



UNIVERSIDADE FEDERAL DO RIO
GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA
QUÍMICA
ENG07053 - TRABALHO DE DIPLOMAÇÃO EM
ENGENHARIA QUÍMICA



Detecção e identificação de falhas em válvulas de controle

Autor: Micael Attolini

Orientador: Prof. Dr. Marcelo Farenzena

Porto Alegre, dezembro de 14

Sumário

Agradecimentos	iv
Resumo	v
Lista de Figuras	vi
Lista de Tabelas	vii
Lista de Símbolos	viii
Lista de Abreviaturas e Siglas	ix
1 Introdução	1
2 Revisão Bibliográfica	2
2.1 Malha de controle	2
2.2 Importância do aperfeiçoamento da malha de controle	2
2.3 Componentes de uma válvula de controle	3
2.4 Auditoria de malhas de controle	3
2.5 Falhas comumente encontradas em válvulas de controle	4
2.5.1 Backlash	4
2.5.2 Agarramento	5
2.5.3 Suprimento de pressão	9
2.6 Técnicas de FDI	10
2.6.1 Detecção baseada em modelo	10
2.6.2 Monitoramento de variáveis	10
3 Materiais e Métodos	12
3.1 Software utilizado	12
3.2 Modelagem das falhas	12
3.2.1 Válvula com operação normal	12
3.2.2 Backlash	13
3.2.3 Válvula com agarramento	14
3.2.4 Válvula com problema de suprimento de pressão	15
3.2.5 Malha fechada	17
3.2.6 Adição de ruído	18
3.3 Estratégia de detecção	19
3.3.1 Índice 1: Inclinação no topo e vale	20
3.3.2 Índice 2: Inclinação na origem	21
3.3.3 Índice 3: Inclinação intermediária	21
3.3.4 Índice 4: Assimetria de curva – diferença	22
3.3.5 Índice 5: Assimetria de curva – razão	22
3.3.6 Índice 6: Atraso Inicial	22
3.4 Redes neurais Artificiais	23
3.4.1 Treinamento da rede neural	23
4 Resultados	25
4.1 Regressão da rede no treinamento	25
4.2 Análise dos índices	26

4.3	Regressão de validação e de teste	27
4.4	Matriz de confusão	28
4.5	Adição de ruído	29
4.5.1	Regressão da rede com ruído	30
4.5.2	Matriz de confusão com ruído	30
5	Conclusões e Trabalhos Futuros	32
6	Referências	33
7	Apêndice 1	35

Agradecimentos

Agradeço a todos meus amigos e familiares que de alguma forma colaboraram ao longo de minha faculdade. Em especial, aos meus pais Carlos e Miriam, pelo apoio incondicional e conselhos preciosos, ao meu irmão Samuel, pela amizade e parceria em todos os momentos, e também a minha “táta” Ana Maria, pelo carinho desde os meus primeiros dias de vida.

Um agradecimento especial ao professor Marcelo Farenzena pela paciência, por todos os ensinamentos e principalmente pela amizade demonstrada ao longo da graduação.

Resumo

Uma operação estável e segura em sistemas industriais cada vez mais complexos é um dos maiores desafios e objetivo de profissionais de engenharia química, sendo um dos mais importantes campos de pesquisa e desenvolvimento da área. Um elemento crucial para o êxito dessa tarefa está no bom funcionamento do elemento atuador em sistemas de controle: a válvula de controle. Sistemas de detecção e identificação de falhas em válvulas de controle devem ser capazes de identificar em tempo real quando uma falha ocorre durante a operação e, mais do que isso, identificar qual falha ocorreu, para que a devida ação seja executada.

Nesse trabalho é proposta uma metodologia capaz de detectar avarias em válvulas de controle e, caso o tal teste seja positivo, distinguir qual a causa, sendo minimamente invasivo. Essa ferramenta é construída primeiramente com simulação computacional do sistema saudável e dos possíveis problemas que podem ocorrer: agarramento, *backlash* e problema de suprimento de pressão. O segundo passo é reconhecer padrões de distúrbios de cada falha, encontrar sinais que sejam como impressão digital de cada falha, e assim criar índices que diferenciem tais características. Tendo-se esses índices, fez-se então o treinamento da rede neural.

As redes neurais configuradas desempenharam bem sua função tanto de detectar quanto de identificar qual falha ocorreu. O bom desempenho foi demonstrado através de métricas de coeficiente de regressão e matrizes de confusão em três situações distintas: sistema em malha aberta, malha fechada e malha fechada com ruído. As RNA's se mostraram capazes de servir de base para monitoramento das válvulas de controle, avaliando sua aplicação em processos reais.

Lista de Figuras

Figura 2.1: malha de controle simplificada (adaptado de Aubrun et al., 1995)	2
Figura 2.2: partes de uma válvula de controle e corte transversal	3
Figura 2.3: Comparação de válvula normal e com <i>backlash</i> e ênfase à banda morta gerada pelo backlash. (Adaptado de Aubrun et al., 1995)	5
Figura 2.4: da esquerda para direita, diferentes níveis de agarramento: agarramento com undershoot, sem offset e overshoot (adaptado de Shoukat Chodhury et al.,2005)	5
Figura 2.5: Algoritmo do modelo de Kano (retirado de Garcia, 2008)	8
Figura 2.6: Agarramento conforme o modelo de Kano (retirado de Garcia, 2008)	8
Figura 2.7: Falha de suprimento de pressão em diferentes graus (Karpenko, 2002).	9
Figura 3.1: Sistema em operação normal implementado em Simulink (esquerda) e resposta das variáveis do processo para (direita)	13
Figura 3.2: Sistema em operação com <i>backlash</i> implementado em Simulink e resposta das variáveis do processo.	14
Figura 3.3: Sistema em operação com agarramento implementado em Simulink(esquerda) e resposta das variáveis do processo para valores aleatórios da simulação (direita)	15
Figura 3.4: Sistema em operação com vazamento implementado em Simulink e resposta das variáveis do processo para uma simulação.	16
Figura 3.5: Abertura de uma válvula com vazamento e saturação do atuador.	17
Figura 3.6: Diagrama de blocos da falha de saturação do atuador e resposta das variáveis do processo em uma simulação.	17
Figura 3.7: Implementação das simulações em malha fechada.	18
Figura 3.8: Comparação entre as possíveis falhas e de válvula normal.....	19
Figura 3.9: Inclinação no topo da simulação para diferentes falhas.	20
Figura 3.10: Primeiro índice aplicado nos sinais de agarramento e normal.....	20
Figura 3.11: Inclinação em zero da simulação para diferentes falhas.....	21
Figura 3.12: Tempo morto presente apenas no <i>backlash</i>	22
Figura 3.13: Esquema de funcionamento de uma RNA.	23
Figura 4.1: matriz de confusão para dados em malha aberta.	28
Figura 4.2: matriz de confusão para dados de malha fechada.	29
Figura 4.3: sinal de saída para diferentes níveis de ruído.....	30
Figura 4.4: matriz de confusão para a diferentes intensidades de ruído.	31

Lista de Tabelas

Tabela 3.1: Parâmetros alterados na simulação de válvula normal.	13
Tabela 3.2: Parâmetros alterados na simulação de válvula com <i>backlash</i>	14
Tabela 3.3: Parâmetros alterados na simulação de válvula com agarramento.....	15
Tabela 3.4: Parâmetros na simulação de válvula com vazamento.	16
Tabela 3.5: Parâmetros alterados na simulação de válvula com saturação do atuador. ...	17
Tabela 3.6: Parâmetros do controlador alterados na simulação de malha fechada.	18
Tabela 3.7: Classes de dados geradas	19
Tabela 3.8: conjunto de entradas da rede neural.....	24
Tabela 3.9: conjunto de saídas da rede neural.	24
Tabela 4.1: regressão de rede para malha aberta com diferente número de neurônios. 25	
Tabela 4.2: regressão de rede para malha fechada com diferente número de neurônios.26	
Tabela 4.3: performances dos treinamentos para diferentes variáveis de entrada.	26
Tabela 4.4: regressão em malha aberta de todas etapas de treinamento.....	27
Tabela 4.5: regressão em todas etapas para 20 neurônios em malha fechada.	27
Tabela 4.6: regressão para diferentes níveis de ruído.....	30
Tabela 7.1: regressão de treinamento para um índice.	35
Tabela 7.2: regressão de treinamento para dois índices.....	35
Tabela 7.3: regressão de treinamento para três índices.	35
Tabela 7.4: regressão de treinamento para quatro índices.....	36
Tabela 7.5: regressão de treinamento para cinco índices.	36

Lista de Símbolos

C_v – coeficiente de vazão

τ – dinâmica do sistema

u_p – variável de entrada do processo

x_p – variável de meio do processo

y_p – variável de saída do processo

Lista de Abreviaturas e Siglas

FDI – *fault detection and isolation*

NNTool – Neural Network Toolbox

RNA – rede neural artificial

1 Introdução

Com processos cada vez mais complexos e um mercado mais competitivo e acirrado, a operação adequada das plantas na indústria química é fundamental, tanto em questão de segurança quanto econômica. Em termos de segurança, garantir com que a planta opere em condições seguras sem expor a riscos os operários. Em economia, tanto para que não se tenha desperdícios - energia, matéria prima, sistema de aquecimento e refrigeração - quanto na qualidade do produto, que é crucial para ganhar mercado.

Por trás de toda estratégia de controle estabelecida para o processo estão as válvulas: elemento atuador na malha de controle. O bom funcionamento dessas é fundamental para garantir qualidade do produto e estabilidade operacional. Quando elas apresentam avarias, não só comprometem o sistema de controle como também suas falhas podem trazer danos à planta e se propagarem no processo, podendo levar a uma situação perigosa.

Na literatura, há uma série de trabalhos que permitem diagnosticar isoladamente as principais avarias das válvulas: agarramento, *backash* e falha de suprimento de pressão. Entretanto, não há uma metodologia unificada que permita, a partir da possível falha, auditar seu funcionamento e, caso tenha avarias, diagnosticá-las sendo minimamente invasivo.

Esse tipo de metodologia também permite monitorar a situação de várias válvulas de uma linha, podendo-se então adotar medidas de manutenção preventiva e hierarquia no conserto dessas, de acordo com o grau de importância de atuação e de avaria da válvula. Também, é possível adotar uma estratégia de compensação de algumas falhas, o que exige para isso a identificação correta de qual falha está acontecendo para que se tome a ação correta.

O escopo do presente trabalho objetiva elaborar uma metodologia capaz identificar em tempo real. Primeiro, são descritas e modeladas essas falhas em malha aberta, para assim se coletarem dados e então criar indicadores dessas falhas. Por fim, é feito treinamento de uma rede neural com base nos dados de saída da simulação e indicadores criados, para então testar em três situações: sistema em malha aberta, em malha fechada e em malha fechada com adição de ruído. Além de detectar quando uma falha ocorre, o desafio está em isolar qual falha ocorreu.

O presente trabalho de conclusão está segmentado como segue: no capítulo 2 apresenta-se a revisão bibliográfica relacionada a pesquisas referentes a detecção e identificação de falhas. No capítulo 3, é explicada a metodologia utilizada para se alcançar o objetivo desse trabalho, descrevendo como foi feita a modelagem de cada um dos cenários de simulação e de criação dos índices. No capítulo 4, os resultados são apresentados e discutidos, para que verificação se a metodologia empregada mostrou-se eficiente. Por fim, no capítulo 5, são feitas conclusões sobre a realização desse trabalho, bem como sugestões de etapas futuras para melhoria da ferramenta de detecção e identificação de falhas.

2 Revisão Bibliográfica

Neste capítulo, é apresentada uma revisão bibliográfica sobre os benefícios da detecção de falhas em válvulas de controle, principais problemas encontrados e métodos utilizados para atingir o objetivo de detectar e identificar falhas.

2.1 Malha de controle

Um sistema de controle é composto essencialmente por três elementos: o sensor, responsável pela medição da variável de interesse, o controlador, que recebe esse sinal e envia a ação necessária para o atuador aplicar efetivamente no processo. Em resumo, um sistema de controle é uma série de componentes interconectados que interagem entre si para atingir os objetivos do sistema. O comportamento de cada componente pode ser descrito por uma série de equações definindo a trajetória das variáveis do processo. Um esquema simplificado é apresentado na Figura 2.1. (Dustegör et al., 2006; Aubrun et al., 1995)

A malha de controle, responsável por manter as variáveis de operação dentro do patamar desejado, funciona da seguinte forma: a variável controlada é medida, direta ou indiretamente, através de um indicador, que passa o sinal para o instrumento que registra a medição, o registrador. O sinal vai então para o transmissor, que determina o valor de uma variável de processo através de um elemento primário, dando o sinal de saída de forma eletrônico ou digital. Após, passa pelo transdutor, elemento que recebe as informações na forma de quantidade física (pressão e temperatura, por exemplo), converte e fornece um sinal de saída resultante, que é repassado ao controlador. Nele, a variável controlada é comparada com um valor desejado (*setpoint*) e fornece uma ordem de ação. O sinal é enviado ao elemento de atuação, que modifica diretamente o valor da variável manipulada no processo. Esse elemento de atuação é a válvula de controle. (Instrumentação Básica, Instituto Brasileiro de Petróleo; Apostila ABRAMAN, 2004).

