



**João Paulo Francisco Moreira**

Licenciado em Ciências da Engenharia Electrotécnica e de  
Computadores

## **Análise de Desempenho de Anéis de Controlo Baseado em PCA**

Dissertação para obtenção do Grau de Mestre em  
Engenharia Eletrotécnica e de Computadores

Orientador : Luís Filipe Figueira Brito Palma,  
Professor Auxiliar, Universidade Nova de Lisboa

Júri:

Presidente: Paulo José Carrilho de Sousa Gil

Arguente: João Francisco Alves Martins

Vogal: Luís Filipe Figueira de Brito Palma



FACULDADE DE  
CIÊNCIAS E TECNOLOGIA  
UNIVERSIDADE NOVA DE LISBOA

**Setembro, 2013**



## **Análise de Desempenho de Anéis de Controlo Baseado em PCA**

Copyright © João Paulo Francisco Moreira, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.



*Aos meus pais*



# Agradecimentos

Gostaria de agradecer ao meu orientador, o Professor Doutor Luís Brito Palma por ter estado sempre disponível para esclarecer dúvidas, partilha de conhecimentos e pelos seus conselhos.

Ao Departamento de Engenharia Electrotécnica da Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, a todos os seus docentes, fundamentais na minha formação académica, o meu agradecimento.

Agradeço a todos os meus colegas de curso e amigos pelo companheirismo e apoio importantes neste período.

Por fim, quero agradecer à minha família, em especial aos meus pais, o apoio, a paciência e por tornarem esta etapa possível.



# Resumo

---

Existem vários trabalhos na literatura que elucidam a importância da avaliação de desempenho de anéis de controlo em sistemas industriais. A indústria está interessada nesta área de investigação e desenvolvimento, devido aos benefícios económicos e de qualidade.

Duas metodologias de análise de desempenho, em situações sem falhas e com falhas, para sistemas SISO em tempo real, são propostas nesta dissertação.

A primeira contribuição deste trabalho é uma abordagem híbrida fundamentalmente baseada no índice de Harris normalizado, na análise em componentes principais e numa rede neuronal preditiva. Esta abordagem permite analisar o desempenho, assim como detetar e isolar algumas perturbações e falhas típicas na indústria.

A segunda contribuição é uma abordagem baseada nas características dinâmicas dos sistemas e num multi-modelo PCA do processo. Esta abordagem fundamenta-se no ganho estático estimado, na largura de banda estimada, num modelo PCA para cada ponto de operação e num classificador neuronal de padrões. Esta abordagem também permite avaliar o desempenho, bem como detetar e isolar diferentes tipos de falhas e perturbações.

De modo a avaliar o desempenho global das metodologias foram realizados testes experimentais num sistema não-linear de referência de três tanques (AMIRA<sup>®</sup> DTS 200).

**Palavras-chave:** Avaliação de desempenho de anéis de controlo, índice de Harris normalizado, análise em componentes principais, rede neuronal preditiva, ganho estático, largura de banda, classificador neuronal de padrões.

---



# Abstract

---

There are several works in literature which shows the importance of control loops performance assessment. Increasingly the industry is interested in this research area due to the economic benefits and quality.

Two methodologies of control loop performance assessment, in situations without faults and with faults, for SISO systems in real time are proposed in this dissertation.

The first contribution of this work is a hybrid approach based mainly on the normalized Harris index, on principal component analysis and on neural network predictor. This approach allows the performance assessment, as well the detection and isolation of some typical disturbances and faults in industry.

The second contribution is an approach based on dynamic features of systems and on multi-model PCA of the process. This approach is based on the estimated static gain, the estimated bandwidth, on a PCA model for each operating point and on a neural pattern classifier. This approach also allows to performance assessment, as well the detection and isolation of different types of faults and disturbances.

In order to assess the overall performance of the methodologies were carried out experimental tests on a non-linear three-tank benchmark (AMIRA<sup>®</sup> DTS 200).

**Keywords:** Control loop performance assessment, normalized Harris index, principal component analysis, neural network predictor, static gain, bandwidth, neural pattern classifier.

---



# Acrónimos

<b>ACF</b>	<i>Auto Correlation Function</i>
<b>AR</b>	<i>Auto Regressive</i>
<b>ARMA</b>	<i>Auto Regressive Moving Average</i>
<b>ARX</b>	<i>Auto Regressive with eXogenous input</i>
<b>CPI</b>	<i>Control performance index</i>
<b>CPM</b>	<i>Control performance monitoring</i>
<b>CVM</b>	<i>Controlador de Variância Mínima</i>
<b>FCOR</b>	<i>Filtering and Correlation</i>
<b>HL</b>	<i>Hidden-Layer</i>
<b>IAE</b>	<i>Integral of absolute error</i>
<b>IE</b>	<i>Integral error</i>
<b>IL</b>	<i>Input-Layer</i>
<b>ISE</b>	<i>Integral square error</i>
<b>ITAE</b>	<i>Integral of time multiplied by absolute error</i>
<b>ITSE</b>	<i>Integral of time multiplied by square error</i>
<b>MLP</b>	<i>Multi-Layer Perceptron</i>
<b>MSE</b>	<i>Mean Squared Error</i>
<b>NARX</b>	<i>Nonlinear Auto-Regressive Model with eXogenous Input</i>
<b>NIPALS</b>	<i>Non-linear Iterative Partial Least Squares</i>
<b>NOP</b>	<i>Neural Output Predictors</i>
<b>OL</b>	<i>Output-Layer</i>
<b>PCA</b>	<i>Principal Component Analysis</i>
<b>PI</b>	<i>Proporcional-Integral</i>
<b>PI</b>	<i>Proporcional-Integral-Derivativo</i>
<b>PRESS</b>	<i>Predicted Error Sum of Squares</i>
<b>RBF</b>	<i>Radial Basis Function</i>
<b>RVI</b>	<i>Relative Variance Index</i>

<b>SISO</b>	<i>Single Input-Single Output</i>
<b>SMC</b>	<i>Sliding Mode Control</i>
<b>SVD</b>	<i>Singular Value Decomposition</i>
<b>VM</b>	Variância Mínima

# Nomenclatura

$b$	Horizonte de predição
$C$	Modelo do controlador
$D$	Modelo da perturbação
$d$	Tempo morto
$d_e$	Distância Euclidiana
$d_{sp}$	Distância Euclidiana para ponto de funcionamento $sp$
$E[.]$	Valor esperado
$e$	Erro de controlo
$\hat{e}$	Estimativa do erro de controlo
$e_p$	Erro associado ao modelo PCA
$F$	Polinómio da resposta ao impulso de um sistema em anel fechado sob a ação de um CVM
$F(z)$	Função de transferência em tempo discreto da instalação
$F_d$	<i>Fault detection</i>
$F_i$	<i>Fault isolation</i>
$F_n$	Falhas provocadas no sistema; $n = 0, 1, 2, 3$
$f_i$	Coefficientes do polinómio $F$
$G$	Modelo da instalação
$I$	Número de componentes principais incluídas no modelo PCA

$i_n$	Índice de deteção e diagnóstico; $n = 1, 2, 3$
$K_p$	Ganho proporcional
$k$	Amostra no instante $k$
$M$	Número de variáveis
$N$	Número de elementos de um vetor
$n$	Ordem do modelo
$n_a$	Número de pólos
$n_b$	Número de zeros
$n_d$	Atraso
$P$	Matriz característica do modelo PCA ( <i>loading vector</i> )
$P_i$	Vetor de pesos
$p$	Pólo
$q$	Operador deslocamento no tempo
$q_0$	Resíduo do modelo PCA
$r$	Sinal de referência
$r_e$	Resíduo do erro de controlo
$r_i$	Índices de metodologia híbrida; $i = 1, 2, 3, 4, 5$
$r_{ib}$	Índices binarizados de metodologia híbrida; $i = 1, 2, 3, 4, 5$
$r_{ye}$	Covariância entre os sinais $y$ e $e$
$S$	Covariância da matriz de dados de um modelo PCA
$sp$	<i>Set-point</i> (ponto de funcionamento)
$T$	Vetor de componentes principais
$T_d$	Tempo derivativo
$T_i$	Tempo integral
$T_s$	Período de amostragem
$t$	Instante de tempo

$t_i$	Componente principal; $i = 1, 2, \dots, n$ , com $n$ igual ao número de componentes principais
$t_r$	Tempo de subida
$thr_i$	Thresholds para detetar falhas; $i = sp1, sp2, sp3$
$thr_{r_i}$	Thresholds para binarizar os sinais $r_i$ ; $i = 1, 2, 3, 4, 5$
$w$	Tamanho de janela deslizante
$X$	Matriz bidimensional com tamanho $n \times m$
$\hat{X}$	Estimativa da matriz $X$
$x_0$	Coordenada $x$ do centro de elipse
$y$	Saída do processo
$y_0$	Coordenada $y$ do centro de elipse
$\hat{y}_{nop}$	Saída da rede neuronal preditora (NOP)
$Z$	Vetor de coeficientes de correlação cruzada entre $y$ e $e$
$\alpha$	Correlação cruzada
$\delta_g$	Ganho estático
$\zeta_w$	Largura de banda
$\eta$	Índice de Harris
$\eta^{nivel}$	Índice de variância mínima de tanques de nível
$\eta_{nor}$	Índice de Harris normalizado
$\theta$	Vetor de coeficiente estimados
$\lambda$	Valor próprio
$\xi$	Regressor do modelo PCA
$\rho_{ye}$	Correlação cruzada entre os sinais $y$ e $e$
$\sigma_{CO}^2$	Variância do controlador ótimo
$\sigma_e^2$	Variância do sinal $e$
$\sigma_{MV}^2$	Variância mínima
$\sigma_{OL}^2$	Variância do anel aberto

$\sigma_{r_e}^2$	Variância do resíduo $r_e$
$\sigma_y^2$	Atual mínima do processo
$v$	Regressor de modelo ARX
$\varphi$	Regressor do modelo AR para estimar o erro
$\chi_{a1}$	Sinal de detecção de metodologia híbrida
$\chi_{a2}$	Sinal de isolamento de metodologia híbrida
$\chi_{b1}$	Sinal de detecção de metodologia baseada em características dinâmicas
$\chi_{b2}$	Sinal de isolamento de metodologia baseada em características dinâmicas
$\chi_e$	Erro quadrático médio ( <i>mean square error</i> ) do erro de controlo
$\Psi$	Regressor da rede neuronal classificadora
$\psi$	Regressor da rede neuronal NOP

# Conteúdo

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Motivação . . . . .	1
1.2	Objetivos . . . . .	2
1.3	Contribuições . . . . .	2
1.4	Estrutura da Dissertação . . . . .	3
<b>2</b>	<b>Revisão Bibliográfica</b>	<b>5</b>
2.1	Análise de Desempenho de Anéis de Controlo . . . . .	5
2.2	Índices Estocásticos . . . . .	6
2.2.1	Índice de variância mínima . . . . .	6
2.2.2	Índices baseados em variância mínima . . . . .	7
2.2.3	Índices baseados no erro de controlo . . . . .	12
2.3	Índices Determinísticos . . . . .	14
2.3.1	Índices determinísticos para quantificar o desempenho do sistema	14
2.3.2	Índices determinísticos para quantificar a robustez do sistema . . . .	15
2.4	Técnicas Estatísticas . . . . .	17
2.4.1	Função de autocorrelação (ACF) . . . . .	17
2.4.2	Correlação cruzada . . . . .	17
2.4.3	Resposta ao impulso . . . . .	18
2.4.4	Análise espectral . . . . .	18
2.4.5	Teste de resíduos . . . . .	18
2.5	Análise em Componentes Principais (PCA) . . . . .	18
2.5.1	Objectivo . . . . .	19
2.5.2	Interpretação Geométrica . . . . .	19
2.5.3	Definição matemática . . . . .	20
2.5.4	Seleção do número de componentes principais . . . . .	21
2.6	Redes Neurais . . . . .	22
2.6.1	Modelos neuronais preditivos . . . . .	24

2.6.2	Modelos neuronais classificadores . . . . .	25
<b>3</b>	<b>Metodologias Propostas para Análise de Desempenho</b>	<b>27</b>
3.1	Perturbações, Falhas e Avarias . . . . .	28
3.2	Metodologia Híbrida . . . . .	29
3.2.1	Índices de avaliação de desempenho . . . . .	31
3.2.2	Índices de detecção e diagnóstico de falhas . . . . .	34
3.2.3	Deteção e diagnóstico de falhas . . . . .	35
3.3	Metodologia Baseada em Caraterísticas Dinâmicas e Modelos PCA . . . . .	36
3.3.1	Caraterísticas dinâmicas: ganho estático e largura de banda . . . . .	38
3.3.2	Análise em componentes principais (PCA) . . . . .	39
3.3.3	Deteção de falhas . . . . .	40
3.3.4	Isolamento de falhas . . . . .	41
<b>4</b>	<b>Resultados Experimentais</b>	<b>43</b>
4.1	Descrição do Processo Experimental . . . . .	44
4.2	Objetivo de Controlo . . . . .	44
4.3	Controlador PI(D) . . . . .	45
4.3.1	Ação proporcional . . . . .	45
4.3.2	Ação Integral . . . . .	45
4.3.3	Ação Derivativa . . . . .	46
4.3.4	Algoritmo de controlador PID . . . . .	46
4.4	Experiências com Metodologia Híbrida . . . . .	47
4.4.1	Operação nominal ( $F_0$ ) . . . . .	47
4.4.2	Variação de referência ( $F_1$ ) . . . . .	51
4.4.3	Dessintonização do controlador ( $F_2$ ) . . . . .	55
4.4.4	Falha intermitente ( $F_3$ ) . . . . .	59
4.4.5	Todas as falhas na mesma experiência . . . . .	63
4.4.6	Pontos de funcionamento não incluídos nos modelos . . . . .	67
4.5	Experiências com Metodologia Baseada em Caraterísticas Dinâmicas e Modelos PCA . . . . .	71
4.5.1	Operação nominal ( $F_0$ ) . . . . .	71
4.5.2	Variação de referência ( $F_1$ ) . . . . .	73
4.5.3	Dessintonização do controlador ( $F_2$ ) . . . . .	75
4.5.4	Falha intermitente ( $F_3$ ) . . . . .	77
4.5.5	Todas as falhas na mesma experiência . . . . .	78
4.5.6	Pontos de funcionamento não incluídos nos modelos . . . . .	81
4.6	Comparação entre Metodologias Propostas e Índice de Harris Normalizado . . . . .	83
<b>5</b>	<b>Conclusões</b>	<b>87</b>
5.1	Conclusões Gerais . . . . .	87
5.2	Apontadores para Trabalho Futuro . . . . .	88

# Lista de Figuras

1.1	Arquitetura de monitorização de desempenho de anel de controlo. . . . .	3
2.1	Esquemático FCOR. . . . .	12
2.2	IAE para um sistema com referência fixa. . . . .	13
2.3	Medidas determinísticas. . . . .	15
2.4	Margens de ganho e de fase baseadas no diagrama de Bode. . . . .	16
2.5	Máxima sensibilidade usando diagrama de Nyquist. . . . .	16
2.6	Representação gráfica do PCA. . . . .	19
2.7	Neurónio biológico simplificado. . . . .	23
2.8	Neurónio artificial. . . . .	23
2.9	Arquitetura possível de uma NOP. . . . .	24
3.1	Arquitetura geral de análise de desempenho. . . . .	27
3.2	Arquitetura do supervisor. . . . .	28
3.3	Arquitetura da metodologia híbrida. . . . .	30
3.4	Esquemático do índice de Harris normalizado. . . . .	31
3.5	Esquemático de rede neuronal preditiva. . . . .	32
3.6	Esquemático índice $r_3(k)$ . . . . .	32
3.7	Esquemático índice $r_4(k)$ . . . . .	34
3.8	Esquemático índice $r_5(k)$ . . . . .	34
3.9	Esquemático de índices de deteção e diagnóstico. . . . .	35
3.10	Arquitetura da metodologia baseada em características dinâmicas e modelos PCA. . . . .	37
3.11	Exemplo de zonas de funcionamento nominal de projeções PCA para 3 pontos de funcionamento. . . . .	40
3.12	Projeções de modelos PCA num instante $k$ numa situação de falha. . . . .	41
4.1	AMIRA DTS 200. . . . .	43
4.2	Esquemático do processo industrial AMIRA DTS 200. . . . .	44

4.3	Índices de avaliação de desempenho $r_i$ para situação $F_0$ . . . . .	48
4.4	Binarização, índices $r_{ib}$ , na situação $F_0$ . . . . .	49
4.5	Índices de detecção e diagnóstico $i_n$ , para a situação $F_0$ . . . . .	50
4.6	Deteção e isolamento de falhas, situação $F_0$ . . . . .	50
4.7	Índices de avaliação de desempenho $r_i$ para situação $F_1$ . . . . .	52
4.8	Binarização, índices $r_{ib}$ , na situação $F_1$ . . . . .	53
4.9	Índices de detecção e diagnóstico $i_n$ , para a situação $F_1$ . . . . .	54
4.10	Deteção e isolamento de falhas, situação $F_1$ . . . . .	54
4.11	Índices de avaliação de desempenho $r_i$ para situação $F_2$ . . . . .	56
4.12	Binarização, índices $r_{ib}$ , na situação $F_2$ . . . . .	57
4.13	Índices de detecção e diagnóstico $i_n$ , para a situação $F_2$ . . . . .	58
4.14	Deteção e isolamento de falhas, situação $F_2$ . . . . .	58
4.15	Índices de avaliação de desempenho $r_i$ para situação $F_3$ . . . . .	60
4.16	Binarização, índices $r_{ib}$ , na situação $F_3$ . . . . .	61
4.17	Índices de detecção e diagnóstico $i_n$ , para a situação $F_3$ . . . . .	62
4.18	Deteção e isolamento de falhas, situação $F_3$ . . . . .	62
4.19	Índices de avaliação de desempenho $r_i$ para situação $F_n$ . . . . .	64
4.20	Binarização, índices $r_{ib}$ , na situação $F_n$ . . . . .	65
4.21	Índices de detecção e diagnóstico $i_n$ , para a situação $F_n$ . . . . .	66
4.22	Deteção e isolamento de falhas, situação $F_n$ . . . . .	66
4.23	Índices de avaliação de desempenho $r_i$ . . . . .	68
4.24	Binarização, índices $r_{ib}$ . . . . .	69
4.25	Índices de detecção e diagnóstico $i_n$ . . . . .	70
4.26	Deteção e isolamento de falhas. . . . .	70
4.27	Processo, ganho estático, largura de banda e distâncias de modelos PCA em funcionamento nominal. . . . .	72
4.28	Deteção e isolamento de falhas, situação nominal. . . . .	73
4.29	Processo, ganho estático, largura de banda e distâncias de modelos PCA em variação de referência. . . . .	74
4.30	Deteção e isolamento de falhas, situação de variação de referência. . . . .	74
4.31	Processo, ganho estático, largura de banda e distâncias de modelos PCA em dessintonização do controlador. . . . .	76
4.32	Deteção e isolamento de falhas, situação de dessintonização do controlador. . . . .	76
4.33	Processo, ganho estático, largura de banda e distâncias de modelos PCA em falha intermitente. . . . .	77
4.34	Deteção e isolamento de falhas, situação de falha intermitente. . . . .	78
4.35	Processo, ganho estático, largura de banda e distâncias de modelos PCA em experiências com todas as falhas. . . . .	80
4.36	Deteção e isolamento de falhas, situação de experiências com todas as falhas. . . . .	81
4.37	Processo, ganho estático, largura de banda e distâncias de modelos PCA. . . . .	82
4.38	Deteção e isolamento de falhas. . . . .	82

# Lista de Tabelas

3.1	Falhas. . . . .	29
3.2	Thresholds para a binarização. . . . .	31
3.3	Thresholds para detecção de falha. . . . .	41
4.1	Legenda das figuras de testes. . . . .	47
4.2	Instantes de introdução, detecção e isolamento da falha $F_1$ . . . . .	55
4.3	Instantes de introdução, detecção e isolamento da falha $F_2$ . . . . .	59
4.4	Instantes de introdução, detecção e isolamento da falha $F_3$ . . . . .	59
4.5	Resumo de experiência com todas as falhas. . . . .	63
4.6	Instantes de introdução, detecção e isolamento das falhas. . . . .	65
4.7	Legenda do gráfico das distâncias. . . . .	72
4.8	Instantes de introdução, detecção e isolamento da variação de referência. . . . .	75
4.9	Instantes de introdução, detecção e isolamento da dessintonização do controlador. . . . .	75
4.10	Instantes de introdução, detecção e isolamento da falha intermitente. . . . .	78
4.11	Descrição experiência. . . . .	79
4.12	Instantes de introdução, detecção e isolamento das falhas, em experiências com todas as falhas. . . . .	80
4.13	Experiência com falha $F_1$ . . . . .	83
4.14	Experiência com falha $F_2$ . . . . .	84
4.15	Experiência com falha $F_3$ . . . . .	84
4.16	Experiência com todas as falhas. . . . .	84





# Introdução

Neste capítulo é apresentada uma introdução ao trabalho desenvolvido na dissertação, nomeadamente a motivação que levou à escolha do tema da dissertação, os objetivos a que se propõe, as suas maiores contribuições e por fim a forma como está organizada a dissertação.

