

UNIVERSITAT POLITÈCNICA DE CATALUNYA

Programa de Doctorat:

AUTOMÀTICA, ROBÒTICA I VISIÓ

Tesi Doctoral

**GENERACIÓ DE DECISIONS DAVANT
D'INCERTESES**

Antoni Escobet i Canal

Directors:

Àngela Nebot Castells
François Cellier

Juliol de 2012

Resum

Aquesta tesi tracta sobre la metodologia del raonament inductiu difús (FIR, de l'anglès *fuzzy inductive reasoning*) aplicada a sistemes de detecció i diagnòstic de fallades. La metodologia FIR sorgeix de l'enfocament del *general systems problem solver* (GSPS) proposat per Klir l'any 1989 i és una eina per analitzar i estudiar els modes de comportament dels sistemes dinàmics. FIR és una metodologia de modelització i simulació qualitativa de sistemes basada principalment en l'observació del comportament del sistema. Aquesta metodologia ha anat evolucionant al llarg del temps amb l'objectiu d'ampliar la classe de problemes que es poden abordar amb FIR.

El treball desenvolupat en aquesta tesi té el propòsit de contribuir a reduir els esforços de modelització i simulació de sistemes industrials reals complexos. En aquesta línia, s'ha aconseguit augmentar, mitjançant diferents aportacions, la robustesa de FIR i desenvolupar una nova metodologia que permeti crear sistemes de detecció i diagnòstic de fallades robustos i eficients.

L'objectiu principal d'aquesta tesi és reduir tant com sigui possible la sensibilitat de la metodologia FIR, és a dir, maximitzar-ne la robustesa, de manera que esdevingui una eina cabdal per desenvolupar sistemes de detecció i diagnòstic de fallades eficients.

Les contribucions principals de la tesi són:

- Incrementar la robustesa del FIR creant una nova eina, anomenada Visual-FIR, que permet identificar models i predir comportaments futurs de sistemes dinàmics en un entorn molt senzill d'utilitzar i molt eficient.
- Desenvolupar una nova metodologia per crear sistemes de detecció i diagnòstic de fallades basats en FIR. S'ha desenvolupat una tècnica de detecció, anomenada *envolupant*, i una mesura per al diagnòstic, anomenada *mesura d'acceptabilitat del model*, que han permès millorar i fer més sòlids els processos de detecció i diagnòstic de fallades del FIRFDDS (sistema de detecció i diagnòstic de fallades basat en FIR).
- Desenvolupar una eina que permeti crear de manera senzilla i altament eficient FIRFDDS per a aplicacions específiques. S'ha desenvolupat una plataforma, anomenada VisualBlock-FIR, que permet que l'usuari creï, d'una manera senzilla, sistemes de detecció i diagnòstic de fallades basats en el FIR.

Per validar la metodologia i les eines desenvolupades es mostren un parell de casos d'estudi. El primer correspon al problema de referència de la vàlvula automàtica de Damadics, en què es proposen quatre fallades de petita i mitjana magnitud que es detecten i s'aïllen/s'identifiquen d'una manera molt ràpida i eficient. En el segon es posa a prova el VisualBlock-FIR en una pila de combustible simulada a la qual s'apliquen cinc fallades diferents, les quals són detectades i identificades correctament. Finalment, es comprova la robustesa afegint soroll blanc, en diferents magnituds, a les sortides de la pila de combustible.

Abstract

This thesis deals with the Fuzzy Inductive Reasoning (FIR) methodology applied to fault detection and diagnosis systems. FIR, based on the General Systems Problem Solver (GSPS) proposed by Klir in 1989, is a methodological tool for data-driven construction of dynamical systems and for studying their conceptual modes of behavior. FIR is a qualitative modeling and simulation methodology that is based on observation of the input–output behavior of the system to be modeled, rather than on structural knowledge about its internal composition. This methodology has evolved over time with the aim of enlarging the class of problems that can be dealt with by FIR.

The work presented in this thesis aims to contribute to reducing modeling and simulation efforts of real industrial complex systems. Several methodological contributions have been made to increase FIR robustness as well as to develop a new methodology to create robust and efficient fault detection and diagnosis systems.

The main objective of this thesis is to reduce as much as possible the sensitivity of the FIR methodology, by maximizing its robustness, in such a way that it becomes a fundamental tool for developing efficient fault detection and diagnosis systems.

The main contributions of this thesis are:

- To improve the robustness of FIR by creating a new tool, *Visual-FIR*, that identifies patterns and predicts future behavior of dynamical systems in a very efficient and simple to use environment.
- To develop a new methodology for creating fault detection and diagnosis systems based on FIR. We have developed a detection technique, the *enveloping*, and a diagnosis measure, known as the *acceptability measure*, that allow improving and making more robust the fault detection and diagnosis processes of the FIRFDDS (fault detection and diagnosis system based on FIR).
- To develop a tool that allows to easily create highly efficient FIRFDDS for specific applications. A platform, named *VisualBlock-FIR*, has been developed that allows the user to create, in a simple way, fault detection and diagnosis systems based on FIR.

In order to validate the methodological contributions and the developed tools a couple of case studies have been presented in this dissertation. The first corresponds to the benchmark problem of the Damadics automatic valve system, which proposes four failures of small and medium

sizes that are detected and isolated / identified in a quick and highly efficient way. The second is a simulated fuel cell where five different faults are applied. The five faults are detected and identified correctly. Finally, we check the robustness of the FIRFDDS by adding white noise, at different magnitudes, to the outputs of the fuel cell.

Agraïments

Aquesta tesi no hagués estat possible sense l'ajuda i el suport de tots els que m'heu envoltat durant aquests anys, per a tots vosaltres les gràcies més sinceres.

Un agraïment molt especial a l'Àngela i al François, la vostra paciència, ajuda i guiatge al llarg d'aquests anys m'ha ajudat a tirar endavant aquest projecte. Gràcies per ser-hi i ajudar-me a enfocar i reorientar el tema quan calia.

Gràcies Teresa, sense tu aquest treball no s'hauria acabat mai.

Gràcies a tots els membres del departament de DiPSE i els companys de Terrassa, sempre m'heu estat donant ànims i disposats a donar un cop de mà.

Finalment, vull dedicar les darreres línies a les persones que més estimo. A vosaltres Àngels, Eloi i Aina us dedico aquest treball, i perdoneu-me per si darrerament no us he dedicat tota l'atenció que us mereixeu.

Índex

RESUM	I
ABSTRACT	III
AGRAÏMENTS.....	V
ÍNDEX.....	VII
ÍNDEX DE FIGURES	XI
ÍNDEX DE TAULES.....	XV
1 INTRODUCCIÓ.....	1
1.1 Motivació	1
1.2 Selecció de la metodologia.....	4
1.3 Objectius i aportacions.....	5
1.4 Estructura de la memòria	8
2 DETECCIÓ I DIAGNÒSTIC DE FALLADES: ESTAT DE LA QÜESTIÓ	11
2.1 Introducció	11
2.2 Conceptes bàsics	13
2.2.1 Terminologia usada en la detecció i el diagnòstic de fallades	13
2.2.2 Tipus de models.....	14
2.2.2.1 Classes de model	14
2.2.2.2 Models de coneixement profund o deep knowledge.....	15
2.2.2.3 Models de coneixement superficial o shallow surface.....	15
2.2.3 Supervisió.....	16
2.2.4 Generació de símptomes.....	17
2.2.4.1 Generació analítica de símptomes	18
2.2.4.2 Generació heurística de símptomes	19
2.2.4.3 Diagnòstic de fallades.....	19
2.3 Mètodes de detecció i diagnòstic de fallades.....	19
2.3.1 Panorama general	19
2.3.2 Mètodes basats en models quantitativs.....	21
2.3.3 Mètodes basats en models qualitativs.....	23
2.3.3.1 Tècniques basades en regles	23
2.3.3.2 Tècniques basades en models funcionals.....	23
2.3.4 Mètodes basats en dades del procés.....	25
2.3.4.1 Caixa negra	25
2.3.4.2 Caixa gris.....	26

2.3.5	La lògica difusa i els FDDS.....	27
2.4	Rendiment i robustesa dels FDDS	30
2.4.1	Rendiment d'un FDDS	30
2.4.2	Robustesa.....	31
2.5	Comentaris finals	32
3	RAONAMENT INDUCTIU DIFÚS (FIR)	35
3.1	Introducció	35
3.2	<i>General systems problem solver (GSPS)</i>	36
3.3	La metodologia FIR.....	41
3.4	Codificació difusa	42
3.4.1	Propietats que garanteixen la interpretabilitat d'una partició difusa.....	43
3.5	Modelització qualitativa.....	44
3.6	Simulació qualitativa.....	49
3.7	Regeneració.....	52
3.8	Mètode millorat de la partició amb igual freqüència.....	52
3.8.1	Introducció.....	52
3.8.2	Mètode millorat de partició amb igual freqüència	53
3.8.3	Sistema de distribució d'aigües	54
3.8.4	Codificació difusa de les variables del sistema.....	56
3.8.5	Identificació dels models de pressió	60
3.9	Conclusions.....	63
4	SISTEMA DE MONITORATGE DE FALLADES	65
4.1	Introducció	65
4.2	Sistema de monitoratge de fallades amb FIR	67
4.2.1	Selecció i agrupació causal de les variables	67
4.2.2	Detecció de fallades.....	68
4.2.3	Diagnòstic de la fallada	69
4.2.4	Limitacions del sistema de monitoratge de fallades	70
4.3	FIRFMS millorat	72
4.3.1	Envolupant.....	72
4.3.2	Mesura de l'acceptabilitat.....	74
4.4	Aplicacions.....	75
4.4.1	Circuit elèctric	76
4.4.2	Sistema nerviós central de control.....	80
4.4.3	Sistema de distribució de la demanda d'aigua.....	86
4.5	Debat i conclusions	90
5	PLATAFORMA VISUAL DEL FIR: VISUAL-FIR.....	93

5.1	Introducció	93
5.1.1	MATLAB Fuzzy Logic Toolbox.....	94
5.1.2	FuzzyTech	95
5.1.3	FLINT.....	96
5.1.4	FuzzyCLIPS	97
5.1.5	FIDE	98
5.1.6	KEEL.....	98
5.2	La metodologia FIR mitjançant un exemple	99
5.3	Plataforma visual del raonament inductiu difús: Visual-FIR.....	105
5.3.1	Fase d'identificació del model.....	105
5.3.1.1	Ajust dels paràmetres.....	105
5.3.1.2	Dades d'entrenament.....	107
5.3.1.3	Codificar.....	108
5.3.1.4	Màscara òptima.....	112
5.3.2	Fase de predicció	114
5.3.2.1	Càrrega de les dades de test.....	114
5.3.2.2	Predicció	114
5.3.2.3	Regeneració.....	115
5.3.2.4	Visualització de resultats	116
5.4	Contribució del Visual-FIR a la metodologia FIR	118
5.5	Conclusions.....	119
6	DIAGRAMES DE BLOCS EN EL FIR: EL VISUALBLOCK-FIR.....	121
6.1	Introducció	121
6.2	Un pas més cap als diagrames de blocs.....	122
6.3	Descripció de la plataforma VisualBlock-FIR	128
6.3.1	Mòduls de modelització.....	129
6.3.1.1	Mòdul de codificació difusa.....	129
6.3.1.2	Simulació qualitativa.....	131
6.3.1.3	Regeneració.....	133
6.3.1.4	Configuració del FIR.....	133
6.3.2	Mòdul de detecció i diagnòstic de fallades	136
6.4	Aplicació del VisualBlock-FIR: Cas pràctic.....	140
6.5	Aportacions del VisualBlock-FIR	147
6.6	Conclusions.....	147
7	APLICACIONS	149
7.1	Introducció	149
7.2	DAMADICS.....	150
7.2.1	Descripció del sistema	150
7.2.2	Identificació dels models FIR del sistema en funcionament normal i en fallada.....	152
7.2.3	Detecció i diagnòstic de les fallades.....	154
7.2.4	Fallada 10 (f_{10}): perforació del diafragma del servomotor.....	155
7.2.5	Fallada 11 (f_{11}): fallada de la molla del servomotor.....	157
7.2.6	Fallada 1 (f_1): obstrucció a la vàlvula de control	158