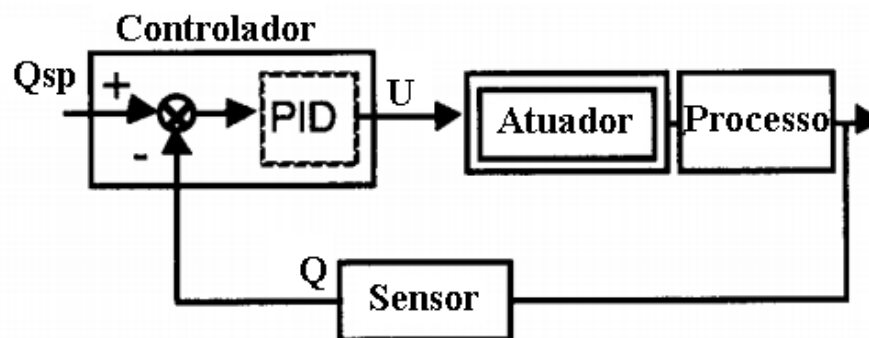


Figura 2.1: malha de controle simplificada (adaptado de Aubrun et al., 1995)

2.2 Importância do aperfeiçoamento da malha de controle

Uma típica planta da indústria química contém uma quantidade considerável de malhas de controle. O desempenho do controle é de suma importância para garantir a qualidade do produto e diminuir os custos de produção. Mesmo uma ação que implique na melhoria de 1% da eficiência energética ou na melhora da manutenção do controle, pode representar centenas de milhares de dólares economizados no processo industrial (Shoukat Choudhury et al., 2005; Desborough e Miller, 2002)

Visando entender à crescente necessidade por sistemas dinâmicos mais seguros e confiáveis, a detecção preliminar usando detecção e identificação de falhas, FDI (do

inglês, *fault detection and isolation*), é fundamental. Assim como os processos ficam mais complexos, a capacidade de detectar e identificar a falha operacional em válvulas de controle se torna cada vez mais importante. Em cada grau de falha, o custo de produção e/ou manutenção aumenta (Dustegör et al., 2006; Karpenko e Sepehri, 2002).

A detecção de falhas pode ser o passo preliminar para manutenção. Se pequenas falhas são detectadas cedo, o componente com defeito pode ser trocado ou reparado antes que efeitos críticos apareçam no sistema. Além disso, algumas falhas não são percebidas sem que se tenha um sistema de detecção e identificação de falhas mais elaborado, visto que o sistema em malha fechada consegue compensar parte de seus efeitos. Com um sistema de detecção de falhas, não é preciso adicionar sensores extras ou outro equipamento, o que poderia encarecer o processo de detecção consideravelmente. Os sistemas de detecção permitem detectar falhas em tempo real, podendo-se tomar uma rápida ação, conforme o caso (Aubrun et al., 1995).

2.3 Componentes de uma válvula de controle

A válvula de controle é a componente chave em qualquer sistema de controle. O mau funcionamento delas pode prejudicar o desempenho e levar a parada não programada da planta, resultando em perdas econômicas desnecessárias. Ela pode ser dividida em três regiões distintas, como mostrado na Figura 2.2. O corpo é o que liga a válvula à tubulação e contém o orifício variável para passagem do fluido. O castelo é a parte que liga o corpo ao atuador, dá sustento à haste da válvula e completa o fechamento do corpo. Por fim, há o atuador, que é o componente que recebe o sinal de controle e converte em abertura modulada da válvula. A atuação pode ser manual ou automática, tendo fonte de potência hidráulica, elétrica ou pneumática, conforme o caso e necessidade (Ribeiro, 1999; Ling et al., 2007).




Figura 2.2: partes de uma válvula de controle e corte transversal
(Fonte: Ribeiro, 1994, e Karpenko e Sepehri, 2002)

2.4 Auditoria de malhas de controle

Auditoria de malhas de controle trata da avaliação do desempenho das malhas de um processo visando mantê-las em um nível ótimo. Os benefícios econômicos resultantes de uma auditoria são difíceis de quantificar em uma base “malha-por-malha”, porque cada problema contribui de maneira complexa no desempenho do processo como um todo, ou

seja, é difícil separar os problemas de desempenho da planta por malha. (Shoukat Choudhury et al., 2005)

O primeiro passo para melhoria de desempenho da malha está em auditar. Para isso, inúmeras ferramentas podem ser utilizadas para gerar índices de desempenho, desde uma simples análise estatística a modelos complexos de análise de desempenho, tais como variância mínima (Coelho et al., 2006). Com esses índices, é possível fazer o diagnóstico do que está prejudicando o desempenho, como fricção da válvula, válvula superdimensionada, controlador mal ajustado e oscilações vindas de outras malhas, sendo que nesta é fundamental encontrar a causa raiz do distúrbio (Garcia, 2008). Após, devem-se desenvolver ações para alcançar o desempenho desejado, encontrando formas de compensação ou correção do que está causando o desempenho insatisfatório. As ferramentas de auditoria para malhas devem possuir características que permitam maximizar a utilização de dados do processo e reduzir o tempo de atividade para auditoria (Pereira et al., 2011).

Aproximadamente 30% das malhas de controle são oscilatórias principalmente devido a não linearidades da válvula de controle, causadas por histerese, saturação da válvula, entre outros fenômenos. A identificação de falhas que ocorrem nas válvulas é fundamental para melhoria do desempenho da malha de controle. Mais do que identificar, quantificar a gravidade da falha permite que se faça a compensação correta no sistema (Bialkowski, 1993; Wang, G. e Wang, J., 2009).

2.5 Falhas comumente encontradas em válvulas de controle

Em geral, FDI é designado a esquemas de diagnóstico de falhas operacionais de um sistema dinâmico monitorando alguns aspectos do desempenho do sistema ou variáveis da operação, como temperatura crítica e pressão. Quando fica evidente que uma falha ocorreu (detecção), é preciso tomar a decisão sobre qual a causa dessa falha (identificação). O primeiro passo antes da determinação de um método de diagnóstico consiste em fazer um levantamento das falhas que podem ocorrer no sistema (Karpenko e Sepehri, 2002; Aubrun et al., 1995).

A seguir serão apresentadas as principais falhas encontradas em válvulas de controle.

2.5.1 Backlash

A falha denominada de *backlash* é o movimento relativo entre peças fixas da válvula devido à interação entre as partes mecânicas. O resultado da folga entre essas partes, quando se aciona um movimento reverso, é uma faixa sem variação do sinal de saída. Como resultado, há o surgimento de uma banda morta, que adiciona tempo de atraso à malha de controle e prejudica a qualidade de controle. Também, há o risco de os distúrbios causados pelo *backlash* se propagarem para outras malhas. O comportamento de uma válvula com *backlash* pode ser descrita pela seguinte relação:

$$\begin{aligned} \operatorname{Re}Y_N(a) &= \frac{1}{\pi} \left(\frac{\pi}{2} \arcsin \left(1 - \frac{d}{a} \right) + \left(1 - \frac{d}{a} \right) \sqrt{\frac{d}{a} \left(2 - \frac{d}{a} \right)} \right) \\ \operatorname{Im}Y_N(a) &= -\frac{d}{\pi a} \left(2 - \frac{d}{a} \right) \end{aligned} \quad (2.1)$$

onde a é a amplitude do sinal de entrada d a medida de banda morta, e $\operatorname{Re}Y_N$ e $\operatorname{Im}Y_N$ se referem ao sinal real e imaginário que descreve a falha (Hagglund, 2007; EnTech,

1998). Uma comparação entre a operação da válvula saudável e com *backlash*, além do efeito causado por essa falha, a banda morta, são apresentados na Figura 2.3.

Hagglund(2007) propõe um método para detecção de *backlash*. O procedimento de detecção é baseado em dados de operação normal, não sendo necessárias informações adicionais referentes ao processo, apenas os parâmetros do controlador. Um algoritmo para previsão da falha é proposto, baseado no monitoramento do ganho estático do sistema, onde variações consideráveis desse denunciam a falha. O trabalho apresentou também metodologia para compensação desta falha.

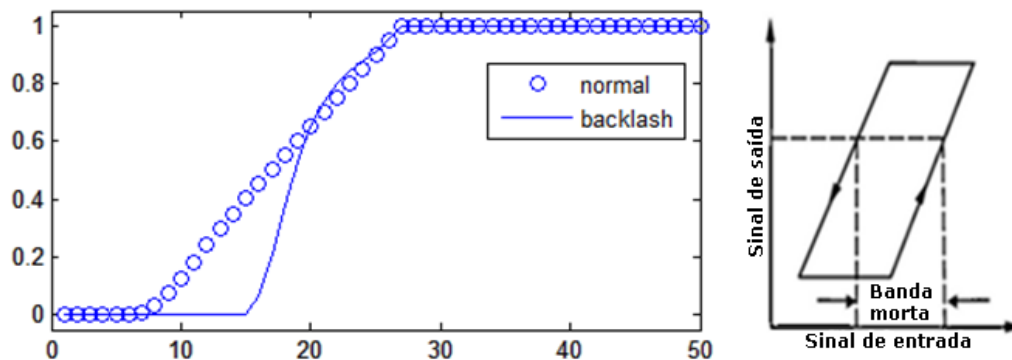


Figura 2.3: Comparação de válvula normal e com *backlash* e ênfase à banda morta gerada pelo backlash. (Adaptado de Aubrun et al., 1995)

2.5.2 Agarramento

O agarramento é definido pela ISA (2000) como a resistência a iniciar movimento, geralmente medido como a diferença entre os valores exigidos para superar o atrito estático e o atrito dinâmico. Já para a EnTech (1998) é a tendência ao movimento de “agarrar-deslizar” devido ao alto atrito estático, se comparado com o atrito dinâmico. O fenômeno causa movimento da válvula com resolução limitada. “Agarrar-deslizar” é a tendência da válvula de controle agarrar e, de repente, deslizar de forma abrupta quando uma força é suficiente para iniciar movimento, podendo superar o ponto de operação desejado. A Figura 2.4 mostra diferentes níveis de agarramento:




Figura 2.4: da esquerda para direita, diferentes níveis de agarramento: agarramento com undershoot, sem offset e overshoot (adaptado de Shoukat Chodhury et al., 2005)

Essa é a avaria mais incidente na válvula de controle e o fenômeno que mais causa distúrbios à malha, sendo assim muito pesquisado. Na literatura, há trabalhos visando sua detecção, quantificação, compensação e propostas de modelos para melhor representá-lo. Entre esses modelos, Olsson (1996) resumiu alguns modelos estáticos de fricção, no qual a fricção é modelada em função da velocidade v , da seguinte forma:

$$F_{fricção} = \begin{cases} F_{fricção}(v), & \text{se } v \neq 0 \\ F_e, & \text{se } v = 0 \text{ e } |F_e| \leq F_s \\ F_s \text{sgn}(F_e), & \text{se } v = 0 \text{ e } |F_e| > F_s \end{cases} \quad (2.2)$$

Onde $F_{fricção}$ é a força de fricção, F_e a força externa e F_s a força estática. A segunda linha da equação representa a fricção quando a haste está parada, enquanto a terceira linha representa a força quando a haste está prestes a se mover, por ter superado as forças estáticas e Coulombianas. O problema desse modelo é para o comportamento quando a velocidade é nula, visto que em simulações a velocidade nunca chega exatamente a ser zero.

Karnopp (1985) apresenta um modelo para ajudar a resolver o problema de velocidade nula. Para isso, representa valores numa faixa próxima a zero, criando assim uma zona morta. Em resumo, a ideia de Karnopp é a substituição do termo “ $v=0$ ” por “ $v < DV$ ”, onde DV deve ser estimado por simulação.