## 1.1 Motivação

Hoje em dia os processos industriais têm centenas de controladores. Esses controladores são normalmente controladores do tipo PI, devido à sua simplicidade, fácil implementação e baixos recursos computacionais necessários. Com o passar do tempo, mesmo que inicialmente os controladores estejam bem sintonizados, vários fatores contribuem para a sua deterioração (T. Harris, Seppala & Desborough, 1997), incluindo os sensores, atuadores, falhas no processo, mudança de produto, válvulas defeituosas entre muitos outros fatores. Estima-se que 50% dos controladores industriais tenham problemas de desempenho (Ender, 1993; Siemens, 2008; K. Astrom, 1991). Estes fatores causam baixa qualidade do produto e até por vezes problemas de segurança, fazendo com que as indústrias diminuam os lucros.

O objetivo da avaliação de desempenho dos controladores é recolher informação para o utilizador, quantificando o desempenho do sistema, uma vez que é humanamente impossível monitorizar centenas de controladores existentes numa instalação. Entre as muitas técnicas propostas ao longo dos anos podemos dividi-las em duas grandes categorias, técnicas determinísticas e técnicas estocásticas. Uma das técnicas dentro da categoria das estocásticas mais utilizada é a variância mínima que foi proposta por T. J. Harris (1989).

Esta técnica é largamente utilizada nesta área pois já está bastante consolidada, tendo uma boa fundamentação teórica, fácil implementação, não é uma técnica invasiva e requer apenas os dados de operação do processo, sendo ideal para ser utilizada em tempo real.

## 1.2 Objetivos

Na literatura existem diversas técnicas para avaliar o desempenho dos anéis de controle. Desde técnicas baseadas em variância mínima, estatísticas, no erro de controle, determinísticas, entre outras. Tendo em conta as características do sistema e fazendo uma escolha da técnica adequada, é possível uma boa monitorização do sistema. No entanto quando se pretende ir mais além e descobrir automaticamente a causa do problema, ou seja, fazer o diagnóstico, já não é assim tão simples. São em geral necessárias outras técnicas mais complexas.

O principal objetivo desta dissertação é combinar diferentes técnicas, que não sejam computacionalmente muito pesadas nem invasivas para o sistema, de modo a permitir a sua implementação na maioria dos sistemas e permitir avaliar o desempenho do sistema. Pretende-se ainda combinar a informação de cada técnica para permitir diagnosticar a origem do problema. É ainda pretendido que as técnicas utilizadas possam ser usadas em tempo real. As técnicas utilizadas serão focadas no índice de Harris normalizado, na análise em componentes principais (PCA) e em redes neuronais.

Pretende-se desenvolver uma arquitetura capaz de detetar e diagnosticar regimes transitórios (variações de referência), dessintonização do controlador PI (adicionando uma elevada componente derivativa) e oscilações provocadas por uma válvula. As metodologias propostas nesta dissertação são aplicadas em sistemas SISO, e os resultados experimentais são obtidos num sistema não-linear de três tanques (AMIRA<sup>®</sup> DTS 200).

A arquitetura que se pretende implementar neste trabalho pode ser observada na figura 1.1. O bloco de monitorização (CPM) irá calcular um índice de desempenho do sistema (CPI).

## 1.3 Contribuições

A contribuição desta dissertação inclui-se na área de avaliação de desempenho de anéis de controle.

Novos índices de desempenho são apresentados, resultantes da combinação de técnicas já existentes, nomeadamente a construção de modelos PCA com novas variáveis baseadas em técnicas com provas dadas. Nesta dissertação são propostas duas metodologias:

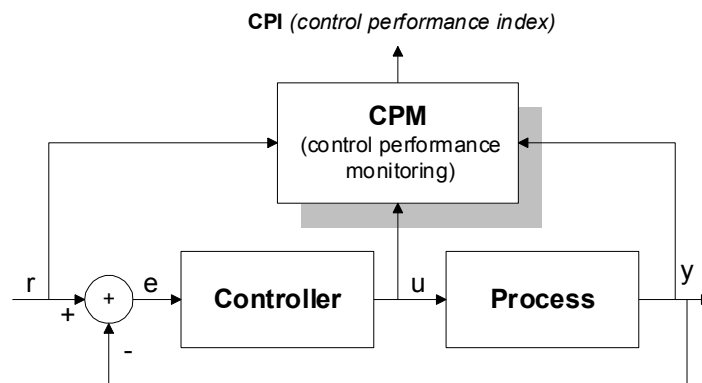


Figura 1.1: Arquitetura de monitorização de desempenho de anel de controlo.

- Na primeira metodologia são propostos alguns índices focados para certo tipos de falhas, que avaliam o desempenho do sistema. A novidade deste trabalho é conseguir diagnosticar a origem do problema fazendo apenas uma combinação dos vários índices.
- A segunda metodologia, consiste num conceito novo, que se baseia em três modelos PCA do processo a funcionar em paralelo, baseados em características dinâmicas do sistema. Esta metodologia também permite detetar e diagnosticar falhas.

## 1.4 Estrutura da Dissertação

Esta dissertação encontra-se dividida em 5 capítulos. No capítulo 2 é apresentada uma revisão bibliográfica sobre o trabalho mais importante desenvolvido até aqui sobre o tema em que se enquadra esta dissertação. Serão abordados índices estocásticos e determinísticos, técnicas estatísticas, e ainda análise em componentes principais (PCA), preditores neuronais (NOP) e classificadores neuronais.

No capítulo 3, são apresentadas as duas metodologias propostas nesta dissertação para análise de desempenho de anéis de controlo. Em primeiro lugar é apresentada uma metodologia baseada em cinco índices: índice de Harris normalizado, resíduo de modelo PCA baseado no índice de Harris normalizado, resíduo da rede neuronal preditiva, filtragem passa alto da referência e variância da ação de controlo. De seguida é explicado de que forma estes índices são combinados para permitir o diagnóstico. A segunda metodologia é então em seguida apresentada. São descritos os três modelos PCA construídos baseados no ganho estático e na largura de banda estimados do sistema, bem como são utilizados estes três modelos para detetar e diagnosticar falhas.

No capítulo 4 são apresentados os resultados experimentais obtidos para as duas metodologias propostas.

Por fim, no capítulo 5, são apresentadas as conclusões sobre o trabalho desenvolvido e são discutidos apontadores para trabalhos futuros.



# Revisão Bibliográfica

Neste capítulo será feita uma revisão sobre os principais métodos de avaliação de desempenho de controladores e de anéis de controle para sistemas SISO.

## 2.1 Análise de Desempenho de Anéis de Controle

Avaliar o desempenho de um dado anel de controle significa avaliar uma propriedade específica do controlador que reflete o seu desempenho, com uma referência que providencia uma métrica clara dessa propriedade (Jelali, 2006).

Um índice de desempenho é uma medida quantitativa do desempenho do sistema e é escolhido de forma a dar relevo às especificações importantes do processo.

A teoria de controle moderna assume que o engenheiro de sistemas pode especificar quantitativamente o desempenho do sistema desejado.

Uma medida quantitativa do desempenho do sistema é necessária para otimização automática de parâmetros de um sistema de controle e também para o desenho de sistemas de controle ótimos.

Todos os anéis de controle de uma instalação devem ser avaliados (ou monitorizados) para manter a instalação no seu ponto máximo de eficiência. Mesmo controladores que estejam com um bom desempenho hoje podem ver o seu desempenho deteriorado ao longo do tempo.

Muitos anéis de controlo são sintonizados empiricamente ou continuam a usar a sintonização de parâmetros padrão, fatores que são responsáveis por um mau desempenho. Engenheiros e operadores "aceitam" o desempenho atual devido a alguns fatores (Paulonis & Cox, 2006):

- Poucas pessoas responsáveis pela manutenção dos controladores;
- Controladores sintonizados de forma conservadora para assegurar a estabilidade de instalações não-lineares quando as condições de operação mudam;
- Controladores sintonizados sem otimização;
- Operadores e engenheiros muitas vezes não têm o conhecimento devido para entender que o desempenho de cada controlador vai deteriorando ao longo do tempo e cada controlador tem potencial para ser otimizado.

Alguns controladores nunca terão um bom desempenho devido à estrutura de controlo inapropriada (Trierweiler, 1997), nomeadamente:

- Seleção de variáveis errada;
- Controlador linear aplicado em instalação fortemente não-linear;
- Controladores descentralizados aplicados em algumas instalações altamente acopladas;
- Cenários em que a perturbação tem um impacto forte no desempenho do anel de controlo sem compensação na retroação;

O primeiro conjunto de índices para avaliar o desempenho dos anéis de controlo usa apenas dados de operação e pouco conhecimento do processo (T. J. Harris, 1989). Este conjunto é denominado de índices estocásticos. Estes índices permitem avaliar todos os controladores de uma instalação devido à sua simplicidade.

Para além dos índices estocásticos, existem ainda os índices determinísticos. Estes índices providenciam uma clara avaliação do processo e da sua robustez.

## 2.2 Índices Estocásticos

### 2.2.1 Índice de variância mínima

T. J. Harris (1989) propôs um índice de avaliação de desempenho para anéis de controlo, baseado na comparação da atual variância do anel de controlo com a variância mínima do controlador proposto por K. J. Astrom (1970). Este índice que ficou conhecido como, *Harris Index*, e ganhou grande popularidade nesta área devido à sua simplicidade e mínimos recursos necessários para a sua implementação. Outro ponto a favor deste índice

é o facto de permitir uma avaliação em linha e com o mínimo conhecimento do processo. Depois de Harris ter proposto este índice muitos outros autores basearam o seu trabalho a partir deste.

O índice de Harris,  $\eta$ , é definido da seguinte forma.

$$\eta = 1 - \frac{\sigma_{MV}^2}{\sigma_y^2} \quad (2.1)$$

Onde  $\sigma_{MV}^2$  é a variância mínima e  $\sigma_y^2$  é a atual variância da saída do processo. Este índice tem sempre valores entre 0 e 1, onde 0 é o melhor desempenho possível e 1 o pior.

### 2.2.2 Índices baseados em variância mínima

Desborough e T. J. Harris (1992) propuseram uma das mais populares variâncias do índice de Harris. Apenas os dados de operação e o tempo morto são necessários. A variável chave para o cálculo deste índice é o erro de controlo, equação 2.2, onde  $r$  é a referência e  $y$  a saída do processo. Para um bom funcionamento do anel de controlo este deve rejeitar perturbações e a variável de saída do processo deve seguir a referência. Estes requisitos implicam que o erro de controlo não deverá ter componente predizível.

O objetivo é determinar o quanto predizível é o erro de controlo dentro de uma janela de tempo. No caso de um bom desempenho o erro de controlo não é predizível dentro de uma janela de tempo, caso contrário numa situação de mau desempenho, o erro é predizível na janela de tempo (N. Thornhill et al., 1996).

Este índice baseia-se num resíduo (2.3), entre o erro de controlo medido e a sua predição.

$$e(k) = r(k) - y(k) \quad (2.2)$$

$$r_e(k) = e(k) - \hat{e}(k) \quad (2.3)$$

Num sistema com bom desempenho é esperado que o erro apenas contenha ruído branco que é representado pelo resíduo, uma vez que não existe previsibilidade. O índice proposto por Desborough e T. J. Harris (1992) é apelidado de índice de Harris normalizado e é então dado por:

$$\eta(k)_{nor} = 1 - \frac{\sigma_{r_e}^2(k)}{\chi_e(k)} \quad (2.4)$$

Sendo que  $\sigma_{r_e}^2(k)$  representa a variância do resíduo 2.3, e  $\chi_e(k)$  é o erro quadrático médio do erro de controlo. Para um valor de  $\eta(k)_{nor}$  perto de 0 significa um bom desempenho, já para valores perto de 1 representa um mau desempenho.

Para obter o modelo de predição  $\hat{e}(k)$  uma simples auto-regressão  $AR(n, b)$  que faça predições  $b$  passos à frente é suficiente. A equação 2.5 mostra a auto-regressão.

$$\hat{e}(k) = a_0 - a_b e(k-b) - a_{b+1} e(k-(b+1)) + \dots - a_{b+n-1} e(k-(b+n-1)) \quad (2.5)$$

O modelo AR da equação 2.5, pode ser formulado em termos de uma regressão de um vetor de dados e um vetor de parâmetros, obtido através da estimação dos mínimos quadrados ou outro algoritmo de estimação, como mostram as equações 2.6, 2.7 e 2.8, onde  $\varphi$  é o regressor,  $e$  o erro de controle e  $\theta$  o vetor de coeficientes estimados.

$$\hat{e}(k) = \varphi^T(k)\theta(k); \hat{e}(k) \in R^{1 \times 1} \quad (2.6)$$

$$\varphi(k) = [1 - e(k-b) - e(k-(b+1)) \dots - e(k-(b+n-1))]^T; \varphi(k) \in R^{(n+1) \times 1} \quad (2.7)$$

$$\theta(k) = [a_0 \ a_b \ a_{b+1} \ \dots \ a_{b+n-1}]^T; \theta(k) \in R^{(n+1) \times 1} \quad (2.8)$$

Este método é muito apelativo, pois não necessita que o sistema seja interrompido para testes, apenas os dados de funcionamento são necessários. N. Thornhill et al. (1996) aplicou este método a uma refinaria da BP, diagnosticando as oscilações em anéis de controle de fluxos.

Mais tarde, outros autores propuseram metodologias para estimar a VM para controladores SISO (Huang & Shah, 1999; Kempf, 2003; Tyler & Morari, 1996).

A tarefa mais complicada no cálculo deste género de índices é calcular o tempo morto de cada anel. Muitas vezes são utilizados valores padrão dependendo do tipo de anel, o que resulta por vezes em resultados enganadores sobre o desempenho do anel (N. F. Thornhill & Hagglund, 1997). Para resolver este problema existem na literatura muitos trabalhos com o objetivo de calcular este parâmetro com base apenas nos dados do processo (Ahmed, Huang & Shah, 2006; Elnaggar, Dumont & Elshafei, 1991; Tuch, Feuer & Palmor, 1994).

O índice de Harris inspirou vários autores a desenvolverem ferramentas de avaliação de desempenho em tempo real para a indústria (Desborough & T. J. Harris, 1992; Olaleye, Huang & Tamayo, 2004; N. F. Thornhill, Oettinger & Fedenczuk, 1999).

Existem na literatura várias propostas para calcular CVM (controlador de variância mínima) para tipos específicos de controladores:

- O índice de Harris assume uma referência fixa. Este facto levou a que alguns autores estudassem outras aproximações:
  - N. F. Thornhill, Huang e Shah (2003) estudaram a discrepância do índice de Harris quando existem várias mudanças de referência e quando a referência é fixa;
  - Seppala, Harris e Bacon (2002) propuseram uma metodologia para avaliação de anéis de controlo quando existem variações de referência;
  - Alguns trabalhos foram propostos para calcular a VM (variância mínima) quando existem muitas variações da referência (Perrier & Roche, 1992; Seppala et al., 2002; N. F. Thornhill, Cox & Paulonis, 2003);
  - Também o desempenho de controladores em cascata foi estudado por Ko e Edgar (2000).
- Desempenho de controladores em anel aberto foi estudado por Stanfelj, Marlin e MacGregor (1993)

Controladores de variância mínima têm algumas limitações, para compensar este facto algumas metodologias foram propostas por vários autores:

- Tyler e Morari (1996) propuseram uma metodologia a que chamaram *Generalized Likelihood Method* para estimar a VM para instalações com fase não mínima;
- Huang e Shah (1999) e Li e Evans (1997) avaliaram CVM quando ocorrem perturbações variantes no tempo.

O efeito que alguns fatores produzem no cálculo de um índice de variância mínima também foi estudado:

- A ordem do controlador (Kendra & Cinar, 1997);
- A ordem da instalação (Basseville, 1998; Kumar, Martin & Morris, 2002);
- Compressão dos dados (N. F. Thornhill, Choudhury & Shah, 2004);
- Seleção dos dados (Olaleye et al., 2004);
- Padrão da perturbação (Salsbury, 2005; Xia & Howell, 2005).

Outros índices baseados no CVM foram propostos por vários autores para avaliar os anéis de controlo:

- Bezergianni e Georgakis (2000) propuseram o índice de variância relativa (*Relative Variance Index*), baseado no CVM e na variância em anel aberto. Este índice é dado por:

$$RVI = \frac{\sigma_{OL}^2 - \sigma_y^2}{\sigma_{OL}^2 - \sigma_{MV}^2} \quad (2.9)$$

Sendo  $\sigma_{OL}^2$  a variância em anel aberto,  $\sigma_y^2$  a variância da saída do processo e  $\sigma_{MV}^2$  a variância mínima. A mais valia deste índice é o facto de demonstrar o melhor controlo possível (CVM) e o pior (anel aberto). A contrapartida deste índice tem a ver com a necessidade de estimar os modelos da instalação, controlador e da perturbação.

- Hugo (2001) propõe um índice para avaliar o desempenho do controlo de nível em tanques, equação 2.10, em que compara a variância do tanque com a variância de um controlador ótimo que mantém o liquido do tanque no nível desejado.

$$\eta^{nivel}(k) = 1 - \frac{\sigma_{CO}^2}{\sigma_y^2} \quad (2.10)$$

Sendo  $\sigma_{CO}^2$  a variância do controlador ótimo e  $\sigma_y^2$  a variância da saída do processo.

Um dos algoritmos mais populares para calcular VM (variância mínima) chama-se *Filtering and Correlation* (FCOR) e foi proposto por Huang e Shah (1999). Para o cálculo deste algoritmo apenas são necessários os dados de operação e o tempo morto.

Um sistema em anel fechado estável pode ser descrito como uma média móvel de ordem infinita (Huang & Shah, 1999) como descrito na equação 2.11.

$$y(k) = (f_0 + f_1q^{-1} + \dots + f_{d-1}q^{-d+1} + f_dq^{-d} + \dots)e(k) \quad (2.11)$$

Multiplicando 2.11 por  $e(k)$ ,  $e(k-1)$ ,  $\dots$ ,  $e(k-d+1)$  respetivamente e tomando a média dos dois lados da equação, obtém-se:

$$\begin{aligned} r_{ye}(0) &= E[y(k)e(k)] = f_0\sigma_e^2 \\ r_{ye}(1) &= E[y(k)e(k-1)] = f_1\sigma_e^2 \\ r_{ye}(2) &= E[y(k)e(k-2)] = f_2\sigma_e^2 \\ &\vdots \\ r_{ye}(d-1) &= E[y(k)e(k-d+1)] = f_{d-1}\sigma_e^2 \end{aligned} \quad (2.12)$$

Sendo  $r_{ye}(k)$  a covariância entre os dados da amostra  $y(k)$  e os dados da perturbação deslocados  $k$  unidades. Já  $E[\cdot]$  é o valor esperado. A variância mínima do controlador

CVM é então dada por:

$$\begin{aligned}
\sigma_{MV}^2 &= (f_0^2 + f_1^2 + f_2^2 + \dots + f_{d-1}^2)\sigma_e^2 \\
&= \left[ \left( \frac{r_{ye}(0)}{\sigma_e^2} \right)^2 + \left( \frac{r_{ye}(1)}{\sigma_e^2} \right)^2 + \dots + \left( \frac{r_{ye}(d-1)}{\sigma_e^2} \right)^2 \right] \sigma_e^2 \\
&= \frac{[r_{ye}^2(0) + r_{ye}^2(1) + r_{ye}^2(2) + \dots + r_{ye}^2(d-1)]}{\sigma_e^2}
\end{aligned} \tag{2.13}$$

Sendo  $\sigma_e^2$  a variância do erro de controlo e  $d$  o tempo morto. Substituindo a na equação 2.1 a equação 2.13 obtém-se:

$$\begin{aligned}
\eta(k) &= \frac{[r_{ye}^2(0) + r_{ye}^2(1) + r_{ye}^2(2) + \dots + r_{ye}^2(d-1)]}{\sigma_y^2 \sigma_e^2} \\
&= \rho_{ye}^2(0) + \rho_{ye}^2(1) + \rho_{ye}^2(2) + \dots + \rho_{ye}^2(d-1) \equiv ZZ^T
\end{aligned} \tag{2.14}$$

Onde  $Z$  é o vetor de coeficientes de correlação cruzada entre  $y(k)$  e  $e(k)$ . O valor  $\rho_{ye}(k)$  é dado por:

$$\rho_{ye}(k) = \frac{\frac{1}{N} \sum_{t=1}^N y(t)e(t-k)}{\sqrt{\frac{1}{N} \sum_{t=1}^N y(t)^2 \frac{1}{N} \sum_{t=1}^N e(t)^2}} \tag{2.15}$$

Sendo  $N$  o tamanho do conjunto de dados,  $y$  a saída do processo e  $e$  o erro. Embora  $e(k)$  seja desconhecido, este pode ser estimado ( $\hat{e}(k)$ ), adicionando ruído branco na saída do processo  $y(k)$  via análise de séries temporais. O esquemático deste algoritmo (FCOR) pode ser visto na figura 2.1 (Farenzena, 2008), onde o controlador é representado por  $C$ , o modelo da instalação por  $G$  e o modelo da perturbação por  $D$ .

O ruído branco pode ser estimado ( $\hat{e}(k)$ ) como a diferença entre o sinal original da saída do processo e o seu valor previsto (Chatfield, 1989). A saída do processo pode ser modelada usando um modelo AR, ARMA ou filtro de Kalman (tendo o modelo em espaço de estados) dependendo dos dados (Huang & Shah, 1999).

Este método (FCOR) pelo facto de não requerer inversão de matrizes, o que acarreta problemas de estabilidade numérica e pode inviabilizar a implementação em sistemas com escassos recursos computacionais, tem vantagem sobre o método proposto por Desborough e T. J. Harris (1992).