7.2.7	Fallada 13 (f_{13}): fallada del sensor de la tija del posicionador	159
7.2.8	Rendiment del VisualBlock-FIR vs. la metodologia dels observadors d'interval.....	161
7.2.9	Comparació dels rendiments en la detecció i el diagnòstic amb metodologies afins.....	162
7.3	Sistema de piles de combustible.....	164
7.3.1	Descripció del sistema	164
7.3.2	Identificació dels models FIR del sistema en funcionament normal i en fallada.....	166
7.3.3	Detecció i diagnòstic de les fallades	168
7.3.4	Fallada f_1 : augment de la fricció al motor del compressor	170
7.3.5	Fallada f_2 : sobreescalfament del motor de compressió	172
7.3.6	Fallada f_3 : augment de la resistència del flux d'aigua.....	174
7.3.7	Fallada f_4 : fuga d'aire al col·lector de subministrament d'aire	175
7.3.8	Fallada f_5 : increment de la tensió mínima del motor del compressor	177
7.3.9	Comparació dels rendiments en la detecció i el diagnòstic amb metodologies afins.....	178
7.4	Anàlisi de robustesa del VisualBlock-FIR.....	179
7.5	Conclusions.....	182
8	CONCLUSIONS I TREBALL FUTUR	185
8.1	Conclusions generals i aportacions	185
8.2	Resum dels resultats obtinguts.....	186
8.3	Treball futur.....	187
8.4	Contribucions científiques.....	188
8.4.1	Articles en revistes internacionals indexades	188
8.4.2	Articles en congressos internacionals	189
8.4.3	Reports de recerca	190
8.4.4	Participació en projectes de recerca.....	190
9	BIBLIOGRAFIA	193

Índex de figures

Figura 2-1	Exactitud assolida pels models segons el grau de coneixement que es té de les variables del sistema [71].....	14
Figura 2-2	Esquema de la detecció i el diagnòstic de fallades basat en el coneixement (adaptada de [69]).....	18
Figura 2-3	Esquema general de detecció i diagnòstic.....	20
Figura 2-4	Esquema de classificació dels mètodes FDDES.....	21
Figura 2-5	Esquema d'un sistema d'FDI basat en models quantitativs.....	22
Figura 2-6	Estructura del mètode integrat de diagnòstic de fallades basat en xarxes neuronals difuses [18].....	28
Figura 3-1	GSPS dins l'espectre de les teories de sistemes.....	38
Figura 3-2	Jerarquia de nivells epistemològics de sistemes i la seva relació amb el raonament inductiu difús.....	39
Figura 3-3	Representació esquemàtica de la metodologia FIR.....	41
Figura 3-4	Procés de codificació de la metodologia FIR.....	42
Figura 3-5	Exemple d'una partició difusa forta.....	44
Figura 3-6	Procés per aconseguir la matriu d'E/S (base de regles patró).....	48
Figura 3-7	Esquema del procés de simulació qualitativa del FIR.....	49
Figura 3-8	Paràmetres del mètode EEFP.....	53
Figura 3-9	Diagrama simplificat de la xarxa de distribució d'aigües de Sintra (Portugal).....	55
Figura 3-10	Entrades i sortides del sistema de la xarxa de distribució d'aigües de Sintra (Portugal).....	56
Figura 3-11	Distribució de les dades de la demanda d'aigua de DI (dipòsit de Monte Abráao). a) Senyal original de la demanda d'aigua; b) senyal ordenat de la demanda d'aigua.....	57
Figura 3-12	Distribució de les dades de la vàlvula 2. a) Senyal original de la vàlvula 2; b) senyal ordenat de la vàlvula 2.....	58
Figura 3-13	Distribució de les dades de la pressió en el node 5. a) Senyal original de la pressió en el node 5; b) senyal ordenat de la pressió en el node 5.....	59
Figura 3-14	Predicció de la pressió en el node 5: (a) mètode EFP, (b) mètode EEFP.....	62
Figura 4-1	Procés de detecció de fallades en FIR (De Albornoz).....	68
Figura 4-2	Procés de diagnòstic de la fallada de FIR (De Albornoz).....	69
Figura 4-3	Exemple de detecció de fallades pel mètode de l'envolupant (finestra de temps = 15).....	72
Figura 4-4	Procés de detecció de fallades del FIR (envolupant).....	73
Figura 4-5	Procés de diagnòstic de la fallada en el FIR (mesura d'acceptabilitat).....	75
Figura 4-6	Circuit elèctric.....	76
Figura 4-7	Identificació del model per al circuit 000.....	77
Figura 4-8	Identificació del model per al circuit 011.....	77
Figura 4-9	Resultat del FIRFMS aplicat al circuit elèctric utilitzant la tècnica de l'envolupant i la mesura de l'acceptabilitat (prova amb TW = 10 i CE = 2).....	78
Figura 4-10	Resultat del FIRFMS aplicat al circuit elèctric utilitzant la metodologia de De Albornoz (TW = 10 i 50 mostres; CE = 2).....	79
Figura 4-11	Senyal de sortida del controlador de la contractilitat miocardiaca (MC): (a) pacient 1, (b) pacient 2, (c) pacient 3, (d) pacient 4 i (e) pacient 5.....	80
Figura 4-12	Distribució de les dades de prova o experiment per a cadascun dels 5 controladors.....	81
Figura 4-13	Resultat HR (TW = 10 mostres; CE = 2).....	82
Figura 4-14	Resultats MC (TW = 10 mostres; CE = 2).....	83
Figura 4-15	Resultats PR (TW = 10 mostres; CE = 2).....	84
Figura 4-16	Resultats CR (TW = 10 mostres; CE = 2).....	85
Figura 4-17	Resultats VT (TW = 10 mostres; CE = 2).....	85
Figura 4-18	Diagrama simplificat del sistema de demanda d'aigua.....	86
Figura 4-19	Senyals de sortida per als tres escenaris.....	88

Figura 4-20	Resultats del FIRFMS aplicat a la xarxa de distribució d'aigua utilitzant la tècnica de l'envolupant i la mesura de l'acceptabilitat (TW = 10 mostres; CE = 1).....	89
Figura 4-21	Resultats del FIRFMS aplicat a la xarxa de distribució d'aigua utilitzant la tècnica de l'envolupant i la mesura de l'acceptabilitat (TW = 5 mostres; CE = 2)	90
Figura 5-1	Interfície gràfica de la FLT. Pantalla principal.	95
Figura 5-2	Finestra principal de l'editor FuzzyTECH.	96
Figura 5-3	Editor de variables difuses del FLINT.	97
Figura 5-4	Pantalla principal del Visual-FIR amb les quatre etapes de la metodologia FIR.	100
Figura 5-5	Codi MATLAB per inicialitzar els paràmetres de FIR per a la fallada F3 de DAMADICS.	101
Figura 5-6	Màscara candidata per a la fallada F3 de DAMADICS.	101
Figura 5-7	Codi MATLAB de la fase d'identificació del model FIR per a la fallada F10 de DAMADICS.	102
Figura 5-8	Codi MATLAB de la fase de predicció de FIR per a la fallada F3 de DAMADICS.	103
Figura 5-9	Pantalla de configuració dels paràmetres de la plataforma Visual-FIR.	106
Figura 5-10	Pantalla d'entrada de les dades d'entrenament de la plataforma Visual-FIR.	107
Figura 5-11	Pantalla del procés de codificació difusa de la plataforma Visual-FIR.	109
Figura 5-12	Funcions de pertinença de la variable de sortida X obtingudes amb l'opció data memb de la pantalla del procés de codificació difusa de la plataforma Visual-FIR.	111
Figura 5-13	Pantalla de cerca de la màscara òptima de la plataforma Visual-FIR.....	112
Figura 5-14	Pantalla de visualització del model FIR de la plataforma Visual-FIR.	113
Figura 5-15	Pantalla de predicció de la plataforma Visual-FIR.	114
Figura 5-16	Pantalla de regeneració de les dades de test de la plataforma Visual-FIR.	115
Figura 5-17	Pantalla de visualització de la predicció de les dades de test de la plataforma Visual-FIR.....	116
Figura 5-18	Definició de l'experiment i predicció amb el model FIR que representa el comportament normal de l'actuador i amb el model FIR que representa la fallada F3.	117
Figura 6-1	Codi MATLAB per inicialitzar les variables globals i els paràmetres per detectar i aïllar la fallada #1 de la pila de combustible.	123
Figura 6-2	Codi MATLAB de la fase de detecció de la fallada de la variable λ_{O_2} de la pila de combustible.	124
Figura 6-3	Codi MATLAB de la fase d'identificació/aïllament de la fallada de la variable λ_{O_2} de la pila de combustible.	125
Figura 6-4	Detecció i aïllament/identificació de la variable λ_{O_2} de la pila de combustible.	127
Figura 6-5	Llibreria VisualBlock-FIR.	128
Figura 6-6	Metodologia de predicció del FIR.	129
Figura 6-7	Mòdul de codificació difusa.....	129
Figura 6-8	Codificar. Finestra de configuració.....	130
Figura 6-9	Entrades i sortides dels mòduls de codificació difusa.	130
Figura 6-10	Mòdul de simulació qualitativa.....	131
Figura 6-11	Predicció. Finestra de configuració.	131
Figura 6-12	Entrades i sortides del mòdul de simulació qualitativa.	132
Figura 6-13	Esquema del procés de simulació qualitativa.	132
Figura 6-14	Mòdul de regeneració.	133
Figura 6-15	Configuració FIR.	133
Figura 6-16	Configuració inicial.	134
Figura 6-17	Model de la variable O2 sense fallades.	134
Figura 6-18	Configuració del Simulink.	135
Figura 6-19	Exemple I. Sense realimentació.....	135
Figura 6-20	Exemples de VisualBlock-FIR.....	136
Figura 6-21	Mòdul de detecció i identificació.	136
Figura 6-22	Bloc DetectorFDDS.	137
Figura 6-23	Finestra de configuració del DetectorFallRes.	138
Figura 6-24	Connexió del detector per a l'exemple en estudi de la pila de combustible.	139
Figura 6-25	Esquema del model sense fallada.	140
Figura 6-26	Pila de combustible i llibreria de models.	142

Figura 6-27	Resposta del sistema de predicció de la variable λ_{O_2}	142
Figura 6-28	Esquema final del FDDS per la variable λ_{O_2}	143
Figura 6-29	Configuració del FDDS.....	144
Figura 6-30	Diagnòstic del FDDS amb una finestra de diagnòstic de 25 punts (2,5 segons).....	144
Figura 6-31	Quantitat d'errors per a cada model.....	145
Figura 7-1	Representació esquemàtica del sistema DAMADICS.....	150
Figura 7-2	Esquema de predicció per al sistema en funcionament correcte desenvolupat en Simulink que empra el model FIR identificat prèviament amb el Visual-FIR.....	153
Figura 7-3	Model de detecció i diagnòstic de fallades de VisualBlock-FIR per al sistema DAMADICS.....	154
Figura 7-4	Detecció i diagnòstic de la fallada f_{10s} amb VisualBlock-FIR.....	155
Figura 7-5	Detecció i diagnòstic de la fallada f_{10m} amb el VisualBlock-FIR.....	156
Figura 7-6	Detecció i diagnòstic de la fallada f_{11} amb el VisualBlock-FIR.....	157
Figura 7-7	Detecció i diagnòstic de la fallada f_{1s} amb el VisualBlock-FIR.....	158
Figura 7-8	Detecció i diagnòstic de la fallada f_{1m} amb el VisualBlock-FIR.....	159
Figura 7-9	Detecció i diagnòstic de la fallada f_{13s} amb el VisualBlock-FIR.....	160
Figura 7-10	Detecció i aïllament/identificació de la fallada f_{13m} amb el VisualBlock-FIR.....	160
Figura 7-11	Esquema del sistema de la pila de combustible.....	164
Figura 7-12	Senyals d'entrada a la pila.....	166
Figura 7-13	Model de detecció i diagnòstic de fallades del VisualBlock-FIR per al sistema de piles de combustible PEM.....	168
Figura 7-14	Contingut del mòdul models format pels 5 models FIR de fallada i el del funcionament correcte (ModelNF).....	169
Figura 7-15	Contingut del mòdul Pila NF, amb les quatre sortides del sistema. És a dir, conté els 4 models FIR, un per a cada variable de sortida, del sistema quan funciona correctament.....	169
Figura 7-16	Contingut del mòdul FDDS format pels sistemes de detecció i diagnòstic de fallades de les quatre variables de sortida.....	170
Figura 7-17	Detecció i diagnòstic de la fallada f_1 amb el VisualBlock-FIR per al conjunt de models $M_{\omega_{cm}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.....	171
Figura 7-18	Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_1	172
Figura 7-19	Detecció i diagnòstic de la fallada f_2 amb el VisualBlock-FIR per al conjunt de models $M_{\lambda_{O_2}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.....	173
Figura 7-20	Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_2	173
Figura 7-21	Detecció i diagnòstic de la fallada f_3 amb el VisualBlock-FIR per al conjunt de models $M_{I_{cm}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.....	174
Figura 7-22	Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_3	175
Figura 7-23	Detecció i diagnòstic de la fallada f_4 amb el VisualBlock-FIR per al conjunt de models $M_{v_{fc}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.....	176
Figura 7-24	Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_4	176
Figura 7-25	Detecció i diagnòstic de la fallada f_5 amb el VisualBlock-FIR per al conjunt de models $M_{\omega_{fc}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.....	177
Figura 7-26	Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_5	178
Figura 7-27	Envolupant de la fallada f_1 amb un increment del 8 %, quan s'afegeix als senyals de sortida un soroll del 20 dB.....	180
Figura 7-28	Resposta del VisualBlock-FIR FDDS amb un soroll de 20 dB.....	181