Em outra linha, foram criados modelos dinâmicos, no qual a força de agarramento pode variar enquanto o movimento do atuador está preso. No modelo de sete parâmetros, proposto por Armstrong-Hélouvy et al. (1994) o coeficiente de atrito estático aumenta com o tempo que a válvula fica parada, o que pode ser descrito pelas seguintes equações:

$$F_{fricção} = \begin{cases} \sigma_0 X x, & \text{(agarrando)} \\ \left\{ F_c + F_s(\gamma, t_d) \frac{1}{1 + \left[\frac{v(t-t_l)}{v_s} \right]^2} \right\} \text{sgn}(v) + F_v \times v, & \text{(deslizando)} \end{cases} \quad (2.3)$$

onde $F_s(\gamma, t_d) = F_{s,a} + (F_{s,\infty} - F_{s,a}) \frac{t_d}{t_d + \gamma}$

Sendo $F_{s,a}$ o coeficiente de atrito estático pouco antes do deslizamento e t_d o tempo morto. Além disso, o modelo requer sete parâmetros, que dão nome ao modelo: σ_0 é a rigidez pré-deslizamento, F_c é o coeficiente de atrito Coulombiano, $F_{s,inf} = F_s - F_c$ é o coeficiente de atrito no estado estacionário, F_v o coeficiente de atrito viscoso, v_s a velocidade de Stribeck, t_l o atraso de atrito, e γ determina o comportamento temporal do agarramento.

Como se nota, esse modelo é composto de uma equação para o agarramento, e outra para quando a válvula estiver deslizando. A troca de uma equação para outra não fica clara, o que pode requerer um oitavo parâmetro. Além disso, os estados do modelo devem ser inicializados apropriadamente a cada troca de uma equação para outra que, caso não for cuidadosamente feito, pode acarretar em erros.

O modelo de Lugre foi estudado nos trabalhos de Canudas de Wit et al. (1995), Olsson (1996) e Olsson et al. (1998). Nesse modelo, são descritos os efeitos da fricção com maior representatividade, principalmente para baixas velocidades e reversões de velocidade. O modelo é descrito por:

$$\begin{aligned} \frac{dz}{dt} &= v - \frac{|v|}{g(v)} z \\ g(v) &= \frac{1}{\sigma_0} \left[F_c + (F_s - F_c) e^{-\left(\frac{v}{v_s}\right)^2} \right] \\ F_{\text{fricção}} &= \sigma_0 \times z + \sigma_1 \frac{dz}{dt} + F_v \times v \end{aligned} \quad (2.4)$$

Onde z é a deflexão média das cerdas (superfície irregular), v a velocidade relativa entre as duas superfícies, $g(v)$ uma função positiva que especifica como a deflexão média depende da velocidade relativa, σ_0 é o coeficiente de rigidez, σ_1 é o coeficiente de amortecimento, F_c é o coeficiente de atrito Coulombiano, F_s o coeficiente de atrito estacionário e v_s a velocidade de Stribeck.

Um modelo físico detalhado possui muitos parâmetros desconhecidos, sendo geralmente difícil de estimá-los. Além disso, modelos muito complexos geralmente possuem integração numérica mais lenta, afastando seu uso para auditoria. Com isso, modelos mais simples têm sido propostos para que se façam análises. No modelo de Stenman (2003), a ideia básica é imitar o movimento de agarramento, baseado na equação:

$$x(t) = \begin{cases} x(t-1), & \text{se } |u(t) - x(t-1)| \leq d \\ u(t), & \text{caso contrário} \end{cases} \quad (2.5)$$

Onde $x(t-1)$ e $x(t)$ correspondem à posição passada e presente da haste, $u(t)$ a saída do controlador e d corresponde à faixa em que ocorre agarramento.

Já o modelo de Choudhury (2005) depende de dois parâmetros: S representa a banda morta criada pelo atrito estático e dinâmico da válvula, e J quantifica o súbito salto quando o atrito estático é vencido. Como esse modelo não é disponível tanto para sinais determinísticos quanto para estocásticos, Kano et al. (2004) propõem uma extensão do modelo com os mesmos parâmetros S e J . O modelo de Choudhury é representado pela equação 2.6. O algoritmo desse modelo é apresentado na Figura 2.5.

$$x(t) = x(t) - \text{sign}(\text{inclinação}) \frac{(S-J)}{2} \quad (2.6)$$

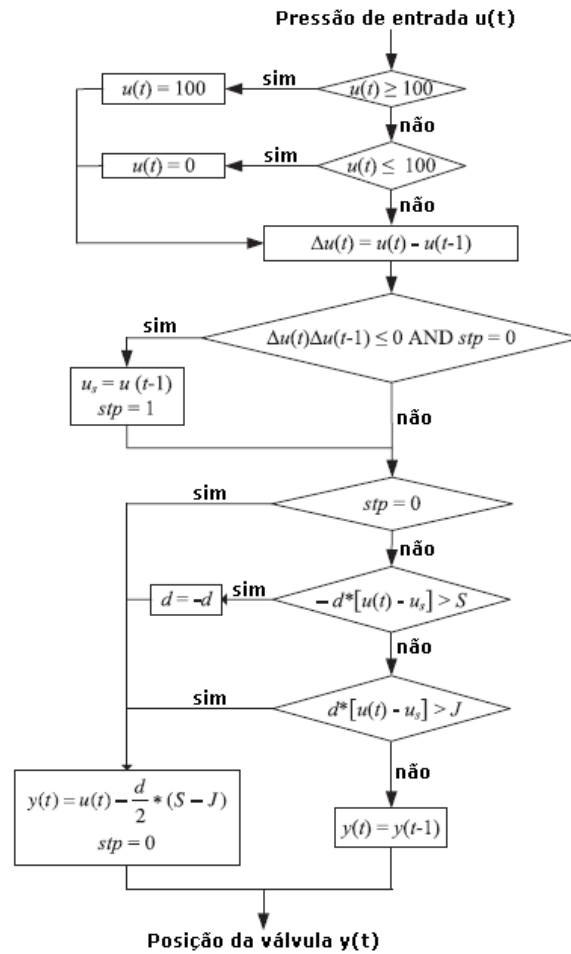


Figura 2.5: Algoritmo do modelo de Kano (Fonte: Garcia, 2008)

Garcia (2008) fez uma revisão sobre os modelos descritos acima e realizou testes propostos pela ISA, para assim avaliar quais dos modelos eram capazes de representar o agarramento. Para isso, realizou testes de rampa e pausa, *baseline* e degrau pequeno, tendo como resultado final que três modelos conseguiam representar fielmente a falha: Karnopp, Luge e Kano.

Graficamente, o modelo de Kano pode ser ilustrado conforme Figura 2.6, onde F_s representa a banda morta causada pelo atrito estático e F_D pelo atrito dinâmico. O parâmetro J é definido como a diferença $F_s - F_D$, enquanto S por $F_s + F_D$.

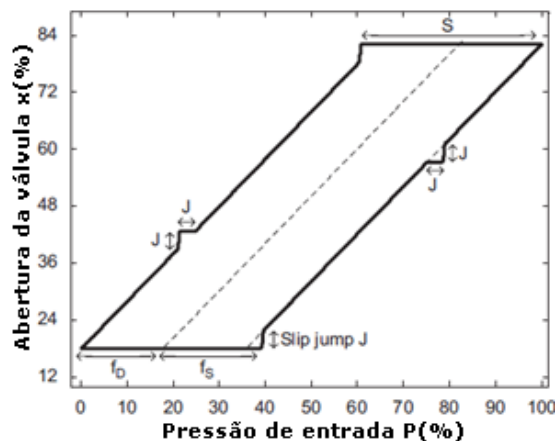


Figura 2.6: Agarramento conforme o modelo de Kano (Fonte: Garcia, 2008)

2.5.3 Suprimento de pressão

A falha de suprimento de pressão no atuador surge do bloqueio ou restrição das linhas de suprimento de ar devido ao aumento da demanda de ar localizada da planta. O suprimento influencia diretamente a quantidade de ar que pode ser entregue ao atuador. Conseqüentemente, a resposta transiente da válvula pode ser afetada por essa falha. Conforme a causa dessa falha, o grau de avaria é diferente, resultando em diferentes níveis máximos de abertura da válvula. (Fisher Controls Inc.,1999).

Karpenko e Sepehri(2002) utilizou classificadores baseados em rede neural para identificar três causas da falha de suprimento de pressão: suprimento de ar incorreto, vazamento do diafragma e bloqueio do respiro. Para isso, utilizou parâmetros de desempenho experimentais obtidos a partir do *software ValveLink*, da Fisher Controls Inc., associados à operação da válvula. Com a técnica de extração característica, é possível obter a relação entre esses parâmetros para cada falha, que então é classificada por uma rede neural.

Com isso, conseguiu-se detectar diferentes causas de uma mesma falha, conforme ilustrado na Figura 2.7:

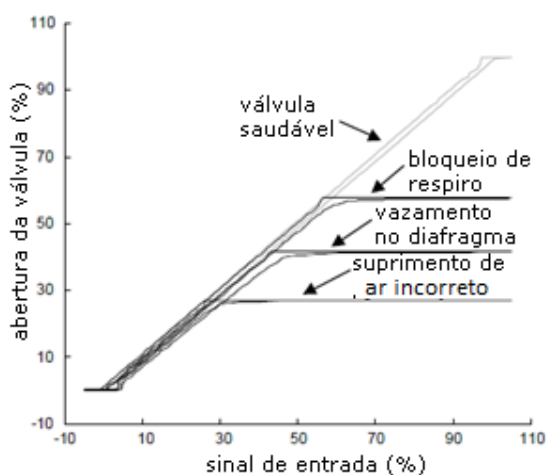


Figura 2.7: Falha de suprimento de pressão em diferentes graus (Fonte: Karpenko, 2002).

Conceitualmente, a ideia de extração característica é encontrar os parâmetros que dão a maior quantidade de informação sobre a condição do sistema. Um grande número de aproximações foi proposto para resolver o problema de extração correta dos dados. Uma delas é utilizar medidas discretas do estado do sistema como de uma rede neural utilizada como classificadora.

Uma aproximação mais elaborada é proposta por Le et al.(1998), onde uma codificação de predição linear é utilizada para gerar os parâmetros de entrada do classificador. Outros pesquisadores (Yen e Lin, 2000; Lin e Qu, 2000; Zhang et al., 2000) demonstram que transformadas *wavelets* são também ferramentas poderosas para extração característica. Em todos os casos, contudo, o que se percebe é que uma instrumentação de qualidade e em grande número pode ser necessária para que se obtenham parâmetros confiáveis e assim a extração característica seja efetiva.

2.6 Técnicas de FDI

Muitos trabalhos acerca de FDI são encontrados na literatura, como Hagglund (2007), Dustegor et al. (2005) e Karpenko e Sepehri (2002), propondo novas técnicas ou simplesmente aperfeiçoando existentes. Dentre todos os propósitos, os estudos podem ser divididos entre os que utilizam modelos do sistema e os que utilizam apenas dados de operação rotineira. Em todos os casos, a ideia básica é comparar o estado atual da válvula com sua operação normal identificar variáveis características de cada falha. (Hafaifa et al., 2012).

2.6.1 Detecção baseada em modelo

As técnicas de FDI baseadas em modelos levam em conta a modelagem de operação normal do sistema e a posterior inserção de parâmetros que descrevem comportamentos não lineares (falhas), causados, por exemplo, pela banda morta. A geração de modelos apresenta a vantagem de permitir detectar falhas com maior precisão, além de melhor detalhamento da falha. Um ponto fraco das técnicas de modelagem é que elas geralmente são restritas a sistemas lineares e não lineares passíveis de serem linearizados em algum ponto de operação. Além disso, em casos onde há pouca informação sobre o modelo analítico, a técnica se mostra problemática. (Frank, 1990; Aubrun et al., 1995)

A técnica mais popular de FDI baseada em modelo é proposta por Frank (1990). Nela, uma informação *a priori* matemática do sistema é utilizada para a modelagem do sistema normal. Baseados nesse modelo, então, são feitas aproximações para estimação de parâmetros ou estado para assim facilitar a comparação entre o processo real e o modelado e assim detectar falhas. Essa comparação pode ser usada também para gerar um vetor de resíduos sobre qual a causa da falha que pode ser identificada por métodos estatísticos e geométricos. (Isermann, 1997; Leonhardt e Ayoubi, 1997)

Aubrun et al.(1995) modelou, baseado no sistema estático e dinâmico, a faixa de operação normal da válvula. Para isso, utilizou as variáveis de entrada, de saída e parâmetros do controlador. A dificuldade encontrada foi determinar os parâmetros dessa faixa de operação, sendo então utilizado um algoritmo em lógica Fuzzy para determinar estes. Esse estudo mostrou-se eficiente para monitorar desvios do *setpoint*.

Hafaifa et al.(2012) desenvolveu um sistema de supervisão de falhas baseado em redes neurais para gerar indicadores de avarias em válvulas. Para gerar esses indicadores, os resíduos foram analisados através do acompanhamento de quatro variáveis de entrada e duas de saída, o que permite avaliar a condição do sistema. Após uma série de testes, foi possível obter um bom modelo para refletir a operação de uma válvula de controle.