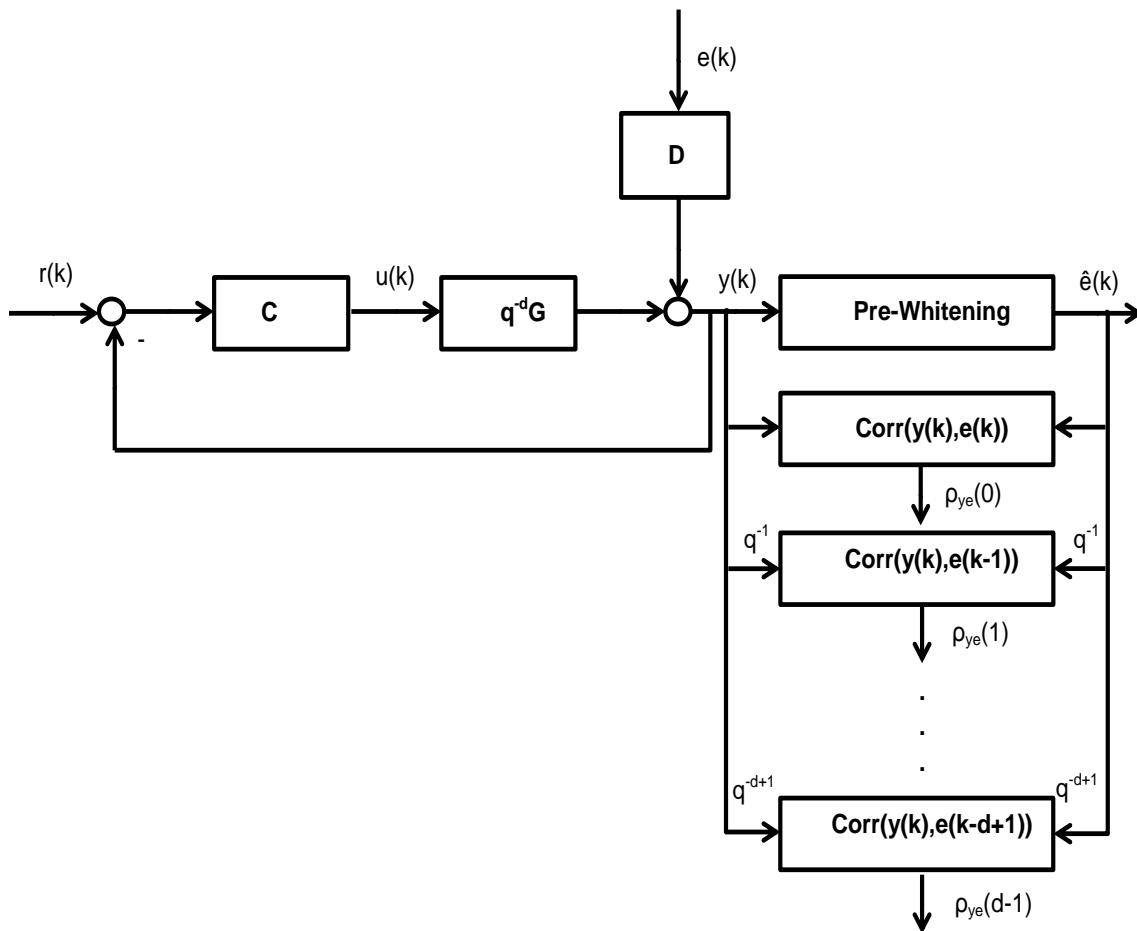


Figura 2.1: Esquemático FCOR.

### 2.2.3 Índices baseados no erro de controle

Um dos índices muito utilizados na indústria para avaliação de desempenho bastante eficaz na detecção de oscilações é o chamado *Integral of Absolute Error* (IAE) (Hagglund, 1995). Onde é efetuado o cálculo do integral da diferença entre a referência e a saída do processo, figura 2.2 (Farenzena, 2008).

O integral do erro absoluto (IAE) é dado por:

$$IAE = \int_{t_{i-1}}^{t_i} |r - y| dt \quad (2.16)$$

Onde  $t_{i-1}$  e  $t_i$  são duas passagens pela referência consecutivas.

Apenas os dados de operação são necessários para calcular o índice. A maior contrapartida deste índice é pelo facto de ter que ser imposto pelo utilizador o valor de referência, uma vez que este parâmetro depende do processo, do tipo de perturbação e do desempenho do controlador.




Figura 2.2: IAE para um sistema com referência fixa.

Gerry (2004) propôs um índice baseado no IAE, chamado *Expert Tune Index* (ETI). Este índice compara o IAE atual com o IAE ótimo ( $IAE_{OPT}$ ).

$$ETI = \frac{IAE - IAE_{OPT}}{IAE} \quad (2.17)$$

O  $IAE_{OPT}$  é definido quando o controlador é dimensionado para um certo tipo de desempenho desejado.

Quando o processo é não-oscilatório, por norma utiliza-se uma aproximação do IAE, denominado integral do erro ou *integral error* (IE).

$$IE = \int_{t_{i-1}}^{t_i} (r - y) dt \quad (2.18)$$

Sendo  $r$  a referência e  $y$  a saída do processo. Outro índice de fácil implementação é o chamado, integral do erro quadrático ou *integral square error* (ISE). A desvantagem deste índice reside no facto de quantificar em maior escala os erros iniciais que possam ocorrer

em sistemas oscilatórios, sendo mais apropriado para sistemas menos oscilatórios.

$$ISE = \int_{t_{i-1}}^{t_i} (r - y)^2 dt \quad (2.19)$$

Para tratar o problema de quantificação dos erros iniciais em sistemas oscilatórios, utilizam-se índices como o integral do tempo multiplicado pelo erro absoluto (*integral of the time multiplied by absolute error* - ITAE) ou o integral do tempo multiplicado pelo erro quadrático (*integral of the time multiplied by square error* - ITSE).

$$ITAE = \int_{t_{i-1}}^{t_i} t |r - y| dt \quad (2.20)$$

$$ITSE = \int_{t_{i-1}}^{t_i} t(r - y)^2 dt \quad (2.21)$$

## 2.3 Índices Determinísticos

Características dos sistemas como o tempo de subida, margem de ganho, margem de fase, entre outros, podem ser utilizados para determinar o desempenho e a robustez do sistema. Estas características permitem retirar conclusões sobre o sistema (Goodwin, Graebe & Salgado, 2001). Estas técnicas são aplicadas em alguns casos pois permitem obter características e robustez do sistema (Seborg, Mellichamp, Edgar & Doyle, 2004) que tornam a avaliação e o diagnóstico ao desempenho do sistema mais fácil e correto.

### 2.3.1 Índices determinísticos para quantificar o desempenho do sistema

O desempenho de sistemas estáveis pode ser avaliado usando o conjunto de parâmetros clássicos que descrevem a dinâmica de um sistema. As seguintes propriedades, representadas na figura 2.3 (Farenzena, 2008), podem ser medidas (Goodwin et al., 2001):

- Tempo de subida (*Rise time,  $R_t$* ) - tempo decorrido entre 5% do valor final e 95% do valor final ( $0.05y_\infty - 0.95y_\infty$ )
- Tempo de estabelecimento (*Settling time,  $S_t$* ) - tempo necessário para que a resposta entre e permaneça dentro do intervalo de 5% em torno do valor final.
- Sobreelevação (*Overshoot,  $O_s$* ) - Rácio entre o valor máximo da resposta ( $O_s$ ) e o valor final ( $y_{inf}$ ).




Figura 2.3: Medidas determinísticas.

### 2.3.2 Índices determinísticos para quantificar a robustez do sistema

De modo a avaliar a robustez do sistema é comum medir-se a margem de ganho e margem de fase do sistema.

A margem de ganho pode ser definida como o máximo ganho adicional que leva o anel fechado a atingir o ponto crítico. A margem de fase quantifica o atraso que pode ser adicionado ao anel para atingir o ponto crítico. A figura 2.4 (Farenzena, 2008) mostra as margens de ganho e fase num diagrama de Bode (Goodwin et al., 2001).

Outra alternativa para medir a robustez do sistema é a Máxima Sensibilidade (*Maximal Sensitivity*). Traça-se o diagrama de Nyquist, e mede-se a distância do ponto  $-1$  ( $r$ ), como mostra a figura 2.5 (Farenzena, 2008). A máxima sensibilidade é definida com base no inverso de  $r$ . Quando maior o valor mais instável o sistema será.

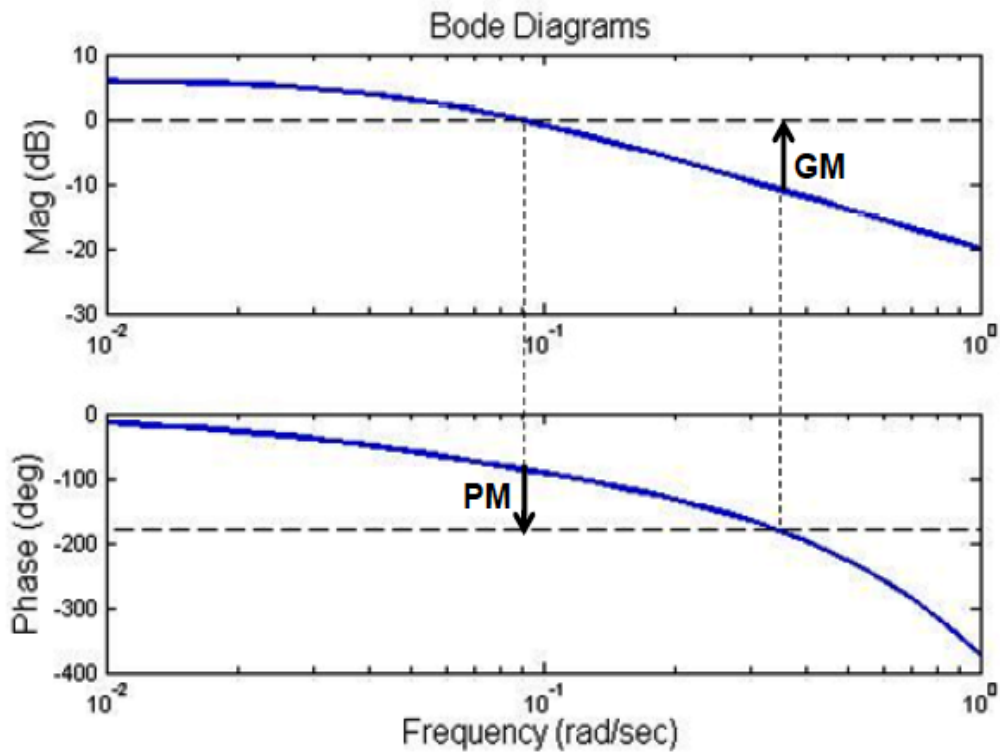


Figura 2.4: Margens de ganho e de fase baseadas no diagrama de Bode.




Figura 2.5: Máxima sensibilidade usando diagrama de Nyquist.

## 2.4 Técnicas Estatísticas

É comum acoplar aos índices de avaliação de desempenho algumas técnicas estatísticas tradicionais. Isto porque facilitam o diagnóstico e avaliação do sistema.

### 2.4.1 Função de autocorrelação (ACF)

A ACF da saída do processo é uma medida aproximada do quão perto da variância mínima o sistema se encontra. Calcula-se a ACF através dos valores de correlação da série temporal em relação a ela mesma para deslocamentos de zero até um horizonte de predição desejado, equação 2.22. Quando os valores de autocorrelação são elevados, significa que os valores no tempo  $t$  da série temporal são muito influenciados pelos valores anteriores ( $t-1, t-2, \dots$ ). Isto leva a que, para um controlador bem ajustado a ACF deve ir para zero logo após o tempo morto do sistema, pois uma boa ação de controle elimina a dependência dos valores anteriores da série temporal. Por vezes a ACF também é utilizada como uma ferramenta para avaliar a qualidade do conjunto de dados sendo analisado a periodicidade.

$$ACF(b) = \frac{\sum_{i=1}^{N-b} (x_i - \bar{x})(x_{i+b} - \bar{x})}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (2.22)$$

Sendo  $b$  o horizonte de predição,  $N$  o tamanho do conjunto de dados,  $x_i$  é o valor da variável no atraso  $i$  e  $\bar{x}$  é a média da amostra. A ACF toma valores entre -1 e 1, sendo que valores perto de 1 e -1 indica forte correlação.

### 2.4.2 Correlação cruzada

A correlação cruzada mede a influência que um determinado anel tem sobre o outro. Por vezes o desempenho de um anel é prejudicado pela interação com outro anel, mesmo o controlador estando bem sintonizado. Isto deve ser levado em conta na avaliação de desempenho em relação à variância mínima.

A equação 2.23 mostra a função de correlação cruzada entre duas amostras  $x$  e  $y$  para um atraso  $d$ .

$$\alpha(d) = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_{i-d} - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_{i-d} - \bar{y})^2}} \quad (2.23)$$

### 2.4.3 Resposta ao impulso

A função da resposta ao impulso relaciona a série temporal da perturbação na forma de ruído branco com a saída do processo. Pode ser calculada analisando as séries temporais. Foi desta forma que T. J. Harris (1989) calculou a variância do processo e a variância mínima para o cálculo do seu índice. A resposta pode ter um decaimento lento ou rápido, suave ou oscilatório para diferentes sintonizações do controlador, dando assim indicação sobre a dinâmica do controlador. Modelando a série temporal como uma função do tipo ARMA, MA ou AR e efetuando a divisão longa do numerador pelo denominador, calcula-se a resposta ao impulso (Huang & Shah, 1999).

### 2.4.4 Análise espectral

Também no domínio da frequência pode-se avaliar a qualidade do anel. Detetar oscilações, *offset's* e ruídos. Para fazer a análise espectral é primeiro necessário passar os dados no domínio do tempo para o domínio da frequência, geralmente através da transformada de Fourier.

A comparação entre a resposta no domínio da frequência real do sistema em anel fechado com a resposta em frequência do sistema em CVM (controlador de variância mínima) possibilita avaliar possíveis melhorias no desempenho através de ajustes no controlador. Esta comparação permite ainda verificar quais as frequências em que o controlador se desvia da variância mínima. Sendo que desvios de frequência normalmente indicam ação integral insuficiente ou ganho proporcional baixo. Picos largos em frequências médias tipicamente indicam um controlador ajustado de forma muito sensível ou presença de perturbações oscilatórias.

### 2.4.5 Teste de resíduos

Para o cálculo de índices de desempenho baseados em variância mínima, supõe-se que o sistema é linear ou que possa ser considerado aproximadamente linear. Os resíduos são então obtidos ajustando-se um modelo linear aos dados. Se o resultado obtido for uma sequência aleatória, independente, igualmente distribuída e possuir média nula, significa que o modelo estimado utilizado para a avaliação de desempenho é válido. De referir ainda que para ser considerado ruído branco, a função de autocorrelação dos resíduos deve estar contida no intervalo de confiança de 95%. Esta característica é um indicativo da qualidade de estimação do índice de desempenho.

## 2.5 Análise em Componentes Principais (PCA)

O PCA surgiu pela primeira vez por Pearson (1901), na altura descrito como "*finding lines and planes of closest fit to systems of points in space*". O PCA como o conhecemos atualmente

foi proposto por Hotelling (1933), que propôs usar esta técnica para analisar a covariância/correlação entre as variáveis. Contudo esta técnica não teve grande uso até chegarem os computadores mais poderosos. Desde aí tem sido utilizada nas mais diversas áreas, como a química, engenharia, geologia, entre muitas outras.

### 2.5.1 Objectivo

A aplicação do PCA a um conjunto multi-variável  $X$ , resulta na criação de novas variáveis que são uma combinação linear das variáveis originais e são constrangidas a ser mutuamente ortogonais (Jolliffe, 1986). Através da exclusão das componentes principais associadas ao ruído, reduz-se a dimensão e mantém-se as componentes principais que caracterizam as fontes de variação.

### 2.5.2 Interpretação Geométrica

A figura 2.6 ("Análise de Componente Principais – PCA", 2009) elucida o conceito geométrico do PCA. Os três eixos representam as três variáveis originais e "•" representa as observações originais. O eixo vermelho " $PC_1$ " define a primeira componente principal. E o eixo " $PC_2$ " define a segunda componente principal que é perpendicular à primeira componente.

A localização de cada observação original no plano é dada pelo seu *score vector*. Isto é, a distância da origem do plano ao longo da componente principal, até à projeção da observação da componente principal.

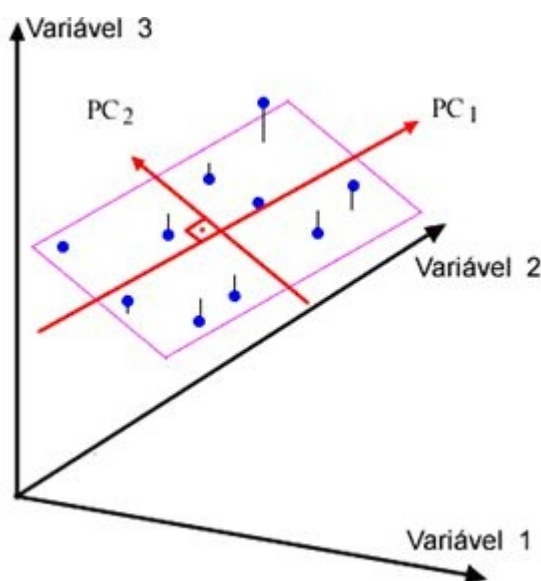


Figura 2.6: Representação gráfica do PCA.

### 2.5.3 Definição matemática

Vários métodos podem ser aplicados para determinar as componentes principais. Incluindo, *Non-linear Iterative Partial Least Squares* (NIPALS) (Geladi & Kowalski, 1986; Wold, Geladi, Esbensen & Ohman, 1987) e *Singular Value Decomposition* (SVD) (Jolliffe, 1986). O algoritmo NIPALS calcula as componentes principais sequencialmente, enquanto que o SVD deriva todas as componentes simultaneamente. Apenas o algoritmo SVD será abordado pois é o mais utilizado geralmente.

Seja a matriz  $X$  de ordem  $N \times M$  onde,  $N$  é o número de amostras e  $M$  o número de variáveis. A covariância da matriz  $X$  é definida como:

$$S = \frac{X^T X}{N - 1} \quad (2.24)$$

O PCA decompõe a matriz  $X$  como o somatório do produto externo dos vetores  $t_i$  e  $P_i$ . O resultado da decomposição pode ser dividido em duas partes, estrutura interna (modelo estatístico) e estrutura externa (modelo residual):

$$X = \sum_{i=1}^I t_i P_i^T + E \quad (2.25)$$

Onde  $t_i$  é o vetor de projeções no espaço (*vector of scores*) e  $P_i$  é a matriz característica do processo (*loading vector*),  $E$  é a matriz residual e  $I$  o número de componentes principais incluídas no modelo. Os *score vectors*,  $t_i$ , contêm informação sobre como as amostras estão relacionadas umas com as outras. Enquanto que  $P_i$  descreve como as variáveis estão relacionadas. Os *loading vectors* são os vetores próprios da matriz de covariância:

$$S P_i = \lambda_i P_i \quad (2.26)$$

Onde  $\lambda_i$  é o valor próprio associado com o vetor próprio  $P_i$ . Os *scores vector* são obtidos da seguinte forma:

$$T = X P \quad (2.27)$$

Portanto  $T$  é uma combinação linear das variáveis originais da matriz  $X$ , onde os coeficientes são definidos por  $P$ . As componentes principais são dispostas por ordem decendente de acordo com o valor próprio associado  $\lambda_i (i = 1, 2 \dots I)$ .  $\lambda_i$  é uma medida da quanta variância cada componente tem. Com as componentes principais dispostas por ordem decendente de  $\lambda_i$ , a primeira componente principal captura a maior quantidade de informação e cada seguinte componente principal captura a próxima quantidade de variância.

O resíduo é obtido aplicando:

$$q_0 = e_p e_p^T \quad (2.28)$$

Sendo que  $e_p$  é o erro no modelo, que é obtido através:

$$e_p = X - \hat{X} \quad (2.29)$$

Sendo  $\hat{X}$  a estimativa da matriz  $X$  e é obtido pela equação 2.30.

$$\hat{X}(k) = TP^T \quad (2.30)$$

#### 2.5.4 Seleção do número de componentes principais

Uma etapa importante na aplicação do PCA é a escolha adequada do número de componentes principais. Esta escolha deve ser feita com cuidado pois afeta o desempenho do modelo. Um conjunto de variáveis altamente correlacionadas geralmente requer apenas algumas componentes principais. Escolher muitas componentes principais não significa uma melhor representação do processo. Este facto pode levar a que a sensibilidade do modelo seja afetada. Vários autores têm proposto várias técnicas para selecionar o número de componentes principais.

A percentagem total de variância é um critério importante na seleção. Pode ser calculada da seguinte maneira:

$$v = \|X\|^2 \quad (2.31)$$

Ajustando o modelo, a matriz  $X$  pode ser expressa como:

$$X = \hat{X} + E \quad (2.32)$$

Sendo a variância estimada para o modelo dada por:

$$\hat{v} = \|\hat{X}\|^2 \quad (2.33)$$

O critério para a percentagem da variância do modelo é dado por:

$$0.7 \leq \frac{\hat{v}}{v} \leq 0.9 \quad (2.34)$$

Este intervalo foi sugerido por Jolliffe (1986). Contudo esta regra nem sempre é apropriada para certo tipo de dados, onde o ruído é maior do que 30% ou menor que 10%.