Índex de taules

Taula 2-1	Conjunt d'articles que fan una revisió dels mètodes d'FDDS.....	12
Taula 3-1	Llindars de les tres classes de la demanda D_1 obtinguts utilitzant el mètode EFP.....	56
Taula 3-2	Llindars de les tres classes de la vàlvula V_2 obtinguts utilitzant el mètode EFP.....	58
Taula 3-3	Llindars de les tres classes de la vàlvula V_2 obtinguts utilitzant el mètode EEFP	59
Taula 3-4	Llindars de les tres classes del node N_5 obtinguts utilitzant els mètodes EFP	60
Taula 3-5	Llindars de les tres classes del node N_5 obtinguts utilitzant els mètodes EEFP	60
Taula 7-1	Equivalència entre els models i la representació numèrica donada al Simulink.....	152
Taula 7-2	Error quadràtic mitjà en percentatge (MSE) de predicció dels conjunts de dades de prova, formats per 800 punts (200 segons), obtinguts amb els diferents models FIR identificats per a cada fallada.	153
Taula 7-3	Temps de detecció obtinguts en la fase de detecció de fallades del VisualBlock-FIR.	161
Taula 7-4	Temps de detecció obtinguts en la fase de detecció de fallades de la metodologia d'observadors d'interval. Els guions representen temps que no es poden computar d'acord amb la definició donada en el benchmark DAMADICS [125].	162
Taula 7-5	Resultats de diferents FDDS per al sistema de referència DAMADICS.....	163
Taula 7-6	Equivalència entre els models i la representació numèrica assignada en el VisualBlock-FIR.....	166
Taula 7-7	Error quadràtic mitjà en percentatge (MSE) de predicció dels conjunts de dades de prova, formats per 1.600 punts (160 segons), obtinguts amb els diferents models FIR identificats per a cada fallada.	167
Taula 7-8	Resultats en segons del VisualBlock-FIR per a les cinc fallades. Temps de la finestra de detecció = 1 s; temps de la finestra d'identificació = 6 s; errors acumulats = 3. El valor de 6 segons marcat de color vermell en les fallades f_3 i f_4 indica que s'ha diagnosticat incorrectament una fallada al cap de 6 segons i que es diagnostica de nou correctament al cap de 12 i 30 segons, respectivament.	178
Taula 7-9	Resultats en segons del VisualBlock-FIR per a les cinc fallades amb soroll blanc uniforme de 60, 40, 30 i 20 dB afegit als senyals de sortida. Finestra de detecció = 1 segon; finestra de diagnòstic = 10 segons; errors acumulats = 3.	179

1 Introducció

Resum: en aquest capítol s'introdueix la temàtica de la tesi, que se centra, tal com indica el títol, en la generació de decisions davant d'incerteses. Els sistemes industrials, cada dia més complexos, requereixen sistemes de monitoratge i supervisió de fallades al més robustos possible, capaços de prendre decisions en un entorn en què hi ha presents diverses classes d'incerteses. En aquesta línia, les metodologies que treballen incorporant aquestes incerteses i reduint tant com sigui possible la sensibilitat en la presa de decisions són les més adequades per ser emprades com a sistemes de detecció i diagnòstic de fallades. Aquesta recerca se centra en la metodologia del raonament inductiu difús (FIR, de l'anglès *fuzzy inductive reasoning*), que ha demostrat que ofereix un gran potencial en el modelatge i la simulació de sistemes dinàmics complexos en diferents àrees. L'objectiu és, d'una banda, millorar la metodologia com a tal per fer-la més robusta (menys sensible) i, de l'altra, desenvolupar un sistema de detecció i diagnòstic de fallades potent que sigui útil i eficient en sistemes industrials reals. En la primera secció del capítol es presenta la motivació per treballar en el problema que es planteja en aquesta tesi. En la segona secció es justifica la selecció de la metodologia FIR. Els objectius concrets del treball i les aportacions dutes a terme s'expliquen en la tercera secció del capítol. Finalment, es descriu com està organitzada la memòria de la tesi i es resumeix el contingut de cadascun dels capítols.

1.1 Motivació

Els sistemes industrials actuals, com, per exemple, una turbina de gas, una torre de destil·lació, un sistema de distribució d'aigües, etc., tenen uns requeriments de seguretat i eficiència molt severos i se'ls requereix un funcionament òptim. És natural que, atesa la gran complexitat d'aquests sistemes, en alguna de les parts o en algun dels components que els constitueixen tinguin lloc canvis no volguts. Aquests canvis de comportament, ocasionats per causes fortuïtes o deguts a l'envelliment dels components, i anomenats de manera genèrica *fallades*, comporten des de petites pèrdues d'eficiència fins a danys catastròfics per al mateix sistema o, fins i tot, per a l'entorn i els éssers humans. Per tal de proporcionar una resposta ràpida en el cas que es detecti una anomalia o una fallada, s'han desenvolupat eines automàtiques d'ajuda a l'operador humà en les tasques de supervisió del funcionament de la planta. Aquestes eines són conegudes amb el nom de *sistemes de monitoratge i supervisió* i formen part dels esglaons més alts de l'arquitectura de control del sistema. Entre les tasques que aquestes eines han de desenvolupar figuren la detecció i el diagnòstic de les fallades.

Definim *detecció de fallades* com el procés que condueix a determinar si el sistema presenta alguna fallada o no i *diagnòstic de la fallada* com el procés que determina el component o la part del sistema avariada i la magnitud de l'avarada. Aquestes últimes tasques es coneixen amb el nom d'*aïllament de la fallada* i *identificació de la fallada*, respectivament. La tasca de detecció és tan important com la tasca de diagnòstic. La detecció sol ser un requeriment crític per als sistemes en què la seguretat és molt important, com ara les centrals nuclears i les plantes químiques que manipulen productes perillosos. El diagnòstic es justifica a partir de criteris econòmics, en què l'aïllament està relacionat directament amb el temps de

reparació i, per tant, amb la disponibilitat del sistema, i la identificació està relacionada amb el disseny de sistemes de control tolerants a fallades i amb el manteniment predictiu.

En el procés de detecció de fallades hi ha dues incidències que cal tenir molt presents i que cal procurar minimitzar. D'una banda, hi ha el que anomenem *falses alarmes*, que corresponen a avisos incorrectes de fallades, i, de l'altra, hi ha les *fallades no detectades*. A la pràctica, com veurem en la tesi, s'imposa un compromís entre totes dues i, depenent del sistema amb què es treballa, s'ha de valorar la importància relativa de cadascuna. Per exemple, en els sistemes en què una parada representi unes grans pèrdues econòmiques s'ha de propiciar que el sistema de detecció generi el menor nombre de falses alarmes possible, encara que això representi una tolerància a algunes petites fallades. I, al revés, en els sistemes en què la seguretat sigui molt important s'ha de minimitzar el risc de no detectar alguna de les fallades, encara que aquesta decisió acabi generant alguna falsa alarma que provoqui una aturada no necessària del sistema. Podem dir que les característiques que ha de tenir un sistema de detecció de fallades són la *velocitat de detecció*, definida com el temps transcorregut entre el moment en què s'ha generat una fallada i el moment en què aquesta es detecta, i la *sensibilitat respecte a les fallades*, terme que caracteritza l'habilitat per detectar fallades de petita magnitud o en estadi inicial o incipient. Com és de preveure, aquestes característiques entren en competència amb l'objectiu de minimitzar el nombre de falses alarmes.

Un fet que cal constatar és que els sistemes de supervisió informen sobre fets qualitius, per exemple, si hi ha una fallada o no. Aquestes decisions es basen en dades quantitatives (valors reals) obtingudes del sistema que canvia de comportament de manera continuada al llarg del temps, de manera que aquest comportament es pot descriure mitjançant un model de temps continu. Aquestes decisions/informacions qualitatives poden comportar canvis en les accions de control; per tant, per actuar com a entrades del sistema i modificar-ne el comportament, prèviament han de ser transformades en dades quantitatives (valors reals). És interessant observar més detingudament quines de les tasques que ha de desenvolupar el sistema supervisor treballen amb informació qualitativa:

- Detectar que el comportament observat és anòmal i que, per tant, no s'obté un funcionament normal de la planta. Això requereix que es prengui una decisió qualitativa basada en observacions quantitatives.
- Caracteritzar l'anomalia i decidir a quina classe d'anomalia pertany el comportament observat. Aquesta torna a ser una decisió qualitativa.
- Localitzar l'anomalia en un subsistema particular. De nou, es tracta d'una decisió qualitativa.
- Hipotetitzar sobre possibles causes del comportament anòmal observat i idear experiments per provar aquestes hipòtesis.
- Proposar una acció correctiva. Com que els detalls del problema rarament es coneixen en profunditat, és complicat proposar un valor quantitatiu com a acció de correcció. La intervenció

s'ha de descriure, normalment, en termes qualitius. La prescripció s'acostuma a complementar amb una descripció (qualitativa) dels efectes esperats de la intervenció proposada.

Les decisions qualitatives ens poden conduir a dues menes d'errors, els quals s'associen a decisions binàries:

- Es pren la decisió que un valor és *cert* quan en realitat és *fals*.
- Es pren la decisió que un valor és *fals* quan en realitat és *cert*.

En el cas de la detecció, per exemple, es pot prendre la decisió que ha tingut lloc una fallada quan en realitat no n'hi ha hagut cap (falsa alarma) o, contràriament, es pot decidir que no ha tingut lloc cap fallada quan en realitat n'hi ha hagut una (fallada no detectada).

La interfície entre l'actuació qualitativa (valor real), conjuntament amb els senyals mesurats del sistema, i les decisions qualitatives crea certs problemes, ja que petites variacions en els senyals quantitius poden comportar grans canvis en les decisions que estan basades en aquests senyals quantitius.

Qualsevol problema que involucri la presa de decisions pot ser formulat indirectament com un problema de modelització que, a la vegada, pot ser interpretat com un problema d'optimització. Els sistemes difusos acostumen a ser útils a l'hora d'ajudar a resoldre problemes d'optimització. El raonament inductiu difús (FIR, de l'anglès *fuzzy inductive reasoning*) [29, 105] utilitza els conjunts difusos per convertir variables de valors reals en triplets qualitius. El problema d'optimització (problema de modelització) es resol només en l'espai de classes, és a dir, en un subespai discret del conjunt original. Això simplifica considerablement el problema d'optimització. Els valors de les funcions de pertinença s'utilitzen, doncs, per interpoliar entre classes veïnes durant el procés de regeneració de sortides quantitatives (valors reals). Amb tot, aquest procés només ajuda en els aspectes de modelització i no en la interpretació qualitativa dels resultats de les simulacions, que són la base de la presa de decisions.

El problema de la presa de decisions està relacionat amb el problema de l'anàlisi de sensibilitat. Si la sensibilitat d'una decisió que ha d'estar basada en uns paràmetres concrets del sistema és molt alta, llavors la distància entre la primera i la segona classe d'error és molt petita i, en aquest cas, cap procés de monitoratge no pot actuar de manera eficient.

A [37] la metodologia FIR es va utilitzar per detectar fallades de sistemes de gran escala. La decisió d'emprar aquesta metodologia en els problemes de detecció de fallades es deu a la gran complexitat que presenten aquesta mena de sistemes. La utilització del FIR va ajudar a reduir l'espai de cerca de manera considerable. Malauradament, encara que el FIR ajuda a reduir molt la complexitat del model, alhora, pot fer augmentar notablement el problema de la sensibilitat, ja que ara hi ha decisions qualitatives (relacionades amb els valors de classe) addicionals en les etapes de modelització i simulació que poden fer augmentar la sensibilitat de la decisió final respecte dels paràmetres del sistema.

La metodologia FIR es va crear fa unes quantes dècades i s'ha anat desenvolupant arran de diverses tesis doctorals [8, 37, 96, 99, 101, 107]. Cadascun d'aquests treballs ha tractat aspectes molt concrets d'aquesta metodologia i s'ha demostrat que aquesta és vàlida, entre d'altres, per a les classes d'aplicacions següents:

- El control de sistemes.
- La identificació i la predicció de sistemes mèdics i biològics.
- La detecció de fallades en sistemes de gran escala.
- La predicció de sèries temporals.

Cap d'aquests treballs no ha tractat el problema de la sensibilitat (robustesa) en el context de la presa de decisions discretes. Per tal d'obtenir un procés de presa de decisions més robust, cal dessensibilitzar la metodologia FIR de petites variacions en els paràmetres del sistema o en els senyals d'entrada. Aquest és l'objectiu principal de la tesi doctoral que s'ha desenvolupat.