2.6.2 Monitoramento de variáveis

Para superar as limitações dos algoritmos baseados em modelo, alguns pesquisadores têm proposto modelos caixa-preta, baseados em redes neurais para avaliação de válvulas, como Borairi e Wang (1998), Bernieri et al.(1994), assim como McGhee et al. (1997). Estes utilizaram uma rede multicamadas para modelar o torque de uma válvula rotativa. Esse tipo de modelo mostra-se útil para detecção de quando uma situação de falha ocorre, mas não para identificar qual a falha.

Redes neurais podem ser usadas de maneira diferente para resolver o problema de FDI: ao invés de serem usadas para gerar modelos do sistema, podem ser implementadas

como classificadores. Nesse caso, um conjunto de parâmetros que contém informação sobre as condições operacionais do sistema em consideração são primeiramente obtidos para operação normal assim como para um número de condições de operação de falhas. Se bem selecionados, esses conjuntos de parâmetros vão conter não só informação capaz de detectar falhas, mas também informação que pode ser usada para identificar a causa da falha. Os valores específicos de cada parâmetro nos conjuntos são como “impressões digitais” que o sensor é capaz de identificar a falha. Essa técnica também mostra como atrativo não necessitar de regras heurísticas para seu funcionamento. (Karpenko e Sepehri, 2002)

Tão importante quanto identificar falhas, é diagnosticá-la e quantificar sua magnitude. Para isso, Dustegor et al. (2005) propuseram análise estrutural para identificar falhas. No trabalho, foi utilizado o banco de dados Damadics, com 19 falhas possíveis, elaborado pelo WUT *Team* (2001). A partir dessa base, foi construída uma matriz contendo as falhas e as variáveis disponíveis. Fazendo operações nessa matriz, foi possível isolar a maioria das falhas, não tendo êxito para apenas duas falhas.

Ling et al.(2007) montou um sistema capaz de detectar quatro tipos diferentes de falhas que ocorrem em válvulas: banda morta, backlash, vazamento e bloqueio. Para isso, foi preciso medidas das variáveis do sistema vazão, variável de controle e set-point. Para a classificação individual das falhas, foram extraídas características geométricas dos sinais de medida. Com base nesses dados, foram aplicados testes de hipótese estatística para diferenciar as falhas.

3 Materiais e Métodos

O objetivo principal desse trabalho é criar uma ferramenta para detectar e identificar as principais falhas que ocorrem em válvulas de controle: agarramento, *backlash*, e falha de suprimento de pressão, inédito na literatura. Para isso, é necessário o auxílio de um *software* para a modelagem das falhas e criação algoritmos de resposta para a detecção e identificação de cada falha, o qual será baseado em redes neurais. Assim, é necessário também que este permita o treinamento de uma rede neural artificial (RNA) para criação da ferramenta.

3.1 Software utilizado

Para a realização desse trabalho, foi utilizado o programa MATLAB 2009, bem como o Simulink. O MATLAB (abreviatura de *Matrix Laboratory*) é desenvolvido pela companhia The MathWorks e se trata de um *software* de alta performance para resolução de problemas ligados a cálculo numérico.

3.2 Modelagem das falhas

Como toda ferramenta de detecção e identificação de falhas, é preciso ter uma base de dados para que se possa comparar o sistema dinâmico operando de forma normal e das possíveis falhas frente a diferentes plantas e controladores, para assim elaborar um modelo caixa-preta eficiente. A estratégia adotada é simular tais condições variando os parâmetros relacionados à respectiva avaria, planta e controlador, quando em malha fechada, coletando o sinal de entrada (*up*) e de saída (*yp*) que são as variáveis que se tem acesso em uma planta real. Nenhuma informação sobre o posicionador da válvula foi utilizada. Subsequentemente, índices característicos serão propostos para criação de modelo de falhas.

A seguir é mostrado como foi feita a modelagem e simulação de cada condição.

3.2.1 Válvula com operação normal

A primeira condição de simulação criada é de um sistema íntegro, sem perturbações causadas por eventuais falhas. Os dados gerados nessa simulação servem como base de comparação dos sistemas com avarias que serão gerados, além de servir para o teste de análise se a ferramenta de FDI está funcionando corretamente.

Para elaboração dos dados, optou-se por utilizar em todas as simulações um sinal de entrada na forma senoidal, da seguinte maneira:

$$up = \text{sen}\left(\frac{2\pi x}{256}\right) \quad (3.1)$$

$$0 \leq x \leq 5000$$

A escolha por esse formato de entrada se mostrou o mais adequado nesse trabalho, pois se torna útil analisar o comportamento de cada simulação nas condições de válvula totalmente aberta ($yp=1$) e totalmente fechada ($yp=-1$), conforme será explicado em cada falha. Optou-se por tal formato visando minorar o impacto do teste no sistema, sendo que este distúrbio não acarreta alteração da média do processo, apenas variação transiente. Sua magnitude deve ser superior à magnitude dos distúrbios e ruído. Testes utilizando apenas dados de operação rotineira foram realizados, mas não apresentaram bons resultados.

Quanto à planta, optou-se por um sistema de primeira ordem com ganho unitário e constante de tempo variável, isto é:

$$G(s) = \frac{1}{\tau s + 1} \quad (3.2)$$

Sendo τ a dinâmica do sistema. Então, geraram-se dados alterando os valores dos diferentes parâmetros possíveis de serem modificados. No caso de válvula normal, há um único parâmetro a ser modificado, que é a dinâmica do sistema.

Tabela 3.1: Parâmetros alterados na simulação de válvula normal.

Parâmetro	Valor Inicial	Passo	Valor Final
τ	1	0,4	101

Decidiu-se primeiramente por manter o sistema em malha aberta, pois a malha fechada consegue compensar uma parcela da falha, tornando as diferenças menos perceptíveis para elaboração de índices da ferramenta de detecção. No entanto, para o teste de qualidade da ferramenta, os mesmos sistemas em malha fechada foram simulados.

Para cada variação de algum dos parâmetros, era realizada a simulação e coletados o sinal de entrada do sistema (up) e o sinal de reposta na saída (yp). Armazenar a variável intermediária do processo (xp) seria valioso para se diferenciar cada uma das falhas, mas em sistemas reais dificilmente se tem acesso a essas variáveis, optando-se então por não armazená-las.

É ilustrada na Figura 3.1 a implementação do diagrama de blocos no Simulink, bem como o gráfico das duas principais variáveis de uma simulação:

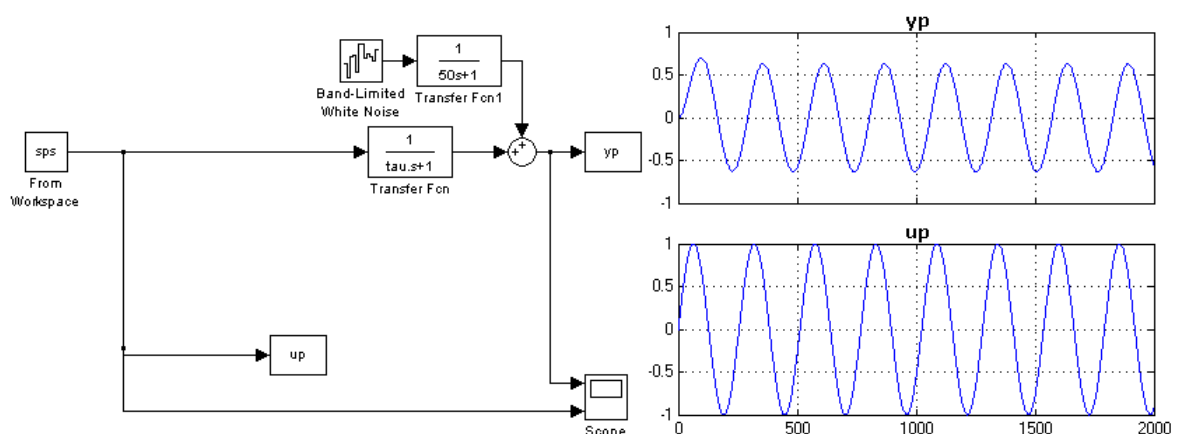


Figura 3.1: Sistema em operação normal implementado em Simulink (esquerda) e resposta das variáveis do processo para (direita)

3.2.2 Backlash

Para a modelagem e geração de dados nas condições de mau funcionamento da válvula, utilizaram-se as mesmas condições de entrada da válvula normal, para depois encontrar as diferenças entre as curvas obtidas.

Para representar o *backlash*, foi inserido antes da dinâmica do sistema o bloco que representa essa falha. Ela já faz parte da biblioteca do Simulink e o parâmetro a ser alterado nesse bloco é o tamanho da banda morta, intitulada na simulação por *dbw* (*dead band width*). Também é descrito quando essa banda morta surge na simulação, que é justamente quando há inversão no sinal de entrada, a principal característica de ocorrência do *backlash*. Com isso, a entrada do sistema na forma senoidal se mostra ideal para se acentuar as características dessa falha. Para geração dos cenários com *backlash*, os parâmetros foram modificados da seguinte maneira:

Tabela 3.2: Parâmetros alterados na simulação de válvula com *backlash*.

Parâmetro	Valor Inicial	Passo	Valor Final
τ	10	10	100
dbw	0,1	0,1	1,1

A dinâmica foi alterada de forma diferente ao da válvula normal com um único propósito: manter a quantidade de simulações de cada cenário próximas, no caso, de 250 simulações.

O diagrama de blocos implementado no Simulink é ilustrado na Figura 3.2 assim como o comportamento do sinal de entrada, *up*, de meio de processo, *xp*, e de saída, *yp*, para uma simulação:

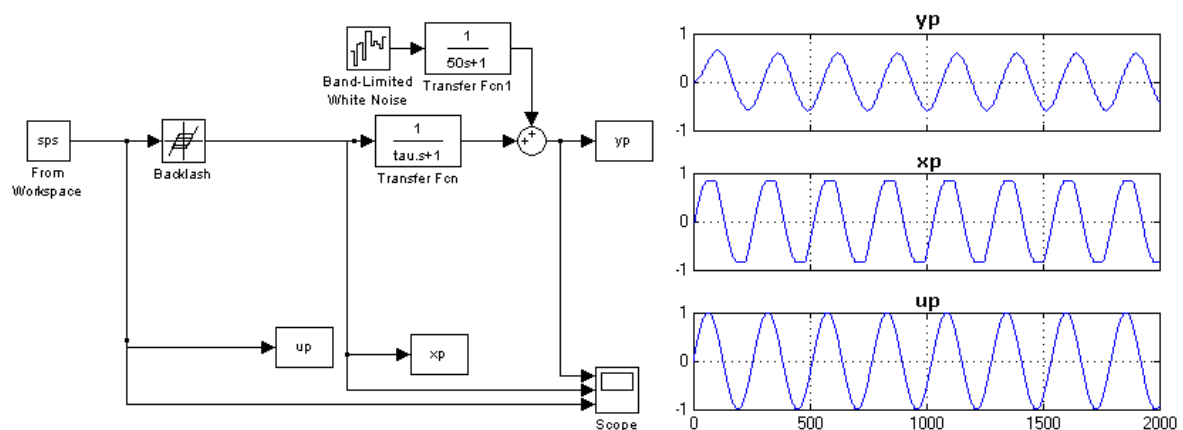


Figura 3.2: Sistema em operação com *backlash* implementado em Simulink e resposta das variáveis do processo.

3.2.3 Válvula com agarramento

O processo de modelagem de uma válvula com agarramento é similar ao do *backlash*: é preciso adicionar um bloco de simulação antes da planta que represente fielmente a falha. Porém, como não há um bloco disponível na biblioteca do Simulink que contemple essa falha, criou-se um bloco de Matlab *Function*. Como são muitos os modelos encontrados para a modelagem de agarramento, optou-se por um que fosse mais simples, para não sobrecarregar a simulação, mas que fosse capaz de representar o agarramento em qualquer situação. Assim, analisando-se o trabalho feito por Garcia (2008), optou-se pelo modelo de Kano(2004).

A elaboração do algoritmo de agarramento foi baseada no respectivo fluxograma, dado na Figura 2.5. Com isso, os parâmetros que podem ser alterados nesse bloco são J , que quantifica o súbito salto quando o atrito estático é vencido, e S , que representa a banda morta criada pelo atrito estático e dinâmico da válvula, além da dinâmica do sistema.

Tabela 3.3: Parâmetros alterados na simulação de válvula com agarramento.