Outra técnica muito popular é a validação-cruzada, proposta por Wold (1978). A primeira etapa é dividir os dados em grupos. Por exemplo, conjunto de dados de 100 amostras pode ser dividido em 4 grupos de 25 amostras cada. O passo seguinte é excluir um

dos grupos e construir o modelo PCA apenas com os restantes grupos de amostras. Admitindo que temos os grupos  $G_1, G_2, G_3, G_4$  e que excluimos os grupo  $G_4$ , a primeira componente principal é então utilizada para calcular o *score vector* do grupo excluído:

$$t_{G_4} = X_{G_4} P_{(G_1:G_3)} \quad (2.35)$$

Onde  $t_{G_4}$  é o *score vector* do grupo  $G_4$  e  $P_{(G_1:G_3)}$  o *loading vector* da primeira componente principal calculada dos grupos  $G_1, G_2, G_3$ . Este valor é então utilizado para estimar os valores do grupo  $G_4$ :

$$\hat{X}_{G_4} = t_{G_4} P_{(G_1:G_3)}^T \quad (2.36)$$

Através desta estimativa, *Predicted Error Sum of Squares* (PRESS) é calculado:

$$E_{G_4} = \sum_{i=1}^{25} (X_{G_4i} - \hat{X}_{G_4i})^2 \quad (2.37)$$

Este procedimento é repetido para todos os grupos que foram excluídos e o PRESS TOTAL é calculado:

$$PRESS\ TOTAL = E_{G_1} + E_{G_2} + E_{G_3} + E_{G_4} \quad (2.38)$$

O procedimento é repetido para as próximas componentes principais, sendo calculado o PRESS TOTAL para cada uma delas. O número de componentes principais que tiver menor PRESS TOTAL é o número indicado de componentes principais.

Porém a técnica mais utilizada e também nesta dissertação, consiste em somar todos os valores próprios da matriz de valores próprios, e em seguida dividir todos os valores próprios pela soma deles. Disto resulta que escolhe-se o número de valores próprios que somados atingem 95% ou mais do total dos valores próprios.

## 2.6 Redes Neurais

Fundamentalmente, uma rede neuronal consiste numa estrutura conexionista, em que o processamento é distribuído por um elevado número de pequenas unidades densamente interligadas (Hertz, Krogh & Palmer, 1991; Wasserman, 1989). Estas pequenas unidades são normalmente designadas de neurónios.

As redes neuronais surgem com o interesse em inteligência artificial e beneficiando dos progressos feitos na neurobiologia, permitindo a compreensão dos processos do cérebro e modelação do neurónio.

O neurónio biológico, esquematizado na figura 2.7 (Gil, 2009), baseia-se numa única célula que é capaz de fazer processamento de uma forma muito simples. Cada um dos neurónios é estimulado por uma ou várias ligações provenientes de outros neurónios, designadas sinapses, dependendo o sinal produzido da força das ligações e da natureza (inibitória, excitatória, etc). O sinal produzido é propagado ao longo do axónio, indo estimular outros neurónios. O princípio dos neurónios artificiais, representado na figura 2.8 (Gil, 2009), baseia-se na generalidade dos casos, neste modelo simplificado dos neurónios biológicos.




Figura 2.7: Neurónio biológico simplificado.




Figura 2.8: Neurónio artificial.

Atualmente existe uma grande variedade de redes neuronais artificiais a serem experimentadas, com a modelização de cada neurónio a variar desde uma simples soma pesada das entradas a conjuntos complexos de equações diferenciais, com a informação na rede a circular apenas num sentido ou em vários, com os neurónios a serem atualizados simultaneamente ou em intervalos temporais entre eles, etc, sendo o número de combinações possíveis quase ilimitado.

É na área da classificação e da predição que o desempenho das redes neuronais artificiais mais se faz notar e onde são mais utilizadas. Também nesta dissertação estes dois tipos de redes serão utilizados.

### 2.6.1 Modelos neuronais preditivos

Este género de redes neuronais permitem identificar e controlar, sistemas não-lineares, e com essa informação detetar e diagnosticar falhas no sistema. A eficácia da rede depende muito do conjunto de dados escolhido para o seu treino. Alguns autores propuseram metodologias usando estes modelos neuronais (Koppen-Seliger, Garcia & Frank, 1999; L. B. Palma, Coito & da Silva, 2003a; Genrup, 2005).

Redes neuronais na forma de preditor neuronal podem ser utilizadas como um modelo neuronal NARX preditor da saída (Narendra & Parthasarathy, 1990; L. B. Palma, Coito & da Silva, 2003b), expresso na forma:

$$\hat{y}_{nop}(k) = NN_{\{a-b-c\}}(W, y(k-1), \dots, y(k-n_a), u(k-1), \dots, u(k-n_b)) \quad (2.39)$$

Sendo que neste caso  $n_a$  representa o número de pólos do sistema e  $n_b$  o número de zeros,  $NN_{\{a-b-c\}}(W, \dots)$  representa uma rede neuronal não-linear, com peso  $W$  e com uma estrutura  $\{a-b-c\}$  que corresponde ao número de neurónios em cada camada, respetivamente a camada de entrada (*input-layer* (IL)), camada intermédia (*hidden-layer* (HL)) e a camada de saída (*output-layer* (OL)). A figura 2.9 mostra uma arquitetura possível para identificação de sistemas através de NOP (*Neural Output Predictors*).

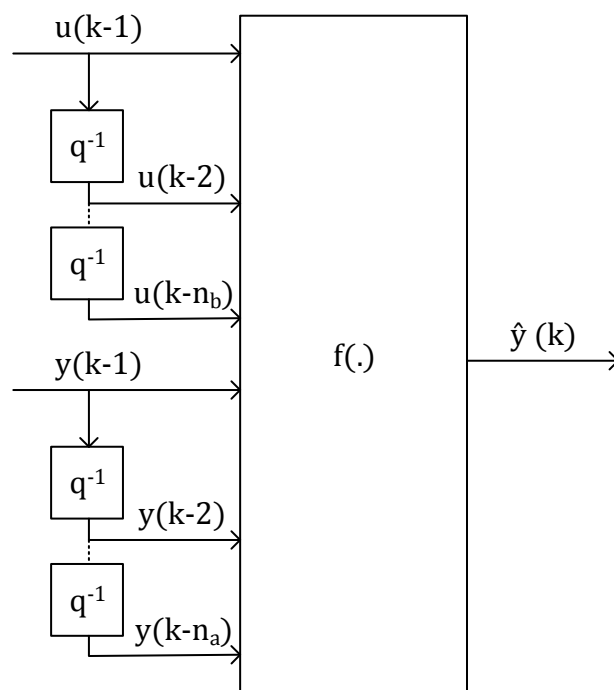


Figura 2.9: Arquitetura possível de uma NOP.

### 2.6.1.1 Treino de redes neurais preditoras

Para implementar modelos não-lineares com base em redes neurais, existem diferentes tipos de redes consoante a sua função de ativação. *Radial Basis Function* (RBF) e *Multi-Layer Perceptron* (MLP) são duas. RBF tem uma função de ativação Gaussiana, um número elevado de neurónios na camada intermédia (HL) e o seu treino é rápido. MLP têm uma função de ativação Sigmoide, um número reduzido de neurónios na camada intermédia (HL) e o seu treino é lento.

Tipicamente um modelo neuronal não-linear NARX com três camadas é suficiente para modelar sistemas não-lineares dinâmicos (Haykin, 1994; Hagan, Demuth & Beale, 1995), tendo uma camada de entrada, uma camada intermédia (sigmoide), e uma camada de saída (linear).

O algoritmo de otimização geralmente mais utilizado é o Levenberg-Marquardt (Hagan et al., 1995).

O número de neurónios da camada intermédia dependerá muito do sistema a modelar, sendo que a comunidade científica sugere uma regra empírica para a escolha dos neurónios da camada intermédia deve ser aproximadamente igual ao número de entradas. Também os dados selecionados para o treino devem ser cuidadosamente escolhidos em ordem a obter um bom modelo. As várias dinâmicas do sistema devem ser captadas e deve ser evitado saturações e derivadas infinitas.

### 2.6.2 Modelos neurais classificadores

Uma das possibilidades mais explorada das redes neurais consiste na sua utilização para classificar padrões de entradas em diferentes categorias. Note-se que esta área é imensa, indo desde o reconhecimento de diversos tipos de terreno em imagens de satélite até à identificação de veículos em imagens de sonar ou de doenças do coração em eletrocardiogramas.

Existem diferentes tipos de padrão, podendo ser classificados segundo Duda (1997) como:

- Padrão estatístico ou fuzzy;
- Padrão estrutural ou sintático;
- Padrão baseado no conhecimento

Uma rede neuronal recebe uma coleção de padrões de entrada cada um associado a uma categoria. Depois pode-se introduzir na rede um padrão desconhecido, e esta classificará o novo padrão corretamente. A vantagem de usar redes neurais para a classificação de padrões é o facto de ela poder construir fronteiras de decisões não-lineares entre as diferentes classes e oferecer um método prático para resolver problemas muito complexos.

Para que a classificação de padrões seja bem sucedida, é necessário existir um mapeamento dos padrões de entrada num espaço de classificação. Este espaço é definido por regiões de decisão que separam os padrões, atribuindo a cada padrão uma classe.

Os classificadores são divididos em quatro grandes grupos baseados na definição de funções discriminantes que definem as regras de decisão, sendo eles:

- Classificadores Probabilísticos;
- Classificadores de Hiperplano;
- Classificadores de Kernel;
- Classificadores de Exemplos.

## Metodologias Propostas para Análise de Desempenho

Ferramentas de avaliação de desempenho de anéis de controle são importantes para obter e manter o processo num ponto de operação de elevada eficiência. Neste capítulo serão apresentadas as metodologias propostas nesta dissertação, capazes de avaliar o desempenho de anéis de controle em tempo real, detetando e isolando anomalias no processo. As metodologias propostas baseiam-se principalmente na técnica PCA, mas também em vários outros algoritmos que combinados eficazmente podem produzir resultados muito interessantes. A arquitetura geral proposta encontra-se na figura 3.1. Cada metodologia apresenta à saída o sinal de deteção de falhas ( $\chi_{a1}, \chi_{b1}$ ) e o sinal de isolamento ( $\chi_{a2}, \chi_{b2}$ ).

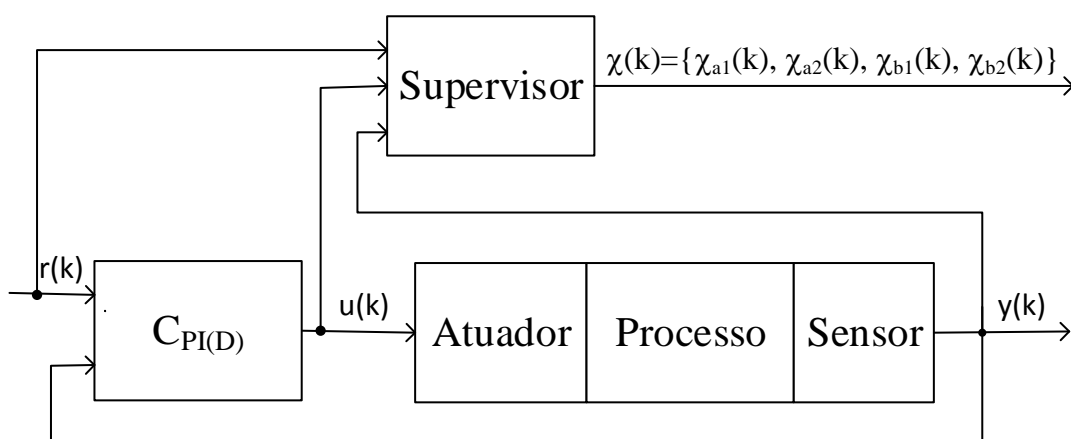


Figura 3.1: Arquitetura geral de análise de desempenho.

O supervisor é responsável por detetar e isolar anomalias no sistema. A arquitetura do supervisor pode ser observada na figura 3.2. Como se pode constatar na figura, as metodologias propostas apenas necessitam dos sinais de operação do sistema.

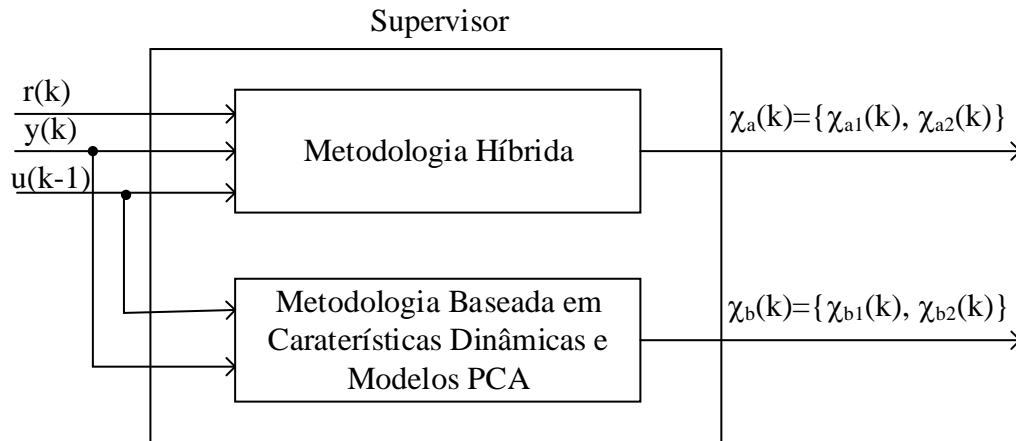


Figura 3.2: Arquitetura do supervisor.

A filtragem passa-baixo é necessária para rejeição de ruído e melhorar o desempenho geral do sistema. Isto é muito importante na monitorização de processos e largamente utilizado nesta dissertação. Um filtro passa-baixo de primeira ordem em tempo discreto é dado pela equação 3.1.

$$\lambda(k) = p \lambda(k-1) + (1-p)\lambda_0(k) \quad (3.1)$$

Sendo que  $\lambda(k)$  é o sinal filtrado, e  $\lambda_0(k)$  é o sinal original. O pólo no "plano-z" é representado por  $p$ .

### 3.1 Perturbações, Falhas e Avarias

Isermann e Ballé (1997) propuseram terminologias para definir e distinguir, falhas, avarias e perturbações. Um resumo destes conceitos segundo os autores referidos apresenta-se a seguir:

- Falha: Desvio não permitido de pelo menos uma característica, propriedade ou parâmetro do sistema, do aceitável / usual / condições padrão;
- Avaria: Interrupção permanente da capacidade do sistema fazer uma dada função sob uma condição de operação especificada;
- Perturbação: Entrada no sistema, que resulta num desvio temporário do estado atual do sistema;

De forma a testar o desempenho e a robustez das metodologias propostas, dois tipos de falhas e uma perturbação são provocadas. As falhas/perturbação provocadas são as que tipicamente ocorrem nos sistemas industriais, sendo elas as seguintes:

- Funcionamento nominal do sistema, isto é, sistema sem falhas;
- Variação do ponto de operação do sistema, ou seja, o controlador passa a seguir outra referência, havendo um período de transitório entre a variação;
- Dessintonização do controlador, neste caso, a um controlador PI bem sintonizado é-lhe adicionado uma forte componente derivativa para causar a dessintonização;
- Oscilação na saída do processo, provocado pela ação humana abrindo e fechando de forma intermitente uma válvula.

Na tabela 3.1 encontra-se um resumo das falhas/perturbação provocadas neste trabalho para efeitos de teste.

Tabela 3.1: Falhas.

Falhas	Descrição	Tipo
$F_0$	Operação nominal	
$F_1$	Variação de referência	Perturbação
$F_2$	Dessintonização do controlador	Falha
$F_3$	Falha intermitente	Falha

## 3.2 Metodologia Híbrida

Uma metodologia híbrida e em tempo real é proposta aqui. São calculados vários índices de monitorização e é depois cruzada a informação fornecida por eles. Esta metodologia é baseada no índice de Harris normalizado (Desborough & T. J. Harris, 1992), PCA linear e numa rede neuronal preditiva. Esta metodologia irá permitir detetar e isolar, falhas intermitentes, transientes e dessintonização do controlador PI(D). Na figura 3.3 está representada a arquitetura desta metodologia. Começa-se por calcular cinco índices de desempenho, depois alguns deles são filtrados passa-baixo para reduzir o ruído. Posteriormente esses índices são binarizados segundo *thresholds* pré-definidos, indicando se houve deteção de falha ou não. De seguida são construídos outros índices baseados nos anteriores, cada um destes novos índices é vocacionado para um certo tipo de falha. Por fim, esses índices são utilizados para o *fault detection* (FD) e para *fault isolation* (FI).




Figura 3.3: Arquitetura da metodologia híbrida.

### 3.2.1 Índices de avaliação de desempenho

Todos os índices depois de calculados nesta sub-secção são binarizados entre 0 ou 1, sendo que 0 representa um bom funcionamento e 1 mau desempenho. A binarização é feita comparando o valor do índice com um *threshold* previamente definido com base em experimentação. Os *thresholds* são definidos pelo utilizador consoante o processo em questão. Na tabela 3.2 estão representados todos os valores dos *thresholds* utilizados.

Tabela 3.2: Thresholds para a binarização.

<i>Thresholds</i>	Valor
$thr_{r_1}$	0.47
$thr_{r_2}$	0.0016
$thr_{r_3}$	0.05
$thr_{r_4}$	$0.5 \times 10^{-8}$
$thr_{r_5}$	0.002

#### 3.2.1.1 Índice de Harris normalizado ( $r_1(k)$ )

Este índice é calculado segundo a equação 3.2. Uma descrição pormenorizada do método encontra-se na sub-secção 2.2.2. O índice é saturado entre 0 e 1. Depois de binarizado o índice recebe a etiqueta  $r_{1b}(k)$ . Fundamentalmente este índice indica situações em que o erro de controlo é elevado.

$$r_1(k) = 1 - \frac{\sigma_{r_e}^2(k)}{\chi_e(k)} \quad (3.2)$$

Tanto  $\sigma_{r_e}^2(k)$ , variância do resíduo 2.3, como  $\chi_e(k)$ , erro quadrático médio do erro de controlo, são calculados com uma janela deslizante de tamanho  $w$ . A figura 3.4 mostra o esquemático deste índice.



Figura 3.4: Esquemático do índice de Harris normalizado.

#### 3.2.1.2 Rede neuronal preditiva ( $r_2(k)$ )

Uma rede neuronal preditiva foi implementada para modelar as não-linearidades do sistema. O resíduo dessa mesma rede é utilizado para monitorização (equação 3.3). O resíduo é depois filtrado passa-baixo para reduzir o ruído segundo a equação 3.1, sendo

depois binarizado ( $r_{2b}$ ). Este índice basicamente indica situações onde a saída do processo está desviada do que seria de esperar.

$$r_2(k) = |y(k) - \hat{y}_{nop}(k)| \quad (3.3)$$

Sendo  $y$  a saída do processo e  $\hat{y}_{nop}$  a saída da rede neuronal. O regressor da rede é descrito por 3.4. Após alguma experimentação conclui-se que a rede deverá ser composta por uma camada de entrada com 7 neurónios, uma camada intermédia com 10 neurónios e uma camada de saída apenas com 1 neurónio. A função de ativação da camada intermédia é uma hiperbólica sigmóide tangente e a da camada de saída é linear. A rede foi treinada segundo os algoritmos Levenberg-Marquardt e MSE.

$$\psi(k) = [ y(k-1) \quad y(k-2) \quad y(k-3) \quad y(k-4) \quad u(k-1) \quad u(k-2) \quad u(k-3) ] \quad (3.4)$$

Sendo  $u$  a ação de controlo. O esquemático deste índice pode ser consultado na figura 3.5.




Figura 3.5: Esquemático de rede neuronal preditiva.

### 3.2.1.3 Sinal de referência ( $r_3(k)$ )

Para detetar variações de referência, recorre-se ao sinal de referência  $r(k)$ . Uma filtragem passa-alto é feita a  $r(k)$  para detetar derivadas altas no sinal, ou seja, variações de referência. O pólo do filtro deve ser escolhido com base na dinâmica do processo e no intervalo de amostragem. O índice  $r_3(k)$  é dado pela equação 3.5, sendo depois binarizado ficando com a etiqueta  $r_{3b}$ . Este índice indica situações em que ocorre uma variação na referência.

$$r_3(k) = |r(k) - r(k-1) + p r_3(k-1)| \quad (3.5)$$

Sendo que  $r$  é a referência e  $p$  o pólo. O modelo funcional deste índice encontra-se na figura 3.6.




Figura 3.6: Esquemático índice  $r_3(k)$ .

