados em modelo são desenvolvidos a partir do conhecimento físico do processo analisado. Nos modelos quantitativos, esse conhecimento é expresso em

termos de funções matemáticas que descrevem a relação entre as entradas e as saídas do processo. Já nos modelos qualitativos, as equações são expressas em termos de funções qualitativas de diferentes unidades de um processo [Venkatasubramanian, Rengaswamy & Kavuri 2003].

Ao contrário dos métodos baseados em modelo que necessitam do conhecimento *a priori* do modelo físico do processo, os modelos baseados em histórico fazem uso apenas de dados passados das variáveis do processo [Venkatasubramanian, Rengaswamy, Kavuri & Yin 2003].

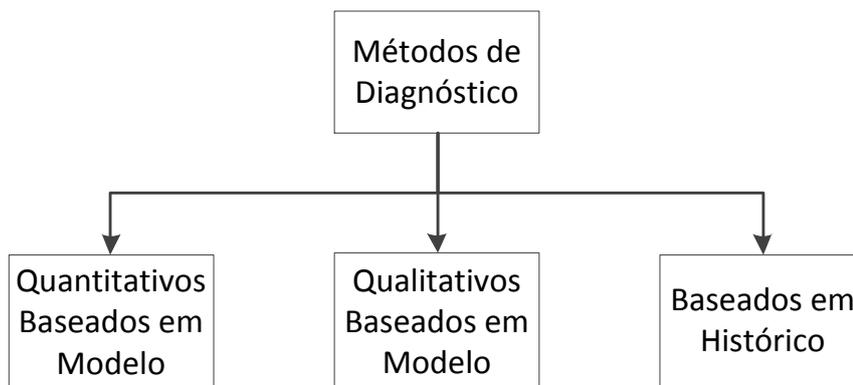
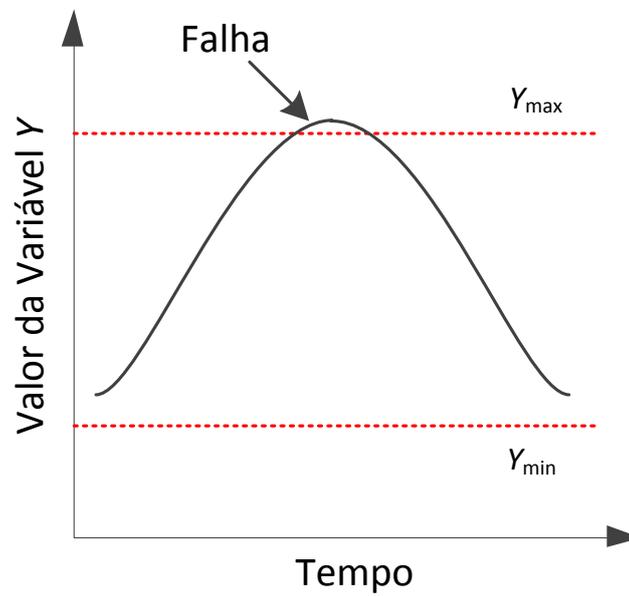


Figura 2.2: Classificação dos algoritmos de diagnóstico.

Já para Isermann (2005), os métodos de detecção de falhas são classificados em diversos tipos, sendo as principais abordagens: verificação de limites, equações de paridade, detecção de falhas com métodos de identificação de processos, através da análise da assinatura de sinais.

Um dos métodos mais simples e frequentemente usados para detecção de falhas é a verificação do limite de uma variável $Y(t)$. No caso, as variáveis de um processo são monitoradas e comparadas aos valores limites, também chamados de *thresholds*. Geralmente, dois valores são escolhidos para serem os *thresholds* máximo Y_{max} e o mínimo Y_{min} , respectivamente. Exceder um dos *thresholds* indica a presença de alguma falha no sistema. A Figura 2.3 ilustra a monitoração de uma variável hipotética $Y(t)$ e seus respectivos limites inferior e superior.

A detecção de falhas com equações de paridade é uma maneira direta de detectar falhas em processo. Nesse caso, a comparação dos sinais de saída do processo real com os sinais de saída das equações do mesmo fornecem os chamados resíduos. Os resíduos são sinais gerados a partir da comparação entre valores mensuráveis do processo real e valores estimados pelos modelos ou equações quando os mesmos estão sujeitos à mesma entrada. São esses resíduos que serão analisados para a decisão sobre falhas ou não. Esta abordagem tem a capacidade de indicar anormalidades no processo através das discrepâncias entre o sinal de saída do processo e das equações. A Figura 2.4 ilustra em esquema

Figura 2.3: *Thresholds* do sinal $Y(t)$.

de blocos essa abordagem, onde a variável θ representa os resíduos, u representa a entrada do processo, y é a saída real do sistema e \hat{y} é a saída estimada.

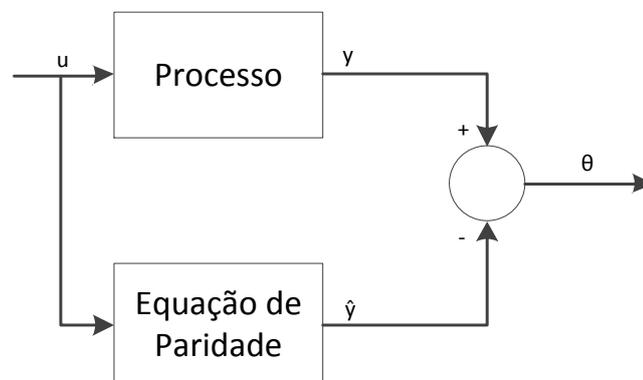


Figura 2.4: Representação do método de detecção de falhas por equações de paridade.

Os métodos de detecção de falhas através de análise da assinatura de sinais são atraivos quando as medições dos processos são altamente correlacionadas e apenas alguns eventos produzem dados não usuais, ou descorrelacionados. Os modelos PCA (*Principal Component Analysis*) são basicamente lineares e estáticos e são desenvolvidos a partir do funcionamento normal do processo. Existem ainda outras técnicas amplamente utilizadas para análise de sinais como Transformadas Wavelets ou FFT (*Fast Fourier Transform*). Assim como PCA, essas não necessitam do modelo matemático do sistema para a detecção de falhas. Essas ferramentas matemáticas são utilizadas para fazer uma transformação em um sinal, tornando-o mais apropriado para a tomada de decisão sobre a existência ou não de uma falha.

Outra possível maneira de detecção de falhas é através da Identificação de Sistemas. No caso, um modelo matemático de um processo descreve a relação entre as entradas $u(t)$ e as saídas $y(t)$. Tais modelos são fundamentais para essa modalidade de detecção de falhas, dado que elas servirão, neste caso, como referência do processo industrial quando o mesmo está em situação normal de funcionamento.

Vale lembrar que, na maioria das vezes, os modelos utilizados com essa abordagem são do tipo caixa preta, ou seja, seus parâmetros não têm nenhum significado físico, isto é, nenhuma relação direta com o modelo fenomenológico do processo em questão.

Observando-se a Figura 2.5, pode-se perceber que o módulo rotulado *classificador* recebe resíduos, representados por θ , que são gerados a partir das saídas do processo real e do Modelo Identificado. Estes são a base para a identificação da falha. Por fim, a saída do classificador indica qual falha ocorreu. Neste caso, elas estão representadas por F1, F2 e F3. Aqui, a etapa de classificação envolve as fases de isolamento e identificação das falhas.

2.4 Tipos de Falhas mais Comuns

Falhas em processos industriais podem ocorrer devido a inúmeros fatores, porém podemos classificar o tipo de falha de acordo com a sua localização. As falhas podem se encontrar no atuador, no sistema dinâmico (processo) ou no sensor, como pode ser visualizado na Figura 2.6 [Venkatasubramanian, Rengaswamy, Yin & Kavuri 2003, Silva 2008].

- Falhas em atuadores: podem ser vistas como qualquer mau funcionamento do equipamento que atua no sistema.
- Falhas no sistema dinâmico: ocorrem quando alguma alteração no sistema muda de alguma forma a relação original de entrada e saída do mesmo. Como por exemplo, um vazamento em um tanque.
- Falhas em sensores: podem ser observadas através de variações específicas nas medidas que possibilitem desconsiderá-las como variações válidas do sistema.

Os atuadores mais encontrados nas malhas de controle dos processos industriais são as válvulas posicionadoras, que apresentam características não lineares (histerese, banda morta, entre outras) provocadas pelo atrito entre as partes móveis da válvula. Este atrito pode causar efeitos indesejáveis como erros estacionários e comportamento oscilatório.

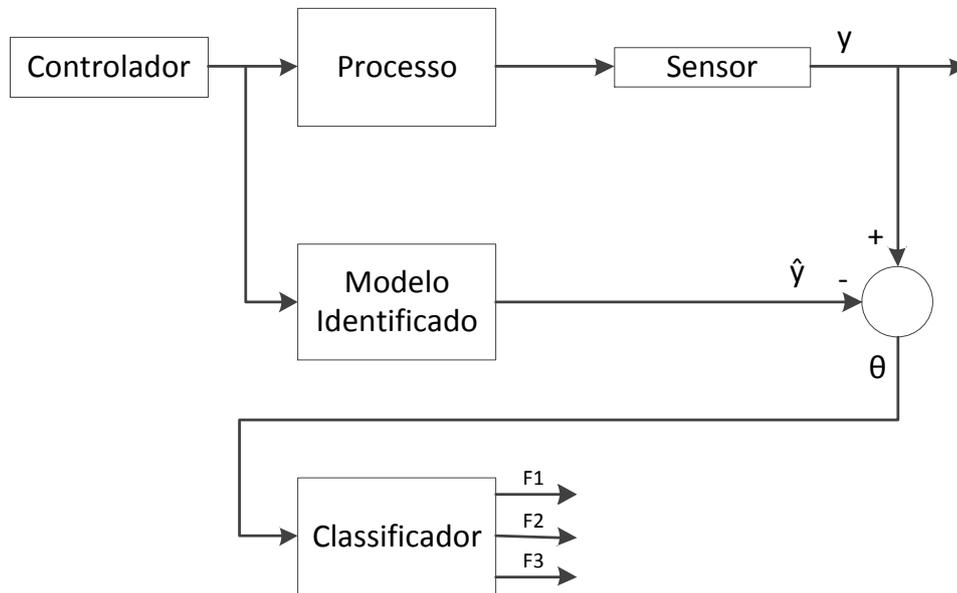


Figura 2.5: Esquema de blocos representando o método de detecção e classificação de falhas através de identificação de sistemas.



Figura 2.6: Classificação de falhas quanto a localização.

Muitos pesquisadores consideram o atrito em válvulas de controle um dos fatores mais relevantes para problemas de desempenho em malhas de controle. Em estudos realizados [Bialkowski 1992], foi mostrado que uma grande quantidade das malhas oscilavam devido a problemas relacionados às válvulas de controle [Romano 2010] e observou-se também que o Agarramento era o tipo de não linearidade mais comum [Choudhury et al. 2008].