1.2 Selecció de la metodologia

S'ha escollit la metodologia del raonament inductiu difús per desenvolupar aquesta tesi, ja que supera moltes de les limitacions tant de les aproximacions basades en el coneixement com de les basades en patrons. Alguns dels principals avantatges d'aquesta metodologia són els següents:

- La tècnica es pot aplicar a qualsevol sistema disponible per a l'experimentació i l'observació. El raonament inductiu està totalment basat en patrons; per tant, no cal conèixer l'estructura interna del sistema en estudi. En aquesta línia, els raonadors inductius són similars a les xarxes neuronals.
- Els raonadors inductius permeten que els models qualitius tractin el temps com una variable (quantitativa) contínua. Això és molt important si volem modelar i simular sistemes mixtos quantitius/qualitius.
- La metodologia conté un mecanisme inherent de validació del model dins del mètode de simulació. Aquest mecanisme prevé que el model arribi a conclusions que no es poden justificar sobre la base de les dades disponibles. En aquesta línia, els raonadors inductius són similars als sistemes basats en coneixement.
- El raonament inductiu opera de manera qualitativa, igual que els raonadors basats en coneixement, i és capaç de proporcionar informació sobre el subconjunt de relacions causals i espacials que s'estableixen entre les variables emprades en el procés de raonament, i pot, si més no, proporcionar una justificació de la predicció feta sobre la base dels estats qualitius de les variables d'entrada seleccionades.

1.3 Objectius i aportacions

El treball desenvolupat en aquesta tesi estableix una contribució als esforços de modelització i simulació de sistemes industrials reals complexos. En aquesta línia, es proposa augmentar, mitjançant diferents aportacions, la robustesa de la metodologia del raonament inductiu difús i desenvolupar una nova metodologia que permeti crear sistemes de detecció i diagnòstic de fallades robustos i eficients. Per il·lustrar els resultats obtinguts en aquest esforç de recerca, s'han utilitzat dos problemes de referència de sistemes industrials:

- Development and Application of Methods for Actuator Diagnosis in Industrial Control Systems (DAMADICS). Es tracta d'un actuador industrial format per una servovàlvula de fluid accionada per un posicionador intel·ligent, desenvolupat en el marc de treball de la Xarxa Europea de Formació d'Investigadors (FP5-RTN-1999-00392). Les parts principals de l'actuador són la vàlvula de control, el servomotor pneumàtic i el posicionador.
- Proton Exchange Membrane Fuel Cell (PEM). Les piles de combustible de membrana d'intercanvi de protons són dispositius electroquímics que converteixen l'energia química d'un combustible gasós directament en electricitat [120]. Se'ls considera una font potencial de futures energies estacionàries i mòbils. Aquests sistemes són molt complexos i impliquen fenòmens tèrmics, hidràulics i electroquímics. A més a més, requereixen un conjunt d'elements auxiliars (vàlvules, compressors, sensors, reguladors, etc.) perquè la cèl·lula de combustible funcioni en el punt òptim.

L'objectiu principal d'aquesta tesi és, doncs, reduir tant com sigui possible la sensibilitat de la metodologia FIR, és a dir, maximitzar-ne la robustesa, de manera que sigui una eina cabdal per desenvolupar una metodologia que permeti crear sistemes de detecció i diagnòstic de fallades (FDDS, de l'anglès *fault detection and diagnosis systems*) eficients.

Podem dividir l'objectiu principal de la tesi en els subobjectius següents:

1. Aconseguir que el raonament inductiu difús sigui més robust mitjançant el desenvolupament d'una eina que permeti l'ús eficient i automatitzat d'aquesta metodologia.
2. Desenvolupar una nova metodologia per crear sistemes de detecció i diagnòstic de fallades basats en el FIR.
3. Desenvolupar una eina que, tot incorporant la metodologia desenvolupada en el punt anterior, permeti crear de manera senzilla i altament eficient FDDS per a aplicacions específiques.
4. Aplicar la metodologia dels FDDS basats en el FIR als problemes de referència esmentats anteriorment: DAMADICS i PEM.
5. Estudiar la robustesa d'aquesta metodologia davant la presència de soroll sobre l'aplicació de la pila de combustible.

A continuació, es fan cinc cèntims de cadascuna d'aquestes aportacions, que s'expliquen àmpliament al llarg d'aquesta memòria.

1. **Aconseguir que el raonament inductiu difús sigui més robust mitjançant el desenvolupament d'una eina que permeti l'ús eficient i automatitzat d'aquesta metodologia.** Dins d'aquest objectiu s'ha treballat en diferents aspectes de la metodologia FIR. D'una banda, s'ha proposat un nou mètode, anomenat *enhanced equal frequency partition*, per determinar els *landmarks* associats a cada classe en el procés de discretització de les variables quantitatives. A [53] es presenta aquest mètode i se'n mostra l'eficiència mitjançant una aplicació d'un sistema de distribució d'aigua en una ciutat. De l'altra, s'ha desenvolupat una eina, anomenada *Visual-FIR*, que permet identificar models FIR i predir comportaments futurs de sistemes dinàmics en un entorn molt eficient i senzill d'utilitzar. Les implementacions anteriors del FIR implicaven desenvolupar, necessàriament, un nou codi per a cada nova aplicació que s'havia d'estudiar. El *Visual-FIR* resol aquesta limitació i ofereix una aplicació d'alt rendiment. La plataforma *Visual-FIR* presenta una nova visió de la metodologia FIR basada en blocs de processos i hi afegeix noves característiques, de manera que augmenta les capacitats generals de la metodologia [48, 51]. La potència del nou FIR, és a dir, del *Visual-FIR*, s'ha demostrat en un gran nombre d'aplicacions en diferents àmbits: modelatge del comportament de l'ozó per predir possibles situacions de contingència ambiental [103, 104], quantitat d'anestèsia que s'ha de subministrar a un pacient durant una intervenció quirúrgica [77], modelatge del sistema nerviós central de control humà [55], a banda de les aplicacions centrades en sistemes industrials que apareixen en altres objectius específics.

2. **Desenvolupar una nova metodologia per crear sistemes de detecció i diagnòstic de fallades basats en el FIR.** Dins d'aquest objectiu s'ha treballat fonamentalment en dues aportacions que han permès consolidar el sistema de diagnòstic de fallades basat en el FIR (FIRFDDS) com un sistema potent, útil i robust per detectar i diagnosticar fallades en sistemes industrials complexos. D'una banda, s'ha desenvolupat una tècnica de detecció anomenada *envolupant* i, de l'altra, s'ha dissenyat una mesura per al diagnòstic, anomenada *mesura d'acceptabilitat del model*, que han permès millorar i fer més sòlids els processos de detecció i diagnòstic de fallades del FIRFDDS. A aquest nou sistema de detecció i diagnòstic de fallades que incorpora l'envolupant i la mesura d'acceptabilitat del model l'anomenem, al llarg d'aquesta memòria, *FIRFDDS*. En aquesta tesi es mostra l'augment de l'eficàcia i l'eficiència del FIRFDDS respecte al desenvolupat prèviament en la tesi doctoral d'A. de Albornoz [37], mitjançant diverses classes d'aplicacions, algunes sobre sistemes reals. El FIRFDDS permet millorar la detecció i el diagnòstic de les fallades d'una manera considerable, ja que es redueix el temps de detecció i n'augmenta la robustesa. La demostració de la millora aconseguida amb la mesura d'acceptabilitat es mostra en diferents aplicacions: un circuit elèctric [54], utilitzat anteriorment en el primer FIRFDDS

desenvolupat, i un sistema de suport a les decisions mèdiques sobre el sistema nerviós central de control humà [55]. A [49] es demostra a partir d'aquestes mateixes aplicacions, més una de nova que correspon a un sistema de distribució de demanda d'aigua en una ciutat, les millores aconseguides pel FIRFDDS complet.

- 3. Desenvolupar una eina que, tot incorporant la metodologia desenvolupada en el punt anterior, permeti crear de manera senzilla i altament eficient FDDS per a aplicacions específiques.** Aquest objectiu prova d'aconseguir que aquesta metodologia de detecció i diagnòstic de fallades estigui a l'abast de tothom i no tan sols dels usuaris familiaritzats amb el FIR. En aquesta línia, en aquesta tesi s'ha treballat en el disseny i el desenvolupament d'una plataforma, anomenada *VisualBlock-FIR*, que permet que l'usuari creï, d'una manera senzilla, sistemes de detecció i diagnòstic de fallades basats en el FIR, és a dir, que creï els seus propis FIRFDDS. Per facilitar la utilització del *VisualBlock-FIR*, aquest s'ha implementat com una llibreria de components sobre l'entorn *Simulink*, una eina gràfica de *Matlab* que permet simular sistemes dinàmics no lineals. El *VisualBlock-FIR* defineix mòduls gràfics interactius que permeten que l'usuari construeixi models del sistema amb i sense fallades, així com que empri els processos de detecció i diagnòstic de l'FDDS. Aquesta nova eina, basada en blocs (mòduls), és molt pràctica i útil, ja que permet construir el sistema de detecció i diagnòstic de fallades de la planta en estudi com si es tractés del muntatge d'un *lego* en què cada peça té una funció específica i, per tant, només cal anar ajuntant les peces de manera adient.

A [50] es presenta aquesta plataforma i se'n mostra el funcionament a partir d'un conjunt de quatre fallades de petita i mitjana magnitud pertanyents a un sistema complex no lineal d'una vàlvula automàtica del problema de referència *DAMADICS*. El FIRFDDS desenvolupat per aquesta aplicació detecta i diagnostica totes les fallades de manera precisa i ràpida.

- 4. Aplicar la metodologia dels FDDS basats en el FIR als *problemes de referència DAMADICS i PEM*.** Per demostrar que el *VisualBlock-FIR* és una eina poderosa per crear sistemes de detecció i diagnòstic de fallades, aquesta es posa a prova mitjançant dues aplicacions industrials. La primera aplicació correspon al problema de referència de la vàlvula automàtica *DAMADICS*, en què es presenten set fallades de petita i mitjana magnitud que s'aconsegueixen detectar i diagnosticar d'una manera molt ràpida i eficient [44, 45]. En la segona aplicació s'usa el *VisualBlock-FIR* sobre una pila de combustible, en què s'apliquen cinc fallades diferents que l'eina és capaç de detectar i diagnosticar eficientment [47]. Tal com ja s'ha explicat anteriorment, la pila de combustible és un sistema més gran que el *DAMADICS*, format per quatre variables de sortida, i ens permet comprovar que el *VisualBlock-FIR* pot tractar grans sistemes de manera eficient.

5. **Estudiar la robustesa d'aquesta metodologia davant la presència de soroll sobre l'aplicació de la pila de combustible.** En aquest objectiu es vol comprovar si la metodologia del FIRFDDS és prou robusta per afrontar les pertorbacions que hi ha ens els senyals que provenen de la planta. Per provar la robustesa s'apliquen diferents nivells de soroll blanc al sistema de la pila de combustible comentat en l'apartat anterior [45]. S'estudien quatre nivells de soroll: 60 dB, 40 dB, 30 dB i 20 dB. Si comparem els temps de detecció quan s'hi afegeixen sorolls de 60 dB i 50 dB, corresponents a un 0.1 % i a un 1 % de soroll, respectivament, veiem que aquests són pràcticament els mateixos que els que es requereixen per detectar les fallades sense soroll. Quan el soroll s'incrementa d'un 3.5 % i un 10 %, el temps necessari per detectar la fallada també s'incrementa, però és encara acceptable i molt baix si es compara amb els resultats obtinguts en altres treballs de recerca.

1.4 Estructura de la memòria

Aquest treball està estructurat en vuit capítols en els quals es desenvolupen els objectius descrits en la secció anterior. Aquest capítol, el primer, és únicament d'introducció.

El capítol 2 presenta l'estat de la qüestió dels sistemes de detecció i diagnòstic de fallades basats en enfocaments quantitius i qualitius per tractar sistemes industrials dinàmics complexos. Aquest estudi proporciona una visió de les diferents metodologies (des del diagnòstic pur fins a mètodes de generació de residus en el cas quantitatiu, i de sistemes experts basats en models de raonadors profunds en el cas qualitatiu) que s'utilitzen per dissenyar sistemes de supervisió de fallades i inclou una comparació dels avantatges i els desavantatges que suposen quan s'apliquen a sistemes dinàmics complexos. D'aquesta manera, es justifica la idoneïtat de l'ús de metodologies qualitatives per detectar i diagnosticar fallades.

En el capítol 3 es presenta la metodologia del raonament inductiu difús, que és la base de la recerca duta a terme en aquesta tesi. Com que la metodologia FIR està basada en el *general system problem solver* (GSPS) proposat per George Klir, primer presentem les línies principals del GSPS i després ens endinsem en el FIR. S'aporten nocions sobre l'origen i la implementació del FIR, es defineix el significat que té i se'n descriu detalladament la composició i el funcionament. Finalment, es proposa una nova fórmula de discretització de les dades i se'n demostra la utilitat amb una aplicació que fa referència a una xarxa d'aigües, que té com a objectiu distribuir l'aigua de manera eficient en una ciutat.