### 3.2.1.4 Análise de componentes principais ( $r_4(k)$ )

O PCA linear, uma técnica estatística multi-variável (Chiang, Russell & Braatz, 2001) foi também incorporada nesta abordagem híbrida. O resíduo do modelo PCA com duas componentes principais ( $t_1, t_2$ ) é utilizado para efeitos de monitorização, equação 3.6. O resíduo é depois filtrado segundo a equação 3.1. Depois de filtrado o sinal é binarizado ( $r_{4b}$ ), sendo que este sinal é construído com base no *threshold*  $thr_{r_4}$  e também no facto de ocorrer ou não uma derivada alta (variação de referência) no sinal  $r_{3b}$ .

$$r_4(k) = e_p(k)e_p^T(k) \quad (3.6)$$

Sendo  $e_p$  o erro associado ao modelo PCA. Este modelo PCA foi construído com base numa matriz  $X$  com o regressor dado pela equação 3.7. A estrutura do regressor foi inspirada nos sinais utilizados no índice de Harris normalizado, equação 3.2, sendo que esses sinais são baseados no erro de controlo este índice permite identificar transientes pois o erro aumenta nessas situações.

$$\xi(k) = [ \sigma_{r_e}^2(k) \quad \sigma_{r_e}^2(k-1) \quad \sigma_{r_e}^2(k-2) \quad \chi_e(k) \quad \chi_e(k-1) \quad \chi_e(k-2) ] \quad (3.7)$$

Onde  $\sigma_{r_e}^2$  é a variância do resíduo do erro e  $\chi_e$  é o erro quadrático médio do erro de controlo. Na construção deste modelo foi utilizada a matriz  $X$  dada por 3.8. A covariância da matriz  $X$  é dada segundo 3.9

$$X = \begin{bmatrix} \xi(1) \\ \vdots \\ \xi(N) \end{bmatrix} \quad (3.8)$$

$$S = \frac{X^T X}{N-1} \quad (3.9)$$

Aplicando decomposição de valores singulares (SVD) a 3.9 obtém-se uma matriz de vetores próprios. Retirando dessa matriz o número de colunas igual ao número de componentes principais obtém-se a matriz  $P$  com tantas linhas quanto o número de elementos do regressor  $\xi$  e tantas colunas quanto o número de componentes principais. O vetor  $T(k)$ , vetor de componentes principais, é dado por 3.10.

$$T(k) = \xi(k)P \quad (3.10)$$

$$T(k) = [ t_1(k) \quad t_2(k) ] \quad (3.11)$$

Para o cálculo de  $e_p(k)$  é ainda necessário estimar a matriz  $\xi(k)$ , equação 3.12. Finalmente o erro associado ao modelo  $e_p(k)$  é dado por 3.13.

$$\hat{\xi}(k) = T(k)P^T \quad (3.12)$$

$$e_p(k) = \xi(k) - \hat{\xi}(k) \quad (3.13)$$

O esquemático deste índice está representado na figura 3.7




Figura 3.7: Esquemático índice  $r_4(k)$ .

### 3.2.1.5 Variância da ação de controlo ( $r_5(k)$ )

A variância da ação de controlo foi utilizada para monitorização. Para o cálculo da variância uma janela deslizante com tamanho  $w$  foi utilizada. Também este sinal é filtrado segundo a equação 3.1 e binarizado ( $r_{5b}$ ). Este índice deteta situações onde a ação de controlo é instável.

$$r_5(k) = \sigma^2(u(k-w+1:k)) \quad (3.14)$$

A figura 3.8 mostra o esquemático deste índice.




Figura 3.8: Esquemático índice  $r_5(k)$ .

## 3.2.2 Índices de deteção e diagnóstico de falhas

Três novos índices são construídos com base nos índices anteriores ( $r_{ib}$  com  $i = 1, 2, \dots, 5$ ), ou seja também estes índices tomam os valores 0 (bom desempenho) ou 1 (mau desempenho). Estes índices são desenhados de forma a permitir decisões inteligentes em tarefas de deteção e diagnóstico, ou seja, cada índice é construído de forma a detetar um certo tipo de falha ou perturbação.

O primeiro índice é dado pela equação 3.15. Este índice é vocacionado para detetar transitórios.

$$i_1(k) = r_{1b}(k)r_{4b}(k) \quad (3.15)$$

Este índice é constituído pelo índice de Harris normalizado ( $r_{1b}$ ) e pelo resíduo do PCA ( $r_{4b}$ ) inspirado no índice de Harris normalizado, portanto, ambos os índices que constituem  $i_1$  são baseados no erro de controlo e assim sendo permitem detetar situações de

regimes transitórios onde o erro é maior.

O segundo índice é representado pela equação 3.16. Este índice é constituído pelo índice  $r_{5b}$  que deteta a variância da ação de controlo e pela negação do índice  $r_{4b}$  (resíduo do modelo PCA) que permite deixar de fora da deteção os transientes onde é normal haver uma variância da ação de controlo. Este índice é portanto vocacionado para a deteção de dessintonização do controlador onde existe uma forte variância na ação de controlo.

$$i_2(k) = r_{5b}(k)\overline{r_{4b}}(k) \quad (3.16)$$

Por fim o último índice é dado pela equação 3.17. Este índice vocacionado na deteção de oscilações no sistema. Sendo constituído pelo índice de Harris normalizado ( $r_{1b}$ ), baseado no erro que aumenta quando a saída do sistema se desvia da referência como é o caso de uma oscilação, pelo resíduo da rede neuronal ( $r_{2b}$ ) que aumenta quando a saída do sistema não é a esperada pelo modelo do processo e pela negação de  $r_{4b}$  (resíduo do modelo PCA) que permite excluir os transitórios.

$$i_3(k) = r_{1b}(k)r_{2b}(k)\overline{r_{4b}}(k) \quad (3.17)$$

Na figura 3.9 é mostrado o esquemático deste três índices, onde "X" representa a multiplicação.




Figura 3.9: Esquemático de índices de deteção e diagnóstico.

### 3.2.3 Deteção e diagnóstico de falhas

A deteção e o diagnóstico de falhas é feita completamente com base nos índices anteriores. Estes índices foram concebidos de forma a que uma correta combinação permita diagnosticar cada tipo de falha.

### 3.2.3.1 Detecção

Para ser detetada uma falha, basta um dos índices  $i_1$ ,  $i_2$  ou  $i_3$  tomar um valor diferente de zero. A equação 3.18 descreve algoritmo.

$$\chi_{a1}(k) = 1 \Leftrightarrow i_n(k) \neq 0 ; n = 1, 2, 3 \quad (3.18)$$

### 3.2.3.2 Diagnóstico

O procedimento para o diagnóstico de falhas é o descrito em 3.19, 3.20, 3.21 e 3.22.

$$\chi_{a2}(k) = 0 \Leftrightarrow (i_1(k) = 0) \& (i_2(k) = 0) \& (i_3(k) = 0) \quad (3.19)$$

$$\chi_{a2}(k) = 1 \Leftrightarrow (i_1(k) = 1) \quad (3.20)$$

$$\chi_{a2}(k) = 2 \Leftrightarrow (i_1(k) = 0) \& (i_2(k) = 1) \quad (3.21)$$

$$\chi_{a2}(k) = 3 \Leftrightarrow (i_1(k) = 0) \& (i_2(k) = 0) \& (i_3(k) = 1) \quad (3.22)$$

O diagnóstico como se pode constatar é feito com base nos índices  $i_1$ ,  $i_2$  e  $i_3$ . Como já foi referido anteriormente cada um desses índices apenas deteta um determinado tipo de falha ou perturbação, sendo assim, se algum destes índices for igual a "1" significa que nesse momento está a ocorrer a falha ou a perturbação que esse índice é vocacionado para detetar.

## 3.3 Metodologia Baseada em Características Dinâmicas e Modelos PCA

Uma metodologia em tempo real para avaliação de desempenho de anéis de controlo é proposta aqui. Baseada essencialmente em características dinâmicas do processo (ganho estático e a largura de banda estimados), análise em componentes principais lineares (PCA) e ainda uma rede neuronal que reconhece padrões. Tal como a metodologia anterior, será possível detetar e isolar, transientes, dessintonização de controlador PI(D) e falhas intermitentes. A arquitetura desta metodologia está representada na figura 3.10.

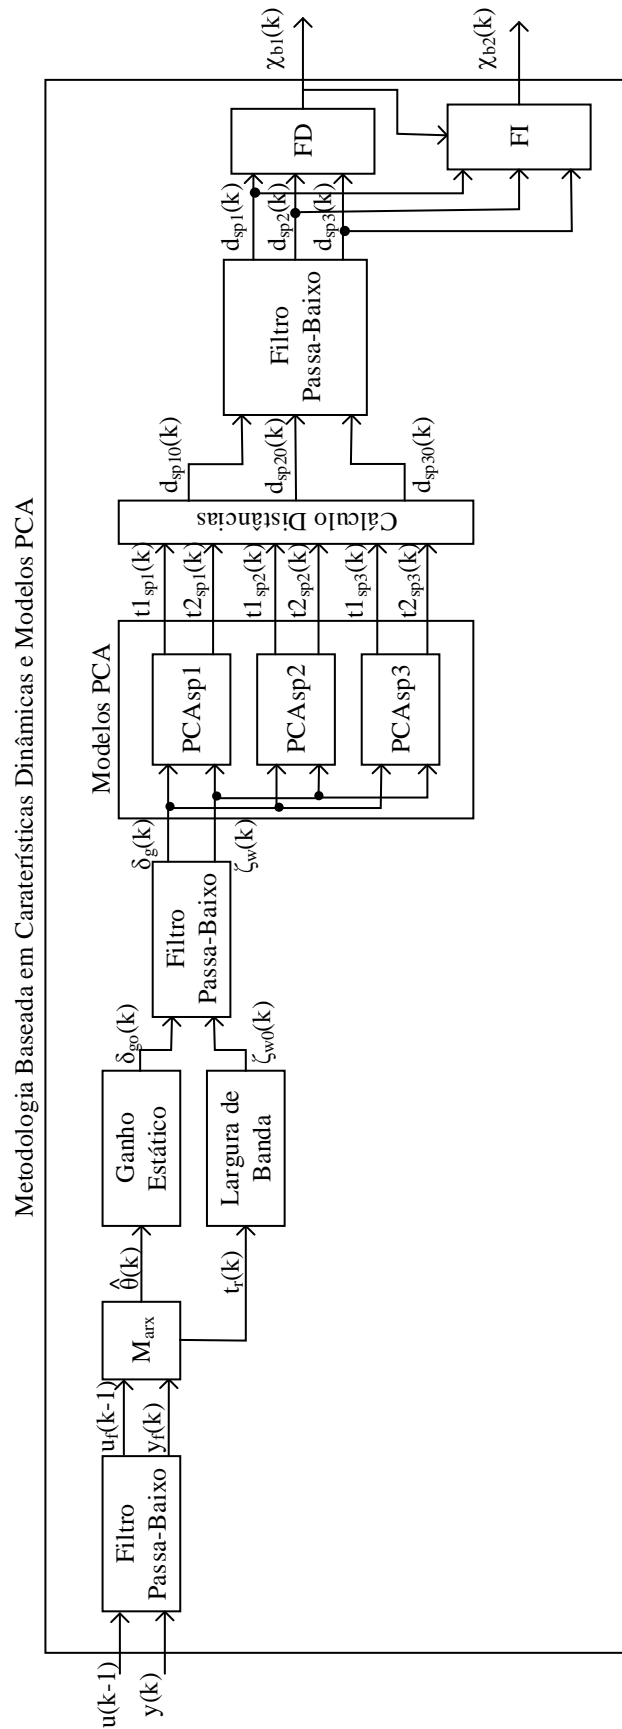


Figura 3.10: Arquitetura da metodologia baseada em características dinâmicas e modelos PCA.

O primeiro passo consiste em filtrar passa-baixo os sinais da ação de controle e da saída do sistema. Isto para obter um modelo estimado do processo mais estável, através do método dos mínimos quadrados (módulo  $M_{arx}$ ). Tendo o modelo estimado, obtém-se o ganho estático e largura de banda estimados do sistema. Filtra-se passa-baixo estes sinais, para evitar algum ruído e injeta-se em três modelos PCA calculados em diferido para cada ponto de funcionamento. O passo seguinte é calcular as distâncias de cada projeção no espaço a duas dimensões de cada modelo PCA até ao centroide de uma elipse pré-definida que caracteriza a zona nominal no espaço do ponto de funcionamento atual. Essas distâncias são filtradas passa-baixo e depois injetadas nos módulos *fault detection* (FD) e no *fault isolation* (FI).

### 3.3.1 Características dinâmicas: ganho estático e largura de banda

O passo inicial desta metodologia é estimar em tempo real o ganho estático e a largura de banda do sistema. Para obter estas características do sistema é primeiro necessário obter um sub modelo na zona de funcionamento. Isso é feito com recurso ao algoritmo ARX. Todos os sinais utilizados para a estimação do modelo são previamente filtrados de acordo com a equação 3.1. Desta forma é obtido um modelo menos nervoso e com melhor qualidade.

O regressor utilizado para o modelo é o seguinte:

$$v(k) = [ -y(k-1) \quad -y(k-2) \quad u(k-1) ]^T \quad (3.23)$$

Sendo  $y$  a saída do processo e  $u$  a ação de controle. Aplicando o método dos mínimos quadrados, equação 3.24, com uma janela deslizante, obtêm-se os parâmetros do modelo, equação 3.25.

$$\theta(k) = (v^T v)^{-1} v^T y \quad (3.24)$$

$$\theta(k) = [ a_1 \quad a_2 \quad b_1 ]^T \quad (3.25)$$

A função transferência em tempo discreto do processo fica então:

$$F(z) = \frac{b_1 z}{z^2 + a_1 z + a_2} \quad (3.26)$$

Para o cálculo do ganho estático em sistemas em tempo discreto, basta fazer  $F(z)_{z \rightarrow 1}$ . O ganho estático é representado por  $\delta_g$  e é dado pela equação 3.27

$$\delta_g(k) = \frac{b_1(k)}{1 + a_1(k) + a_2(k)} \quad (3.27)$$

A largura de banda é representada por  $\zeta_w$ . Assumindo um modelo dinâmico com pólos dominantes de segunda ordem, a largura de banda pode ser aproximadamente estimada

em tempo real baseado no tempo de subida estimado  $t_r$  (a partir da resposta ao degrau) do modelo ARX (Oppenheim, Willsky & Young, 1983).

$$\zeta_w(k) = \frac{2\pi}{t_r(k)} \quad (3.28)$$

Uma vez que a estimação do sub modelo do processo faz uso da ação de controlo, pode acontecer que a ação de controlo contenha derivadas infinitas e conseqüentemente o sistema fica instável e torna-se impossível estimar o ganho estático e a largura de banda. Um exemplo disso é quando ocorre uma falha. Nessas alturas são assumidos os valores anteriores conhecidos. Tanto o ganho estático como a largura de banda são filtrado de acordo com a equação 3.1 para evitar algum ruído nos sinais.

### 3.3.2 Análise em componentes principais (PCA)

Em diferido, para cada ponto de funcionamento do processo é construído um modelo PCA linear nominal, isto é, sem falhas. Estes modelos são inspirados no ganho estático e na largura de banda calculados anteriormente. Esta técnica irá permitir observar o relacionamento que existe entre estas duas características do processo.

O regressor destes modelos PCA é dado por:

$$\xi(k) = [ \delta_g(k - 3 : k) \quad \zeta_w(k - 3 : k) ] \quad (3.29)$$

O processo de construção do modelo PCA é o mesmo explicado na subsecção 3.2.1.4. As equações 3.8 e 3.9 foram utilizadas na construção do modelo. O cálculo em tempo real das projeções é dado pelas equações 3.10 e 3.11.

Em funcionamento nominal, as projeções de cada modelo concentram-se numa região do espaço. De acordo com o processo esta região varia. Previamente em diferido é desenhada manualmente uma elipse que define a região de funcionamento nominal, assumindo que os dados obedecem a uma distribuição normal, a figura 3.11 ilustra três pontos de funcionamento sem falhas, de um dado processo.

Em tempo real, é calculada a distância Euclidiana entre a projeção de cada modelo até ao centroide da elipse correspondente ao ponto de funcionamento atual. As distâncias são calculadas segundo a equação 3.30.

$$d_e(k) = \sqrt{(t_1(k) - x_0)^2 + (t_2(k) - y_0)^2} \quad (3.30)$$

Sendo que  $t_1(k)$  e  $t_2(k)$  são as projeções do modelo PCA e  $x_0$  e  $y_0$  são as coordenadas do centro da elipse.




Figura 3.11: Exemplo de zonas de funcionamento nominal de projeções PCA para 3 pontos de funcionamento.

### 3.3.3 Detecção de falhas

Uma falha é detetada quando a distância calculada segundo a equação 3.30 excede um *threshold* pré-definido com base em experimentação. As projeções utilizadas no cálculo são as do modelo PCA correspondente ao ponto de funcionamento em que se encontra o sistema. Também os pontos  $x_0$  e  $y_0$  correspondem ao centro da elipse correspondente ao modelo PCA do ponto de funcionamento atual.

Para melhor se entender este conceito, a figura 3.12 mostra um exemplo num dado instante  $k$  em que está a ocorrer uma falha. Nesta situação está-se no ponto de funcionamento  $sp1$  e o sinal "+" corresponde à projeção do modelo PCA para o ponto de funcionamento  $sp1$ , o sinal "□" por sua vez corresponde à projeção do modelo PCA para o ponto de funcionamento  $sp2$  e finalmente "o" corresponde à projeção do modelo PCA para o ponto de funcionamento  $sp3$ . Como o sistema está a funcionar no ponto de operação  $sp1$ , apenas a distância  $d_{sp1}$  é calculada. A formula para deteção é dada por:

$$\chi_{b1}(k) = 1 \Leftarrow d_{e_i}(k) > Thr_i ; i = sp1, sp2, sp3 \quad (3.31)$$

Os valores dos *thresholds* utilizados, obtidos com base em experimentação, estão especificados na tabela 3.3.

Tabela 3.3: Thresholds para detecção de falha.

<i>Thresholds</i>	Valor
<i>sp1</i>	0.05
<i>sp2</i>	0.05
<i>sp3</i>	0.06

### 3.3.4 Isolamento de falhas

Todos os tipos de falhas têm um padrão no espaço de projeções PCA. Ou seja, têm também um padrão de distância ao centro da elipse correspondente ao funcionamento nominal de um dado ponto de operação do sistema.

Neste caso são calculadas as distâncias das projeções de todos os modelos PCA até ao centro da elipse que corresponde ao funcionamento nominal do ponto de operação atual. Dando sequência ao exemplo anterior em que foi detetada uma falha, agora no isolamento em vez de apenas ser calculada a distância  $d_{sp1}$ , são calculadas todas as distâncias ( $d_{sp1}$ ,  $d_{sp2}$  e  $d_{sp3}$ ), figura 3.12.




Figura 3.12: Projeções de modelos PCA num instante  $k$  numa situação de falha.

Estas distâncias são injetadas numa rede neuronal, que consegue reconhecer o seu padrão e consequentemente identificar o tipo de falha que ocorreu. O regressor desta rede

é o descrito pela equação 3.32.

$$\Psi(k) = [ d_{sp1}(k - 6 : k) \quad d_{sp2}(k - 6 : k) \quad d_{sp3}(k - 6 : k) ] \quad (3.32)$$

Com base em alguma experimentação e alguma leitura sobre redes neuronais classificadoras foi definida a seguinte estrutura para a rede neuronal. Uma camada de entrada com 21 neurónios, para reduzir o ruído à saída da rede, duas camadas intermédias com 20 neurónios cada, uma vez que é aconselhável para redes classificadoras pelo menos duas camadas intermédias e 1 neurónio na camada de saída. A função de ativação nas duas camadas intermédias é hiperbólica sigmóide tangente e a da camada de saída é linear.

A rede é treinada com dados representativos de todos os tipos de falhas, ver tabela 3.1, e em funcionamento nominal, isto é, sem falhas no sistema. Todos os dados de treino, assim como as distâncias calculadas em tempo real, são filtradas de acordo com a equação 3.1, para reduzir o ruído.

# 4

## Resultados Experimentais

Para avaliar o desempenho das metodologias propostas nesta dissertação, várias experiências foram efetuadas. Todas as experiências foram feitas num processo de referência de três tanques (AMIRA<sup>®</sup> DTS 200), figura 4.1. Todas as falhas descritas na tabela 3.1 foram propositadamente provocadas no sistema com o objectivo de testar a robustez das metodologias propostas. Os resultados obtidos serão comparados com o índice de desempenho de Harris normalizado, bastante utilizado na indústria, para se ter uma percepção da qualidade das metodologias aqui propostas.



Figura 4.1: AMIRA DTS 200.

## 4.1 Descrição do Processo Experimental

Este processo de três tanques é constituído por três vasos de plexiglas conectados entre si por tubos de seção circular, munidos de válvulas de secionamento esféricas. Na figura 4.2 pode-se observar um esquemático do sistema. Os tanques T1 e T2 são alimentados diretamente com água destilada, que se encontra armazenada no reservatório inferior, através de duas bombas P1 e P2. Cada tanque possui um sensor de pressão medindo o nível da água no tanque.

A saída principal do líquido no sistema encontra-se localizada no tanque T2, que conjuntamente com três outras saídas complementares colocadas na base de cada um dos vasos, podem também servir para introduzir perturbações, sob a forma de um caudal de fuga. Uma descrição mais pormenorizada do sistema pode ser encontrada no artigo escrito por Heiming e Lunze (1999).

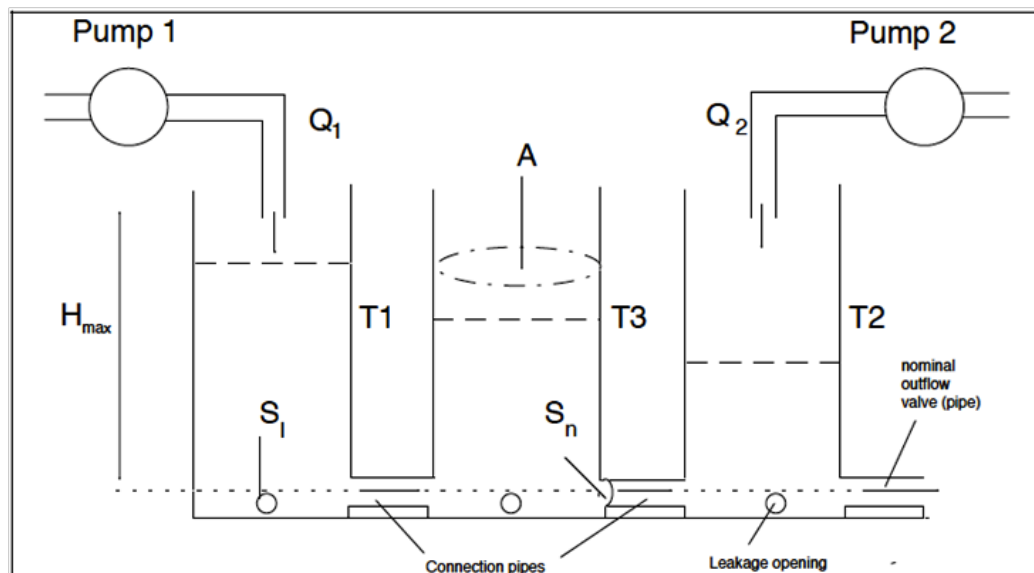


Figura 4.2: Esquemático do processo industrial AMIRA DTS 200.