A rigor, o funcionamento de qualquer válvula é afetado pelas forças de atrito existentes em suas partes móveis, por menor que seja tal influência. Quando o atrito é muito elevado, um procedimento imediato de manutenção pode ser necessário. Por outro lado, em situações menos severas é possível usar compensadores específicos para diminuir a perda de desempenho da malha, até que seja programada uma parada. Portanto, algoritmos para quantificação de atrito podem gerar uma classificação de prioridade de manutenção, de acordo com a intensidade da não linearidade da válvula. Por esse fato, segundo Desbo-

rough & Miller (2002), um método não invasivo, capaz de quantificar o agarramento em válvulas de controle operando em malha fechada é altamente necessário na indústria de processos [Romano 2010].

Antes de ser apresentado qualquer método para detecção de agarramento em válvulas, é necessário primeiro compreender melhor esse tipo de falha tão comumente encontrada nos processos industriais. No capítulo seguinte, será apresentada uma definição mais formal sobre agarramento em válvulas posicionadoras e também será mostrado um modelo empírico para simular esse comportamento não linear da válvula.

Capítulo 3

Agarramento em Válvulas Posicionadoras

Há diversos tipos de não linearidades que podem ser encontradas em válvulas posicionadoras. Dentre os tipos mais comuns podemos destacar a histerese, banda morta e o agarramento.

Folga ou histerese (do inglês *backlash*), é o movimento relativo entre as partes mecânicas nos instrumentos do processo, resultante da folga existente quando é feita uma mudança na direção de movimento das peças. A histerese é um fenômeno que existe em todas as válvulas de controle. Ela se caracteriza pela ocorrência da diferenciação do ganho da malha de controle quando a válvula de controle é submetida a perturbações de intensidades iguais, porém em direções opostas.

Quanto maior a histerese de uma válvula de controle, pior o desempenho da mesma. Pelo fato de introduzir não linearidades ao processo, a histerese afeta a eficácia da resposta da ação do controlador, dificultando o controle da malha.

Já a banda morta é a faixa onde o sinal de entrada varia, porém nenhuma variação no sinal de saída é observada. A Figura 3.1a e a Figura 3.1b mostram o diagrama de fase (Entrada x Saída) comumente encontrado em uma válvula que apresenta histerese e banda morta, respectivamente.

Dentre os vários tipos de não linearidade presentes em válvulas posicionadoras, o agarramento é o tipo mais comum (Choudhury et al., 2008). Não existe na literatura uma definição formal para agarramento em válvulas posicionadoras [Choudhury et al. 2005]. Porém, inúmeras definições propostas por diferentes autores concordam que o agarramento é provocado pelo alto atrito estático presente nas partes mecânicas da válvula, o que as impede de se movimentarem corretamente. Como a válvula encontra-se emperada, a ação integrativa do controlador aumenta o valor do sinal de controle até que o atrito seja superado. Quando isso ocorre, a válvula volta a se mover.

Podemos observar que o diagrama de fase (Saída do controlador - Posição da válvula) de uma válvula "sofrendo de agarramento" consiste de quatro componentes principais: banda morta, *stickband*, *slip jump* e fase de movimento. Essas quatro componentes podem ser observadas na Figura 3.2.

As componentes de banda morta e *stickband* representam a faixa onde o sinal de controle varia sem que seja observada alguma variação na posição da válvula, ou seja, a força de atrito estático não foi superada e a válvula encontra-se parada.

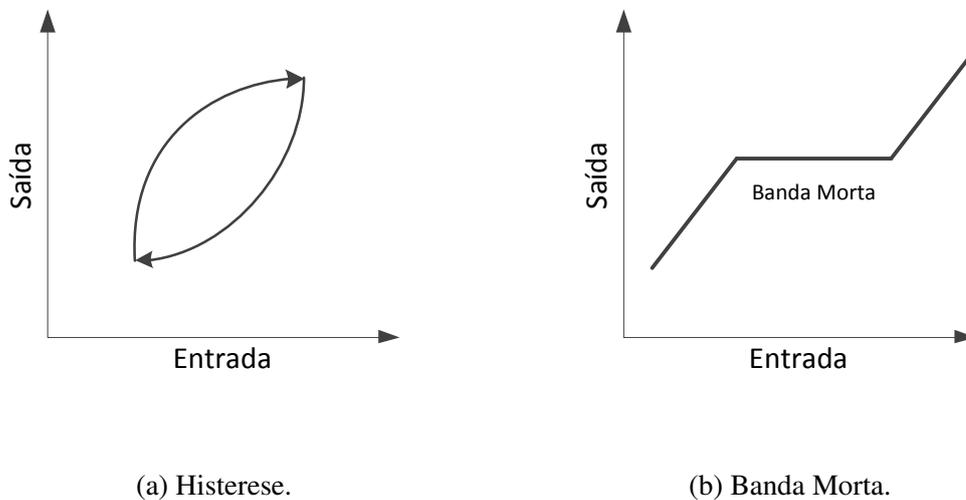


Figura 3.1: Falhas em válvulas posicionadoras

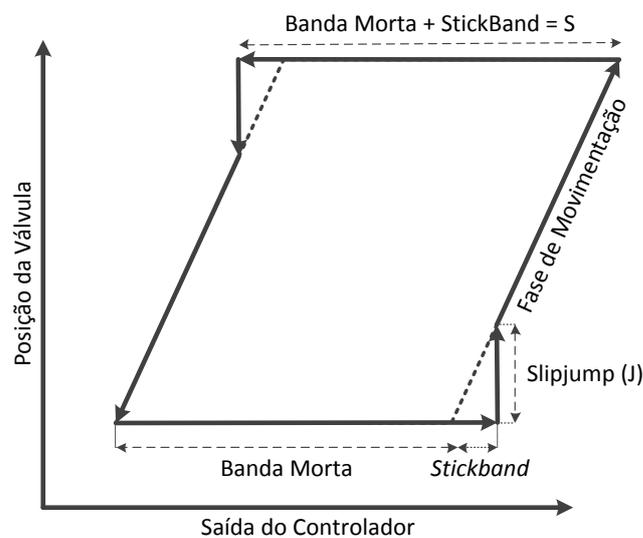


Figura 3.2: Diagrama de fase de uma válvula com agarramento.

Imediatamente após o atrito estático ser superado pelo sinal de controle, ocorre um movimento abrupto da válvula. Esse deslocamento repentino é representado pelo *slip jump*.

Após superar a força de atrito estático, tem-se início a fase de movimento da válvula. O movimento continua até que sua velocidade chegue próximo de zero ou ela mude de direção, fazendo com que a válvula emperre novamente.

3.1 Modelagem de agarramento em válvulas posicionadoras

Encontrar o modelo matemático fenomenológico que reproduz o comportamento de uma válvula pode não ser uma tarefa fácil, uma vez que é necessário o conhecimento de inúmeros parâmetros como, por exemplo, a massa das partes móveis do atuador, a constante elástica e todas as forças de atrito envolvidas no processo [Kayihan & III 2000]. Todas essas informações são difíceis de serem obtidas, além de que o efeito da mudança desses parâmetros não é determinado de maneira direta pelo modelo, tornando seu estudo matemático bastante complexo [Choudhury et al. 2005].

Com isso, o modelo proposto por Choudhury et al. (2005) tem como objetivo superar todas essas limitações do modelo fenomenológico de uma válvula posicionadora. Ele é um modelo empírico composto apenas de dois parâmetros, o parâmetro S que representa o tamanho da componente de banda morta junto com a componente stickband, e o parâmetro J que representa o tamanho da componente *slip jump*.

A Figura 3.3 mostra o diagrama de blocos da arquitetura do modelo proposto, onde o modelo não linear do agarramento de válvula está compreendido entre a saída do controlador e a entrada do processo analisado.

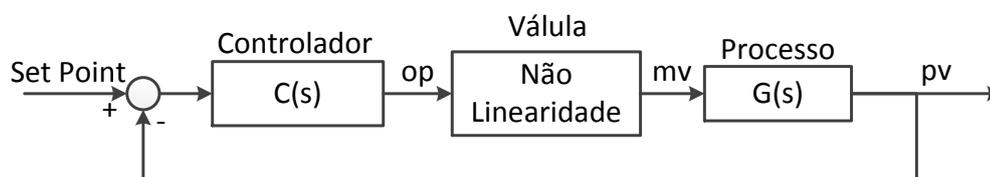


Figura 3.3: Modelo proposto.

No algoritmo proposto por Choudhury, inicialmente é realizada uma saturação no sinal de controle. Se o controlador estiver enviando um sinal inferior a 0% o sinal é saturado em 0% ou se o sinal for maior que 100% a saturação ocorre em 100%. Caso o sinal de controle esteja compreendido na faixa de 0-100% o algoritmo calcula a nova posição da válvula.

A válvula é considerada emperrada quando ela muda de direção ou quando sua velocidade chega a zero ($\Delta u(k) = 0$). O valor do sinal de controle quando a válvula emperra é mantido em memória (u_s) e não se altera até que a mesma emperre novamente. Esse valor mantido em memória é utilizado para calcular o acumulado do sinal de controle após o agarramento e saber se o atrito estático foi superado ou não.

A volta do movimento da válvula depende de como ela tenha emperrado. No caso onde a válvula emperrou devido à mudança em sua direção, se o sinal de controle acumulado for superior ao valor do parâmetro S ($|u(k) - u_s| > S$), então a válvula rompe o atrito estático e inicia sua fase de movimento. Caso a válvula tenha emperrado por estar em re-

posso (velocidade igual a zero) a mesma só romperá o atrito estático e começará a fase de movimento se o sinal de controle acumulado for superior ao parâmetro J ($|u(k) - u_s| > J$).

Em ambos os casos onde a válvula consegue superar o atrito estático, sua nova posição é calculada de acordo com a equação 3.1.

$$mv(k) = op(k) - \frac{dir * (S - J)}{2} \quad (3.1)$$

Além dos parâmetros S e J , o modelo possui três variáveis auxiliares: a variável I que assume valores booleanos *true* ou *false* para indicar se a válvula emperrou por estar em repouso; us que armazena o valor do sinal de controle no exato momento em que a válvula emperra e $dir = \pm 1$ que é usado para denotar o sentido da força de atrito.

A Figura 3.4 resume o algoritmo do modelo proposto por Choudhury. Na realidade, esse modelo não é baseado na dinâmica da válvula. Porém sua grande vantagem é que ele é muito fácil de ser usado para simular agarramento. Além de que seus parâmetros são simples de serem entendidos e relacionados ao comportamento de um agarramento real.