El capítol 4 tracta dues de les principals tasques dels sistemes de monitoratge de fallades (FMS): la detecció de fallades i el diagnòstic de fallades. Durant la detecció, l'FMS ha de reconèixer que el comportament del sistema és anormal i, per tant, que no està funcionant correctament. Durant el diagnòstic de la fallada, l'FMS ha de concloure quina mena de fallada ha tingut lloc. L'objectiu principal d'aquest capítol és presentar, en el context del sistema de monitoratge de fallades basat en el FIR (FIR-FDDS), una nova tècnica de detecció, anomenada *envolupant*, i una millora del mètode de diagnòstic

basat en la mesura d'acceptabilitat del model. Les dues contribucions permetran que el FIRFMS sigui més robust i fiable a l'hora de detectar les fallades i en el procés de diagnòstic. Per demostrar l'eficiència de la tècnica de l'envolupant i de la mesura d'acceptabilitat del model, el FIRFMS millorat s'aplica a tres sistemes d'àrees molt diferents. El primer correspon a un model d'un circuit elèctric utilitzat amb anterioritat amb aquesta finalitat en la literatura. El segon és un sistema biomèdic: el sistema nerviós central de control humà (SNC), que és el primer intent d'aplicar el FIRFMS per donar suport a la presa de decisions mèdiques. El tercer correspon a la demanda d'un sistema de distribució d'aigua. El circuit elèctric s'utilitza per demostrar que el nou FIRFMS és superior a l'anterior FIRFMS. El sistema biomèdic i el de demanda d'aigua es presenten per mostrar el bon funcionament del nou FIRFMS.

En el capítol 5 es presenta una nova plataforma de la metodologia del raonament inductiu difús, desenvolupada en l'entorn de programació MATLAB. La nova eina visual, anomenada *Visual-FIR*, permet identificar models i predir comportaments futurs de sistemes dinàmics en un entorn molt senzill d'utilitzar i molt eficient. Les implementacions anteriors de FIR implicaven desenvolupar, necessàriament, un nou codi per a cada nova aplicació que s'havia d'estudiar. El *Visual-FIR* resol aquesta limitació i ofereix una aplicació d'alt rendiment. D'altra banda, la plataforma *Visual-FIR* presenta una nova visió de la metodologia basada en blocs de processos i hi afegeix noves característiques, de manera que augmenta les capacitats generals de la metodologia FIR. Finalment, s'aborda parcialment l'aplicació de referència DAMADICS utilitzant l'enfocament del *Visual-FIR*.

En el capítol 6 es presenta la plataforma *VisualBlock-FIR*, en què s'emmarca el sistema de detecció i diagnòstic de fallades per a plantes no lineals basat en la lògica difusa, presentat en el capítol 4 d'aquesta tesi. El *VisualBlock-FIR* s'executa en l'entorn *Simulink* i defineix mòduls gràfics interactius que permeten que l'usuari construeixi models del sistema amb i sense fallades, així com que empri els processos de detecció i diagnòstic de l'FDDES. Aquesta nova eina, basada en blocs (mòduls), és molt pràctica i útil, ja que permet construir el sistema de detecció i diagnòstic de fallades de la planta en estudi com si es tractés del muntatge d'un *lego* en què cada peça té una funció específica i, per tant, només cal anar ajuntant les peces de manera adient. En la darrera part del capítol es presenta aquest procés per a un sistema d'una pila de combustible. Aquesta aplicació s'aborda més detalladament en el capítol 7 d'aquesta tesi.

En el capítol 7 es presenta l'FDDES per a aplicacions de detecció i diagnòstic de fallades en sistemes complexos. Es presenten dues aplicacions per demostrar que aquesta nova metodologia és molt útil per detectar i diagnosticar les fallades en sistemes complexos. La primera correspon al problema de referència de la vàlvula automàtica de *Damadics* en què es proposen quatre fallades de petita i mitjana magnitud que es detecten i s'aïllen/s'identifiquen d'una manera molt ràpida i eficient. En la segona aplicació es posa a prova el *VisualBlock-FIR* sobre una pila de combustible simulada en què s'apliquen cinc fallades diferents que es detecten i s'identifiquen. Per comprovar la robustesa de la nova eina s'afegeix soroll blanc a les sortides. La pila de combustible és un sistema molt més gran, format per quatre variables de

sortida, i serveix per comprovar que el *VisualBlock-FIR* pot tractar grans sistemes d'una manera eficient. En les dues aplicacions es compara, amb èxit, el rendiment davant d'altres metodologies similars.

Finalment, el capítol 8 se centra a presentar les conclusions principals que s'obtenen d'aquest treball i a proposar les línies de continuació i els camps d'aplicació.

Aquesta tesi finalitza amb una extensa bibliografia de les referències utilitzades en aquest esforç de recerca. Les publicacions que es deriven d'aquesta tesi es concentren en una secció separada al començament de la bibliografia.

2 Detecció i diagnòstic de fallades: estat de la qüestió

Resum: En aquest capítol es presenta la problemàtica associada a la tasca de detecció i diagnòstic de fallades i a la seva implementació utilitzant models. El primer apartat introdueix a les tasques de detecció i diagnòstic de fallades (FDDS) en els sistemes industrials. En el segon apartat es presenten els principis generals de l'FDDS i la seva terminologia, es descriuen els diferents tipus de models dels sistemes, es dóna una panoràmica de les tècniques de supervisió i, finalment, es presenta la generació de símptomes. El tercer apartat introdueix el lector als diferents mètodes de detecció i diagnòstic de fallades existents, donant una panoràmica general de les tècniques utilitzades actualment. Finalment, el quart apartat se centra en el rendiment i la robustesa dels sistemes de detecció i diagnòstic de fallades.

2.1 Introducció

Des de principis de 1970, a causa de la creixent demanda de seguretat, fiabilitat i disponibilitat dels sistemes automatitzats, estem assistint a un creixement molt important de la recerca, tant en aspectes teòrics com pràctics, referent al disseny de sistemes de detecció i diagnòstic de fallades (FDDS, de l'anglès *fault detection and diagnosis systems*) i de sistemes de control amb tolerància a fallades. Les funcions bàsiques d'un FDDS han estat des d'un principi les de generar alarmes quan s'esdevé una situació anormal en el sistema i identificar-ne el component defectuós. Actualment es requereix que els FDDS a més a més de detectar la fallada siguin capaços d'aïllar el component avariats, identificar-ne el grau de deteriorament, és a dir, diagnosticar l'origen del problema i, fins i tot, en funció del diagnòstic, realitzar les accions necessàries per portar el sistema a un estat segur.

Es pot considerar que una fallada és qualsevol canvi en el comportament d'algun dels components del sistema (desviació no permesa d'alguna de les propietats o paràmetres característics), de forma que aquest ja no pot complir la funció per a la qual ha estat dissenyat [17].

Durant les darreres tres dècades, la investigació relacionada amb la detecció i el diagnòstic de fallades de processos industrials ha adquirit més consideració i rellevància. Aquesta ha estat estimulada principalment per tres factors:

a) L'augment de la complexitat dels sistemes automatitzats, juntament amb l'exigència que aquests sistemes més complexos mantinguin les garanties de fiabilitat, seguretat i disponibilitat. Concretament es volen sistemes d'FDD:

- *Fiables*: La fiabilitat es relaciona amb el comportament del sistema en el cas que succeeixi una fallada interna. Sempre que es produeix una fallada irrecuperable en el sistema, l'FDDS n'ha de realitzar un tancament correcte per evitar que pateixi danys permanents i garantir la seguretat tant dels usuaris com d'altres éssers humans de l'entorn.

- *Segurs*: La seguretat es relaciona amb el comportament del sistema en el cas d'una fallada externa, és a dir, si l'operador del sistema interpreta malament una situació i emet una ordre potencialment nociva per al sistema. En aquest cas, l'FDDS ha d'evitar que el sistema reaccionï a aquesta ordre de manera perillosa.
 - *Alta disponibilitat*: La disponibilitat es refereix al percentatge de temps que el sistema està fora de servei per manteniment o reparació, i està molt relacionada amb el temps mitjà entre fallades.
- b) Les tècniques de control avançat, com ara el control òptim, el control robust, etc., fan que la tasca de diagnòstic de fallades sigui cada vegada més complexa. Aquest fenomen és degut al fet que, a més a més de garantir l'estabilitat i la precisió del sistema controlat, es dissenyen controladors capaços de dessensibilitzar el comportament del sistema respecte a factors externs (supressió de les perturbacions) i als incontrolables factors interns (variabilitat dels paràmetres i l'envelliment), cosa que provoca que el controlador no pugui distingir entre aquests factors i les anomalies menors. El sistema de control tindrà tendència a reduir els efectes causats per petites fallades, amb la qual cosa contrarestarà els esforços de l'FDDS, que té com a objectiu detectar-les. Com més exigent sigui el controlador, més difícil serà la detecció primerenca de fallades, llevat que siguin de tipus catastròfic.
- c) Les tècniques derivades de la intel·ligència artificial, com ara els sistemes basats en el coneixement, els sistemes connexionistes o els raonadors qualitius basats en models, han proporcionat als enginyers de sistemes noves eines que permeten incrementar la sensibilitat dels FDDS i la seva potència de resolució, cosa que ajuda a millorar el diagnòstic de fallades de les plantes complexes.

Isermann (1984)	Various modeling and estimation methods for FDDS
Gertler (1988a)	Survey of model-based FDDS in complex plants
Frank (1990)	Survey of FDDS methods based on analytical and knowledge-based redundancy for dynamic systems
Isermann and Ballé (1997)	Trends in applications for model-based FDDS
Frank (1997)	New developments using artificial intelligence in fault diagnosis
Venkatasubramanian et al. (2003a, 2003b, 2003c)	A review of process fault detection and diagnosis
Iserman (2005)	Model-based fault-detection and diagnosis – status and applications

Taula 2-1 Conjunt d'articles que fan una revisió dels mètodes d'FDDS

La recerca en sistemes FDDS va sorgir per cobrir les necessitats plantejades principalment en els camps de l'aeronàutica, l'exploració de l'espai, l'energia nuclear, les indústries de transformació i fabricació, i la defensa nacional. No és l'objectiu d'aquest capítol presentar un estat de la qüestió complet de la recerca desenvolupada en aquesta àrea. Hi ha força llibres que abasten els treballs desenvolupats en les darreres dècades en FDDS: un dels primers va ser escrit per [143], altres resums importants es recullen a la taula

2-1. D'altra banda, l'evolució dels mètodes de detecció de fallades es recull en els llibres de [33, 64, 69, 70, 86, 97, 113, 116, 128]. L'objectiu d'aquest capítol és contextualitzar la metodologia desenvolupada en aquesta tesi.

2.2 Conceptes bàsics

2.2.1 Terminologia usada en la detecció i el diagnòstic de fallades

A mesura que ens introduïm en el camp de la detecció i el diagnòstic de fallades trobem que la terminologia sovint és una mica confusa. Per exemple, quina és la diferència entre monitoratge i supervisió? O quina és la diferència entre fallada, mal funcionament i error? A [74] es recullen una sèrie de definicions, algunes provinents del diccionari RAM (*Reliability, Availability and Maintainability*) i altres dels estàndards relacionats amb l'automàtica. A continuació s'enumeren les definicions que considerem necessàries per al seguiment de la tesi, suggerides pel Comitè d'Automàtica (IFAC SAFEPROCESS):

- *Fallada*: desviació no permesa de, com a mínim, una propietat característica o un paràmetre de les condicions acceptables / usuals / normals del sistema.
- *Fora de servei*: interrupció permanent de l'habilitat d'un sistema per realitzar les funcions específiques que se li demanen.
- *Funcionament defectuós*: irregularitat intermitent en l'habilitat d'un sistema per dur a terme les funcions específiques que se li requereixen.
- *Error*: desviació entre el valor mesurat o calculat i el que s'espera o que és teòricament correcte en una variable de sortida.
- *Pertorbació*: entrada del sistema no mesurable ni controlable (*disturbance*). També s'entén com a pertorbació l'efecte que produeix aquesta entrada en el sistema (*perturbation*).
- *Residu*: indicador de fallada, basat en una desviació, entre les mesures i els còmputos obtinguts dels models.
- *Síntoma*: canvi d'una quantitat respecte a un comportament normal.
- *Detecció de la fallada*: determinació de la presència de fallades en un sistema i del moment en què s'esdevenen.
- *Aïllament de la fallada*: determinació del tipus, la localització i el moment de temps en què s'ha produït la fallada. Es realitza després de la detecció.
- *Identificació de la fallada*: després de l'aïllament de la fallada, determinació de la grandària i la variació en el temps del comportament d'una fallada. S'especifica clarament si és una fallada

coneguda i quina és. Si és desconeguda se sotmet a anàlisi per determinar si és o no una fallada. Si és una fallada nova s'identifica i es classifica.

- *Diagnòstic de la fallada*: després de la detecció de la fallada, se'n determina la classe, la mida, la localització i el temps de detecció. Inclou l'aïllament de la fallada i la identificació. És l'etapa en què es pren una decisió pel que fa a la veracitat, gradualitat i gravetat de la fallada.
- *Monitoratge*: una tasca en temps real que consisteix a determinar les condicions de funcionament d'un sistema físic, emmagatzemant informació i reconeixent i indicant anomalies en el comportament.
- *Supervisió*: un cop monitorat un sistema físic, es duen a terme les accions apropiades per mantenir-ne el funcionament en el cas de fallades.
- *Protecció*: mitjans pels quals, si és possible, un comportament potencialment perillós del sistema se suprimeix o se n'eviten les conseqüències.