A ligação entre o servidor (*Personal Computer, PC*), onde está localizado o algoritmo de análise de desempenho e o processo é efetuada com recurso a uma placa de aquisição de dados da *National Instruments USB-6009*. Esta placa possui 8 entradas analógicas de 14 bits, 2 saídas analógicas de 10 bits, 12 ligações digitais I/O e um contador de eventos de 32 bits. A ligação é feita por USB.

## 4.2 Objetivo de Controlo

O objetivo do ponto de vista de controlo é controlar o nível do tanque T1 (tanque mais à esquerda) usando a bomba P1.

Em funcionamento nominal, o sistema terá todos os tubos de conexão (*connection pipes*)

abertos, assim como a válvula de saída (*nominal outflow valve*). As válvulas de fuga (*leakage valves*) em cada tanque estarão fechadas em funcionamento nominal.

Todos os sinais envolvidos nas experiências são normalizados entre "0" (0 %) e "1" (100 %). Para controlar o nível  $h_1(k)$  do tanque T1, uma versão incremental de um PI(D) com *anti-windup* em tempo discreto é implementada (K. Astrom & Hagglund, 1988).

Uma vez que o processo em uso apresenta uma dinâmica lenta, o tempo de amostragem escolhido foi  $T_s = 1$  s.

### 4.3 Controlador PI(D)

A implementação de leis de controle contínuas, como as de um controlador PID, em tempo discreto, é necessariamente feita através de aproximações das derivadas e do integral presentes na lei de controle.

#### 4.3.1 Ação proporcional

O termo proporcional é dado por:

$$P = K_p(r - y) \quad (4.1)$$

Onde  $r$  é a referência,  $y$  a saída do processo e  $K_p$  o ganho proporcional. Este termo é discretizado apenas substituindo as variáveis contínuas pela sua versão em amostras, como mostra a equação 4.2.

$$P(k) = K_p(r(k) - y(k)) \quad (4.2)$$

#### 4.3.2 Ação Integral

O termo integral é dado por:

$$I(t) = \frac{K_p}{T_i} \int_0^t e(s) ds \quad (4.3)$$

Sendo  $T_i$  é o tempo integral e  $e$  o erro. Assim, resulta que

$$\frac{dI}{dt} = \frac{K_p}{T_i} e \quad (4.4)$$

Aproximando a derivada por uma diferença

$$\frac{I(k+1) - I(k)}{T_s} = \frac{K_p}{T_i} e(k) \quad (4.5)$$

Isto leva a que a equação do termo integral seja:

$$I(k+1) = I(k) + \frac{K_p T_s}{T_i} e(k) \quad (4.6)$$

Sendo  $T_s$  o tempo de amostragem.

### 4.3.3 Ação Derivativa

O termo derivativo é dado por:

$$\frac{T_d}{N} \frac{dD}{dt} + D = -K_p T_d \frac{dy}{dt} \quad (4.7)$$

Onde  $T_d$  é o tempo derivativo e  $N$  o número de amostras. Existem diversas formas de aproximar a derivada, entre elas, *forward differences*, *backward differences* e aproximação de Tustin. Segundo K. Astrom e Hagglund (1988), o método mais frequentemente utilizado é a aproximação de Tustin, pois é o que se aproxima mais do tempo contínuo.

Nesta implementação é feita aproximação de Tustin, que é dada pela equação 4.8

$$D(k) = -\frac{2T_d - T_s N}{2T_d + T_s N} D(k-1) - \frac{2K_p N T_d}{2T_d + T_s N} [y(k) - y(k-1)] \quad (4.8)$$

### 4.3.4 Algoritmo de controlador PID

Uma ilustração do código de computador implementado para o controlador PI(D) é mostrado a seguir, imprimido em K. Astrom e Hagglund (1988).

Calculo dos coeficientes

$$bi = K_p T_s / T_i$$

Ganho integral

$$ad = (2T_d - NT_s) / (2T_d + NT_s)$$

$$bd = 2K_p N T_d / (2T_d + NT_s)$$

Ganho derivativo

$$a0 = T_s / T_t$$

Algoritmo de controlo

$$r(k) = \text{adin}(ch1)$$

Ler a referência do canal ch1

$$y(k) = \text{adin}(ch2)$$

Ler a saída do processo do canal ch2

$$P(k) = K_p (r(k) - y(k))$$

Cálculo da parte proporcional

$$D(k) = adD(k-1) - bd(y(k) - y(k-1))$$

Atualização da parte derivativa

$$v(k) = P(k) + I(k-1) + D(k)$$

Cálculo da saída temporária

$$u(k) = \text{sat}(v, ulow, uhigh)$$

Simulação da saturação do atuador

$$daout(ch1)$$

Definir saída analógica ch1

$$I(k) = I(k) + bi(r(k) - y(k)) + a0(u(k) - v(k))$$

Atualização da parte integral

Os ganhos utilizados no controlador, obtidos com base em experimentação, são  $K_p = 3$  e  $T_i = 10$  s. Para provocar a falha  $F_2$  (dessintonização do controlador) o termo derivativo  $T_d$  é alterado de 0 s para 20 s.

## 4.4 Experiências com Metodologia Híbrida

Nesta seção serão apresentados testes experimentais realizados no sistema de três tanques (AMIRA<sup>®</sup> DTS 200), com o objetivo de mostrar o desempenho geral da metodologia híbrida para avaliação de desempenho de anéis de controle descrita na seção 3.2.

Desta forma, serão realizados testes a cada tipo de falha (tabela 3.1) individualmente e no final é realizada uma experiência em que ao longo da mesma vão ocorrendo todas as falhas testadas ( $F_0$ ,  $F_1$ ,  $F_2$  e  $F_3$ ). Devido à dinâmica lenta do processo é considerado um transitório inicial de 250 s durante o qual a metodologia não é aplicada. Todas as figuras representativas das experiências terão um gráfico do processo com as entradas e saídas. A legendas por cores desse gráfico está representada na tabela 4.1.

Tabela 4.1: Legenda das figuras de testes.

Cor	Descrição
Verde	Ação de controle
Azul	Saída do processo
Vermelho	Referência
Magenta	Saída da rede neuronal preditora

Como foi referido no capítulo anterior na descrição desta metodologia alguns sinais necessitam de filtragem. Os pólos de cada cada filtro foram obtidos com base em experimentação e tendo em conta um valor que fosse fiável para cada ponto de operação considerado. Sendo assim foi escolhido o pólo em 0.95 para o filtro passa-baixo do resíduo da rede neuronal ( $r_2$ ). Para o filtro passa-alto da referência ( $r_3$ ) foi escolhido o pólo em 0.4. Para o filtro passa-baixo do resíduo do modelo PCA ( $r_4$ ) foi escolhido o pólo em 0.9. Por fim, para o filtro passa-baixo da variância da ação de controle ( $r_5$ ) foi escolhido o pólo em 0.8.


### 4.4.1 Operação nominal ( $F_0$ )


O primeiro teste realizado é livre de falhas. A experiência é realizada em torno do ponto de funcionamento 0.2 do sistema e tem a duração de 400 s. Na figura 4.3 estão representados os índices de avaliação de desempenho  $r_i$  calculados, com  $i = 1, 2, \dots, 5$ .



A azul temos os sinais originais e a ciano o sinal filtrado. Como é de esperar, uma vez que não ocorreu nenhuma falha, os índices apresentam pouca variância, apenas algum ruído.

A binarização destes índices ( $r_{ib}$ ) pode se observada na figura 4.4. A binarização é baseada nos *thresholds* descritos na tabela 3.2.

Todos estes índices binarizados indicam "0", pelo que significa que não foi detetado nenhum problema no sistema, o que se revela uma análise correta.

Figura 4.3: Índices de avaliação de desempenho  $r_i$  para situação  $F_0$ .

Figura 4.4: Binarização, índices  $r_{ib}$ , na situação  $F_0$ .

Figura 4.5: Índices de detecção e diagnóstico  $i_n$ , para a situação  $F_0$ .Figura 4.6: Detecção e isolamento de falhas, situação  $F_0$ .

A etapa seguinte é construir os índices de detecção e diagnóstico ( $i_1$ ,  $i_2$  e  $i_3$ ) cada um vocacionado para detetar um certo tipo de problema. A figura 4.5 mostra o resultado.

Como é lógico também estes índices não detetam qualquer falha.

Por fim, o último passo é construir os sinais de detecção de falha (*Fault detection*,  $F_d$ ) e isolamento de falha (*Fault isolation*,  $F_i$ ). Estes sinais podem ser observados na figura 4.6. Os resultados obtidos são os esperados, nesta situação a metodologia indica o funcionamento normal do sistema, sem nenhuma falha.

#### 4.4.2 Variação de referência ( $F_1$ )

Esta experiência tem a duração de 500 s, e é introduzida a perturbação  $F_1$  (variação de referência) no sistema no instante 301 s.

Na figura 4.7 estão representados os índices de avaliação de desempenho  $r_i$  calculados neste situação.

Novamente os sinais azuis representam os sinais originais e a ciano os sinais filtrados. O índice de Harris normalizado ( $r_1$ ) deteta a variação de referência e enquanto o controlador não estabiliza no novo ponto de funcionamento está a detetar falha no sistema. Depois aparece o resíduo da rede neuronal ( $r_2$ ) que deteta com um pico apenas, mas é eliminado com a filtragem. O filtro passa alto ( $r_3$ ) indica com um pico o instante da variação do ponto de funcionamento. O resíduo do PCA ( $r_4$ ) que é um dos principais índices responsáveis pela detecção deste tipo de falhas, também reconhece que houve uma falha no sistema. Por fim, o índice  $r_5$  (variância da ação de controlo) também deteta a falha no sistema.

A binarização destes índices ( $r_{ib}$ ) pode se observada na figura 4.8. A binarização é baseada nos *thresholds* descritos na tabela 3.2.

Todos os índices, com a exceção de  $r_{2b}$  (resíduo da rede neuronal binarizado) detetaram um problema no sistema, cada um com uma duração diferente.

Uma vez acessíveis os índices  $r_{ib}$ , são construídos os índices de detecção e diagnóstico ( $i_1$ ,  $i_2$  e  $i_3$ ) cada um vocacionado para detetar um certo tipo de problema. A figura 4.9 mostra o resultado.

Apenas o índice  $i_1$  detetou anomalia no sistema entre os 300 s e sensivelmente os 405 s. É normal apenas este índice ter detetado a situação pois apenas ele é vocacionado para detetar variações de referência, baseando-se nos índices  $r_{1b}$  (índice de Harris normalizado) e  $r_{4b}$  (resíduo do PCA) ambos baseados no erro de controlo.







Figura 4.7: Índices de avaliação de desempenho  $r_i$  para situação  $F_1$ .

Figura 4.8: Binarização, índices  $r_{ib}$ , na situação  $F_1$ .

Figura 4.9: Índices de detecção e diagnóstico  $i_n$ , para a situação  $F_1$ .Figura 4.10: Detecção e isolamento de falhas, situação  $F_1$ .

Finalmente, os gráficos de detecção e isolamento de falhas é representado na figura 4.10. Como seria de esperar é detetada uma falha durante a variação do ponto de funcionamento até o sistema estabilizar. O isolamento também foi bem sucedido, indicando "1" que é o numero que representa a falha  $F_1$  (variação de referência). Na tabela 4.2 está representado o instante em que a falha ocorreu, bem como, os instantes em que foi detetada e isolada. O resultado é bastante satisfatório pois para este tipo de falha (variação de referência), esta metodologia apenas demorou 1 s a detetar e a isolar.

Tabela 4.2: Instantes de introdução, detecção e isolamento da falha  $F_1$ .

$F_1$	$F_d$	$F_i$
301 s	302 s	302 s

#### 4.4.3 Dessintonização do controlador ( $F_2$ )

Com o intuito de avaliar a metodologia híbrida proposta em situações de dessintonização do controlador, é realizada uma experiência com uma duração de 400 s, onde é propositadamente dessintonizado o controlador ao instante 300 s, passando de  $T_d = 0$  s para  $T_d = 20$  s.

A figura 4.11 mostra os índices de avaliação de desempenho  $r_i$  calculados para este caso. A azul estão os sinais originais e a ciano os sinais filtrados. O índice de Harris normalizado ( $r_1$ ) nesta situação não deteta nenhum problema, uma vez que é baseado no erro. Apesar de o controlador se encontrar dessintonizado com uma ação de controlo muito nervosa, a saída do sistema continua a seguir aceitavelmente a referência. O resíduo da rede neuronal ( $r_2$ ) aumenta como se pode ver por volta dos 300 s, indicando que algo não está bem. O filtro passa alto ( $r_3$ ) neste caso mantém-se constante pois é aplicado apenas à referência, que não muda. O resíduo do PCA ( $r_4$ ) também se mantém constante ao longo da experiência não detetando o problema, isto também seria de esperar pois o modelo PCA é inspirado no índice de Harris normalizado que por sua vez é inspirado no erro. Finalmente, o índice  $r_5$  (variância da ação de controlo), o mais vocacionado para este tipo de problema, aumenta significativamente quando a falha é introduzida no sistema.

A binarização ( $r_{ib}$ ) é representada na figura 4.12. Consultar a tabela 3.2 para ver os *thresholds* utilizados.

Apenas os índices  $r_{2b}$  (resíduo da rede neuronal) e  $r_{5b}$  (variância da ação de controlo) detetaram o problema, sendo que o último detetou o problema mais atempadamente.

De seguida são calculados os índices de detecção e diagnóstico ( $i_1$ ,  $i_2$  e  $i_3$ ) sendo o índice  $i_2$  o mais vocacionado para este tipo de situação. A figura 4.13 mostra o resultado. Como era de esperar apenas o índice  $i_2$  (vocacionado para detetar dessintonização do controlador e baseado em  $r_{5b}$  e  $\bar{r}_{4b}$ ) detetou anomalia no sistema sensivelmente aos 305 s.







Figura 4.11: Índices de avaliação de desempenho  $r_i$  para situação  $F_2$ .

Figura 4.12: Binarização, índices  $r_{ib}$ , na situação  $F_2$ .

Figura 4.13: Índices de detecção e diagnóstico  $i_n$ , para a situação  $F_2$ .Figura 4.14: Detecção e isolamento de falhas, situação  $F_2$ .

Por fim, a figura 4.14 mostra os gráficos de detecção e isolamento de falhas. A falha foi corretamente detetada aos 306 s (tabela 4.3), apenas 6 segundos depois de ter sido introduzida no sistema. O isolamento indicanda "2" que é o numero que representa a falha  $F_2$  (dessintonização do controlador). Também o isolamento apenas demorou 6 s, o que é um resultado bastante aceitável.

Tabela 4.3: Instantes de introdução, detecção e isolamento da falha  $F_2$ .

$F_2$	$F_d$	$F_i$
300 s	306 s	306 s

#### 4.4.4 Falha intermitente ( $F_3$ )

Para avaliar o desempenho da metodologia quando ocorre a falha  $F_3$  (falha intermitente), é realizada uma experiência com 500 s. Sendo que a falha é provocada por via de ação humana na válvula de saída do tanque T1. A falha é introduzida por volta dos 307 s, abrindo a válvula durante 5 s e fechando 15 s. Este processo é repetido até ao final da experiência.

Na figura 4.15 estão representados os índices de avaliação de desempenho  $r_i$ .

O índice de Harris normalizado ( $r_1$ ) nesta caso é bastante elevado, perto de 1. Isto significa que está a detetar o problema. O sinal do resíduo da rede neuronal ( $r_2$ ) é oscilatório, uma vez que, o modelo neuronal não foi treinado para esta situação. O filtro passa alto ( $r_3$ ) nesta situação não deteta nada de anormal pois é aplicado à referência. O resíduo do PCA ( $r_4$ ) e o índice  $r_5$  baseado na variância da ação de controlo, quando a falha é introduzida aumentam, mas estes valores são muitos pequenos e a baixo dos seus respetivos *thresholds*, dispostos na tabela 3.2.

Aplicando os *thresholds* aos sinais obtém-se os índices  $r_{ib}$  representados na figura 4.16.

Os índices  $r_{1b}$  (índice de Harris normalizado binarizado) e  $r_{2b}$  (resíduo da rede neuronal binarizado) foram os únicos a detetar a falha.

Os índices de detecção e diagnóstico ( $i_1$ ,  $i_2$  e  $i_3$ ) estão representados na figura 4.17.

O índice vocacionado para este género de situação ( $i_3$  baseado em  $r_{1b}$ ,  $r_{2b}$  e  $\overline{r_{4b}}$ ) é o único a detetar.

A detecção e isolamento de falhas é representada na figura 4.18. O algoritmo detetou a falha aos 310 s (tabela 4.4), e isolou corretamente indicando "3" também aos 310 s. A falha foi detetada e isolada com um atraso de 3 s, o que se considera um resultado bastante satisfatório.

Tabela 4.4: Instantes de introdução, detecção e isolamento da falha  $F_3$ .

$F_3$	$F_d$	$F_i$
307 s	310 s	310 s

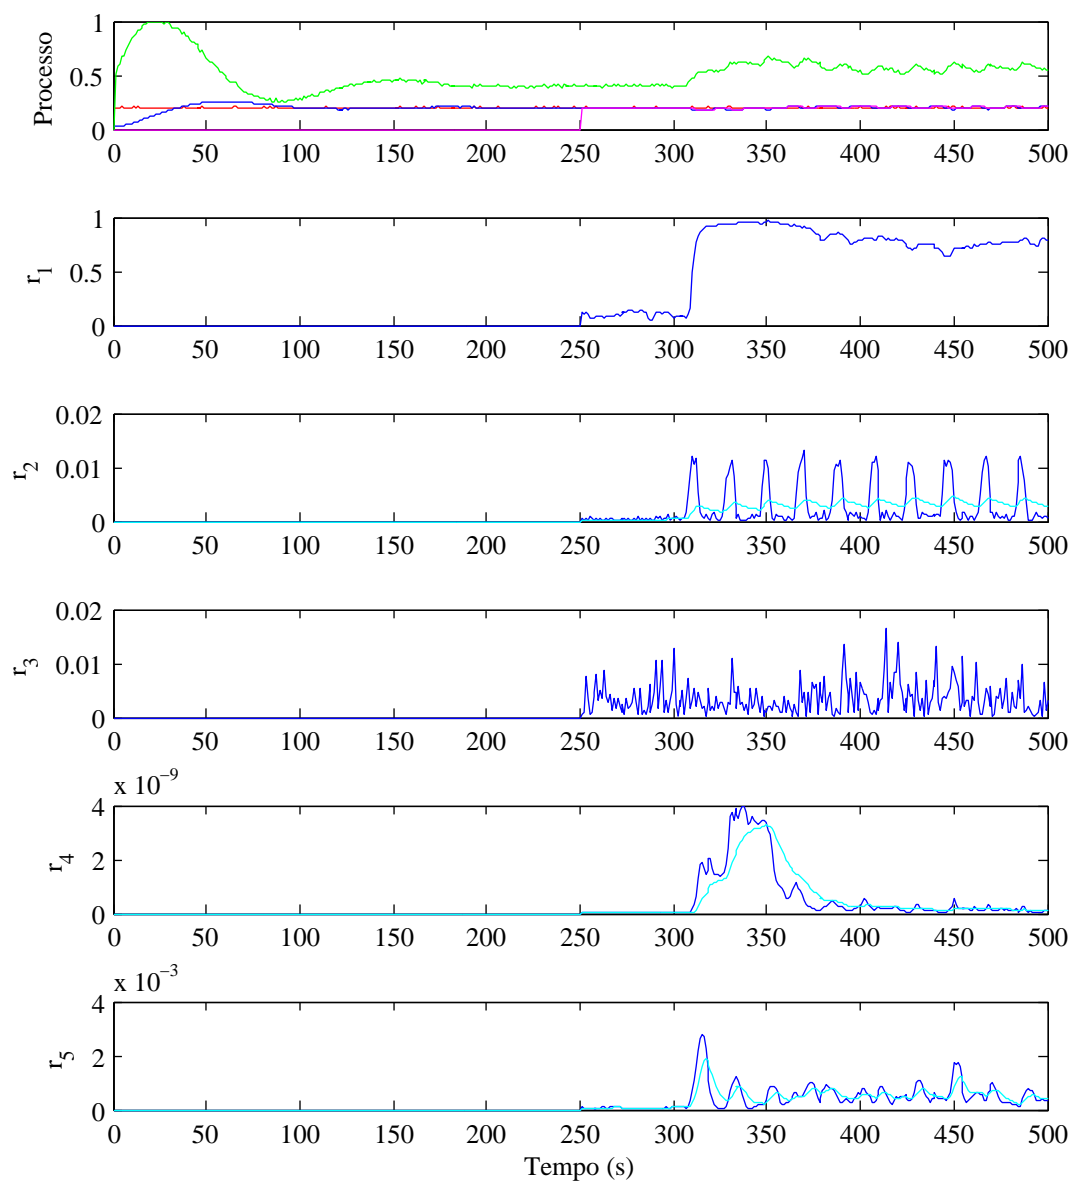



Figura 4.15: Índices de avaliação de desempenho  $r_i$  para situação  $F_3$ .