3.1. MODELAGEM DE AGARRAMENTO EM VÁLVULAS POSICIONADORAS 17

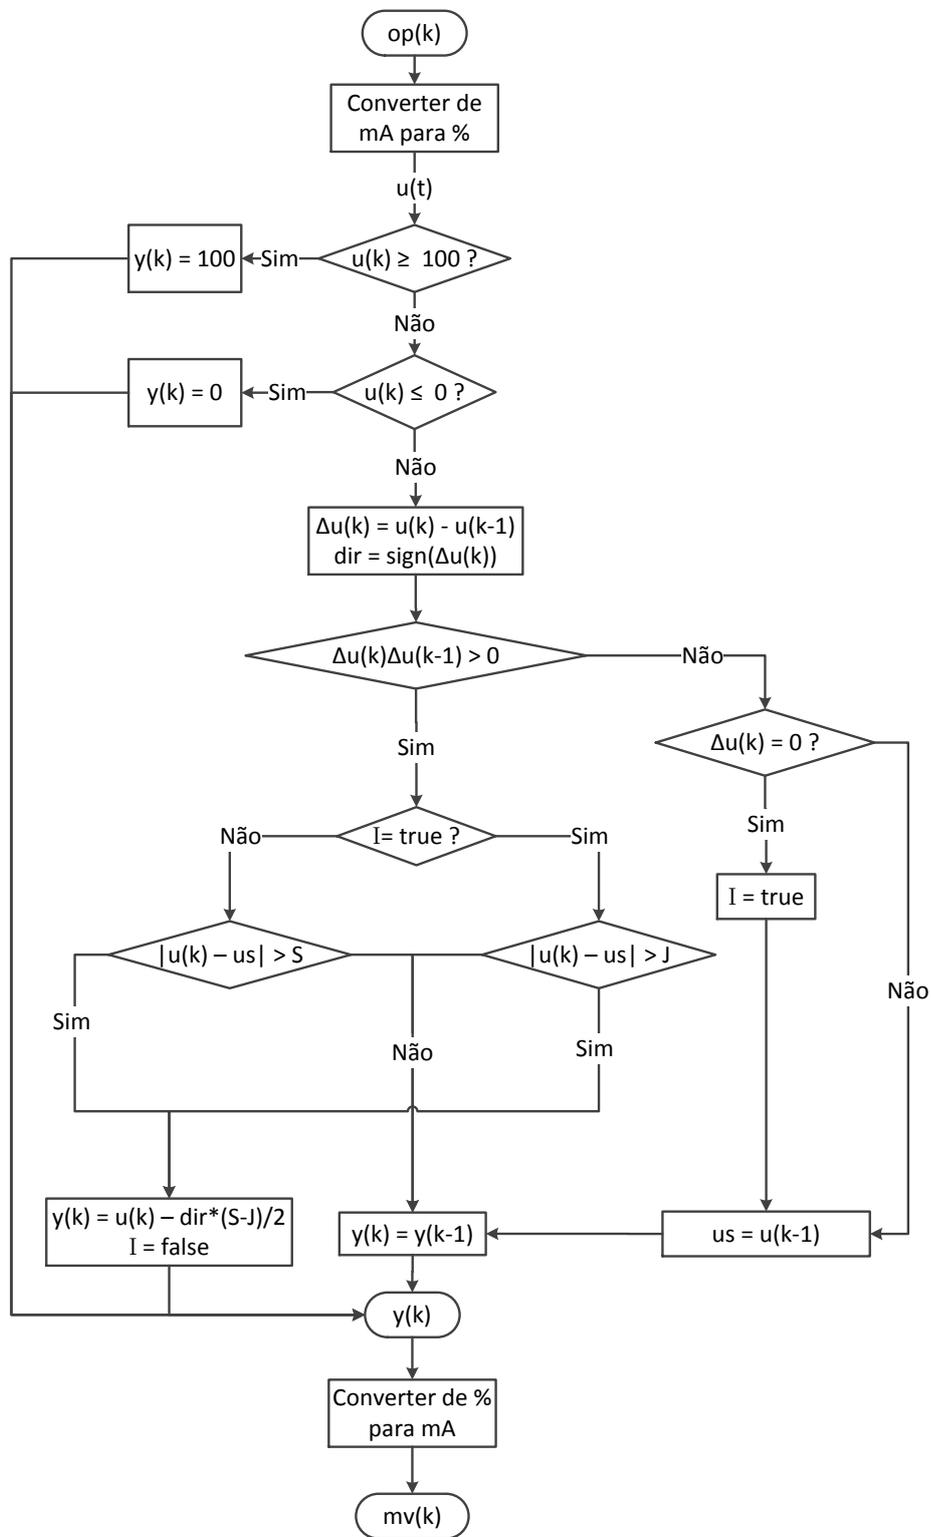


Figura 3.4: Algoritmo de modelagem de agarramento.

Capítulo 4

Estado da Arte

Na literatura é possível encontrar diversos métodos para detectar agarramento em malhas de controle utilizando apenas informações sobre a saída do processo (pv) e a saída do controlador (op).

Um dos primeiros trabalhos desenvolvidos para detectar agarramento em válvulas posicionadoras foi o trabalho de Horch (1999). A ideia central desse trabalho é realizar uma correlação entre os sinais op e pv , com essa informação é possível verificar a defasagem desses dois sinais e a partir daí identificar a presença ou ausência de agarramento na válvula. É importante destacar que essa técnica não é capaz de quantificar o atrito na válvula.

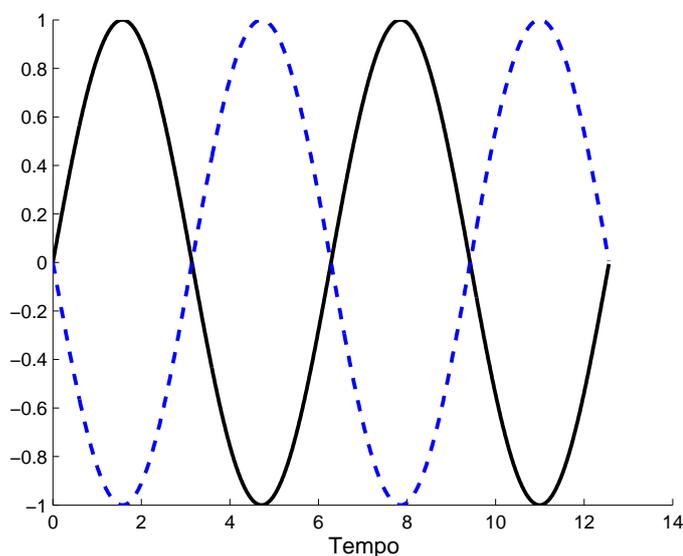


Figura 4.1: Defasagem dos Sinais.

Depois de algum tempo apareceram técnicas capazes não só identificar mas também quantificar o atrito em uma válvula. Um dos primeiros trabalhos publicados nessa área foi desenvolvido por Choudhury et al. (2006). Nesse trabalho é feita uma análise no comportamento elipsoidal do diagrama de fase $PV \times OP$. O método proposto quantifica o grau de agarramento de acordo com o tamanho do raio da elipse encontrada, fazendo uso

de técnicas de agrupamento, como por exemplo, o algoritmo *C-means*.

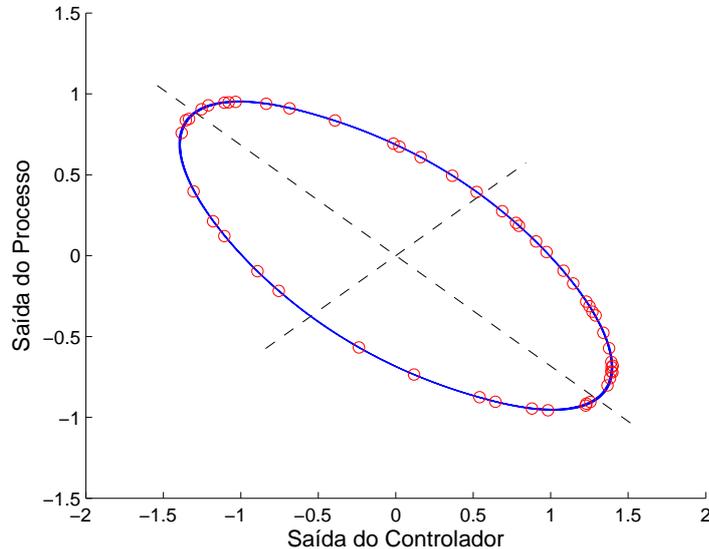


Figura 4.2: Elipse.

Mais tarde, Choudhury propôs uma nova técnica para quantificar o grau de agarramento em uma válvula, estimando os parâmetros S e J [Choudhury et al. 2008]. Esta abordagem baseia-se em busca em uma grade formada com os valores de S e J . Para cada ponto dessa grade a saída do modelo da válvula é computada para que seja feita uma identificação do sistema e em seguida o erro médio quadrático (do inglês *Mean Square Error* - MSE) é calculado. A configuração com o menor erro é utilizada para estimar o grau de agarramento.

Outros autores também se destacam nessa área. Como exemplo temos o trabalho de Jelali (2008). Esse trabalho descreve uma técnica baseada em mínimos quadrados (MSE) e em busca global. A técnica pode ser dividida em duas etapas: primeiro o modelo não linear (agarramento) é identificado e em seguida, baseado no MSE, os parâmetros S e J são calculados. Devido ao grande número de mínimos locais na minimização do erro, é necessária a utilização de um algoritmo estocástico, neste caso foi utilizado algoritmo genético para otimizar a função objetivo.

Todas essas técnicas estão bem difundidas na literatura, porém uma das principais desvantagem nessas abordagens é o tempo computacional necessário para se obter uma estimativa do agarramento. Algumas técnicas podem exigir até 20 minutos para obter o resultado final [Farenzena & Trierweiler 2012]. Isso inviabiliza sua utilização em aplicação em tempo real, onde o algoritmo deve obter respostas dentro de alguns segundos.

Nos capítulos seguintes será apresentada uma abordagem baseada em Redes Neurais Artificiais para quantificar agarramento em válvula posicionadoras. Essa abordagem pode ser utilizada tanto para o diagnóstico *off-line* quanto *online*.

Capítulo 5

Proposta

Os atuadores mais comumente encontrados nas malhas de controles dos processos industriais são as válvulas posicionadoras. Por serem equipamentos mecânicos, eles sofrem muita influência das forças de atrito presentes em suas partes móveis. Essas forças indesejadas adicionam uma componente não linear em sua resposta, podendo fazer com que a saída do processo torne-se oscilatória [Choudhury et al. 2005, Choudhury et al. 2008]. Sendo assim, desenvolver técnicas que possam detectar e diagnosticar não linearidades, mais especificamente, agarramento nas válvulas de controle são bastante importantes para a indústria.

Caso seja possível obter a informação da posição da válvula (como é o caso das *smart valves*), o diagrama de fase *op-mv* apresentará uma assinatura parecida com a observada na Figura 3.2, caso a válvula esteja sofrendo agarramento. No entanto, muitas vezes não é possível obter a saída da válvula, ou mesmo com precisão temporal adequada. Portanto, o desafio é conseguir detectar agarramento conhecendo apenas os sinais de saída do processo e o sinal de controle.

O problema de analisar o diagrama de fase formado pelo sinal de controle e pela saída do processo (*op-pv*) é que as componentes de banda morta, *stick band* e *slip jump*, não podem ser claramente identificadas, pois a dinâmica do processo encobre o padrão da assinatura [Jelali 2008].