Parâmetro	Valor Inicial	Passo	Valor Final
τ	10	10	100
S	0,1	0,2	0,9
J	0,1	0,2	0,9

Com os passos dessa forma, mais uma vez se mantém a quantidade de simulações próxima a dos outros cenários. O diagrama de blocos e gráfico de uma simulação é mostrado na Figura 3.3:

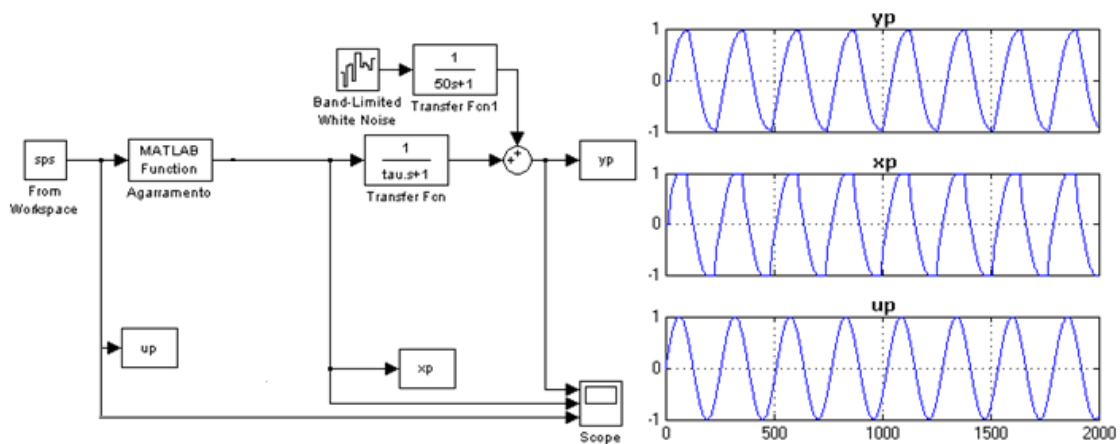


Figura 3.3: Sistema em operação com agarramento implementado em Simulink(esquerda) e resposta das variáveis do processo para valores aleatórios da simulação (direita)

3.2.4 Válvula com problema de suprimento de pressão

Um algoritmo para descrição matemática do problema de suprimento de pressão não foi encontrado na literatura. No trabalho de Karpenko (2004), os dados foram gerados em uma válvula de controle real, provocando falhas de suprimento de pressão. Para isso, utilizaram-se caminhos de ar para simular vazamentos e *bypass*. Nesse trabalho, para gerar a simulação de vazamento, foi proposta uma função matemática para representar o comportamento observado graficamente dessa falha.

A ideia para geração desse vazamento em Simulink é inserir uma equação que descreva o vazamento, como função não-linear antes da planta. A equação utilizada para isso foi:

$$y = \begin{cases} u, & \text{se } u \leq P_{Lim} \\ u - k_{vaz} \sqrt{u - P_{Lim}}, & \text{se } u > P_{Lim} \end{cases} \quad (3.3)$$

Onde u se refere à variável de entrada na válvula, tida como a pressão fornecida para abertura e fechamento dela. Entre os outros parâmetros para a simulação dessa falha

está P_{Lim} , que é a pressão limite a partir da qual ocorre vazamento. Analisando-se essa variável, pode-se perceber que quanto mais crítica a situação da válvula, menor será o valor do parâmetro. Já a constante k_{vaz} é um parâmetro análogo ao C_v de uma válvula: quanto maior seu valor, maior o vazamento, tornando assim a falha mais evidente. Os parâmetros utilizados para descrição dos cenários de falha de suprimento de ar estão listados na Tabela 3.4.

Tabela 3.4: Parâmetros na simulação de válvula com vazamento.

Parâmetro	Valor Inicial	Passo	Valor Final
τ	10	10	100
k_{vaz}	0,1	0,2	0,9
P_{lim}	0,1	0,2	0,9

O formato de entrada senoidal mais uma vez se justifica para esse tipo de falha, que ocorre quando se atinge o pico de operação, ou seja, abertura total da válvula. O diagrama de blocos implementado em Simulink, bem como o escopo de uma simulação é apresentado na Figura 3.4:

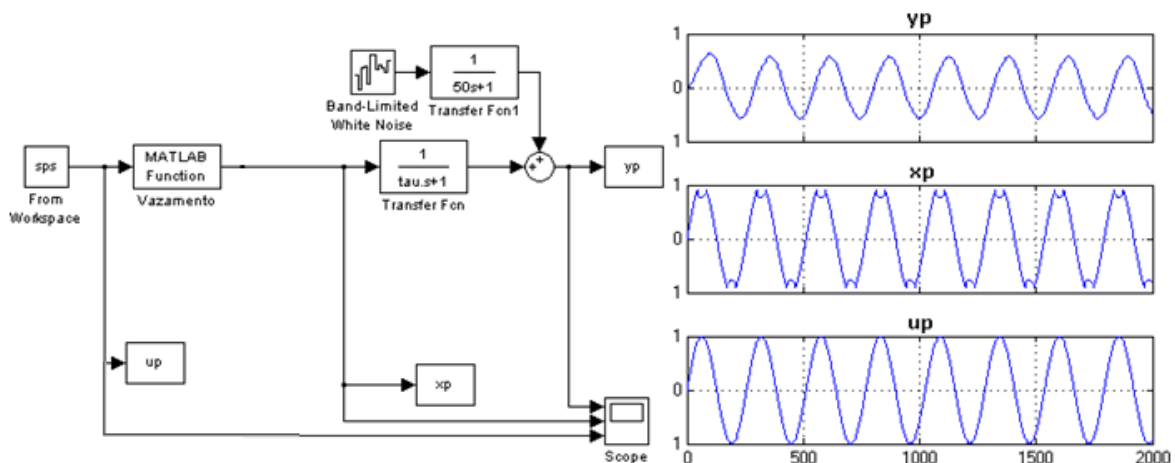


Figura 3.4: Sistema em operação com vazamento implementado em Simulink e resposta das variáveis do processo para uma simulação.

Além de vazamento, simulou-se a falha de suprimento de pressão como a saturação do atuador da válvula. Esse tipo de situação pode ocorrer devido a vários fatores, como peças internas com defeito e desgaste. Ela tem comportamento muito semelhante ao vazamento: em ambos os casos, a válvula não consegue abrir/fechar totalmente, saturando antes de seu limite. O que difere uma falha da outra está na maneira como ocorre essa saturação: na falha de vazamento, essa saturação ocorre de forma suave, que pode ser explicado pela raiz encontrada na equação (3.3) que descreve a falha. Já quando ocorre problema no atuador, essa saturação é abrupta, visto que o movimento cessa sem desacelerar como no vazamento.




Figura 3.5: Abertura de uma válvula com vazamento e saturação do atuador.

Para criação dessa falha, inseriu-se um bloco de saturação antes da dinâmica do sistema, com o parâmetro de saturação P_{sat} . Nessa simulação, os parâmetros foram alterados segundo a Tabela 3.5.

Tabela 3.5: Parâmetros alterados na simulação de válvula com saturação do atuador.

Parâmetro	Valor Inicial	Passo	Valor Final
τ	10	2,5	100
P_{sat}	0,1	0,1	0,9

Verifica-se que quanto menor o valor de P_{sat} , pior é a condição da válvula, que consegue atuar em uma faixa de operação cada vez menor. A implementação em Simulink, bem como o gráfico da simulação são apresentados na Figura 3.6:

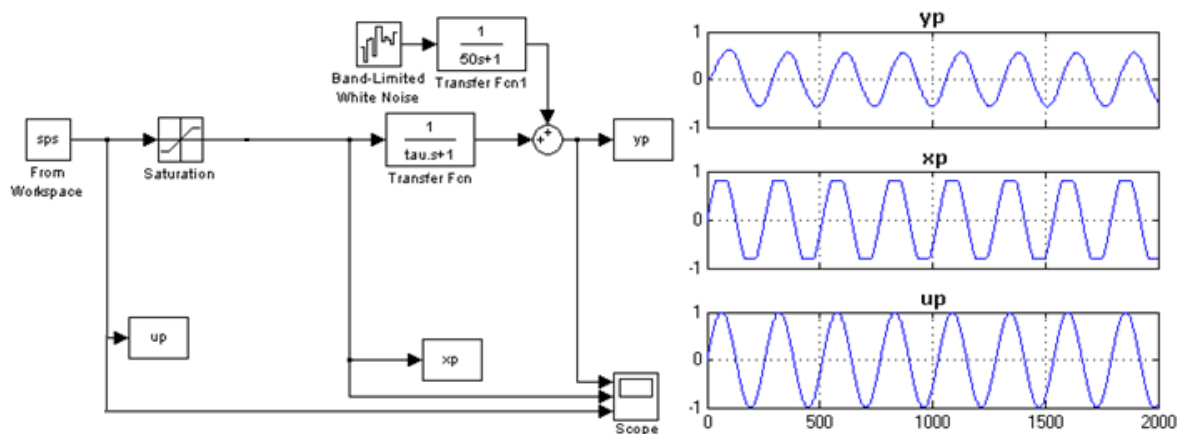


Figura 3.6: Diagrama de blocos da falha de saturação do atuador e resposta das variáveis do processo em uma simulação.

3.2.5 Malha fechada

Foram gerados também dados para a simulação de todas as condições em malha fechada. Essas simulações não foram tomadas como base para a geração dos índices para detecção, visto que em malha fechada as diferenças entre falhas são menores. Elas serviram para testar a qualidade da ferramenta de FDI em uma condição de malha fechada, para assim inferir se os índices escolhidos servem para as duas condições de operação.

Os parâmetros adicionais que podem ser alterados nessa nova simulação são referentes ao controlador: o ganho do controlador, kc , e o termo de integração do controlador, τ_i , que foi ajustado de acordo com o valor da dinâmica do sistema. O termo derivativo foi mantido em zero, visto que o principal objetivo é ver efeitos do sistema, e não do controlador (Hagglund, 2007). Esses parâmetros foram alterados conforme a Tabela 3.6.

Tabela 3.6: Parâmetros do controlador alterados na simulação de malha fechada.

Parâmetro	Valor Inicial	Passo	Valor Final
τ_i	conforme τ	conforme τ	conforme τ
kc	1	1	4

Vale ressaltar que o bloco PID é escrito no Simulink de maneira diferente ao padrão paralelo dos controladores, da seguinte forma:

$$P + \frac{I}{s} + D \cdot s \quad (3.4)$$

Onde P se refere ao termo proporcional, I a parcela integrativa e D ao termo derivativo. Com isso, P foi ajustado com o valor de kc e I pela razão $\frac{kc}{\tau_i}$, para assim ficar-se com a forma convencional de se representar um controlador PID paralelo. Assim, as simulações em Simulink ficaram com o seguinte *layout*:

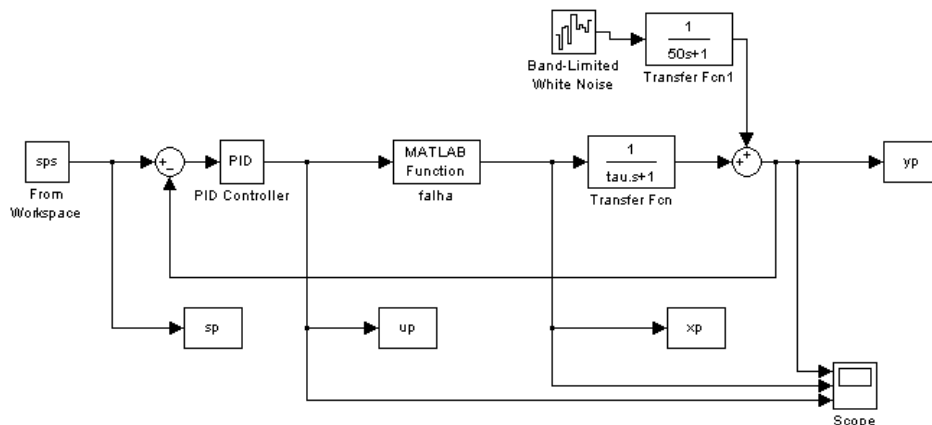


Figura 3.7: Implementação das simulações em malha fechada.

3.2.6 Adição de ruído

Por fim, decidiu-se gerar dados em malha fechada com adição de ruído, para verificar a qualidade da metodologia em uma condição mais próxima a realidade encontrada na indústria. Para isso, inseriu-se um ruído wnp (*white noise power*) nos valores de 0,05 até 0,20, com aumento de 0,05 entre cada simulação. Com isso, há três classes de dados que serão utilizadas na criação e verificação da qualidade da ferramenta, como mostrado na Tabela 3.7.


Tabela 3.7: Classes de dados geradas

Classe	Característica
1	Malha aberta
2	Malha fechada
3	Malha fechada com ruído

3.3 Estratégia de detecção

Para a criação da estratégia de detecção de falhas e, além disso, identificação de qual falha ocorreu, é necessário elaborar indicadores capazes de diferenciar algumas características que sejam como “impressão digital” da falha. Em outras palavras, é preciso encontrar o formato de um sinal disponível que seja peculiar da falha, para que assim não se confunda qual falha ocorreu. Como a entrada (up) é mantida fixa no formato de seno, a saída (yp) é o sinal que deve ser analisado. A ideia é repassar esses indicadores para um algoritmo de reconhecimento de padrões, neste caso uma rede neural, que será utilizada para geração da predição da falha.