2.2.2 Tipus de models

Un model és una representació d'un sistema real que permet preveure, estudiar i analitzar propietats que tenen interès per a un cert propòsit. Segons aquest propòsit es podran realitzar determinades aproximacions o simplificacions, i seleccionar un tipus o altre de model. Cal tenir en compte que un model perfecte d'un sistema és molt difícil d'obtenir i que, per tant, qualsevol model representa una imatge parcial del comportament del sistema.

2.2.2.1 Classes de model

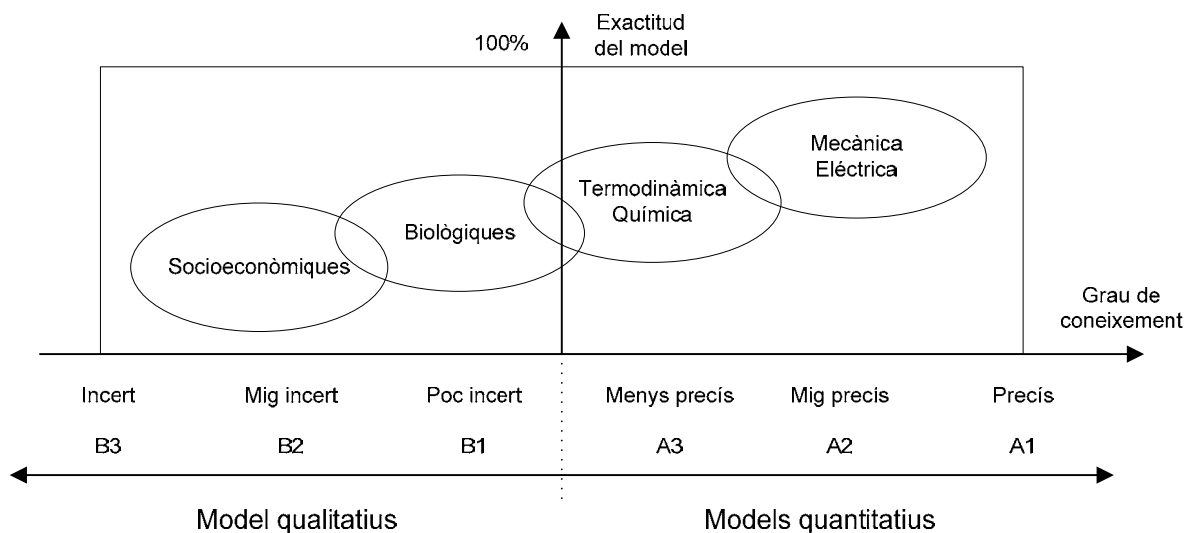


Figura 2-1 Exactitud assolida pels models segons el grau de coneixement que es té de les variables del sistema [71]

En els processos industrials les variables o paràmetres dels models que ens mostren el comportament del sistema poden ser coneguts, coneguts amb un cert grau de precisió o incertesa, o fins i tot desconeguts.

Davant d'aquest fet, podem classificar el tipus de model en qualitatiu o quantitatiu en funció del grau de coneixement que es tingui de les variables del sistema. A mesura que el grau de precisió de les variables creix, el grau d'exactitud en el model també creix, tal com s'observa en la classificació que es mostra en la figura 2-1, proposada per R. Isermann [71].

2.2.2.2 *Models de coneixement profund o deep knowledge*

Aquests models proporcionen informació de gran riquesa i qualitat, però són difícils i costosos d'obtenir. Els més atractius, a causa del seu caràcter sintètic i capacitat de predicció, són els models funcionals, per als quals es requereix una descripció matemàtica del comportament estàtic i dinàmic del sistema. Aquest model tenen molt d'interès tant per al disseny de sistemes de control com per al disseny de sistemes de detecció i diagnòstic de fallades. En funció de la precisió i en relació amb els models de la figura 2-1 es poden distingir tres tipus de models:

- A1. Equacions amb paràmetres coneguts.
- A2. Equacions amb paràmetres parcialment coneguts.
- A3. Equacions amb paràmetres desconeguts.

A la pràctica, el cas A2 apareix més freqüentment que els casos A1 i A3. Si l'estructura del model és coneguda, els paràmetres desconeguts es poden determinar experimentalment mitjançant tècniques d'estimació de paràmetres. El camp dels models quantitatius ha arribat a un estat prou madur i es troben en el mercat eines molt atractives de programari dedicades a aquest propòsit. Quan no es possible representar el comportament d'un sistema mitjançant lleis físiques en forma d'equacions, com seria el cas de processos en què el comportament físic no és del tot conegut, com pot ser l'assecatge, alguns tipus de reaccions químiques o processos biològics, la informació qualitativa dona lloc a relacions o models causals. Una descripció força detallada de com aquests tipus de models s'utilitzen per al diagnòstic de fallades es presenta a [139] i [140].

2.2.2.3 *Models de coneixement superficial o shallow surface*

Són els models preferits per a alguns experts en diagnòstic (més que en detecció) gràcies a la seva simplicitat. Tanmateix, aquests no descriuen el sistema que es diagnostica d'una forma rica, sols permeten establir relacions del tipus causa-efecte (causals), de manera que la qualitat del coneixement que subministren no és gaire elevada, és de naturalesa empírica, compilada o heurística. D'aquesta classe de models, n'assenyalem els següents:

- Model relacional *failure mode effect and criticaly analysis*, FMECA [25]. A cada anomalia s'associa un conjunt de manifestacions o símptomes, és a dir, s'estableix la relació causa-efecte entre les anomalies i els seus símptomes. En els FMECA sols es tenen en compte les fallades previstes *a priori* (la qual cosa és un desavantatge); a la pràctica aquest fet comporta que per poder cobrir un gran nombre de problemes potencials cal escollir un conjunt de fallades suficientment

ampli. Són models de naturalesa binària però es poden representar en lògica difusa, de manera que són aptes per treballar amb incerteses.

- Arbres de fallades o *fault tree analysis* (FTA) [11]. És un mètode probabilístic, quantitatiu i deductiu. Va ser introduït a la dècada de 1960. Per al tractament del problema s'utilitza un model gràfic que mostra les diferents combinacions de les fallades en els components que formen el sistema. La tècnica consisteix en un procés deductiu basat en les lleis de l'àlgebra de Boole, que permet determinar successos complexos estudiats en funció de les fallades bàsiques dels elements que hi intervenen.

2.2.3 Supervisió

En els sistemes automatitzats, els programes de supervisió serveixen per mostrar l'estat del sistema, indicar quan s'assoleixen estats que no interessin o que no són permesos, i prendre les accions apropiades per mantenir-ne el funcionament i evitar danys o accidents. En la supervisió podem distingir les funcions següents [71]:

- Monitoratge*: les variables mesurables són validades respecte a uns valors límit o, en alguns casos, emprant la redundància d'equips (bàsicament sensors) i, si cal, es generen alarmes.
- Protecció automàtica*: en els processos catalogats com a perillosos es requereix que automàticament es realitzin les operacions necessàries per contrarestar els efectes d'una fallada i evitar els danys que aquesta pugui ocasionar.
- Supervisió amb diagnòstic de fallades*: basant-se en les variables mesurades, s'extreuen característiques, es generen símptomes mitjançant tècniques de detecció de fallades a partir dels quals es porta a terme la tasca de diagnòstic i es prenen les decisions oportunes per corregir les fallades o contrarestar-ne els seus efectes nocius (control tolerant).

Els mètodes de supervisió clàssics inclouen sols les funcions definides en (a) i (b) i s'utilitzen molt per a la supervisió de processos industrials [116]. Generalment, per utilitzar-los cal configurar els valors del llindar que limiten les condicions d'operació normal de les variables del sistema. Si se sobrepassen aquests llindars s'activen alarmes, que senyalen que hi ha comportaments anormals en el sistema. Per configurar els valors del llindar cal establir un compromís entre la dimensió de les desviacions anormals i les falses alarmes. En els components en els quals una fallada pot comportar una catàstrofe es dupliquen o, fins i tot, es tripliquen els components bàsics, com ara els sensors, fins al mateix ordinador central de control. La duplicació permet establir una alarma cada vegada que les sortides de dos dispositius que estan posats en paral·lel no concorden; la triplicació permet continuar de manera segura després que s'hagi produït l'avaría d'un component mitjançant l'ús d'un esquema de votació. Si les sortides de dos dels tres dispositius estan d'acord, se suposa que tenen raó, mentre que el tercer dispositiu s'assumeix que està defectuós i a partir d'aquest moment s'ignora. Els operadors humans són alertats del fet i se'ls demana de

substituir el component defectuós. L'avantatge dels mètodes de supervisió clàssics és la simplicitat i fiabilitat. La redundància és essencial en el control de les aeronaus, les naus espacials, les plantes d'energia elèctrica, els reactors nuclears i, en general, tots els processos crítics quant a seguretat.

Aquests mètodes, però, presenten una sèrie de problemes que cal destacar. En general, l'ús de líndars és satisfactori quan el procés està en estat estacionari; no succeeix el mateix quan el procés està en un estat transitori, per exemple en etapes d'arrencada, aturada o canvis de referència, estat en què les variables mesurades solen estar en evolució continuada. D'altra banda, en el cas de sistemes en llaç tancat, els canvis en el procés poden ser contrarestats per les accions de control i, per tant, difícilment es podran detectar observant-ne els senyals de sortida. Aquests mètodes no són sensibles quan s'esdevenen fallades que imperceptiblement s'incrementen al llarg d'un període de temps, i tampoc disposen de les eines suficients per aprofundir en l'anàlisi d'una fallada; per tant, realitzar un diagnòstic de la fallada normalment no és possible.

Els mètodes avançats de supervisió i diagnòstic de fallades (c), utilitzen les variables mesurades i característiques calculades (residus, variàncies, mitjanes, història de la decisió, freqüències d'aparició, etc.) per generar símptomes, de forma que quan es detecta un canvi en alguna d'aquestes característiques es du a terme el diagnòstic i, en funció d'aquest, es poden generar les accions correctores adequades. Els requeriments que els mètodes avançats de supervisió i diagnòstic han de complir són:

- detecció precoç de fallades petites amb un comportament temporal abrupte o incipient,
- diagnòstic de fallada en actuadors, components del procés o sensors,
- detecció de fallades en llaç tancat i
- supervisió de processos en estat transitori.

L'objectiu de la detecció precoç i el diagnòstic és tenir temps suficient per contrarestar les conseqüències que pugui produir una fallada. La detecció precoç es pot aconseguir utilitzant models matemàtics. Per al diagnòstic de fallades es pot utilitzar el coneixement extret de les relacions de causa-efecte. Les conseqüències d'una fallada es poden pal·liar mitjançant operacions com ara la reconfiguració, el manteniment o la reparació.

2.2.4 Generació de símptomes

A la figura 2-2 es mostra un esquema global de detecció i diagnòstic de fallades basat en el coneixement. Segons Isermann [73], les tasques principals poden subdividir-se en la generació analítica de símptomes, la generació heurística de símptomes i el diagnòstic de fallades. La generació de símptomes inclou la detecció de fallades.

2.2.4.1 Generació analítica de símptomes

En la generació analítica de símptomes, el coneixement analític del procés és utilitzat per obtenir informació quantificable. Per aconseguir-ho, en primer lloc cal processar les variables mesurades. Per exemple, es poden obtenir indicadors característics de les variables mesurades mitjançant:

- la *determinació dels valors de llindar* de les variables mesurades, en els quals els indicadors característics són les violacions dels llindars prefixats dels senyals;
- l'*anàlisi dels senyals* mesurats, mitjançant models de senyals com ara les funcions de correlació, espectres de freqüència o models *auto regressive moving average* (ARMA), en els quals els indicadors característics poden ser variàncies, amplituds, freqüències o paràmetres del model, i
- l'*anàlisi de procés*, mitjançant els models matemàtics juntament amb l'estimació de paràmetres, mètodes d'estimació d'estats o equacions de paritat, en els quals els indicadors característics poden ser els paràmetres, les variables d'estat o els residus.