Tomando como exemplo um processo industrial genérico, cuja função de transferência seja dada pela equação 5.1 e controlado em malha fechada por um Controlador descrito pela equação 5.2.

$$G(s) = \frac{1}{s} \quad (5.1)$$

$$C(s) = \frac{0.4(2s + 1)}{2s} \quad (5.2)$$

Utilizando-se o modelo de agarramento proposto por Choudhury, mostrado no Capítulo 3, para simular a falha nessa malha de controle, com os parâmetros $S = 2$ e $J = 1$, obtemos os diagramas de fase mostrados nas figuras 5.1a e 5.1b:

Comparando-se a Figura 5.1b com a Figura 3.2, percebe-se a presença tanto da componente de banda morta quanto a *slip jump*. Ou seja, é evidente que a válvula do processo analisado apresenta não linearidade. Porém, analisando-se o diagrama de fase formado

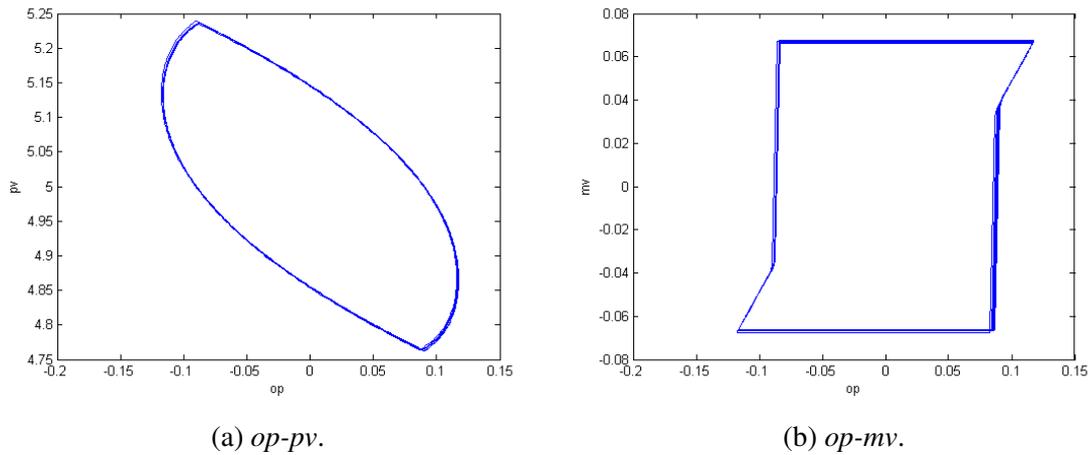


Figura 5.1: Diagrama de fase.

pelo sinal do controlador e a saída do processo ($pv - op$), observado na Figura 5.1a, as componentes de banda morta e *slip jump* deixam de ser evidentes. Mesmo assim, a figura formada pelo diagrama possui um padrão de assinatura que pode ser utilizado para detectar a falha.

Como mostrado no capítulo anterior (4), existem diversas técnicas na literatura que permite diagnosticar agarramento. O objetivo do trabalho em questão é propor uma técnica online para quantificar o grau de agarramento em válvulas posicionadoras, desconhecendo a posição das mesmas.

O modelo proposto se baseia na estimação dos parâmetros S e J do modelo de agarramento mostrado no Capítulo 3, utilizando-se uma Rede Neural Artificial. A RNA utilizada foi uma rede Perceptron de Múltiplas Camadas, treinada com o algoritmo Levenberg-Marquardt [Haykin & Engel 2001].

Foram desenvolvidas três abordagens diferentes para o treinamento da rede neural. A seguir serão descritas cada uma dessas abordagens e no capítulo seguinte será feita uma comparação dos resultados obtidos.

5.1 Abordagem 01 - Centroide

Uma possível abordagem para a geração do conjunto de entrada da RNA seria obter N pontos do sinal de controle e N pontos da saída do processo e utilizar todos esses valores para treinar a rede. Uma desvantagem de se utilizar esse método é que seria necessário 2N pontos na camada de entrada da rede. Isso pode tornar o processo de treinamento demorado, além de consumir bastante memória.

Visando diminuir o tamanho do conjunto de entradas, foi utilizado o conceito de centroide. Como após a obtenção dos N pontos do sinal de controle e N pontos da saída do processo, é possível traçar o diagrama de fase. Assim, o centroide nada mais é do que o ponto médio da figura gerada com o diagrama.

O centroide é representado por um par ordenado, (x_c, y_c) , cuja suas coordenadas são obtidas

através da média das coordenadas de todos os pontos [Lima et al. 2011], onde o eixo x é representado pelos valores de op e o eixo y são os valores de pv . As equações 5.3 e 5.4 mostram o seu cálculo, onde N é a quantidade de pontos analisados. A Figura 5.2 mostra o centroide do diagrama apresentado na Figura 5.1a.

$$x_c = \frac{1}{N} \sum_{i=1}^N x_i \quad (5.3)$$

$$y_c = \frac{1}{N} \sum_{i=1}^N y_i \quad (5.4)$$

Conhecendo o centroide da figura gerada pelo diagrama de fase, é possível calcular a distância de cada ponto ao centroide utilizando a equação 5.5.

$$D_i = \sqrt{(x_i - x_c)^2 + (y_i - y_c)^2} \quad (5.5)$$

A distância de cada ponto ao centroide é então utilizada como conjunto de entrada da rede neural. Com a utilização desse conjunto de treinamento são necessários N pontos na camada de entrada, ao invés de $2N$ como acontecia na abordagem inicial.

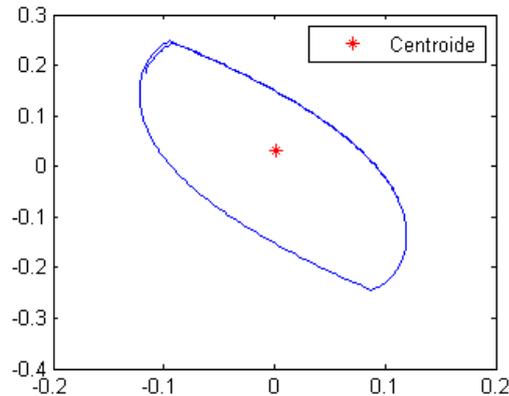


Figura 5.2: centroide.

Uma representação em diagrama de blocos da proposta pode ser visualizada na Figura 5.3. Nesse diagrama, o bloco de pré-processamento recebe como entrada os valores de op e pv e calcula a distância (D) dos pontos ao centroide dos dados. O vetor D é então fornecido para a rede neural, que por sua vez estima os parâmetros S' e J' do modelo não linear de agarramento em válvulas.

Como a rede neural estima os parâmetros S e J , é possível a partir desses valores estimados diagnosticar agarramento em uma válvula posicionadora. Caso os valores estimados sejam todos nulos, quer dizer que a válvula está funcionando de maneira ideal, porém se algum valor diferente de zero for encontrado para S ou J indica que foi identificado agarramento na válvula.

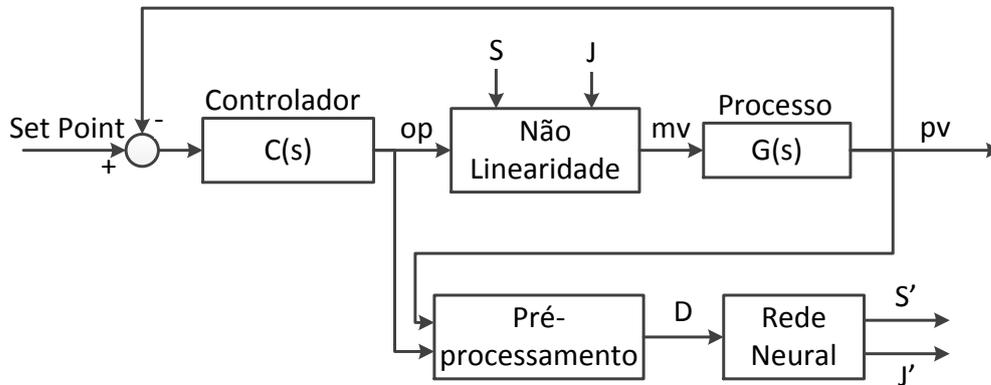


Figura 5.3: Diagrama de blocos da proposta.

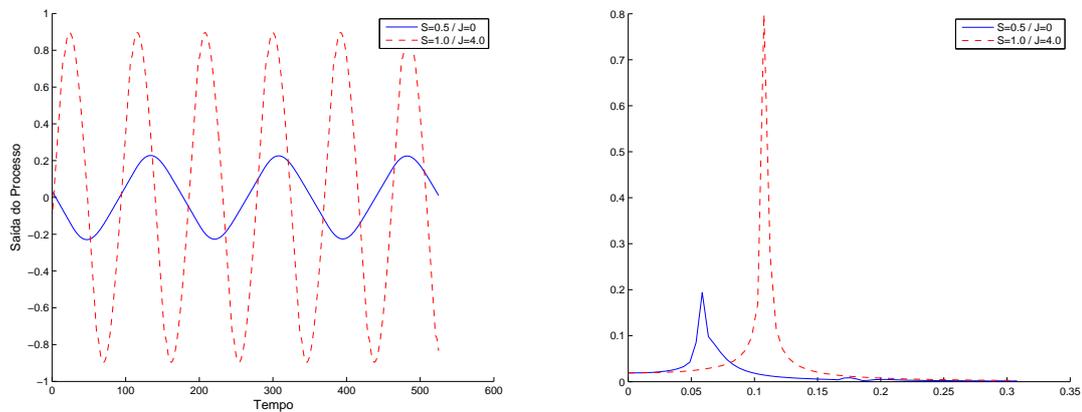
5.2 Abordagem 02 - Análise Espectral

Diferente da primeira abordagem que utiliza tanto a saída do controlador quanto a saída do processo, a abordagem em questão necessita apenas das informações da pv . Como exposto no começo desse capítulo, apenas a informação da saída do processo não é suficiente para quantificar o grau de agarramento de uma válvula em uma malha de controle. No entanto, ao analisar esse sinal percebe-se que diferentes níveis de agarramento causam diferentes oscilações na saída da malha de controle. Tomando como exemplo a situação mostrada na Figura 5.4a, onde o processo descrito pela equação 5.1 foi submetido a duas configurações de agarramento diferentes, observa-se que a frequência de oscilação na saída do processo variou em cada situação. Não apenas a frequência foi diferente, a amplitude do sinal também variou.

Sendo assim, realizar uma análise espectral da saída do processo pode ser utilizada para a detecção e diagnóstico de agarramento em válvulas. A Figura 5.4b mostra a Transformada de Fourier dos sinais da Figura 5.4a. Isso deixa ainda mais evidente que as duas situações oscilaram com frequências e amplitudes diferentes e essas informações poderiam ser utilizadas para quantificar o grau de agarramento.

Para formação do conjunto de treinamento da Rede Neural é utilizada apenas a saída do processo (pv). O sinal pv foi amostrados com uma taxa de 2 amostra/segundo durante 512 segundos. Após a aquisição dos dados foi realizada uma análise espectral do sinal resultante. Para isso, foi necessário calcular a Transformada de Fourier do sinal de pv obtido, fazendo uso do algoritmo FFT (*Fast Fourier Transform*).