É preciso analisar graficamente o conjunto de simulações para que se formulem indicadores eficientes para a diferenciação das falhas. Buscou-se em todas as condições, desde válvula normal até todas as falhas, manter-se o número próximo a 250 simulações. Em uma simulação contendo todas as situações possíveis, desde a válvula operando normalmente e todas as possíveis falhas que foram modeladas nesse trabalho, obtém-se um gráfico como o da Figura 3.8 para comparação das falhas. Essa é apenas uma ilustração com alguns parâmetros de simulação, ou seja, conforme alteram-se estes, o gráfico tende a mudar sua forma.

**Figura 3.8:** Comparação entre as possíveis falhas e de válvula normal.

Como características do sistema, como sua dinâmica e o ganho, não são informações sempre disponíveis em sistemas reais, é preciso buscar indicadores que sejam independentes desses fatores, para que assim possam ser aplicados em qualquer situação real. Com isso, os melhores índices para a resolução do problema são apresentados abaixo.

3.3.1 Índice 1: Inclinação no topo e vale

O primeiro índice criado para isolamento das falhas se refere à inclinação da curva no topo e no vale. Esse índice mostrou valioso, pois independente dos parâmetros utilizados na simulação, verificou-se que no caso da falha de agarramento a inclinação no topo era diferente da qual ocorria na simulação normal, conforme ilustrado na Figura 3.9. Já as falhas de suprimento de pressão e *backlash* não mostraram significativas diferenças nesse índice, assemelhando-se ao comportamento da válvula normal.




Figura 3.9: Inclinação no topo da simulação para diferentes falhas.

Inicialmente, não se obteve êxito no isolamento das falhas com a utilização desse e dos demais índices que serão apresentados. Para melhorar a acurácia desse índice, decidiu-se então gerar o seno com igual frequência equivalente à onda dente de serra padrão do agarramento e sua fase, utilizando-se para isso a Transformada Rápida de Fourier.

Tendo os dados da simulação e do seno gerado, foi possível colocar todos os parâmetros sob uma mesma base. O índice resultante (I_1) é:

$$I_1 = \frac{Inclt_{sim}}{Inclt_{seno}} \quad (3.5)$$

onde $Inclt_{sim}$ se refere à inclinação no topo da curva da simulação e $Inclt_{seno}$ ao seno correspondente de cada simulação, conforme ilustrado na Figura 3.10.




Figura 3.10: Primeiro índice aplicado nos sinais de agarramento e normal.

3.3.2 Índice 2: Inclinação na origem

O segundo índice criado para isolamento das falhas é o da inclinação da curva no ponto de $yp=0$. Esse índice mostrou-se importante para diferenciar as falhas quando não chegam ao máximo do ponto de operação desejado (suprimento de pressão e *backlash*) e que ultrapassam o ponto de operação (agarramento). Inicialmente esse índice só era útil para diferenciar o agarramento do resto das simulações, conforme mostrado na Figura 3.11:




Figura 3.11: Inclinação em zero da simulação para diferentes falhas.

Entretanto, com o índice normalizado com seu seno equivalente, os índices das falhas de *backlash* e suprimento de pressão se diferenciaram da de válvula normal, pois como não atingem o ponto desejado de operação, com a normalização elas acabam se estendendo na vertical, ficando assim com uma inclinação maior do que a operação normal em zero. O segundo índice (I_2) pode ser quantificado como:

$$I_2 = \frac{Inclz_{sim}}{Inclz_{seno}} \quad (3.6)$$

Onde $Inclz_{sim}$ se refere à inclinação da curva da simulação em zero e $Inclz_{seno}$ ao do seno correspondente.

3.3.3 Índice 3: Inclinação intermediária

Seguindo na busca por indicadores que diferenciem geometricamente todas as situações de simulação, elaborou-se um indicador que determinasse a inclinação intermediária das curvas.

Para isso, converteram-se os valores de yp em valores absolutos, dividiu-se então cada simulação em 5 faixas, e determinou-se a quantidade de pontos que ficavam dentro de cada faixa. Por fim, o índice foi determinado pela razão entre quantidade média de pontos na última faixa de separação pela quantidade média de pontos na primeira faixa de separação, isto é:

$$I_3 = \frac{NP_5}{NP_1} \quad (3.7)$$

Onde NP_5 é o número de pontos na última faixa em que foi dividida a simulação, no caso se referindo ao número de pontos próximo ao topo, e NP_1 o número de pontos primeira faixa, referindo-se então aos pontos próximos de zero. Como já há uma razão nesse

índice, não se tornou necessário normalizá-lo utilizando o seno equivalente de cada simulação.

3.3.4 Índice 4: Assimetria de curva – diferença

O quarto índice (I_4) criado para posterior treinamento da rede neural está associado a comparar a curva simulada com o seu respectivo seno puro. Com os dois sinais, calculou-se então a distância entre as duas curvas pela diferença de valores para uma saída yp na mesma posição de operação, ficando-se com:

$$I_4 = yp_{sim}(t90) - yp_{seno}(t90) \quad (3.8)$$

Onde $yp_{sim}(t90)$ e $yp_{seno}(t90)$ são os sinais de saída dos dados simulados e do seno equivalente para um mesmo tempo $t90$ que se refere ao primeiro ponto em que yp_{sim} atinge 90% do máximo. Quanto menor for a diferença nesse índice, menor a defasagem da curva.

3.3.5 Índice 5: Assimetria de curva – razão

O quinto índice utiliza os mesmos princípios do quarto índice. A diferença está em utilizar a razão entre a inclinação da curva da falha e de seu respectivo seno, na forma:

$$I_5 = \frac{(yp_{sim}(t90+1) - yp_{sim}(t90))}{(yp_{seno}(t90+1) - yp_{seno}(t90))} \quad (3.9)$$

Onde as expressões $(yp_{sim}(t90+1) - yp_{sim}(t90))$ e $(yp_{seno}(t90+1) - yp_{seno}(t90))$ se referem, respectivamente, às inclinações das curvas dos dados simulados e do seno no mesmo tempo $t90$ do índice anterior.

3.3.6 Índice 6: Atraso Inicial

O último índice foi criado para diferenciar as falhas de *backlash* e suprimento de pressão, pois como os valores dos índices supramencionados são muito semelhantes para elas, a ferramenta de detecção se torna muito susceptível a erros quanto a essas duas falhas. O que mais diferencia as duas falhas é o atraso inicial visto para o *backlash*, presente no início da simulação, conforme mostrado na Figura 3.12.

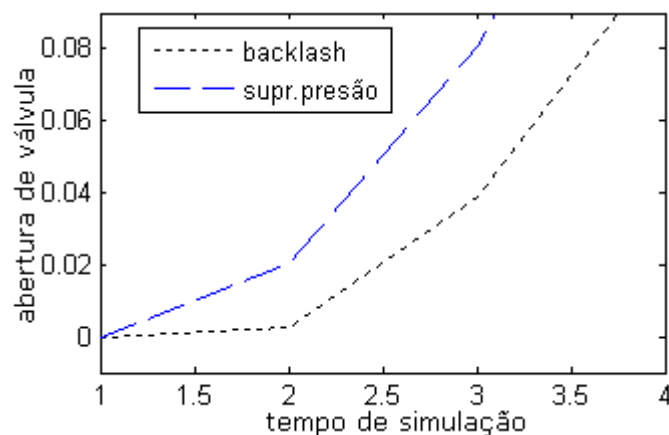


Figura 3.12: Tempo morto presente apenas no *backlash*.

Para isso, determinou-se o tempo do início da simulação até o primeiro pico. Criando-se a lógica para o intervalo de análise:

$$\begin{aligned}
 &tm = 0 \text{ } \} \text{valor inicial de tempo morto} \\
 &tm = tm + 0, \text{ se } |yp_i - yp_{i-1}| \geq 1.10^{-9} \\
 &tm = tm + 1, \text{ caso contrário} \\
 &I_6 = tm
 \end{aligned}
 \left. \vphantom{\begin{aligned} tm = 0 \\ tm = tm + 0 \\ tm = tm + 1 \end{aligned}} \right\} \text{lógica utilizada} \quad (3.10)$$

Onde, tm é o tempo morto, yp_i o valor de saída analisado no momento i e yp_{i-1} o valor de saída anterior. Assim, para uma tolerância de 1.10^{-9} , calcula-se o tempo morto presente em cada simulação.

3.4 Redes neurais Artificiais

As redes neurais artificiais são ferramentas poderosas para a elaboração de uma ferramenta de FDI. As RNA's tratam-se de técnicas computacionais que se baseiam em modelos matemáticos inspirados na estrutura neuronal de organismos inteligentes. A sua principal característica é adquirir conhecimento a partir da experiência obtida pelo treinamento da rede (Fausett, 1994).

Os neurônios que fazem parte da rede podem ser divididos em neurônios de entrada, que são os responsáveis por receber as características de entrada do treinamento, de saída, que fornecem as classes de respostas possíveis da rede, e intermediários, que fazem parte de uma camada oculta que interliga os outros dois tipos de neurônios. A quantidade dos neurônios na camada oculta é um parâmetro a ser determinado, assim como o tipo dos neurônios na rede. O esquema de funcionamento de uma rede neural artificial é apresentado na Figura 3.13:




Figura 3.13: Esquema de funcionamento de uma RNA.

3.4.1 Treinamento da rede neural

De forma simplificada, o treinamento fornece à rede neural entradas, que serão as variáveis posteriormente fornecidas à rede para a detecção e identificação das falhas, e a resposta desejada. Dessa forma, a RNA testa várias vezes a percepção da entrada. A cada acerto, os neurônios envolvidos no processamento ganham ponto, e a cada erro perdem. Dessa forma cria-se na rede a rotina de seguir o caminho com mais pontos, levando à geração da resposta correta. Com isso, quando um sinal desconhecido é inserido, a RNA deve ser capaz de reconhecer padrões semelhantes aos dados no treinamento para determinar a resposta correta.

Para o treinamento, as variáveis escolhidas como o conjunto de entrada são os índices que foram propostos anteriormente, conforme a Tabela 3.8:

Tabela 3.8: conjunto de entradas da rede neural.

Entradas					
I_1	I_2	I_3	I_4	I_5	I_6

Já a saída de rede foi classificada em quatro fatores diferentes, como é ilustrado na Tabela 3.9:

Tabela 3.9: conjunto de saídas da rede neural.

Saídas			
0	1	2	3
Normal	Agarramento	Backlash	Supr. Pressão

Para configuração da rede, utilizou-se a ferramenta *Neural Network Toolbox* (NNTool), biblioteca de ferramentas específica para configuração de Rede Neural do MATLAB. Para a utilização da NNTool na criação de rede, é preciso definir os padrões de entrada e saída, cujo tamanho de matriz deve ser o mesmo, definir os parâmetros de treinamento, que são a quantidade de neurônios na camada oculta, camadas que a rede irá possuir e o tipo dos neurônios. Por fim, é feito treinamento da rede, validação e teste da rede.

O número de camadas da rede neural foi definido como duas camadas, visto que não havia sentido configurar apenas uma camada, onde o efeito de rede não se é aproveitado. Mais do que duas camadas torna a rede complexa, o que não é vantajoso para uma ferramenta de detecção de falhas.

Decidiu-se por utilizar uma conexão *feedforward* como utilizado por Karpenko (2004), o que significa que a saída de um neurônio em uma camada não alimenta outro neurônio da mesma ou de outra camada diferente da qual é sua saída. O número de neurônios foi determinado pelo método de tentativa e erro, método mais comumente utilizado segundo Zhang et al.(1998). Como mencionado anteriormente, em cada treinamento obtém-se um resultado diferente, porque em cada treinamento as redes neurais têm desempenho diferente, visto que a inicialização é randômica dos pesos e bias. Com isso, variou-se de forma crescente o número de neurônios e se padronizou em fazer dez treinamentos consecutivos para cada rede configurada e, com o melhor resultado, escolheu-se a que possuía o valor máximo de correlação.

4 Resultados

Na detecção e identificação de falhas em válvulas de controle, o objetivo não é apenas sinalizar quando ocorre falha, mas também conseguir isolar as falhas para decidir com um grau de confiança considerável qual das falhas ocorreu. Para isso, alguns aspectos devem ser analisados para se verificar se a ferramenta criada tem desempenho satisfatório. Num primeiro momento, as redes serão treinadas e os coeficientes de regressão analisados. Caso apresentem valores adequados, uma análise minuciosa da capacidade de identificação da falha será realizada, utilizando-se gráficos de confusão.