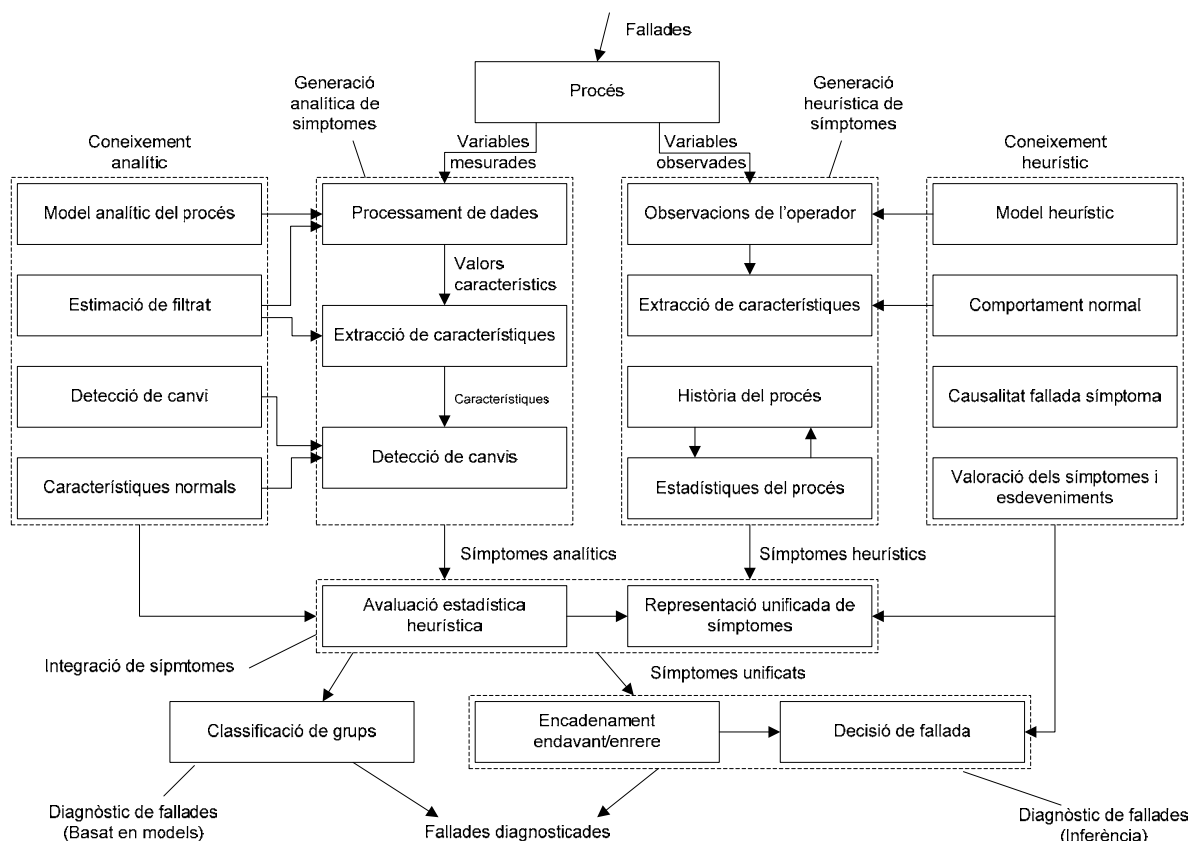


Figura 2-2 Esquema de la detecció i el diagnòstic de fallades basat en el coneixement (adaptada de [73])

En alguns casos, d'aquests indicadors característics es poden deduir altres d'especials, com ara coeficients corresponents a una variable física, residus transformats o filtres especials. Els mètodes de detecció de canvis i classificació permeten avaluar el conjunt de característiques i comparar-les amb les

característiques del procés sense fallades. Els canvis resultants (discrepàncies) d'aquesta comparació se'ls considera símptomes analítics.

2.2.4.2 *Generació heurística de símptomes*

Els símptomes heurístics s'obtenen a partir de la informació qualitativa aportada per un operador humà. A través de l'observació i la inspecció humanes, es poden obtenir valors característics heurístics, per exemple en forma de sorolls especials, colors, olors, vibracions, increment de consums, entre altres.

Les dades històriques del procés recollides quan es fa manteniment, reparacions, fallades anteriors, proves de la vida útil i proves de càrrega constitueixen una font completa d'informació heurística. També es poden utilitzar dades estadístiques adquirides de l'experiència amb el mateix procés o amb un altre de similar. Amb aquesta informació es poden generar símptomes heurístics, els quals poden ser representats per variables lingüístiques com ara “petit”, “mitjà” i “gran” o com nombres incerts que estiguin al voltant d'un cert valor.

Ambdós, els símptomes analítics i heurístics, poden representar-se de forma difusa mitjançant funcions de pertinença amb un rang de $0 < \mu(S_i) < 1$, on μ és la funció de pertinença dels símptomes unificats S_i .

2.2.4.3 *Diagnòstic de fallades*

La tasca de diagnòstic de fallades consisteix a determinar el tipus, la gravetat i la localització de la fallada més probable, així com indicar-ne el temps de detecció.

Els procediments de diagnòstic de fallades utilitzen els símptomes analítics i heurístics; per tant, caldrà presentar-los d'una forma unificada. Com a resultat de fer una avaluació estadística al llarg del temps, podem calcular, per exemple, valors de confiança, funcions de pertinença dels conjunts difusos o funcions de densitat de probabilitat. Es poden aplicar mètodes de classificació o, si es prefereix, un procediment d'aprenentatge basat en patrons, per determinar les fallades a partir dels símptomes dels patrons o grups. Si a part de les relacions símptomes-fallades es disposa de més informació, per exemple, en forma de lògica dels arbres de símptomes de fallades o es coneixen regles del tipus si - llavors, es poden aplicar mètodes de raonament amb encadenament cap endavant i cap enrere.

2.3 Mètodes de detecció i diagnòstic de fallades

2.3.1 Panorama general

La detecció és el primer pas d'un sistema de detecció i diagnòstic de fallades (FDDS). Per determinar per què alguna cosa ha deixat de funcionar o per què no funciona correctament, és útil, en primer lloc, saber com funciona sense fallades. Per aquest motiu, la formulació del problema de detecció s'entén molt millor quan es formula com la interacció entre l'observació i la predicció [36]. L'observació permet observar el comportament del sistema, mentre que la predicció permet deduir el que se suposa que ha de fer. Una

comparació contínua entre l'observació i la predicció garanteix que qualsevol diferència o discrepància pugui ser detectada ràpidament.

La tasca completa d'un FDDS es pot descriure per tant en tres passos, els quals són comuns a totes les aproximacions. La figura 2-3 mostra les tres etapes: observació, comparació i diagnòstic. El funcionament d'una planta s'observa mitjançant la instrumentació disponible en cada aplicació.




Figura 2-3 Esquema general de detecció i diagnòstic

L'objectiu que persegueixen tots els mètodes de detecció i diagnòstic de fallades és caracteritzar el comportament d'un sistema en el seu mode normal de funcionament, ja sigui utilitzant eines estadístiques, models qualitius o quantitius, o models relacionals (com ara xarxes neuronals), i analitzar si el comportament actual del procés es correspon amb el seu comportament normal. Si no s'hi correspon es diu que el sistema està en fallada. A més, les desviacions observades respecte al comportament normal, és a dir els símptomes, han de permetre aïllar el component del procés que està avariats.

El diagnòstic de fallades pot dividir-se en tres etapes segons la profunditat:

- Detecció de la fallada: durant aquesta etapa, el sistema de monitoratge de fallada detecta que el comportament de la planta és anormal i genera símptomes.
- Aïllament de la fallada: localització del component en què s'ha produït la fallada.
- Identificació i estimació de la dimensió de la fallada: identificació del mode de fallada i l'estimació de la magnitud.

Generalment a les dues últimes etapes se'ls anomena *diagnòstic*.

S'utilitzen diversos mètodes per detectar i diagnosticar les fallades. Una forma de classificar-los és la que es mostra en la figura 2-4. En aquest esquema es presenten tres categories principals: els mètodes quantitius basats en models, els mètodes qualitius basats en models i els mètodes basats en dades. Cal dir, però, que les tècniques que actualment s'utilitzen en el disseny de sistemes d'FDDS són el resultat de

combinar diverses d'aquestes tècniques. El mètode FIR (de l'anglès *fuzzy inductive reasoning*, raonament inductiu difús) desenvolupat en aquesta tesi n'és un exemple.

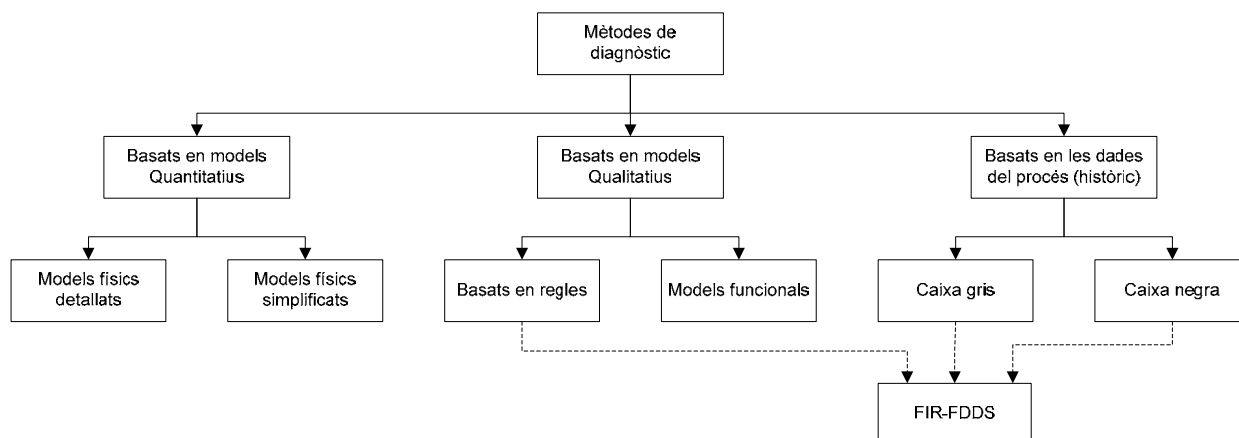


Figura 2-4 Esquema de classificació dels mètodes FDDS

A continuació es fa una breu descripció de cada una d'aquestes tècniques amb l'objectiu d'identificar-ne les limitacions i avaluar-ne els punts forts i febles.

2.3.2 Mètodes basats en models quantitativus

A mesura que la complexitat dels sistemes de control i l'ús dels ordinadors ha anat augmentant, les tècniques d'FDDS basades en models quantitativus s'han incrementat. Aquestes tècniques, conegudes amb el nom de *redundància analítica*, utilitzen les mesures proporcionades pels sensors per predir el comportament del sistema emprant models matemàtics deduïts explícitament a partir dels models funcionals de cada un dels components del procés [64].

En funció de la qualitat del model disponible es podrà disposar de models més o menys precisos (figura 2-1). L'estructura habitual d'aquest tipus de tècniques es mostra en la figura 2-5.

Aquestes tècniques són conegudes amb el nom de *fault detection and isolation*, FDI, i s'inicien en l'àmbit de l'enginyeria de sistemes, en el qual les variables del sistema es relacionen mitjançant models deduïts del comportament físic dels components i, en general, cada una d'aquestes variables actua com a entrada (causa) i/o com a sortida (efecte). L'etapa de detecció es realitza avaluant els residus obtinguts com a resultat de comparar les sortides predites o estimades amb models quantitativus que representen el funcionament normal, a partir d'un conjunt de variables d'entrada. L'avaluació serà més o menys complicada en funció del grau de precisió del model. El cas més habitual és disposar de models amb paràmetres parcialment desconeguts i models funcionals simplificats. En aquestes circumstàncies els models es poden descriure en un context determinista com ara equacions de paritatat [65], observadors [10] i models basats en l'estimació de paràmetres [75], o en el context estocàstic, com ara els filtres de Kalman [93]. Els models detallats poden simular tant estats de funcionament del sistema normals com estats en fallada.

L'etapa de diagnòstic es du a terme avaluant com afecta cada una de les fallades els residus. La relació residu-fallades s'acostuma a donar en forma de taula d'incidència, a partir de la qual, mitjançant raonaments lògics, s'obté el diagnòstic [63]. La dimensió de la fallada es pot estimar emprant tècniques d'anàlisi de sensibilitat [130].

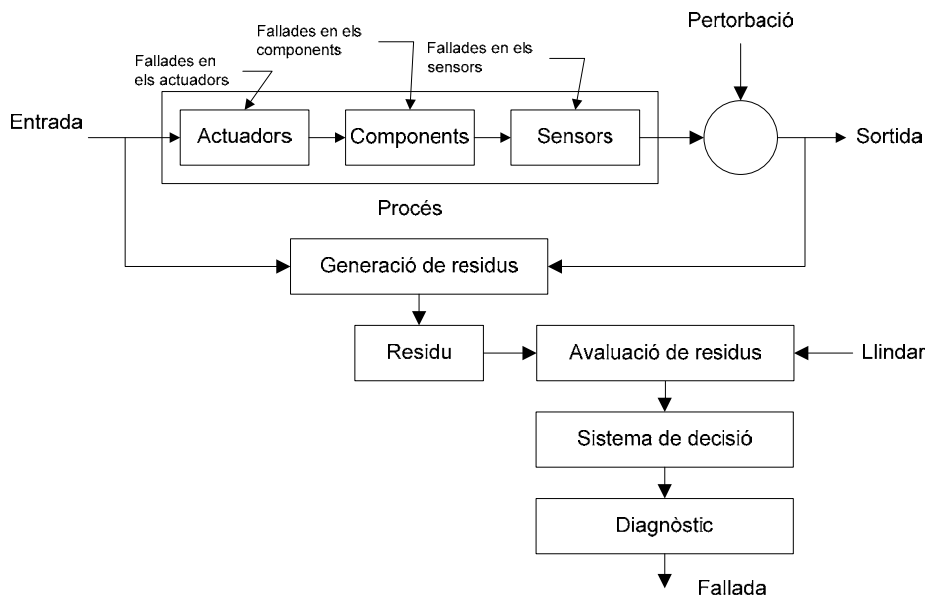


Figura 2-5 Esquema d'un sistema d'FDI basat en models quantitius

Els punts forts dels FDDS basats en models quantitius són:

- Els models es basen en la física o principis de l'enginyeria; per tant, les prediccions de la sortida són més precises quan estan ben formulats.
- Els models funcionals poden modelitzar el sistema en funcionament normal i en fallada, de manera que una fallada es pot distingir fàcilment d'un funcionament normal.
- Els transitoris en un sistema dinàmic es poden modelitzar detalladament amb models funcionals.