A Transformada de Fourier pode ser definida como um mapeamento que leva um sinal representado no domínio do tempo em uma representação no domínio da frequência. Seja $x[k]$ uma sequência discreta periódica com período N . A Transformada Discreta de Fourier de um sinal $x[k]$ é dada pela Equação 5.6 [Oppenheim et al. 1999].



(a) Diferentes Níveis de Oscilação.

(b) Análise Espectral da Saída do Processo.

Figura 5.4: Saída do Processo Para Diferentes Níveis Agarramento.

$$X[k] = \frac{1}{N} \sum_{n=0}^{N-1} x[n] e^{-ik \frac{2\pi n}{N}} \quad (5.6)$$

A realização desse procedimento nos 1024 pontos amostrados, resulta em novos 1024 pontos referente ao espectro do sinal. Apresentar essa enorme quantidade de pontos para uma Rede Neural a tornaria muito complexa, fazendo com que fosse muito custoso o seu processo de treinamento e ainda inviabilizando a sua utilização em situações onde a quantidade de memória é escassa. Para contornar esse problema, foi realizada uma filtragem nos dados, removendo assim informações pouco relevantes para o processo.

Após uma série de análises empíricas, verificou-se que, na grande maioria dos casos, as 3 frequências de maior energia representavam cerca de 90% de toda a energia do espectro. Sendo assim, o restante das frequências agrega pouca informação para a solução do problema. Com isso, as frequências mais relevantes e suas respectivas amplitudes são então apresentadas à Rede Neural.

Uma representação em diagrama de blocos dessa nova proposta pode ser visualizada na Figura 5.5. Nesse diagrama, o bloco de pré-processamento recebe como entrada os valores da p_v , calcula a Transforma de Fourier e então verifica quais são as 3 frequências mais relevantes bem como as suas respectivas energias. Esses valores, representados pelo vetor H , são então fornecido para a Rede Neural, que por sua vez estima os parâmetros S' e J' .

Da mesma forma como foi feito na primeira abordagem, é possível diagnosticar agarramento em uma válvula posicionadora como os valores S' e J' estimados pela rede. Dependendo dos valores encontrados pode-se verificar o grau de agarramento presente na válvula.

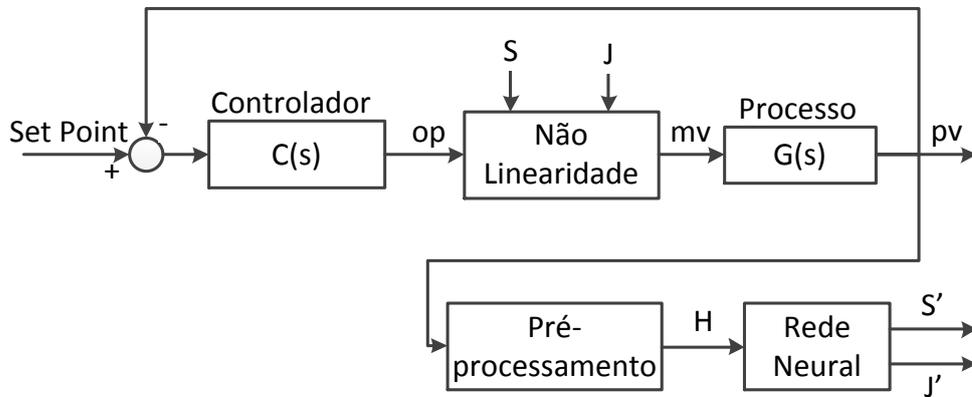


Figura 5.5: Diagrama de Blocos da Proposta Baseada em Análise Espectral.

5.3 Abordagem 03 - Análise Espectral + Centroide

A terceira abordagem proposta neste trabalho visa unir as principais características das duas abordagens anteriores, para construir uma técnica mais robusta e eficiente para o diagnóstico de agarramento em válvulas posicionadoras.

Inicialmente, da mesma forma como descrito na primeira abordagem, os sinais da saída do controlador (pv) e da saída do processo (op) são amostrados. Em seguida é calculada a distância de cada ponto ao centroide dos dados, utilizando as equações 5.3, 5.4 e 5.5.

Esse procedimento gera uma quantidade bastante elevada de pontos. Com o objetivo de reduzir essa massa de dados, é calculada a Transformada de Fourier do sinal (equação 5.6) e em seguida apenas as frequências mais relevantes são levadas em consideração. Novamente, após uma série de análises empíricas, verificou-se que cerca de 90% de toda a energia do sinal está concentrada em apenas 3 frequências.

As 3 frequências de maior energia e suas respectivas amplitudes são então apresentadas à rede neural para que a mesma possa quantificar o grau de agarramento estimando os valores de S e J .

Todo esse procedimento pode ser visualizado na representação em diagrama de blocos, presente na Figura 5.6. Nesse diagrama, o bloco *Centroide* recebe como entrada os valores de pv e op e calcula da distância de cada ponto ao centroide dos dados, representado pelo vetor D . Esse vetor (D) é processado pelo bloco *FFT*, onde são extraídas as frequências de maior energia (F). Essas frequências são então fornecidas à Rede Neural para que os parâmetros S e J sejam estimados.

A seguir, serão mostrados os resultados obtidos com a utilização de cada uma das abordagens propostas.

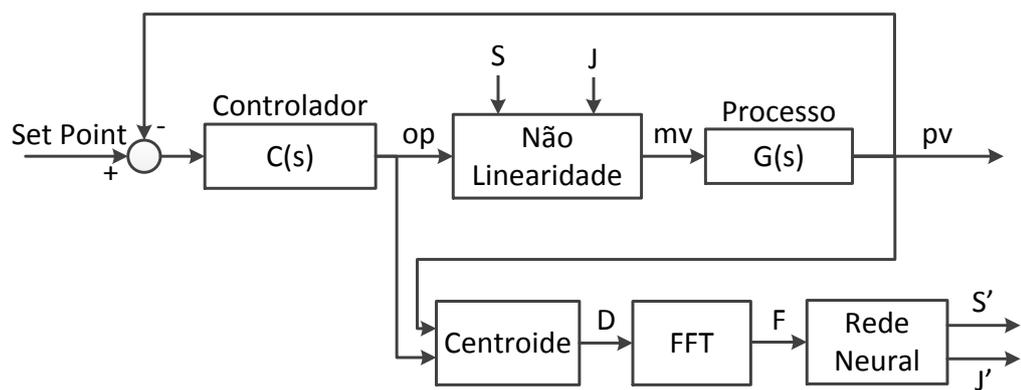


Figura 5.6: Diagrama de Blocos da Proposta Baseada em Análise Espectral.

Capítulo 6

Resultados

O objetivo deste capítulo é avaliar o método proposto em um processo simulado. Todas as simulações foram realizadas usando o modelo de agarramento mostrado no Capítulo 3, para simular a presença de não linearidade na válvula do processo descrito pela equação 6.1. Esse processo é controlado em malha fechada por um controlador PI cuja Função de Transferência é mostrada na equação 6.2.

$$G(s) = \frac{e^{-s}}{(1 + 0.5s)s} \quad (6.1)$$

$$C(s) = 0.4 \left(1 + \frac{1}{0.2s} \right) \quad (6.2)$$

O conjunto de treinamento em todas as situações foi gerado variando os valores de S e J em um intervalo de 0 até 10.

6.1 Abordagem 01 - Centroide

Para formação do conjunto de treinamento da rede neural, os sinais pv e op foram amostrados com uma taxa de 1 amostras/segundo durante 40 segundos. Isso resultou em um total de 80 pontos, sendo 40 de pv e 40 de op . Após a aquisição, foi calculada a distância de cada ponto ao centroide dos dados. Ao final desse processo, foram gerados 40 pontos para serem apresentados à RNA.

A RNA utilizada possui em sua camada de entrada 40 pontos, referente aos 40 pontos de entradas; 15 neurônios na cada oculta e mais 2 neurônios na cada de saída, referentes aos parâmetros S e J estimados.

Várias configurações de agarramento foram testadas a fim de validar a Rede Neural treinada. Ao final desse processo, foi obtido um erro médio quadrático de 10^{-1} . A seguir serão apresentadas algumas dessas situações.

6.1.1 Caso 1: Sem agarramento

O primeiro caso analisado é quando o sistema funciona de maneira ideal, ou seja, sem a presença de não linearidades na válvula. Essa situação pode ser modelada escolhendo

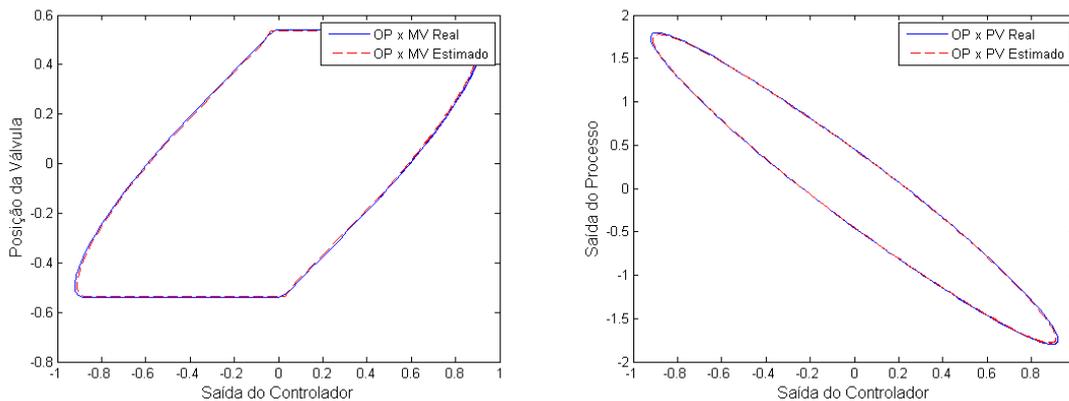
os parâmetros $J = 0$ e $S = 0$.

Os resultados obtidos na estimação dos parâmetros S e J com o método proposto são mostrados no Caso 01 da Tabela 6.1. Ambos os valores estimados de S e J são uma boa aproximação dos valores reais utilizados na simulação, sendo assim, a partir dos valores estimados pode-se inferir que a válvula do sistema está funcionando de maneira correta.

6.1.2 Caso 2: Agarramento com apenas banda morta

O próximo caso analisado é a situação de agarramento com a presença apenas da componente de banda morta. Isso pode ser simulado escolhendo o valor $J = 0$ e $S \neq 0$.

Sendo assim, para a simulação do processo em questão foram escolhidos os valores $J = 0$ e $S = 4$. Comparando a Figura 6.1a com a Figura 3.2, percebe-se a presença apenas da componente banda morta e a ausência do *slip jump*.



(a) OP x MV. $J = 0$ e $S = 4$.

(b) OP x PV. $J = 0$ e $S = 4$.