4.1 Regressão da rede no treinamento

Em um primeiro momento, buscou-se determinar o número ideal de neurônios intermediários para configuração da rede neural. Para isso, utilizaram-se dados de malha aberta, onde no treinamento 70% dos dados desse conjunto são apresentados como entrada e os indicadores de falhas como as saídas desejadas. Assim, para redes com quantidades diferentes de neurônios na camada oculta, obtiveram-se os seguintes resultados coeficientes de regressão mostrados na Tabela 4.1.

Tabela 4.1: regressão de rede para malha aberta com diferente número de neurônios.

Desempenho da RNA	
Número de neurônios	Regressão (R ²)*
10	0,921
15	0,937
20	0,943
25	0,934
30	0,904

* Melhor regressão em 10 treinamentos sucessivos

A análise de regressão mede a correlação entre as saídas da rede e os resultados desejados, sendo que valores mais próximos a 1 significam uma boa aproximação. Analisando-se a Tabela 4.1, decidiu-se por utilizar a rede neural artificial contendo 20 neurônios, visto que foi o arranjo que apresentou melhor regressão em dez treinamentos sucessivos.

Além do sistema em malha aberta, analisou-se o desempenho da rede neural para um sistema mais usual na indústria. Para isso, testou-se em um sistema em malha fechada, e assim como para a malha aberta, buscou-se determinar o número ideal de neurônios na camada oculta para configuração da rede neural artificial. A Tabela 4.2 apresenta a qualidade das regressões para redes com quantidades diferentes de neurônios.

Tabela 4.2: regressão de rede para malha fechada com diferente número de neurônios.

Desempenho da RNA	
Número de neurônios	Regressão (R ²)*
10	0,943
15	0,937
20	0,952
25	0,938
30	0,934

*Melhor regressão em 10 treinamentos sucessivos

Analisando a Tabela 4.2 pode-se verificar que a regressão manteve-se satisfatória para esse novo cenário. Nesse treinamento com o sistema em malha fechada, mais uma vez mostra-se adequado utilizar 20 neurônios, com a qual se obteve uma regressão de mais de 0,95 na fase de treinamento.

Tendo-se escolhido o número de neurônios, pode-se então analisar outros aspectos de desempenho da rede.

4.2 Análise dos índices

Após se determinar o melhor número de neurônios intermediários para a rede, fez-se uma análise dos índices criados para se verificar há necessidade ou não de se utilizar todos. Para isso, analisaram-se as regressões do treinamento de todas as combinações possíveis, isto é, uma rede neural foi treinada para cada combinação possível, para diferentes números de entradas (1 a 6). A arquitetura da mesma foi igual a utilizada anteriormente.

A Tabela 4.3 sumariza os dados para análise exploratória dos índices, a qual mostra a melhor combinação para diferentes números máximos de índices, bem como a correlação obtida.

Tabela 4.3: performances dos treinamentos para diferentes variáveis de entrada.

Número de índices	Variáveis	R ² Treinamento
1	1	0,713
2	13	0,853
3	126	0,914
4	1356	0,933
5	13456	0,937
6	123456	0,943

Baseado na Tabela 4.3, verifica-se que todos os 6 índices de entrada são necessários para assegurar a performance do modelo de falhas criado.

Como era o esperado, com a utilização de apenas um índice o resultado não é satisfatório, pois nenhum dos índices obtém características diferentes para isolar todas as

falhas. Uma melhor detecção ocorre para 2 índices, entretanto o coeficiente de correlação ainda é insatisfatório. Caso o usuário busque um modelo de menor dimensão, 4 entradas podem ser usadas, mas há sensível perda de qualidade em relação ao modelo de 6. Verifica-se ainda que a primeira entrada é a mais importante, pois se mantém em todos os conjuntos ótimos. Além disso, há uma coerência na seleção de variáveis, visto que os conjuntos agregam variáveis com seu aumento, mantendo as mesmas do conjunto anterior. Excetua-se neste caso a rede de 3 neurônios. As melhores combinações para cada conjunto são mostradas no Apêndice 1.

4.3 Regressão de validação e de teste

Além da regressão do treinamento, pode-se avaliar esse fator nas etapas de validação e teste. Na validação, 15% dos dados de entrada são selecionados randomicamente e utilizados para medir a capacidade de generalização da rede e interromper o processo iterativo quando o desempenho da rede se tornar adequado ou constante.

Já na etapa de teste, os 15% restantes de dados de entrada são utilizados para medir o desempenho da rede durante e após a etapa de treinamento. Sob ponto de vista prático, estes dados podem ser vistos como a simulação do funcionamento real da rede. Para todas as etapas envolvidas, foram obtidos os seguintes resultados de regressão para malha aberta (veja Tabela 4.4):

Tabela 4.4: regressão em malha aberta de todas etapas de treinamento.

Desempenho da RNA com 20 neurônios	
Etapa	Regressão (R^2)
Treinamento	0,943
Validação	0,888
Teste	0,891

Esses resultados mostram desempenho satisfatório da rede neural treinada, visto que em todas as etapas os resultados foram similares, com desempenho sempre próximo a 0,90. Isso significa que a rede conseguiu aproximar as diversas saídas de forma satisfatória, determinando de forma correta qual falha ocorreu na maioria das vezes.

Para o segundo caso de análise, do sistema em malha fechada, obtiveram-se os seguintes resultados de regressão das etapas de treinamento (veja Tabela 4.5):

Tabela 4.5: regressão em todas etapas para 20 neurônios em malha fechada.

Desempenho da RNA com 20 neurônios	
Etapa	Regressão (R^2)
Treinamento	0,952
Validação	0,919
Teste	0,916

Pode-se perceber que o desempenho em todas as etapas do treinamento se manteve satisfatório, sempre acima de 0,91, demonstrando que a qualidade da rede neural se manteve mesmo com o novo cenário de malha fechada.

4.4 Matriz de confusão

Outra maneira de se analisar o desempenho das redes neurais é utilizando matrizes de confusão geradas pelo próprio Matlab, que mostram o número de classificações corretas e errôneas para cada classe de falhas. Além disso, é possível analisar qual falha foi a com menor índice de acerto na detecção e com qual falha foi confundida. Para realizar essa análise, utilizaram-se as mesmas redes anteriormente treinadas. A matriz para estudo em malha aberta é mostrada na Figura 4.1.

Confusion Matrix

Output Class	Normal	251 19.1%	0 0.0%	0 0.0%	2 0.2%	99.2% 0.8%
	Agarramento	0 0.0%	164 12.5%	0 0.0%	11 0.8%	93.7% 6.3%
	Backlash	0 0.0%	1 0.1%	228 17.4%	0 0.0%	99.6% 0.4%
	Supr. Pressão	0 0.0%	85 6.5%	0 0.0%	570 43.4%	87.0% 13.0%
		100% 0.0%	65.6% 34.4%	100% 0.0%	97.8% 2.2%	92.5% 7.5%
		Normal	Agarramento	Backlash	Supr. Pressão	
		Target Class				

Figura 4.1: matriz de confusão para dados em malha aberta.

Na matriz mostrada na Figura 4.1, as entradas 1, 2, 3 e 4 são, respectivamente, a válvula normal, com agarramento, com *backlash* e com problema de suprimento de pressão. Mais uma vez percebe-se o bom desempenho da rede neural. O último quadrado do canto inferior direito da matriz representa os acertos (valor superior) e a percentagem de erros (valor inferior) totais da matriz. Esse resultado significa que a RNA configurada pode classificar qual falha ocorreu com um grau de certeza de 92,5% no geral. Também, verifica-se que o desempenho é afetado pela detecção incorreta de algumas falhas de agarramento e suprimento de pressão.

Por fim, analisou-se a matriz de confusão para a simulação de malha fechada, a qual é mostrada na Figura 4.2.

Confusion Matrix

Output Class \ Target Class	Normal	Agarramento	Backlash	Supr. Pressão	
Normal	204 17.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
Agarramento	0 0.0%	588 49.3%	24 2.0%	23 1.9%	92.6% 7.4%
Backlash	0 0.0%	1 0.1%	264 22.1%	0 0.0%	99.6% 0.4%
Supr. Pressão	0 0.0%	11 0.9%	0 0.0%	77 6.5%	87.5% 12.5%
	100% 0.0%	98.0% 2.0%	91.7% 8.3%	77.0% 23.0%	95.1% 4.9%

Figura 4.2: matriz de confusão para dados de malha fechada.

Nota-se um ótimo desempenho da rede neural para o caso de malha fechada mais uma vez. O resultado significa que a RNA configurada pode classificar qual falha ocorreu com um grau de certeza de 95,1% no geral. Analisando-se entrada por entrada, o que se nota é que o resultado só não é melhor por se ter mais uma vez engano na detecção de suprimento de pressão, sendo detectado como agarramento em alguns casos.

Para as demais entradas, o resultado obtido ficou muito bom. Vale ressaltar que a entrada 1, de válvula sem avaria, o acerto foi de 100% e não se enganou com nenhuma falha, o que conclui-se que a tarefa de detecção de falha foi completada com êxito. A identificação de falhas apresentou a mesma performance, mas tratando-se de isolar três falhas, pode-se considerar o resultado satisfatório.

4.5 Adição de ruído

Como última análise, avaliou-se o desempenho do modelo treinado em malha fechada com dados gerados para diferentes intensidades de ruídos, aproximando-se assim de uma situação real. Com isso, quer-se observar até que ponto os índices escolhidos para o treinamento da rede geram um resultado satisfatório para a detecção e identificação das falhas. O termo de ruído, *wnp* (*white noise power*) foi variado de 0,05 até 0,20 de intensidade, como ilustrado na Figura 4.3:

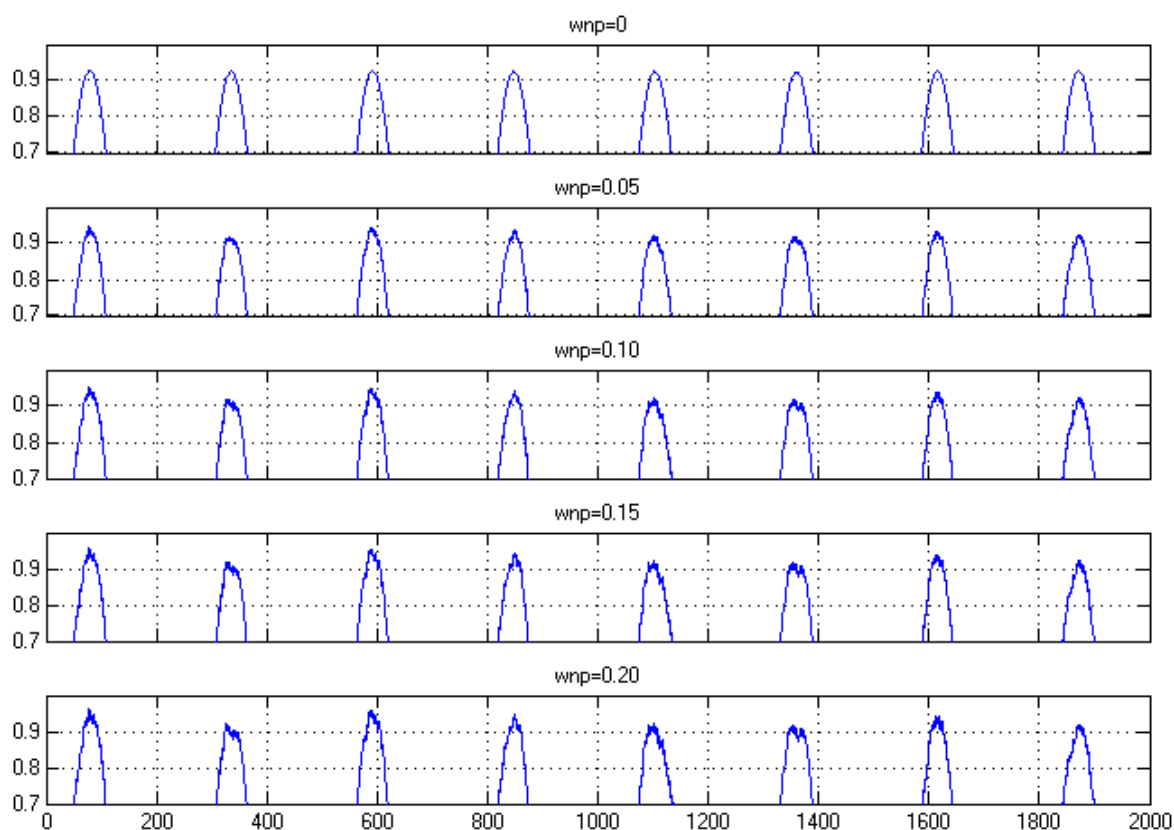


Figura 4.3: sinal de saída para diferentes níveis de ruído.

4.5.1 Regressão da rede com ruído

Em uma primeira análise, avaliou-se o desempenho da rede para diferentes magnitudes de ruído verificando-se os valores de regressão, cujos valores são apresentados na Tabela 4.6.