Figura 4.16: Binarização, índices  $r_{ib}$ , na situação  $F_3$ .




Figura 4.17: Índices de detecção e diagnóstico  $i_n$ , para a situação  $F_3$ .




Figura 4.18: Detecção e isolamento de falhas, situação  $F_3$ .

#### 4.4.5 Todas as falhas na mesma experiência

As falhas têm vindo a ser testadas individualmente. Nesta experiência serão provocadas todas as falhas descritas na tabela 3.1. As falhas serão provocadas ao longo dos 1000 s de experiência. A tabela 4.5 resume o que ocorre durante a experiência.

Tabela 4.5: Resumo de experiência com todas as falhas.

Situações	Instante tempo
Transitório	0-250 s
Nominal	251-300 s
$F_1$	301-409 s
Nominal	410-500 s
$F_1$	501-429 s
Nominal	430-705 s
$F_3$	706-809 s
Nominal	810-900 s
$F_2$	901-1000 s

Os índices de avaliação de desempenho  $r_i$  desta experiência podem ser observados na figura 4.19.

O índice de Harris normalizado ( $r_1$ ) é elevado em todas as falhas e nos respectivos transientes com exceção da última falha introduzida ( $F_2$  dessintonização do controlador), uma vez que este índice se baseia no erro. O sinal do resíduo da rede neuronal ( $r_2$ ) aumenta quando ocorrem as falhas  $F_3$  (falha intermitente) e  $F_2$ . O filtro passa alto ( $r_3$ ) apresenta dois "picos" quando a referência se altera, indicando as transições da referência. O resíduo do PCA ( $r_4$ ) aumenta nos transitórios de mudança de ponto de funcionamento. O índice  $r_5$  baseado na variância da ação de controlo, aumenta nas variações de referência e quando a falha  $F_2$  é introduzida.

Os índices binarizados  $r_{ib}$  podem ser consultados na figura 4.20.

O índice  $r_{1b}$  (índice de Harris normalizado binarizado) demora um pouco a estabilizar depois de terminada a falha, portanto indica falha quase durante toda a experiência, exceção no fim, uma vez que não deteta esse tipo de falha (dessintonização do controlador). O índice  $r_{2b}$  (resíduo da rede neuronal binarizado) deteta as falhas  $F_3$  (falha intermitente) e  $F_2$  (dessintonização do controlador) corretamente, sendo que na falha  $F_3$  apresenta um "pico" devido a algum ruído no sinal. Como seria de esperar o índice  $r_{3b}$  (filtro passa-alto da referência binarizado) apresenta dois "picos" quando ocorre a mudança de ponto de funcionamento. Já o índice  $r_{4b}$  (resíduo do PCA binarizado) deteta os transientes resultantes da variação de referência. Por último, o índice  $r_{5b}$  (variância da ação de controlo binarizada) deteta o momento da alteração da referência bem como a falha  $F_2$ .

Os índices de deteção e diagnóstico ( $i_1$ ,  $i_2$  e  $i_3$ ) são mostrados na figura 4.21.

Cada índice é vocacionado para um certo género de falha, e é isso mesmo que se pode

observar. O índice  $i_1$ , baseado em  $r_{1b}$  e  $r_{4b}$ , deteta a falha  $F_1$  (variação da referência), o índice  $i_2$ , baseado em  $r_{5b}$  e  $\overline{r_{4b}}$ , deteta a falha  $F_2$  (dessintonização do controlador) e o último índice  $i_3$ , baseado em  $r_{1b}$ ,  $r_{2b}$  e  $\overline{r_{4b}}$ , deteta a falha  $F_3$  (falha intermitente).





Figura 4.19: Índices de avaliação de desempenho  $r_i$  para situação  $F_n$ .

O último passo do algoritmo, a detecção e isolamento de falhas, são representados na figura 4.22. Todas as falhas foram prontamente detetadas e identificadas, como se pode ver na tabela 4.6. A metodologia testada aqui teve um desempenho bastante bom, como os resultados obtidos comprovam.

Tabela 4.6: Instantes de introdução, detecção e isolamento das falhas.

	Início	$F_d$	$F_i$
$F_1$	301 s	302 s	302 s
$F_1$	501 s	502 s	502 s
$F_2$	901 s	903 s	903 s
$F_3$	706 s	708 s	708 s

Figura 4.20: Binarização, índices  $r_{ib}$ , na situação  $F_n$ .




Figura 4.21: Índices de detecção e diagnóstico  $i_n$ , para a situação  $F_n$ .




Figura 4.22: Detecção e isolamento de falhas, situação  $F_n$ .

#### 4.4.6 Pontos de funcionamento não incluídos nos modelos

De forma a testar a robustez da metodologia proposta são efetuados testes com pontos de funcionamento não tidos em conta na elaboração desta metodologia.

Na figura 4.23 podem ser observados os índices de avaliação de desempenho  $r_i$ . O índice  $r_1$ , baseado no índice de Harris, consegue detetar as variações do ponto de funcionamento. O índice  $r_2$ , baseado no resíduo da rede neuronal, observa-se um aumento do resíduo para os pontos de funcionamento para os quais não está treinada. O índice  $r_3$  (filtro passa-alto da referência) deteta os instantes de variação do ponto de funcionamento. Pode-se observar ainda que o índice  $r_4$  (resíduo do PCA) deteta as variações do ponto de funcionamento. Finalmente o índice  $r_5$  (variância da ação de controlo) também consegue detetar as variações do ponto de funcionamento.

A binarização dos índices anteriormente apresentados encontra-se na figura 4.24. O índice  $r_{1b}$  (índice de Harris normalizado binarizado) apesar de detetar o transiente encontra-se um pouco instável. Isto é justificado pelo facto do *threshold* não ter sido ajustado para estes pontos de funcionamento. O índice  $r_{2b}$  deteta erradamente falha pois é baseado no resíduo da rede neuronal que não está treinada para estes pontos de funcionamento. O índice  $r_{3b}$  (filtro passa-alto da referência binarizado) deteta corretamente os instantes de transição do ponto de funcionamento. Também o índice  $r_{4b}$  (resíduo do PCA binarizado) deteta corretamente os transitórios. O índice  $r_{5b}$  deteta as variações do ponto de funcionamento embora a saturação da ação de controlo não ajude neste índice uma vez que é baseado na variância da ação de controlo.

Os índices de deteção e diagnóstico são apresentados na figura 4.25. O índice  $i_1$  que é vocacionado para a deteção de transitórios deteta corretamente todos os transitórios, uma vez que é apenas baseado no erro ( $r_{1b}$  e  $r_{4b}$ ). O índice  $i_2$  vocacionado para dessintonização do controlador não deteta nada como seria de esperar. O índice  $i_3$  é vocacionado para detetar oscilações, mas neste caso deteta parte do transitório uma vez que pesa na construção deste índice o resíduo da rede neuronal, rede neuronal essa que não está treinada para estes pontos de funcionamento.

A deteção e isolamento está representado na figura 4.26. A deteção é correta embora em alguns pontos um pouco nervosa devido ao índice  $i_3$ . O isolamento também é errado em alguns pontos devido também ao índice  $i_3$  que é baseado no resíduo da rede neuronal que não foi treinada para esses pontos de funcionamento.

Pode-se afirmar que o desempenho geral desta metodologia em pontos de funcionamento desconhecidos é razoável, podendo ser boa com alguns ajustes em alguns índices

de avaliação de desempenho, nomeadamente treinando a rede neuronal para esses pontos de funcionamento.


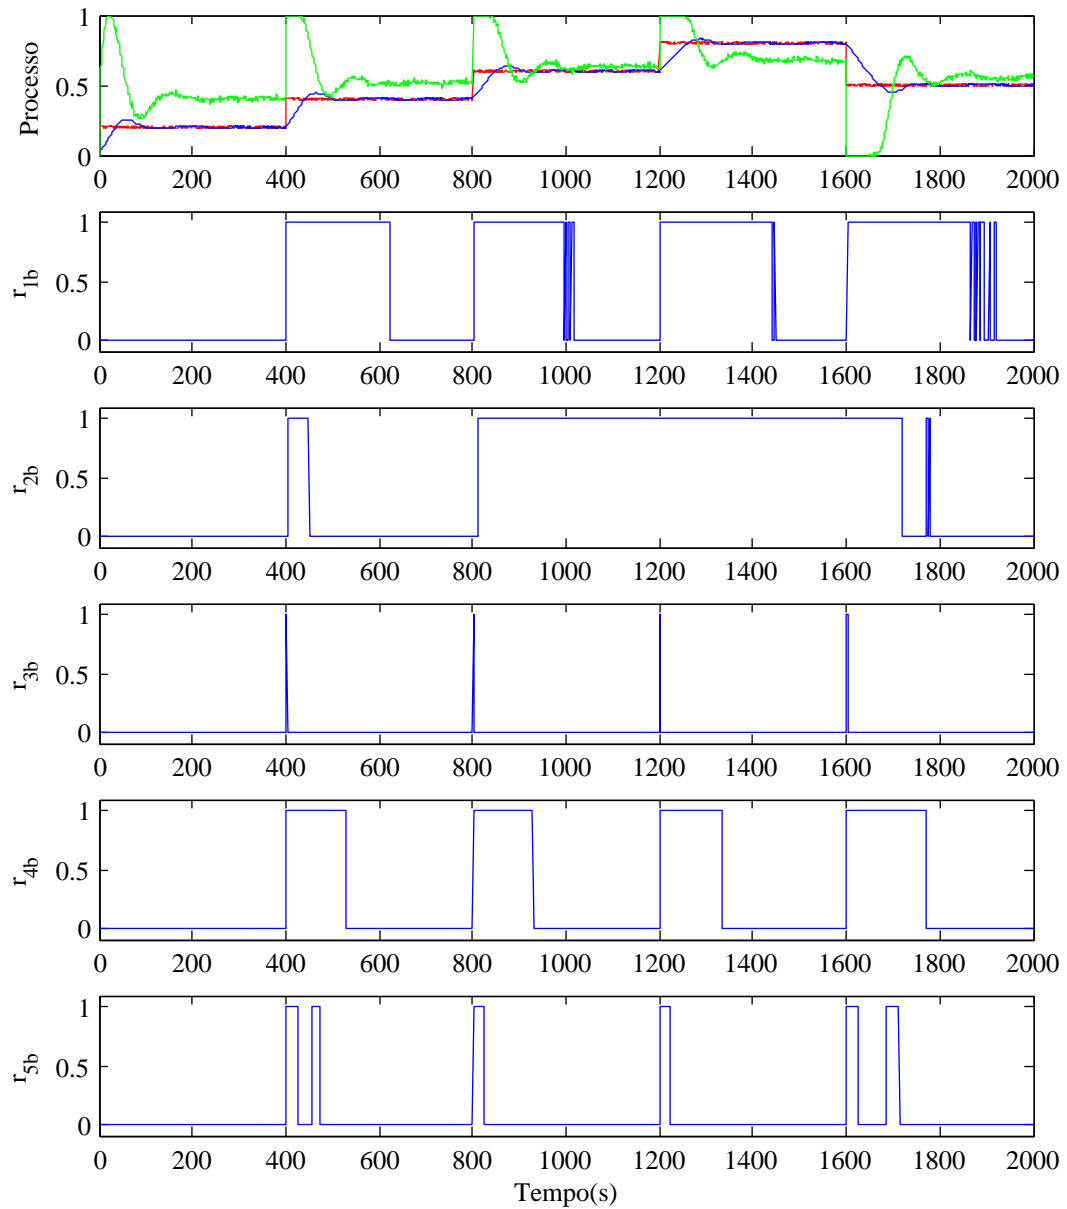


Figura 4.23: Índices de avaliação de desempenho  $r_i$ .

Figura 4.24: Binarização, índices  $r_{ib}$ .




Figura 4.25: Índices de detecção e diagnóstico  $i_n$ .




Figura 4.26: Detecção e isolamento de falhas.

## 4.5 Experiências com Metodologia Baseada em Características Dinâmicas e Modelos PCA

À imagem da seção anterior, também esta metodologia foi testada no sistema de três tanques (AMIRA<sup>®</sup> DTS 200). O objetivo é demonstrar o desempenho geral desta metodologia no âmbito de avaliação de desempenho de anéis de controlo. Os fundamentos teóricos foram descritos na seção 3.3.

Todas as falhas descritas na tabela 3.1 são testadas. Primeiro individualmente e depois todas numa só experiência. À semelhança da seção anterior, um transitório de 250 s é considerado, devido à dinâmica lenta do processo, durante o qual não é aplicada a metodologia. A legenda do primeiro gráfico de cada figura é de acordo com a tabela 4.1.

Também esta metodologia faz uso de filtragem passa-baixo. Novamente as localizações dos pólos foram obtidas com base em experimentação e tendo em conta um valor fiável para os pontos de funcionamento considerados. Tanto na filtragem passa-baixo dos sinais da ação de controlo, da saída do processo, do ganho estático estimado, da largura de banda estimada e das distâncias calculadas foi escolhido o pólo em 0.9.

Tendo em conta o processo em questão, para a estimação do mesmo foi considerado um  $ARX(n_a = 2, n_b = 1, n_d = 1)$  uma vez que é suficiente para estimar este processo e para estimação da largura de banda é necessário um sistema de segunda ordem (Oppenheim et al., 1983). O cálculo da resposta ao degrau do sub modelo estimado é feito com recurso à função *setepinfo()* do MatLab.

### 4.5.1 Operação nominal ( $F_0$ )

O primeiro teste realizado é em funcionamento nominal, isto é, sem falhas. Esta experiência tem uma duração de 400 s e é realizada em torno do ponto de funcionamento 0.2.

O primeiro passo, passa por estimar o ganho estático ( $\delta_g$ ) e a largura de banda ( $\zeta_w$ ). Estes sinais estão representados no segundo e terceiro gráficos da figura 4.27 respectivamente. O primeiro gráfico da figura diz respeito ao processo, ação de controlo, saída e referência.

O ganho estático mantém-se constante, uma vez, que não existem falhas no sistema e o ponto de operação também não se altera. A largura de banda já é um pouco mais instável, mas também nesta situação não varia significativamente.

Calculado o ganho estático e a largura de banda, prossegue-se ao cálculo das projeções dos modelos PCA. Calculadas as projeções determina-se as distâncias, que estão representadas no quarto gráfico da figura 4.27.

A cor azul representa a distância do modelo PCA ao ponto de funcionamento 0.2, o verde é do modelo PCA para o ponto de funcionamento 0.3 e o preto é do ponto de funcionamento 0.4 (tabela 4.7). Como era de esperar, a menor distância é a do ponto de funcionamento 0.2, uma vez que o sistema está a operar nesse ponto de funcionamento. A distância a azul mantém-se constante uma vez que não existem falhas. Também as outras duas distâncias estão relativamente constantes.

Tabela 4.7: Legenda do gráfico das distâncias.

Cor	Modelo PCA
Azul	0.2
Verde	0.3
Preto	0.4

Depois de calculadas as distâncias, constroem-se os sinais de deteção e isolamento. Estes sinais são mostrados na figura 4.28.

Nenhuma falha é detetada no sistema, ou seja, esta metodologia avaliou a situação corretamente.




Figura 4.27: Processo, ganho estático, largura de banda e distâncias de modelos PCA em funcionamento nominal.




Figura 4.28: Detecção e isolamento de falhas, situação nominal.

#### 4.5.2 Variação de referência ( $F_1$ )

Um teste em que é provocada uma variação do ponto de funcionamento, falha  $F_1$ , é realizado aqui. A experiência tem uma duração de 500 s. O ponto de funcionamento inicial é 0.2 e no instante 301 s é alterado para 0.3.

O ganho estático estimado ( $\delta_g$ ) e a largura de banda estimada ( $\zeta_w$ ) podem ser observados na figura 4.29, gráficos dois e três.

O ganho estático mantém-se constante, aumentando o seu valor quando o sistema estabiliza no novo ponto de funcionamento. A largura de banda também se mantém constante, mas neste caso o seu valor diminui quando o sistema estabiliza no novo ponto de funcionamento.

As distâncias calculadas estão representadas no quarto gráfico da figura 4.29. Como é possível observar as distâncias aumentam durante o transitório da variação de referência. Nota-se ainda que a menor distância até aos 301 s é a do modelo PCA correspondente ao ponto de funcionamento 0.2 (cor azul), quando o sistema estabiliza em 0.3 a menor distância corresponde à do modelo PCA do ponto de funcionamento 0.3 (cor verde).




Figura 4.29: Processo, ganho estático, largura de banda e distâncias de modelos PCA em variação de referência.




Figura 4.30: Detecção e isolamento de falhas, situação de variação de referência.

A detecção e o isolamento está representado na figura 4.30. A detecção foi rápida, apenas um 1 s após a falha ter ocorrido. Também o isolamento demorou apenas 1 s, apresentando um pequeno ruído insignificante no início, devido ao classificador neuronal. A tabela 4.8 resume os instantes de detecção e isolamento.

Tabela 4.8: Instantes de introdução, detecção e isolamento da variação de referência.

$F_1$	$F_d$	$F_i$
301 s	302 s	302 s

### 4.5.3 Dessintonização do controlador ( $F_2$ )

Uma experiência em torno do ponto de funcionamento 0.2 é demonstrada agora. A experiência tem uma duração de 400 s, e ao instante 300 s é introduzida a falha  $F_2$ , dessintonização do controlador.

Os gráficos dois e três da figura 4.31 mostram o ganho estático ( $\delta_g$ ) e a largura de banda ( $\zeta_w$ ) estimados.

O ganho estático mantém-se constante com uns "picos" em dados instantes da falha, o filtro atenua esse problema. A largura de banda também se mantém relativamente constante, diminuindo de valor durante a situação de falha.

No quarto gráfico da figura 4.31 pode-se observar as distâncias calculadas. A variação das distâncias é algo irregular, no entanto, verifica-se uma troca entre as distância do ponto de funcionamento 0.2 (azul) com a distância do ponto de funcionamento 0.3 (verde).

A figura 4.32 mostra os sinais de detecção e de isolamento de falhas. A detecção bem como o isolamento demoraram a detetar e isolar 34 s. Tendo em conta a dinâmica muito lenta do processo, pode-se considerar um valor aceitável. Na tabela 4.9 estão resumidos os instantes de detecção e isolamento.

Tabela 4.9: Instantes de introdução, detecção e isolamento da dessintonização do controlador.

$F_2$	$F_d$	$F_i$
300 s	334 s	334 s




Figura 4.31: Processo, ganho estático, largura de banda e distâncias de modelos PCA em dessintonização do controlador.




Figura 4.32: Detecção e isolamento de falhas, situação de dessintonização do controlador.

#### 4.5.4 Falha intermitente ( $F_3$ )

Para avaliar o desempenho da metodologia em situações de falha intermitente (oscilação), é realizada uma experiência com 500 s. A falha é introduzida no sistema aos 307 s de experiência, abrindo 5 s e fechando 15 s a válvula de saída do tanque T1.

Nos gráficos dois e três da figura 4.33, podem ser consultados o ganho estático estimado ( $\delta_g$ ) e a largura de banda estimada ( $\zeta_w$ ).

O ganho estático antes de ocorrer a falha mantém o seu valor normal para o ponto de funcionamento 0.2. Quando a falha ocorre, diminui tendendo a manter-se constante. Já a largura de banda, depois da falha ocorrer, tende a aumentar de uma forma oscilatória.

À semelhança da largura de banda, as distâncias calculadas tendem a aumentar e de uma forma oscilatória. As distâncias podem ser consultadas no quarto gráfico da figura 4.33. A legenda das cores está descrita na tabela 4.7.




Figura 4.33: Processo, ganho estático, largura de banda e distâncias de modelos PCA em falha intermitente.

A detecção e o isolamento de falhas é mostrada na figura 4.34. A detecção é bem efetuada após 8s da falha ocorrer e o isolamento também é efetuado de forma correta, também após 8 s da falha se dar no sistema. Os resultados obtidos são considerados bastante bons. A tabela 4.10 resume os instantes de detecção e isolamento.

Tabela 4.10: Instantes de introdução, detecção e isolamento da falha intermitente.

$F_2$	$F_d$	$F_i$
307 s	315 s	315 s




Figura 4.34: Detecção e isolamento de falhas, situação de falha intermitente.

#### 4.5.5 Todas as falhas na mesma experiência

Esta experiência tem por objetivo testar o desempenho global da metodologia baseada em características dinâmicas e modelos PCA proposta. Ao longo da experiência todas as falhas serão provocadas ( $F_1, F_2, F_3$ ) ver tabela 3.1. A experiência tem uma duração de 1000 s. Na tabela 4.11 encontra-se descrito todos os acontecimentos que ocorrem durante a experiência.

Na figura 4.35, gráficos dois e três, estão representados o ganho estático ( $\delta_g$ ) e a largura de banda ( $\zeta_w$ ) estimados.

Tabela 4.11: Descrição experiência.