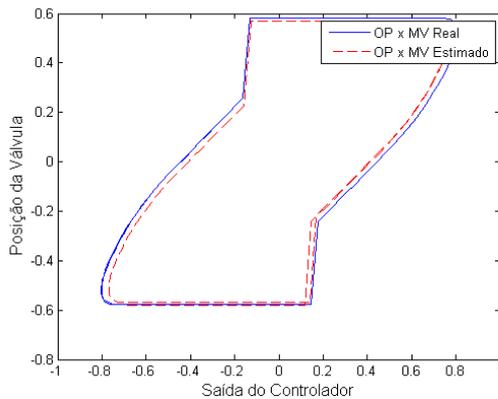
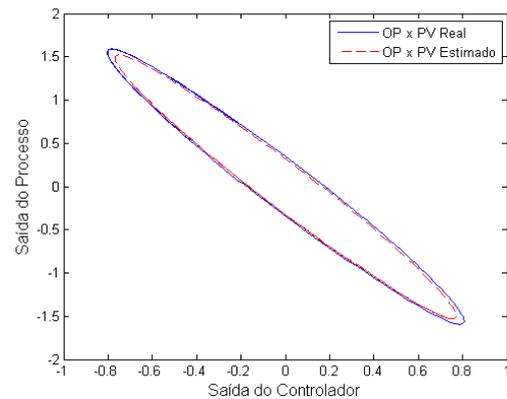
Figura 6.1: Agarramento com apenas Banda Morta para a abordagem 01.

Os valores de S e J estimados estão presentes no Caso 02 da Tabela 6.1. Novamente o método foi capaz de estimar os parâmetros com um erro bastante pequeno. A boa estimação pode ser observada também analisando a Figura 6.1a e a Figura 6.1b que mostram os diagramas de fase do sistema com os valores de S e J reais e estimados. Tanto o diagrama estimado de $PV-OP$ quanto o de $MV-OP$ se aproxima bastante do real.

6.1.3 Caso 3: Undershoot

O terceiro caso a ser analisada é quando $J < S$. Quando isso ocorre, temos a situação onde a saída da válvula nunca alcançará seu sinal de entrada. A essa situação dá-se o nome de agarramento do tipo *undershoot*. Os parâmetros escolhidos para essa simulação foram $J = 2$ e $S = 4$.

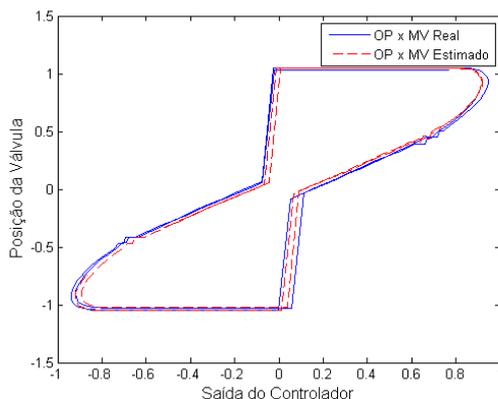
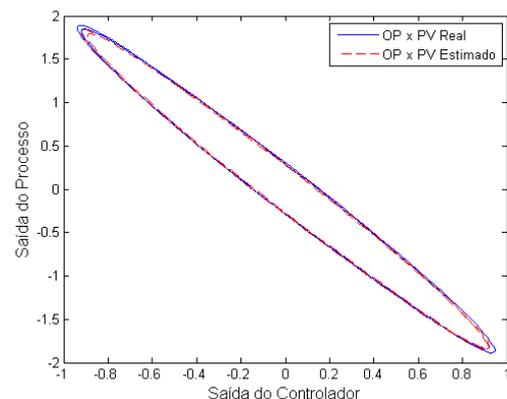
Analisando o diagrama de fase presente na Figura 6.2a, percebe-se a presença tanto da componente de banda morta quanto a *slip jump*.

(a) OP x MV. $J = 2$ e $S = 4$.(b) OP x PV. $J = 2$ e $S = 4$.Figura 6.2: Agarramento do tipo *Undershoot* para a abordagem 01.

Novamente, a partir da Figura 6.2a e da Figura 6.2b percebe-se que os diagramas de fase estimados se assemelham bastante do real. Fato que pode ser confirmado no Caso 03 da Tabela 6.1, onde os valores estimados de S e J são mostrados.

6.1.4 Caso 4: Overshoot

Diferente do que acontece no caso de *undershoot*, no *overshoot* a saída do processo ultrapassa o sinal de controle. Isso ocorre devido à presença de um elevado atrito estático e pode ser modelado fazendo $J > S$. Sendo assim, foram utilizados os valores $J = 6$ e $S = 3$ para simular essa falha.

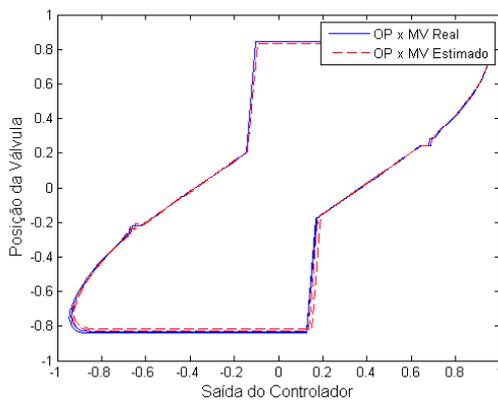
(a) OP x MV. $J = 6$ e $S = 3$.(b) OP x PV. $J = 6$ e $S = 3$.Figura 6.3: Agarramento do tipo *Overshoot* para a abordagem 01.

Tanto no diagrama *OP-MV* (Figura 6.3a) quanto no *OP-PV* (Figura 6.3b), o método conseguiu estimar o agarramento de maneira satisfatória. Os valores estimados estão presentes no Caso 04 da Tabela 6.1.

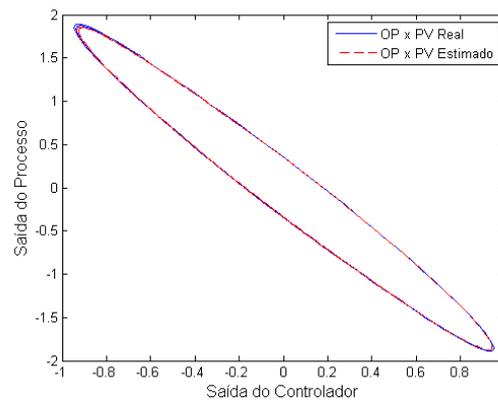
6.1.5 Caso 5: Sem offset

A última situação de agarramento é o caso onde $J = S$, ou seja, o caso onde não há *offset* entre o sinal de controle e a saída do processo. Uma vez que a válvula supera a força de atrito, ela acompanha exatamente o sinal de controle. Para esse caso foram usados os parâmetros $J = 4$ e $S = 4$.

Os resultados da simulação estão presentes nas figuras 6.4a e 6.4b.



(a) OP x MV. $J = 4$ e $S = 4$.



(b) OP x PV. $J = 4$ e $S = 4$.

Figura 6.4: Agarramento sem *offset* para a abordagem 01.

Mais uma vez o método proposto se mostrou eficiente e conseguiu estimar os valores de S e J com uma boa precisão, como pode ser visualizado no Caso 05 da Tabela 6.1.

6.1.6 Caso 06: Outras Situações

A técnica de Centroide obteve resultados bem expressivos na maioria das situações, porém em alguns casos o resultado já não foi tão satisfatório. Analisando a configuração $J = 2$ e $S = 4$, mostrada na Figura 6.5, percebe-se que a rede neural não foi capaz de aproximar os valores reais tão bem quanto nas outras situações. Neste caso, o erro foi superior a 10%, como pode ser observado no Caso 06 da Tabela 6.1.

6.2 Abordagem 02 - Análise Espectral

Para formação do conjunto de treinamento da Rede Neural é utilizada apenas a saída do processo (pv). O sinal pv foi amostrado com uma taxa de 2 amostra/segundo durante 512 segundos, resultando em um total de 1024 pontos. Após a aquisição desses valores, foi calculada a Transformada de Fourier do sinal obtido e em seguida foram extraídas apenas as 3 frequências mais relevantes, com suas respectivas amplitudes.

Ao final desse processo, a RNA resultante possui 6 pontos em sua camada entrada, referente às 3 frequências de maior energia e suas respectivas amplitudes; 10 neurônios na cada oculta e mais 2 neurônios na camada de saída, referentes aos parâmetros S e J

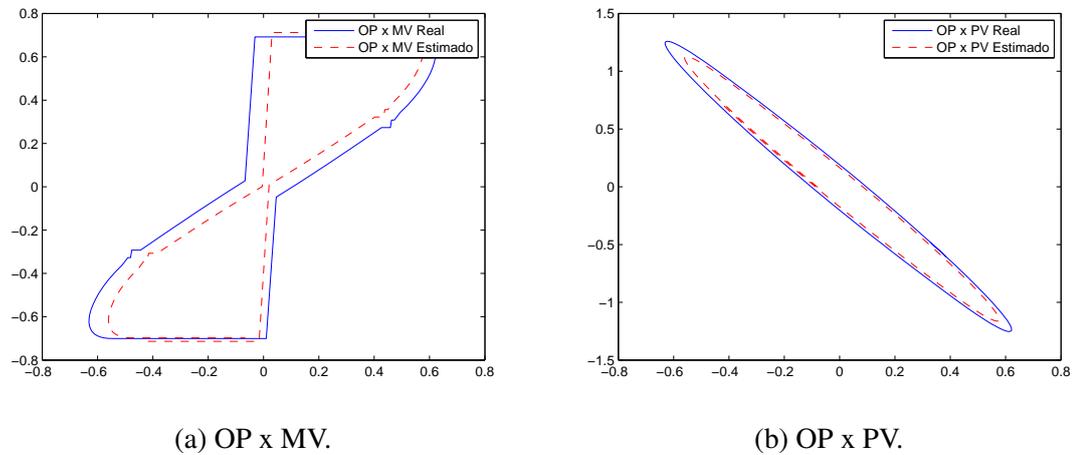


Figura 6.5: Configuração de Agarramento para a abordagem 01: $J = 2$ e $S = 4$.

Tabela 6.1: Comparação dos Valores Reais e Estimados de S e J para Várias Configuração de Agarramento para a Abordagem 01.

		Real	Estimado	Erro
Caso 01	S	0	0.0344	0.0344
	J	0	0.0143	0.0143
Caso 02	S	4	4.1566	0.1566
	J	0	0.2157	0.2157
Caso 03	S	4	3.7872	0.2128
	J	2	2.1214	0.1214
Caso 04	S	3	2.9879	0.0121
	J	6	6.1222	0.1222
Caso 05	S	4	3.9826	0.0174
	J	4	3.9052	0.0948
Caso 06	S	2	1.5440	0.4560
	J	4	4.4051	0.4051

estimados. Para formar o conjunto de treinamento da rede, foram geradas várias configurações de agarramento variando os valores de S e J em um intervalo entre 0 e 10.

A rede treinada foi validada utilizando novos valores que não haviam sido mostrados durante o processo de treinamento. Ao final da validação, foi obtido um erro médio quadrático de 10^{-2} . A seguir será apresentado como a Rede Neural treinada comportou-se em algumas simulações de agarramento.

O primeiro caso analisado é quando o sistema funciona de maneira ideal, ou seja, sem a presença de não linearidades na válvula. Essa situação foi modelada escolhendo os parâmetros $J = 0$ e $S = 0$. Os resultados obtidos são mostrados na Tabela 6.2. Ambos os valores estimados de S e J são uma boa aproximação dos valores reais utilizados na simulação, sendo assim, a partir dos valores estimados pode-se inferir que a válvula do sistema está funcionando de maneira correta.