Tabela 4.6: regressão para diferentes níveis de ruído.

Ruído (wnp)	Razão Sinal/Ruído	R ² Teste
0	Inf.	0,926
0,05	2,256	0,912
0,1	1,128	0,904
0,15	0,752	0,906
0,2	0,564	0,876

O resultado de regressão demonstra que houve uma queda de desempenho da rede com o aumento de ruído, mas não chega a ser uma queda brusca de desempenho.

4.5.2 Matriz de confusão com ruído

Na análise da matriz de confusão para os diferentes ruídos, foram obtidos os seguintes resultados (ver Figura 4.4):




Figura 4.4: matriz de confusão para a diferentes intensidades de ruído.

Pode-se perceber que a qualidade da detecção decai com o acréscimo de ruído, mas não de forma expressiva. Isso pode ser explicado pelo ruído atrapalhar na determinação correta dos índices, e, conseqüentemente, da qualidade do treinamento da rede neural. Como é mostrado na Figura 4.3, o ruído atrapalha o sinal próximo aos picos, piorando assim a qualidade dos índices que dependem de sinais nessa região.

Em todos os cenários, obteve-se um desempenho superior a 81%, o que demonstra que a rede pode ser utilizada para as situações mais adversas de dados que pode se encontrar. Em sistemas reais, com ruído inferior ao que foi simulado e/ou com tratamento dos dados, é possível alcançar um desempenho semelhante ao do primeiro cenário.

5 Conclusões e Trabalhos Futuros

Neste trabalho, uma metodologia para detecção e diagnóstico de falhas em válvulas de controle, a partir de testes minimamente invasivos foi proposta. Outros trabalhos propostos e encontrados na literatura utilizam como ferramentas *softwares* especializados para geração de dados e proposição de algoritmos de detecção para uma falha específica, com melhor desmembramento de níveis desta. Nesse trabalho, buscou-se gerar os próprios dados com uma ferramenta de fácil acesso e manuseio, o Matlab, e geração de algoritmos de detecção para diferenciar quatro situações distintas: válvula saudável, com agarramento, com *backlash* e com problema de suprimento de pressão.

A ferramenta com rede neural artificial proposta mostrou-se com bom desempenho para o problema proposto: conseguiu detectar quando falhas ocorrem em válvulas de controle com quase 100% de confiança em todas as situações, e identificar qual falha ocorreu com grau de confiança de aproximadamente 90%, tendo esse grau piorado quanto maior a intensidade do ruído que acompanha o sinal de saída. Isso demonstra a importância de um tratamento de sinal em situações reais, o que auxilia no melhor desempenho da ferramenta.

A metodologia proposta para criação da ferramenta mostrou-se capaz de servir de base para a detecção e identificação de falhas em uma planta de processo real. Tendo-se um treinamento satisfatório, onde se garante um bom desempenho, as redes neurais podem ser conectadas com a planta para geração de resposta em tempo real.

Muitas possibilidades surgem com o desempenho satisfatório da ferramenta criada. Um trabalho mais detalhado, fazendo-se uma análise minuciosa dos índices criados pode verificar quais índices podem ser melhorados para melhor desempenho da ferramenta além da proposição de novos índices para melhor isolar as falhas de agarramento e suprimento de pressão. Também, testar a qualidade da ferramenta ramificando-se as três falhas gerais propostas em falhas mais específicas, necessitando-se para isso analisar o grau que caracteriza cada uma dessas falhas dentro das três.

Por fim, sugere-se também a extensão de tal metodologia para diferentes sinais de entrada, além do seno proposto. Espera-se que tal método seja base para futuros desenvolvimentos de um sistema global de detecção e diagnóstico de falhas em válvulas de controle, usando apenas dados de operação rotineira, sem a inserção de sinais na entrada.

6 Referências

As referências consultadas para a realização desse trabalho de conclusão de curso são listadas abaixo:

- [1] Armstrong-Hélouvry, B., Dupont, P., and Canudas de Wit, C., 1994, A survey of models, analysis tools and compensation methods for the control of machines with friction. *Automatica*, 30(7), 1083-1138.
- [2] Associação Brasileira de Manutenção e Gestão de Ativos - ABRAMAN , 2004, Apostila de Instrumentação.
- [3] Aubrun, C., Robert, M. and Cecchin, T., 1994, Fault Detection in a Control Loop, *Control Engineering Practice* 3(1995),1441-1446, Vandoeuvre,France.
- [4] Bernieri, A, D'Apuzzo, M., Sansone, L., and Savastano, M., 1994, A neural network approach for identification and fault diagnosis on dynamic systems, *IEEE Transactions on Instrumentation and Measurement* 43(6), 867-873.
- [5] Bialkowski, W. L., 1993, Dreams versus reality: a view from both sides of the gap. *Pulp and Paper Canada* (1994) vol.11, Boston, USA.
- [6] Borairi, M., and Wang, H, 1998, Actuator and sensor fault diagnosis of non-linear dynamic systems via genetic neural networks and adaptative parameter estimation technique, *IEEE Conference on Control Applications I* (1998) 278-282, Trieste, Italy.
- [7] Canuddas de Wit, C., Olsson, H., Aström, K. J., and Lischinsky, P., 1995, A new model of control systems with friction, *IEEE Transactions on Automatic Control*, 40(3), 419-425.
- [8] Coelho, A. A. R., Almeida, O. M., Coelho, L. S., 2000, Controlador nebuloso PID autoajustável com especificação de margem de fase e de ganho: implementação e análise de um processo não linear de luminosidade. CBA, pp. 747-752, Florianópolis.
- [9] Desborough, L. D., and Miller, R. M., 2002, Increasing customer value of industrial control performance monitoring – Honeywell's experience. *Chemical Process Control-VI*(2001) Vol.98, Tuscon, USA.
- [10] Dustegör, D., Frisk, E., Cocquempot, V., Krysander and M., and Staroswiecki, M., 2005, Structural analysis of fault isolability in the DAMADICS benchmark, *Control Engineering Practice* 14 (2006),597-608, Lille, France.
- [11] EnTech. (1998). EnTech control valve dynamic specification (version 3.0).
- [12] Fausett, L., *Fundamentals of Neural Networks: architectures, algorithms, and applications*. Englewood Cliffs, N. J.: Prentice-Hall International, 1994.
- [13] Fisher Controls Inc., 1999b. *Control Valve Handbook*, Fisher Controls International Inc., Iowa, USA.
- [14] Frank, P. M., 1990, Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy- A survey and some results, *Automatica* 26(3), 459-474.
- [15] Garcia, C., 2008, Comparison of friction models applied to a control valve, *Control Engineering Practice* 16 (2008) 1231-1243, São Paula, Brasil.
- [16] Hafaifa, A., Djeddi, A. Z., and Daoudi, A., 2012, Fault detection and isolation in industrial control valve based on artificial neural networks diagnosis, Djelfa, Algeria.
- [17] Hägglund, T., 2007, Automatic on-line estimation of backlash in control loops, *Journal of Process Control* 17 (2007) 489-499, Lund, Sweden.
- [18] Instituto Brasileiro do Petróleo – IBP, *Instrumentação Básica*
- [19] ISA. (2000). *Standard ANSI/ISA-75.36.01-2000. Test procedures for control valve response measurement from step inputs*.
- [20] Isermann, R., 1997, Supervision, fault-detection and fault-diagnosis methods- an introduction, *Control Engineering Practice* 5(5), 639-652.

- [21] Kano, M., Maruta, H., Kugemoto, H., and Shimizu, K., 2004, Practical model and detection algorithm for valve stiction, Proceedings of the 7th IFAC DYCOPS (CD-ROM), Boston, USA.
- [22] Karnopp, D., 1985, Computer simulation of stick-slip friction in mechanical dynamic systems. Transactions of the ASME- Journal of Dynamic Systems, Measurement and Control, 107(1), 100-103. California, USA.
- [23] Karpenko, M., and Sepehri, N., 2002, Neural network classifiers applied to condition of a pneumatic process valve actuator, Engineering Applications of Artificial Intelligence 15 (2002) 273-283, Winnipeg, Canada.
- [24] Le, T. T., Watton, J., and Pham, D. T., 1998, Fault classification of fluid power systems using dynamics feature extraction technique and neural networks, Journal of Systems and Control Engineering 212(2), 87-97.
- [25] Leonhardt, S., and Ayoubi, M., 1997, Methods of fault diagnosis, Control Engineering Practice 5(5), 683-692.
- [26] Lin, J., and Qu, L., 2000, Feature extraction based on morlet wavelet and its application for mechanical fault diagnosis, Journal of Sound and Vibration 234(1), 135-148.
- [27] Ling, B., Zeifman, M., and Liu, M., 2007, A Practical System for Online Diagnosis of Control Valve Faults, 46th IEEE Conference on Decision and Control (New Orleans, USA, 2007), Walpole, USA.
- [28] McGhee, J., Henderson, I. A., and Baird, A., 1997, Neural networks applied for the identification and fault diagnosis of process valves and actuators, Journal of the International Measurement Confederation 20(4), 267-275.
- [29] Olsson, H., 1996, Control systems with friction. Ph.D thesis. Department of Automatic Control, Lund Institute of Technology, Sweden.
- [30] Olsson, H., Åström, K. J., Canudas de Wit, C., Gäfvert, M., and Lischinsky, P., 1998, Friction models and friction compensation. European Journal of Control 3(4), 176-195. Lund, Sweden.
- [31] Pereira, G. G. M., Gomes, R. A. S., Carmo, M. J., and Oliveira, A. R., 2011, Por que a auditoria em malhas de controle seria mais importante no ensino da graduação do que o controle avançado?, XXXIX Congresso Brasileiro de Educação em Engenharia (Blumenau, SC, 2011), Leopoldina (MG), Brasil.
- [32] Ribeiro, M. A., Válvulas de Controle e Segurança, 1999, 5ª edição.
- [33] Shoukat Choudhury, M. A. A., Thornhill, N. F., and Shah, S. L., 2005, Modelling valve stiction, Control Engineering Practice 13 (2005) 641-658, London, UK.
- [34] Stenman, A., Gustafsson, F., and Forsman, K., 2003, A segmentation based method for detection of stiction in control valves. International Journal of Adaptive Control and Signal Processing, 17(7-9), 625-634.
- [35] Wang, G., and Wang, J., 2009, Quantification of Valve Stiction for Control Loop Performance Assessment, Beijing, China.
- [36] WUT Team, 2001, Damadics benchmark definition, <http://diag.mchtr.pw.edu.pl/damadics/>.
- [37] Yen, G. G., and Lin, K., 2000, Wavelet packet feature extraction for vibration monitoring, IEEE Transactions on Industrial Electronics 47(3), 650-667.
- [38] Zhang, J., Ma, J., and Yan, Y., 2000. Assessing blockage of the sensing line in a differential-pressure flow sensor by using the wavelet transform of its output, Measurement Science and Technology 11(3), 178-184.

7 Apêndice 1

Consta nesse apêndice a análise feita com todas as combinações possíveis dos indicadores para treinamento da rede neural.

Análise com 1 índice:

Tabela 7.1: regressão de treinamento para um índice.

Índice utilizado	R ² Treinamento
1	0,713
2	0,704
3	0,683
4	0,675
5	0,471
6	0,121

Análise com 2 índices:

Tabela 7.2: regressão de treinamento para dois índices.

Índices utilizados	R ² Treinamento	Índice utilizado	R ² Treinamento
13	0,853	45	0,737
12	0,852	26	0,731
14	0,828	36	0,715
15	0,825	46	0,703
23	0,799	25	0,693
16	0,783	35	0,688
34	0,771	56	0,514
24	0,759		

Análise com 3 índices:

Tabela 7.3: regressão de treinamento para três índices.

Índices utilizados	R ² Treinamento	Índices utilizados	R ² Treinamento
126	0,914	235	0,823
146	0,895	236	0,821
156	0,892	234	0,817
124	0,88	346	0,813
134	0,871	246	0,806
136	0,869	456	0,804
145	0,86	345	0,785
125	0,859	245	0,759
123	0,857	256	0,742
135	0,851	356	0,732

Análise com 4 índices:

Tabela 7.4: regressão de treinamento para quatro índices.

Índices utilizados	R ² Treinamento	Índices utilizados	R ² Treinamento
1356	0,933	1345	0,881
1236	0,932	1234	0,88
1246	0,924	2356	0,861
1346	0,919	3456	0,827
1256	0,901	2345	0,825
1456	0,889	2346	0,82
1235	0,889	2456	0,803
1245	0,882		

Tabela 7.5: regressão de treinamento para cinco índices.

Índices utilizados	R ² Treinamento
13456	0,937
12356	0,935
12346	0,931
12456	0,914
12345	0,896
23456	0,852