Situações	Instante tempo
Transitório	0-250 s
Nominal	251-300 s
$F_1$	301-409 s
Nominal	410-500 s
$F_1$	501-429 s
Nominal	430-705 s
$F_3$	706-809 s
Nominal	810-900 s
$F_2$	901-1000 s

Relativamente ao ganho estático, verifica-se que aumenta o seu valor após o sistema estabilizar no novo ponto de funcionamento. Quando o ponto de operação regressa para 0.2, o ganho estático fica instável, pois nessa altura dá-se uma saturação da ação de controlo e conseqüentemente o sistema estimado pelo ARX, que permite calcular o ganho estático, é um sistema instável. Depois regressa ao seu valor nominal, até que é introduzida a falha  $F_3$  (falha intermitente). Nessa situação novamente fica instável mas desta feita apenas por breves instantes, baixando depois o seu valor, que volta a normalizar depois de retirada a falha do sistema. Por fim, dá-se a falha  $F_2$  (dessintonização do controlador), verificando-se uma redução do valor do ganho estático.

Na largura de banda estimada verifica-se uma pequena redução do seu valor quando a falha  $F_1$  (variação da referência) ocorre. Depois de retirada a falha e o sistema estabilizar novamente, o valor da largura de banda volta a aumentar um pouco. Durante a falha  $F_3$  verifica-se um aumento significativo do seu valor e tendo uma tendência para oscilar. Retirada a falha o valor volta a estabilizar e diminui significativamente quando a falha  $F_2$  ocorre.

Observando o ultimo gráfico da figura 4.35, podemos constatar que sempre que ocorre uma falha, o valor das distâncias aumenta. Sendo que para cada tipo de falha aumenta de forma diferente e com uma distância diferente também.

A deteção e isolamento de falhas desta experiência pode ser vista na figura 4.36. Como se pode ver na figura, o desempenho desta metodologia foi bom, detetando e isolando corretamente e atempadamente todas as falhas ocorridas durante a experiência. A tabela 4.12 pode ser consultada para melhor se perceber os instante de deteção e isolamento e assim ter uma ideia do desempenho desta abordagem aqui analisada.

Tabela 4.12: Instantes de introdução, detecção e isolamento das falhas, em experiências com todas as falhas.

	Início	$F_d$	$F_i$
$F_1$	301 s	302 s	302 s
$F_1$	501 s	501 s	501 s
$F_2$	901 s	953 s	953 s
$F_3$	706 s	721 s	721 s




Figura 4.35: Processo, ganho estático, largura de banda e distâncias de modelos PCA em experiências com todas as falhas.




Figura 4.36: Detecção e isolamento de falhas, situação de experiências com todas as falhas.

#### 4.5.6 Pontos de funcionamento não incluídos nos modelos

À imagem da metodologia híbrida, também esta metodologia é submetida a testes com pontos de funcionamento não testados.

Os gráficos dois e três da figura 4.37 mostram o ganho estático ( $\delta_g$ ) e a largura de banda ( $\zeta_w$ ) estimados.

O ganho estático vai-se alterando conforme o ponto de funcionamento. Por volta do instante 1700 s devido à saturação da ação de controlo não é possível estimar o ganho estático. A largura de banda mantém-se relativamente constante.

No quarto gráfico da figura 4.31 pode-se observar as distâncias calculadas. Observa-se que as distância dos pontos de funcionamento não testados é maior com um elevado "pico" depois da saturação.

A figura 4.38 mostra os sinais de deteção e de isolamento de falhas. A deteção da primeira variação do ponto de funcionamento é correta. Nos pontos de operação não testados é detetada falha constantemente pois a metodologia não foi projetada para esses pontos de funcionamento. Também o isolamento não é correto pelo mesmo motivo.




Figura 4.37: Processo, ganho estático, largura de banda e distâncias de modelos PCA.




Figura 4.38: Detecção e isolamento de falhas.

Pode-se afirmar que o desempenho geral desta metodologia em pontos de funcionamento desconhecidos é mau, no entanto se projetada para esses pontos de funcionamento pode ter um bom desempenho.

## 4.6 Comparação entre Metodologias Propostas e Índice de Harris Normalizado

Nesta seção é avaliado e comparado o desempenho das metodologias propostas nesta dissertação entre elas e com o índice de Harris normalizado (Desborough & T. J. Harris, 1992), que é um índice largamente utilizado na análise de desempenho e com bons fundamentos teóricos, visto ser um índice já com duas décadas de existência.

Uma vez que as duas metodologias propostas foram testadas com as mesmas experiências, exatamente as mesmas condições, a comparação torna-se fácil. Recorre-se a tabelas para facilitar a visualização e comparação entre a metodologia híbrida, denominada *met1*, a metodologia baseada em características dinâmicas e modelos PCA, denominada *met2*, e o índice de Harris normalizado, denominado por *Harris*. Nesta tabela será indicado o instante em que a falha ocorre, assim como o tempo necessário para a detecção e o tempo decorrido entre a detecção e o isolamento.

Na tabela 4.13 pode-se ver a comparação entre os três índices, para a experiência com a falha  $F_1$ , variação de referência, figuras 4.10 e 4.30.

O resultado para esta situação é igual para todos os índices e bastante bom, apenas 1 s para detetar e isolar a falha no sistema.

Tabela 4.13: Experiência com falha  $F_1$ .

Falha	Início		Harris	met1	met2
$F_1$	301 s	$F_d$	1 s	1 s	1 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s

A tabela 4.14 apresenta a comparação entre os índices, para a situação com a falha  $F_2$ , dessintonização do controlador, figuras 4.14 e 4.32.

Neste caso, verifica-se que o índice de Harris normalizado é incapaz de detetar a falha. Ambas as metodologias propostas detetam e isolam a falha, sendo que *met1* deteta mais atempadamente, apenas com 6 s de atraso, enquanto que *met2* demora 34 s.

Tabela 4.14: Experiência com falha  $F_2$ .

Falha	Início	Harris	met1	met2	
$F_2$	300 s	$F_d$	-	6 s	34 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s

A experiência com a falha  $F_3$ , falha intermitente, é comparada na tabela 4.15. As figuras desta experiência são a 4.18 e 4.34.

Neste experiência, o índice de Harris e a *met1* detetam a falha com um atraso de apenas 3 s. Já *met2* demora mais um pouco, 8 s.

Tabela 4.15: Experiência com falha  $F_3$ .

Falha	Início	Harris	met1	met2	
$F_3$	307 s	$F_d$	3 s	3 s	8 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s

Por fim, é apresentada na tabela 4.16 a comparação entre os três índices, para a experiência com todas as falhas, representadas nas figuras 4.22 e 4.36.

Como se pode observar, o resultado para as duas falhas  $F_1$  introduzidas é idêntico para os três índices.

A falha  $F_2$  é detetada e isolada atempadamente por *met1*, porém *met2* demora 50 s e o índice de Harris nem sequer consegue detetar o problema.

Em relação à falha  $F_3$ , verifica-se que o índice de Harris e *met1* detetam num espaço muito curto de tempo, enquanto que *met2* demora mais alguns segundos.

Tabela 4.16: Experiência com todas as falhas.

Falhas	Início	Harris	met1	met2	
$F_1$	301 s	$F_d$	1 s	1 s	1 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s
$F_1$	501 s	$F_d$	1 s	1 s	0 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s
$F_2$	901 s	$F_d$	-	2 s	52 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s
$F_3$	706 s	$F_d$	1 s	2 s	15 s
		$F_i$	-	$\simeq 0$ s	$\simeq 0$ s

Feitas as comparações, é possível concluir que para a falha  $F_1$  (variação de referência) os três índices são equivalentes, sendo que o índice de Harris normalizado não consegue isolar a falha. No caso da falha  $F_2$  (dessintonização do controlador), verifica-se que o índice de Harris não deteta esta situação e que a metodologia híbrida apresenta melhor

desempenho, fazendo a deteção e o isolamento mais rapidamente. Tendo em conta a falha  $F_3$  (falha intermitente), pode-se dizer que o índice de Harris e a metodologia híbrida são relativamente iguais, sendo que a última permite isolar também. A metodologia baseada em características dinâmicas e modelos PCA também apresenta bons resultados, mas é um pouco mais lenta a detetar e a isolar, o que tendo em consideração a dinâmica lenta do processo não se torna um mal maior.

Em relação à robustez pode-se afirmar que a metodologia híbrida é mais robusta uma vez que apresentou melhores resultados nos testes com pontos de funcionamento desconhecidos.

Em suma, podemos afirmar que as duas metodologias propostas permitem detetar e isolar uma gama variada de falhas, sendo que a metodologia híbrida apresenta um desempenho um pouco superior.





# Conclusões

Neste capítulo são apresentadas as conclusões relativas à dissertação e indicados alguns apontadores para trabalho futuro.

## 5.1 Conclusões Gerais

Nesta dissertação foi abordado o tema de análise de desempenho de anéis de controlo em sistemas dinâmicos. Este é um tema largamente estudado pela comunidade de controlo e automação, com grande interesse para a indústria, pois bons algoritmos de análise de desempenho aumentam a qualidade do produto e consequentemente os lucros. Duas novas metodologias são propostas nesta dissertação. Ambas funcionam em tempo real e são capazes de detetar e diagnosticar uma gama de falhas comuns na indústria.

A primeira metodologia é baseada em cinco índices de desempenho, que combinados permitem detetar e isolar diferentes tipos de falhas. Esta metodologia híbrida é fundamentalmente baseada no índice proposto por Desborough e T. J. Harris (1992), na análise em componentes principais (PCA) e numa rede neuronal preditiva (NOP).

A segunda metodologia proposta nesta dissertação é fundamentalmente baseada em características dinâmicas do processo (ganho estático e largura de banda estimados), numa rede neuronal que reconhece padrões e em modelos lineares PCA (para cada ponto de funcionamento). São calculadas distâncias das projeções de cada modelo PCA no espaço a duas dimensões ( $t_1, t_2$ ) ao centro de uma elipse que define a zona nominal para o ponto de funcionamento atual. Essas distâncias são utilizadas para a deteção de falhas e também para o isolamento com recurso a uma rede neuronal classificadora.

Os resultados experimentais foram obtidos num processo não-linear de três tanques (AMIRA<sup>®</sup> DTS 200), usando um controlador PI(D) com mecanismo *anti-windup*.

Tendo como referência o índice de Harris normalizado para avaliar o desempenho das metodologias propostas, foi possível concluir que ambas as metodologias são superiores em termos de desempenho, uma vez que permitem detetar/isolar uma maior gama de falhas que o índice de Harris normalizado. Comparando as metodologias entre si, a metodologia híbrida leva vantagem, uma vez que para certo tipo de situações é mais rápida a detetar e a isolar a falha. Quanto à robustez das metodologias, conclui-se que se obtém melhor desempenho projetando as metodologias para os pontos de operação pretendidos.

No âmbito do desenvolvimento desta dissertação foi apresentado o artigo "*Hybrid Approach for Control Loop Performance Assessment*" publicado em conferência (L. Palma, Moreira, Gil & Coito, 2013).

## 5.2 Apontadores para Trabalho Futuro

Apresenta-se de seguida alguns apontadores para trabalho futuro, tendo como base a experiência adquirida neste trabalho:

- Implementação de novos procedimentos de análise de desempenho, com foco em índices determinísticos e técnicas estatísticas;
- Investigação de abordagens baseadas em modelos de referência do sistema em anel fechado;
- Comparação do desempenho entre PCA linear e não-linear;
- Investigação de abordagens híbridas baseadas no filtro de Kalman e PCA;
- Geração automática de regras com recurso a inteligência artificial;
- Comparação de metodologias baseadas em lógica difusa com metodologias baseadas em redes neuronais;
- Avaliação do desempenho baseado nas metodologias aqui propostas, mas utilizando outros tipos de controladores;
- Introdução de técnicas de controlo robusto, como por exemplo *Sliding Mode Control* (SMC);
- Seleção e comutação de filtros para diferentes pontos de funcionamento.

# Bibliografia

- Ahmed, S., Huang, B. & Shah, S. L. (2006). Parameter and delay estimation of continuous-time models using a linear filter. *Journal of Process Control*, 16(4), 323–331.
- Astrom, K. (1991). Assessment of achievable performance of simple feedback loops. *International Journal of Adaptive Control and Signal Processing*, 5(1), 3–19.
- Astrom, K. J. (1970). *Introduction to stochastic control theory*.
- Astrom, K. & Hagglund, T. (1988). *Automatic tuning of pid controllers*. Instrument Society of America.
- Basseville, M. (1998). On-board component fault detection and isolation using the statistical local approach. *Automatica*, 34(11), 1391–1415.
- Bezergianni, S. & Georgakis, C. (2000). Controller performance assessment based on minimum and open-loop output variance. *Control Engineering Practice*, 8(7), 791–797.
- Chatfield, C. (1989). *The analysis of time series : an introduction*. London; New York: Chapman and Hall.
- Chiang, L., Russell, E. & Braatz, R. (2001). *Fault detection and diagnosis in industrial systems*. Springer-Verlag.
- Desborough, L. & Harris, T. J. (1992). Performance assessment measures for univariate feedback control. *Canadian Journal of Chemical Engineering*, 70(6), 1186–1197.
- Duda, R. O. (1997). Pattern recognition for hci. **retrieved from** [http://www.cs.princeton.edu/courses/archive/fall08/cos436/Duda/PR\\_home.htm](http://www.cs.princeton.edu/courses/archive/fall08/cos436/Duda/PR_home.htm)
- Elnaggar, A., Dumont, G. A. & Elshafei, A.-L. (1991). Parameter and delay estimation of continuous-time models using a linear filter. *Proceedings of the American Control Conference*, 2812–2817.
- Ender, D. (1993). Process control performance: not as good as you think. *Control Engineering*, 40, 180–190.
- Farenzena, M. (2008). *Novel methodologies for assessment and diagnostics in control loop management* (Ph.D. Degree, Universidade Federal do Rio Grande do Sul, Porto Alegre).
- Geladi, P. & Kowalski, B. R. (1986). Partial least squares regression: a tutorial. *Analytica Chimica Acta*, 185, 1–17.

- Genrup, M. (2005). *On degradation and monitoring tools for gas and steam turbines* (Phd Thesis, Lund University, Sweden).
- Gerry, J. (2004). Performance measurement - the rest of history. *ExperTune Newsletter*.
- Gil, P. (2009). *Redes neuronais artificiais na modelação e controlo de sistemas dinâmicos*. FCT-UNL.
- Goodwin, G. C., Graebe, S. F. & Salgado, M. E. (2001). *Control system design*. Upper Saddle River, N.J.: Prentice Hall.
- Hagan, M., Demuth, H. & Beale, M. (1995). *Neural network design*. Boston - USA: PWS Publishing Company.
- Hagglund, T. (1995). A control-loop performance monitor. *Control Engineering Practice*, 3(11), 1543–1551.
- Harris, T. J. (1989). Assessment of control loop performance. *Canadian Journal of Chemical Engineering*, 67(5), 856–861.
- Harris, T., Seppala, C. & Desborough, L. (1997). A review of performance assessment and process monitoring techniques for univariate and multivariate control systems. Em *Ifac adchem conference*. Banff-Canada.
- Haykin, S. (1994). *Neural networks – a comprehensive foundation*. MacMillan College Publishing Company, Inc.
- Heiming, B. & Lunze, J. (1999). Definition of the three-tank benchmark problem for controller reconfiguration. Em *Proc. of the european control conference ecc'99*. Karlsruhe, Germany.
- Hertz, J., Krogh, A. & Palmer, R. (1991). *Introduction to the theory of neural computation*. Addison-Wesley Publishing Company.
- Hotelling, H. (1933). Analysis of a complex of statistical variables into principal components. *Educational Psychology*, 24, 417–441.
- Huang, B. & Shah, S. L. (1999). *Performance assessment of control loops : theory and applications*. London: Springer.
- Hugo, A. J. (2001). Process controller performance monitoring and assessment. **retrieved from <http://controlartsinc.com>**
- Isermann, R. & Ballé, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Eng. Practice*, 5(5), 709–719.
- Jelali, M. (2006). An overview of control performance assessment technology and industrial applications. *Control Engineering Practice*, 14(5), 441–466.
- Jolliffe, I. T. (1986). *Principal component analysis*. New York: Springer-Verlag.
- Kempf, A. O. (2003). *Avaliação de desempenho de malhas de controle* (Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, Porto Alegre).
- Kendra, S. J. & Cinar, A. (1997). Controller performance assessment by frequency domain techniques. *Journal of Process Control*, 7(3), 181–194.
- Ko, B.-S. & Edgar, T. F. (2000). Performance assessment of cascade control loops. *AIChE Journal*, 46(2), 281–291.

- Koppen-Seliger, B., Garcia, E. & Frank, P. (1999). Fault detection: different strategies for modelling applied to the three tank benchmark – a case study. Em *Proc. of the european control conference ecc'99*. Karlsruhe, Germany.
- Kumar, S., Martin, E. B. & Morris, J. (2002). Detection of process model change in pls based performance monitoring. Em *Ifac world congress*. Barcelona, Spain.
- Li, Z. & Evans, R. J. (1997). Minimum-variance control of linear time-varying systems. *Autonia*, 33(8), 1531–1537.
- Narendra, K. & Parthasarathy, K. (1990). Identification and control of dynamical systems using neural networks. *IEEE Trans. on Neural Networks*, 1(1), 4–27.
- Olaleye, F., Huang, B. & Tamayo, E. (2004). Parameter and delay estimation of continuous-time models using a linear filter. *Journal of Process Control*, 14(8), 867–877.
- Oppenheim, A., Willsky, A. & Young, I. (1983). *Signals and systems*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc.
- Palma, L. B., Coito, F. V. & da Silva, R. N. (2003a). Fault diagnosis based on black-box models with application to a liquid-level system. Em *Proc. of the iee international conference on emerging technologies and factory automation, etfa'03*. Lisbon, Portugal.
- Palma, L. B., Coito, F. V. & da Silva, R. N. (2003b). Neural observer-based approach to fault diagnosis applied to a liquid level system. Em *Proc. of the ifac international conference on intelligent control systems and signal processing*. Univ. of Algarve, Portugal.
- Palma, L., Moreira, J., Gil, P. & Coito, F. (2013). Hybrid approach for control loop performance assessment. Em *5th kes internacional conference on intelligent decision technologies*. Sesimbra, Portugal.
- Paulonis, M. A. & Cox, J. W. (2006). A practical approach for large-scale controller performance assessment, diagnosis, and improvement. *Journal of Process Control*, 13(2), 155–168.
- Pearson, K. (1901). On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 2, 559–572.
- Perrier, M. & Roche, A. A. (1992). Towards mill-wide evaluation of control loop performance. *Proc. Control. Syst. '92*, 251–258.
- Salsbury, T. I. (2005). A practical method for assessing the performance of control loops subject to random load changes. *Journal of Process Control*, 15(4), 393–405.
- Seborg, D. E., Mellichamp, D. A., Edgar, T. F. & Doyle, F. J. (2004). *Process dynamics and control*. Hoboken, N.J.: Wiley.
- Seppala, C. T., Harris, T. J. & Bacon, D. W. (2002). Time series methods for dynamic analysis of multiple controlled variables. *Journal of Process Control*, 12(2), 257–276.
- Siemens, A. (2008). How to improve the performance of your plant using the appropriate tools of simatic pcs 7 apc portfolio – white paper. *Siemens AG*.
- Stanfelj, N., Marlin, T. E. & MacGregor, J. F. (1993). Monitoring and diagnosing process control performance: the single-loop case. *Industrial and Engineering Chemistry Research*, 32(2), 301–314.

- Thornhill, N. F., Choudhury, M. A. A. S. & Shah, S. L. (2004). The impact of compression on data-driven process analyses. *Journal of Process Control*, 14(4), 389–398.
- Thornhill, N. F., Cox, J. W. & Paulonis, M. A. (2003). Diagnosis of plant-wide oscillation through data-driven analysis and process understanding. *Control Engineering Practice*, 11(12), 1481–1490.
- Thornhill, N. F. & Hagglund, T. (1997). Detection and diagnosis of oscillation in control loops. *Control Engineering Practice*, 5(10), 1343–1354.
- Thornhill, N. F., Huang, B. & Shah, S. L. (2003). Controller performance assessment in set point tracking and regulatory control. *Internacional Journal of Adaptive Control and Signal Processing*, 17, 709–727.
- Thornhill, N. F., Oettinger, M. & Fedenczuk, P. (1999). Refinery-wide control loop performance assessment. *Journal of Process Control*, 9(2), 109–124.
- Thornhill, N., Sadowski, R., Davis, J., Fedenczuk, P., Knight, M., Prichard, P. & Rothenberg, D. (1996). Practical experiences in refinery control loop performance assessment. *Em Iee ukacc int. confer. on control*.
- Trierweiler, J. O. (1997). *A systematic approach to control structure design* (Ph.D. Degree, University of Dortmund, Dortmund).
- Tuch, J., Feuer, A. & Palmor, Z. J. (1994). Time delay estimation in continuous linear time-invariant systems. *IEEE Transactions on Automatic Control*, 39(4), 823–827.
- Tyler, M. L. & Morari, M. (1996). Performance monitoring of control systems using likelihood methods. *Automatia*, 32(8), 1145–1162.
- Wasserman, P. D. (1989). *Neural computing, theory and practice*.
- Wold, S. (1978). Cross-validatory estimation of the number of components in factor and principal components models. *Technometrics*, 20, 397–405.
- Wold, S., Geladi, P., Esbensen, K. & Ohman, J. (1987). Multi-way principal components and pls-analysis. *Journal of Chemometrics*, 1, 41–56.
- Análise de Componente Principais – PCA. (2009). **retrieved from** <http://fspanero.wordpress.com/>
- Xia, C. & Howell, J. (2005). Isolating multiple sources of plant-wide oscillations via independent component analysis. *Control Engineering Practice*, 13(8), 1027–1035.