O segundo caso a ser analisada é o agarramento do tipo *undershoot*, ou seja, a situação quando $J < S$. Os parâmetros escolhidos para essa simulação foram $J = 2$ e $S = 4$. Novamente, analisando a Tabela 6.2 percebe-se que os valores estimados de S e J assemelham-se bastante do real. Para facilitar a visualização dos resultados obtidos, as Figuras 6.6a e 6.6b mostram o diagrama de fase *op-mv* e *op-pv*, respectivamente. Esses diagramas mostram como o sistema comportou-se com os valores reais de S e J e com os valores estimados pela Rede Neural. Em ambos os gráficos, as curvas praticamente se sobrepõem comprovando novamente que os resultados obtidos se aproximam bastante dos valores reais.

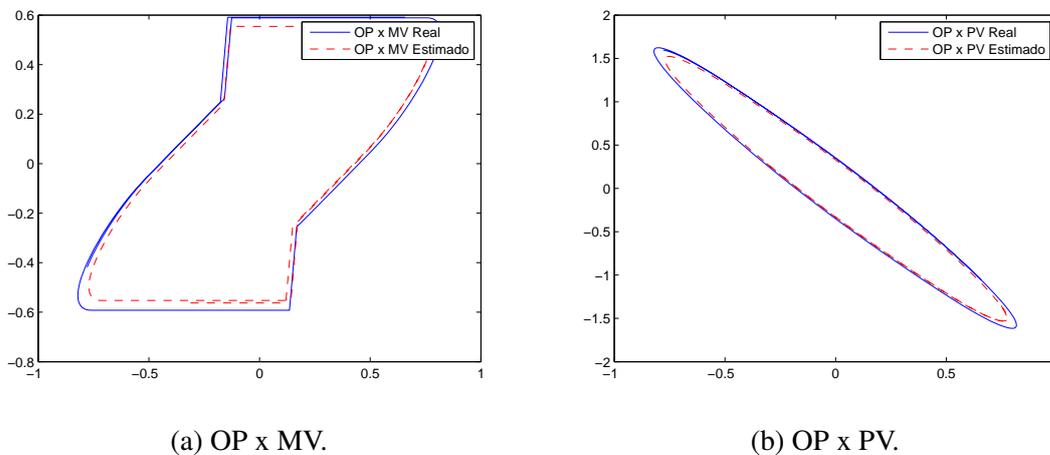


Figura 6.6: Configuração de agarramento para a abordagem 02: $J = 2$ e $S = 4$.

A próxima situação de agarramento é o caso onde $J = S$, ou seja, o caso onde não há offset entre o sinal de controle e a saída do processo. Uma vez que a válvula supera a força de atrito, ela acompanha exatamente o sinal de controle. Para esse caso foram usados os parâmetros $J = 4$ e $S = 4$.

Novamente o método mostrou-se eficiente e conseguiu estimar os valores de S e J com uma boa precisão, como pode ser visualizado na Tabela 6.2 e nas Figuras 6.7a e 6.7b.

A última situação de agarramento analisada foi o agarramento do tipo *overshoot*. Essa situação pode ser modelada fazendo $J > S$, sendo assim, foram utilizados os valores $J = 6$ e $S = 3$ para simular essa falha.

Tanto no diagrama *op-mv* (Figura 6.8a) quanto no *op-pv* (Figura 6.8b), o método conseguiu estimar o agarramento de maneira satisfatória. Os valores estimados estão presentes na Tabela 6.2.

6.3 Abordagem 03 - Centroide + Análise Espectral

Inicialmente os sinais de *pv* e *op* foram amostrados a uma taxa de 2 amostras/segundo durante 512 segundo. Após a aquisição desses 1024 pontos, foi calculada a distância de cada ponto ao centroide dos dados. Em seguida a Transformada de Fourier do sinal

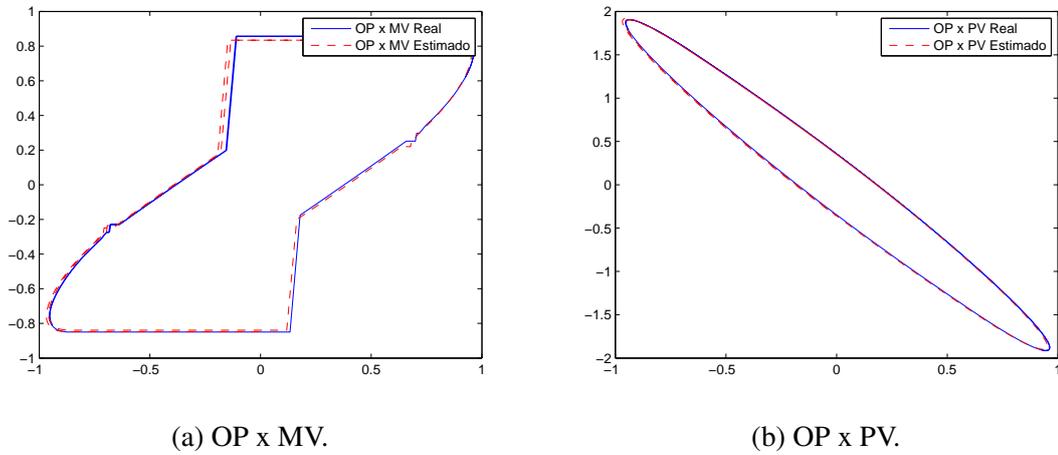


Figura 6.7: Configuração de agarramento para a abordagem 02: $J = 4$ e $S = 4$.

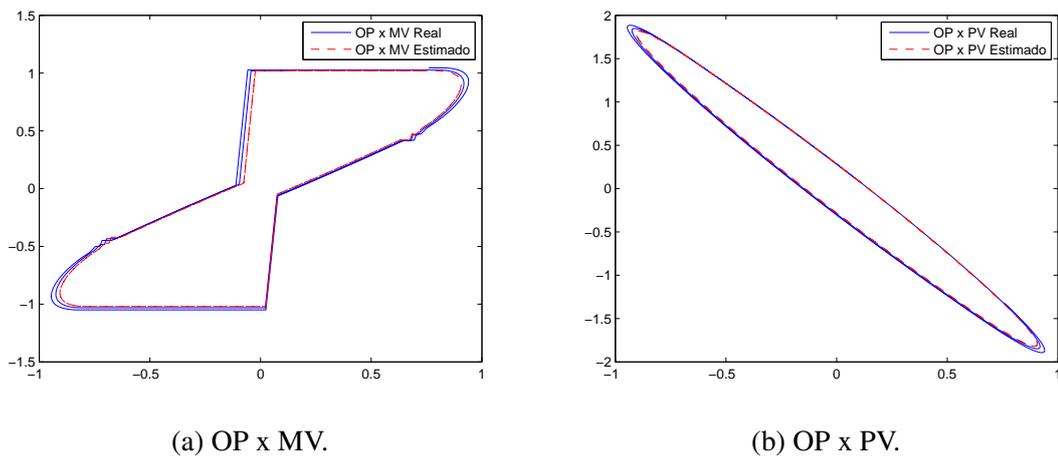


Figura 6.8: Configuração de agarramento para a abordagem 02: $J = 6$ e $S = 3$.

Tabela 6.2: Comparação dos Valores Reais e Estimados de S e J para Várias Configuração de Agarramento para a Abordagem 02.

		Real	Estimado	Erro
Caso 01	S	0	0.0247	0.0247
	J	0	0.0114	0.0114
Caso 02	S	4	3.8477	0.1523
	J	2	1.9147	0.0853
Caso 03	S	4	4.1433	0.1433
	J	4	3.9490	0.0510
Caso 04	S	3	2.9385	0.0615
	J	6	6.0134	0.0134

resultante foi obtida e as 3 frequências de maior energia foram utilizada para formar o conjunto de treinamento da RNA.

Sendo assim, a rede neural possui em sua camada de entrada 6 pontos referente às 3 frequências mais relevantes e suas respectivas amplitudes; 10 neurônios na camada oculta e mais 2 neurônios na camada de saída, referentes aos parâmetros S e J. Após o processo de treinamento, novos valores foram utilizados para a validação da rede. Esse procedimento resultou em um erro médio quadrático de 10^{-3} , valor menor do que o obtido nas outras duas abordagens.

Será mostrada a seguir a resposta da rede treinada para algumas configurações de agarramento. Seguindo o mesmo raciocínio das outras abordagens, a primeira situação analisada é caso onde é desconsiderada a não linearidades na válvula de controle. Os valores estimados podem ser observados no Caso 01 da Tabela 6.3.

Outras três configurações de agarramento são mostradas nas figuras 6.9, 6.10 e 6.11 e os valores estimados podem ser visualizados na Tabela 6.3. Assim como as outras duas técnicas, a abordagem em questão foi capaz de quantificar, de maneira satisfatória, o grau de agarramento de uma válvula.

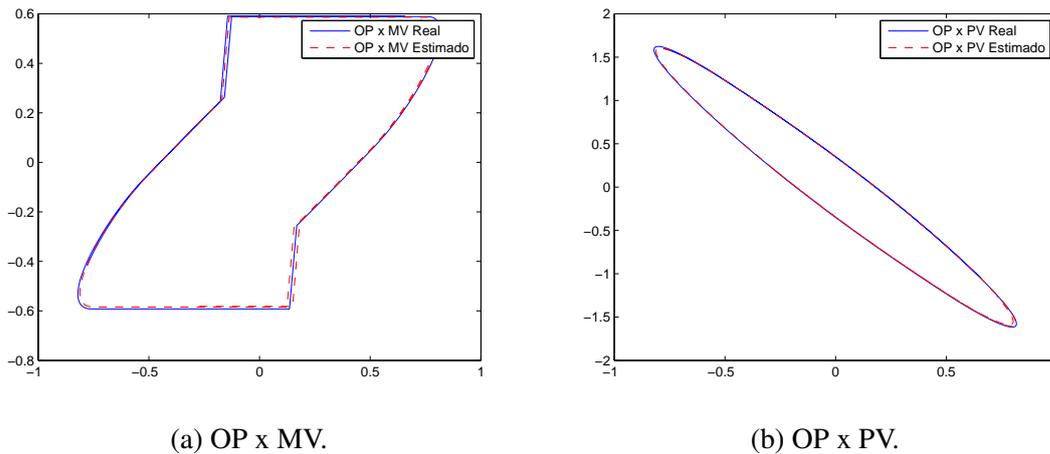


Figura 6.9: Configuração de agarramento para a abordagem 03: $J = 2$ e $S = 4$.

Com a utilização da abordagem em questão, foi possível obter uma arquitetura mais reduzida, além de alcançar resultados mais precisos, quando comparados com as outras duas abordagens apresentadas nesse capítulo. Resultando assim em uma técnica bem mais robusta e eficiente para a quantificação de agarramento em válvulas posicionadoras.

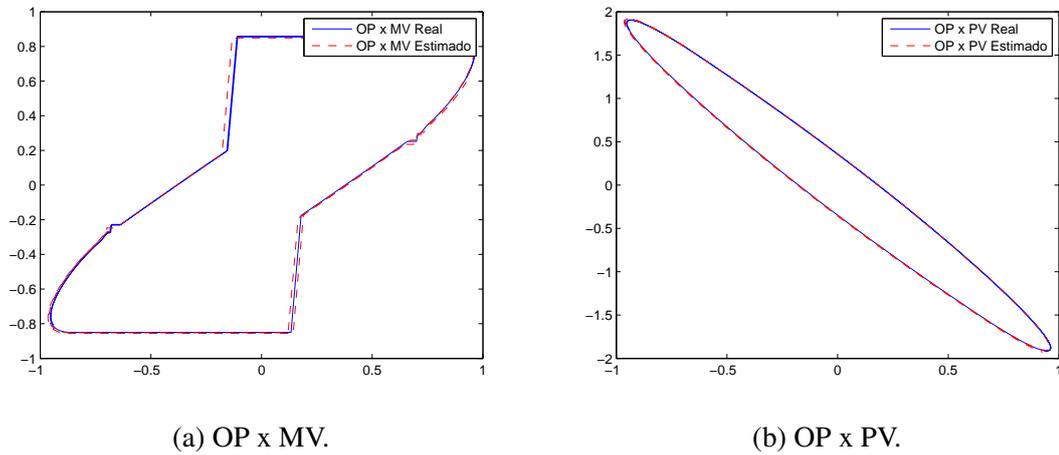
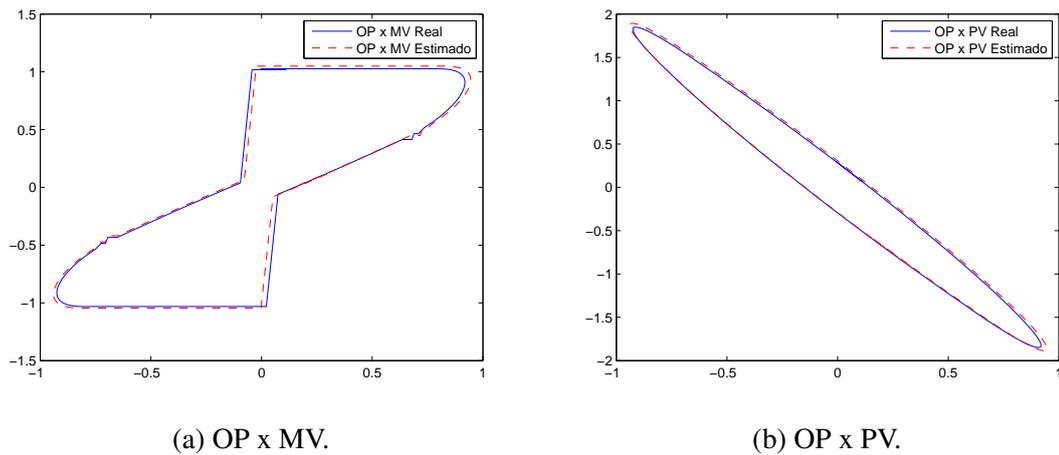
Figura 6.10: Configuração de agarramento para a abordagem 03: $J = 4$ e $S = 4$.Figura 6.11: Configuração de agarramento para a abordagem 03: $J = 3$ e $S = 6$.

Tabela 6.3: Comparação dos Valores Reais e Estimados de S e J para Várias Configuração de Agarramento para a Abordagem 03.

		Real	Estimado	Erro
Caso 01	S	0	0.0015	0.0015
	J	0	0.0013	0.0013
Caso 02	S	4	3.9883	0.0117
	J	2	2.1151	0.1151
Caso 03	S	4	4.0979	0.0979
	J	4	4.0487	0.0487
Caso 04	S	3	2.9913	0.0087
	J	6	5.9888	0.0112

Capítulo 7

Conclusões

O Gerenciamento de Eventos Anormais (AEM) é um tema que vem tendo cada vez mais relevância no cenário da automação industrial. Isso tem ocorrido devido à enorme quantidade de informação disponibilizada para o operador, que se vê impossibilitado de diagnosticar um eventual problema no processo e realizar alguma ação preventiva/corretiva em tempo hábil.

Esse trabalho apresentou um método online baseado em Redes Neurais Artificiais para detectar e quantificar o grau de agarramento em válvulas posicionadoras, que pode ser enquadrado como uma funcionalidade do AEM. As principais vantagens desse método é não necessitar do conhecimento da dinâmica do processo analisado, assim como não é preciso medir a posição da válvula.

Foram propostas três abordagens para o treinamento da rede neural. Na primeira abordagem uma técnica baseada no cálculo do centroide foi desenvolvida, sendo necessário as informações da saída do controlador (op) e da saída do processo (pv). Na segunda abordagem desenvolveu uma técnica baseada na análise espectral apenas do sinal pv do processo. E por fim, na última abordagem uniu-se o cálculo do centroide dos dados à análise espectral para desenvolver uma técnica mais eficiente capaz de quantificar o grau de agarramento em válvulas posicionadoras.

O método foi testado em diversas configurações de agarramento em um modelo simulado e se mostrou eficiente em detectar e quantificar a falha em processos industriais. Essa abordagem de detecção de falhas pode ser aplicada a vários processos industriais modernos, uma vez que ela reflete a realidade industrial onde a posição da válvula é muitas vezes desconhecida. Porém, espera-se que no futuro a posição da válvula seja uma informação de fácil acesso, o que possibilitaria o desenvolvimento de algoritmos bem mais precisos e confiáveis.

7.1 Trabalhos Futuros

Apesar de trazer diversas contribuições, a proposta ainda pode receber melhorias e adaptações para serem desenvolvidas. A seguir, alguns pontos que serão desenvolvidos até a versão final dessa dissertação:

- Analisar a arquitetura da Rede Neural utilizada a fim de encontrar a menor configuração possível. Uma técnica que poderia ser utilizada seria o algoritmo do "Ci-

urgião Neural Ótimo"[Haykin & Engel 2001]. Isso viabilizaria embarcar a rede treinada em dispositivos com pouca capacidade de memória.

- Avaliar a utilização de Redes Neurais Recorrentes.
- Validar o método proposto fazendo uso de dados reais de processos industriais.

7.2 Publicações Associadas

Até o presente momento, foram obtidas as seguintes publicações relacionadas a esta dissertação:

- "Detecção e Diagnóstico de Agarramento em Válvulas Posicionadoras- Congresso Brasileiro de Automática 2012 (CBA).
- "*Artificial Neural Network Approach for Detection and Diagnosis of Valve Stiction-Emerging Technologies & Factory Automation 2012 (ETFA)*, na seção de *Work in Progress*.

Referências Bibliográficas

- Aurélio, Buarque de Holanda Ferreira (1993), *Dicionário Aurélio da Língua Portuguesa*, 3ª edição, Editora Positivo, Rio de Janeiro, Brasil.
- Bailey, S. J. (1984), 'From desktop to plant floor, a crt is the control operators window on the process.', *Control Engineering* pp. 86–90.
- Bialkowski, W. L. (1992), 'Dreams vs. reality: A view from both sides of the gap', *Control systems* pp. 283–294.
- Choudhury, M.A.A. Shoukat, Mridul Jain & Sirish L. Shah (2008), 'Stiction: definition, modelling, detection and quantification', *Journal of Process Control* **18**, 232 – 243.
- Choudhury, M.A.A. Shoukat, N.F. Thornhill & S.L. Shah (2005), 'Modelling valve stiction', *Control Engineering Practice* **13**(5), 641 – 658.
- Choudhury, M.A.A. Shoukat, S.L. Shah, N.F. Thornhill & David S. Shook (2006), 'Automatic detection and quantification of stiction in control valves', *Control Engineering Practice* **14**(12), 1395 – 1412.
- Desborough, L. & R. Miller (2002), Increasing customer value of industrial control performance monitoring - Honeywell's experience, *em* 'Preprint of Chemical Process Control, CPC-6', Tucson, Arizona, pp. 153–186.
- Farenzena, M. & J.O. Trierweiler (2012), 'Valve stiction estimation using global optimisation', *Control Engineering Practice* **20**(4), 379 – 385. Special Section: IFAC Symposium on Advanced Control of Chemical Processes - ADCHEM 2009.
- Garcia, Claudio (2008), 'Comparison of friction models applied to a control valve', *Control Engineering Practice* **16**(10), 1231 – 1243.
- Haykin, Simon & Paulo M. Engel (2001), *Redes neurais : princípios e prática*, Bookman.
- Horch, Alexander (1999), 'A simple method for detection of stiction in control valves', *Control Engineering Practice* **7**(10), 1221 – 1231.
- Isermann, R. (2005), *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*, Springer.
- Jelali, Mohieddine (2006), 'An overview of control performance assessment technology and industrial applications', *Control Engineering Practice* **14**(5), 441 – 466.

- Jelali, Mohieddine (2008), 'Estimation of valve stiction in control loops using separable least-squares and global search algorithms', *Journal of Process Control* **18**, 632 – 642.
- Kayihan, Arkan & Francis J. Doyle III (2000), 'Friction compensation for a process control valve', *Control Engineering Practice* **8**(7), 799 – 812.
- Leitão, Gustavo Bezerra Paz (2008), Algoritmos para análise de alarmes em processos petroquímicos, Dissertação de mestrado, Universidade Federal do Rio Grande do Norte, UFRN, Natal, RN.
- Lima, Fábio Soares de, Luiz Affonso Guedes & Diego R. Silva (2011), *Digital Image Processing*, His Publisher, Erehwon, NC.
- Oppenheim, Alan V., Ronald W. Schaffer & John R. Buck (1999), *Discrete-Time Signal Processing (2nd Edition) (Prentice-Hall Signal Processing Series)*, 2ª edição, Prentice Hall.
- Romano, Rodrigo Alvite (2010), Identificação de processos não lineares e quantificação de atrito em válvulas de controle, Dissertação de mestrado, Escola Politécnica da Universidade de São Paulo, EPUSP, São Paulo, SP.
- Silva, Diego Rodrigo Cabral (2008), Sistema de Detecção e Isolamento de Falhas em Sistemas Dinâmicos Baseados em Identificação Paramétrica, Tese de doutorado, Universidade Federal do Rio Grande do Norte, UFRN, Natal, RN.
- Venkatasubramanian, Venkat, Raghunathan Rengaswamy, Kewen Yin & Surya N. Kavuri (2003), 'A review of process fault detection and diagnosis: Part I: Quantitative model-based methods', *Computers and Chemical Engineering* **27**(3), 293 – 311.
- Venkatasubramanian, Venkat, Raghunathan Rengaswamy & Surya N Kavuri (2003), 'A review of process fault detection and diagnosis: Part II: Qualitative models and search strategies', *Computers and Chemical Engineering* **27**(3), 313 – 326.
- Venkatasubramanian, Venkat, Raghunathan Rengaswamy, Surya N. Kavuri & Kewen Yin (2003), 'A review of process fault detection and diagnosis: Part III: Process history based methods', *Computers and Chemical Engineering* **27**(3), 327 – 346.