Els punts febles dels FDDS basats en models quantitius són:

- El models funcionals poden ser complexos i poden tenir un cost de còmput molt alt.
- L'esforç que cal per desenvolupar un model és significatiu.
- Aquests models generalment requereixen moltes variables per descriure el sistema i sovint algunes d'aquestes variables no es poden mesurar fàcilment.
- Quan es treballa amb models aproximats cal prendre desicions sobre com s'han d'avaluar els residus per evitar diagnòstics incorrectes.

2.3.3 Mètodes basats en models qualitius

La detecció i el diagnòstic de fallades basats en models qualitius representen una altra àmplia categoria per el disseny de sistemes d'FDDS. Hi ha dues formes de construir models qualitius, utilitzant bases de coneixement o a partir dels models funcionals. Les bases de coneixement es poden obtenir analitzant els històrics de dades i/o de forma heurística, a partir de l'experiència dels operadors.

Les tècniques basades en models qualitius i destinades als FDDS poden agrupar-se en tècniques basades en regles i tècniques basades en relacions físiques.

2.3.3.1 Tècniques basades en regles

Les tècniques basades en regles fan servir el coneixement per derivar un conjunt de regles 'si-llavors-sinó' i mitjançant mecanismes d'inferència cerquen a través del conjunt de regles per adduir-ne conclusions.

Dins d'aquesta classificació destaquem els sistemes experts (SE). Aquests són una branca de la intel·ligència artificial, desenvolupada a la dècada de 1960. Un SE es pot definir com un sistema informàtic que representa i raona amb el coneixement disponible d'un tema concret amb l'objectiu de resoldre un problema determinat o donar un consell per resoldre'l. Els SE són sistemes autònoms sustentats per les bases de coneixement i estan formats per un motor d'inferència i una base de coneixement, la qual, al mateix temps, es compon d'una base de regles i una base de fets.

Els punts forts dels FDDS basats en sistemes experts són [139]:

- Són fàcils de desenvolupar.
- El raonament és transparent.
- És possible raonar fins i tot en condicions d'incertesa.
- Tenen la capacitat de donar explicacions de les conclusions assolides.

Els punts febles dels FDDS basats en sistemes experts són:

- Són molt específics d'un procés.
- Poden fallar ràpidament si es fa anar més enllà dels límits dels coneixements incorporats.
- Són difícils d'actualitzar o canviar.

A l'article [94] hi ha un recull de les metodologies basades en SE i la seva aplicació al diagnòstic de fallades desenvolupades durant el període de 1995 a 2004.

2.3.3.2 Tècniques basades en models funcionals

Els models qualitius permeten arribar a conclusions sobre l'estat d'un sistema amb un coneixement incomplet o incert dels processos físics [39]. S'utilitzen dos enfocaments bàsics. El primer tracta d'obtenir, a partir dels models funcionals, un conjunt d'equacions qualitatives basades en equacions

diferencials ordinàries que regeixen el comportament del procés. Aquestes equacions, amb informació imprecisa (per exemple, l'ordre de magnitud de les entrades) es poden resoldre mitjançant l'àlgebra qualitativa i poden obtenir el comportament qualitatiu del sistema [139]. Des d'un punt de vista pràctic, l'ús d'eines de simulació qualitativa [80], permet generar símptomes. El segon enfocament implica extreure el comportament qualitatiu de les equacions diferencials ordinàries que regeixen el comportament físic del sistema i expressar-lo amb models de grafs causals, equacions algebraiques i restriccions.

El graf causal es deriva dels models funcionals del procés estudiat, a partir dels quals es pot establir una relació de causa-efecte, i és una descripció abstracta de la influència que té una variable sobre les altres [100]. El comportament d'un dispositiu es pot descriure parcialment mitjançant un graf causal, el qual representa directament la relació funcional entre variables o conceptes més complexos (símptomes o fallades). Les variables es relacionen mitjançant arcs: $x \rightarrow i$, que significa que la variable i en l'instant t depèn de la variable x , tenint en compte que x és la causa i i és l'efecte. En un graf, l'anàlisi cap endavant i cap enrere permet determinar les relacions causa-efecte.

Des del punt de vista pràctic, la construcció d'un graf causal no és necessàriament una tasca fàcil, es requereix una anàlisi física detallada del sistema, però aquest fet és la font de la seva capacitat explicativa. Els diagnosticadors de fallades provinents de l'àrea de recerca en diagnòstic basat en la consistència (DBS), utilitzen models qualitius. A partir d'aquests models es poden emprar tècniques com ara el motor de diagnòstic general (GDE, de l'anglès *general diagnostic engine*), proposat per Kleer i Willians [38], que permet d'una forma iterativa arribar a un diagnòstic amb detecció de discrepàncies entre les observacions i prediccions, generació d'hipòtesis de diagnòstic i refinament del conjunt d'hipòtesis mitjançant la selecció de noves mesures.

Els punts forts dels FDDS basats en models funcionals qualitius són:

- Són molt adequats per a entorns rics de dades i per a processos no crítics.
- Si es disposa de models funcionals, són fàcils de desenvolupar i aplicar.
- El seu raonament és transparent i disposen de la capacitat de raonar, fins i tot en condicions d'incertesa.
- Posseeixen la capacitat de proporcionar explicacions per al diagnòstic, ja que el mètode es basa en relacions de causa-efecte.
- Alguns mètodes ofereixen la possibilitat de realitzar FDDS sense un coneixement precís del sistema ni valors numèrics exactes d'entrades i paràmetres.

Els punts febles dels FDDS basats en models funcionals qualitius són:

- Els mètodes són específics d'un sistema o un procés.

- Com a resultat del diagnòstic s'obté una relació de possibles causes, el nombre de les quals creix amb la incertesa del model.
- Cal un model funcional complet.

2.3.4 Mètodes basats en dades del procés

Aquestes tècniques són conegudes amb el nom de *mineria de dades* (DM, de l'anglès *data mining*) i consisteixen a extreure la informació que resideix de forma implícita en les dades obtingudes del procés que s'estudia. Aquesta informació es pot utilitzar per construir models matemàtics. Es poden diferenciar dos tipus de models matemàtics, els anomenats *caixa negra* i *caixa gris*. Ambdós tenen com a base les dades observades, però la diferència és si s'utilitza la informació física o el coneixement dels experts a l'hora de construir aquests models. Estrictament parlant, un model de tipus caixa negra es dissenya a partir de les dades observades sense tenir en compte consideracions físiques o verbals¹, cosa que significa que els paràmetres del model perden el significat físic. Quan es combinen les aproximacions caixa negra amb models físics o verbals de tal manera que aquests coneixements del sistema es tenen en compte a l'hora de definir l'estructura del model, s'obtenen les anomenades *aproximacions de tipus caixa gris*. Els models de caixa gris solen utilitzar regressions lineals o múltiples per estimar els paràmetres del model a partir de les entrades i sortides mesurades, de forma que aquests paràmetres preserven el significat físic dels termes que apareixen en els models. A [57] hi ha una bona descripció d'aquestes caixes.

2.3.4.1 Caixa negra

En general les tècniques de FDDS basades en models de tipus caixa negra estan molt relacionades amb les tècniques de reconeixement de patrons, en els quals es busca categoritzar les dades d'entrada i sortida com a classes normals o defectuoses. En l'àmbit de la mineria de dades destaquem com a tècniques estadístiques més utilitzades en aplicacions de diagnòstic l'anàlisi de components principals [112], l'anàlisi de discriminació de Fisher [68], els mínims quadrats parcials [62], la clusterització de dades [111] i les màquines de suport vectorial (SVM) [125]. Com a mètodes no estadístics assenyalen les xarxes neuronals [42, 117, 133] i els algorismes genètics [102].

Les tècniques de caixa negra tenen com a avantatge que requereixen menys temps i esforç de desenvolupament que les tècniques que utilitzen models de caixa gris, però la precisió de la predicció és generalment inferior i en molts casos no es poden utilitzar per inferir resultats no inclosos en les dades tractades.

Esmentem com a exemple la utilització de les xarxes neuronals artificials (*artificial neural network*, ANN) com a sistema de diagnòstic de fallades. Les ANN són anomenades així perquè es van proposar per primera vegada com un model de processos neurobiològics i es poden considerar com un conjunt de nodes interconnectats, generalment distribuïts en capes (d'entrada, oculta i de sortida), els quals serveixen

¹ Definim un model verbal com les relacions de comportament descrites pels experts.

d'elements de càlcul i per passar les dades als altres nodes als quals estan connectats [144]. Trobem un gran nombre de referències en les quals s'utilitzen de forma eficient les ANN tant per a la generació com per a l'avaluació de residus. En destaquem els treballs següents: [33, 59, 86, 115 i 126].

Els punts forts dels FDDS basats en models de tipus caixa negra són:

- Aquests mètodes són molt adequats per als problemes en què els models teòrics de comportament estan molt poc desenvolupats o són inadequats per explicar el desenvolupament observat.
- Són adequats quan les dades d'entrenament són abundants i fàcils de recopilar.
- Són fàcils de desenvolupar i no requereixen una comprensió de la física del sistema que s'ha de modelitzar.
- Els requisits computacionals varien, però generalment són manejables.

Els punts dèbils dels FDDS basats en models del tipus caixa negra són:

- La majoria dels models no es poden utilitzar per extrapolar més enllà de l'abast de les dades d'entrenament.
- Es necessita una gran quantitat de dades d'entrenament en representació dels funcionaments correcte i defectuós.
- Els models són específics del sistema per al qual s'han format i poques vegades es pot utilitzar en altres sistemes.

Els mètodes basats en models de tipus caixa negra són molt útils en els casos en què no es pot aplicar cap altre mètode. Alguns són aplicables a pràcticament qualsevol tipus de problema de reconeixement de patrons.

2.3.4.2 Caixa gris

Tradicionalment en les aproximacions de tipus caixa gris, també coneguda com a *modelització semifísica* o *híbrida*, l'estructura del model acostuma a donar-se directament com una funció matemàtica parametritzada, basada en principis físics. Però, en molts sistemes reals la major part de la informació la proporciona un expert, el qual no raona en termes matemàtics però és capaç de descriure el comportament del sistema de forma verbal mitjançant declaracions més o menys precises. Per exemple, es pot dissenyar un model matemàtic d'un sistema de calefacció de forma declarativa:

SI {s'aplica més energia a l'element calefactor} LLAVORS {la temperatura ha d'incrementar}

Gràcies a la lògica difusa aquest coneixement verbal pot integrar-se en les representacions matemàtiques convencionals. Tal com s'assenyala en [95], la incorporació d'informació verbal en els models de tipus caixa negra fa que aquests esdevinguin models de tipus caixa gris. Destaquem el treball de Takagi i

Sugeno [132], que van utilitzar la lògica difusa per proposar un sistema per definir models difusos, molt útils per modelitzar sistemes dinàmics no lineals.

Els models de caixa gris tenen un gran potencial per als FDDS i les aplicacions de control en línia. Encara que aquests models es deriven de les dades mesurades, es poden utilitzar per extrapolar la informació fora del rang de les dades d'entrenament, ja que estan formulats a partir dels models fonamentals.

Els punts forts dels FDDS basats en models de tipus caixa gris són:

- Aquests mètodes tenen avantatges reals respecte als de la caixa negra, ja que permeten aprofitar el coneixement *a priori* que es tingui del sistema.
- A més a més, donen suport als models físics (caixa blanca) estimant paràmetres difícils d'obtenir o que no es poden aconseguir directament en línia.
- Poden incorporar la informació disponible i mètodes matemàtics fonamentals.

Els punts dèbils dels FDDS basats en models de tipus caixa gris són:

- Els models són específics del sistema per al qual s'han format i poques vegades es pot utilitzar en altres sistemes.

2.3.5 La lògica difusa i els FDDS

Tot i que la lògica difusa no apareix com un mètode d'FDDS a la figura 2-4, ja que no es considera com una font de coneixement, s'utilitza en el camp dels FDDS en molts dels mètodes esmentats, en particular els que tenen caràcter qualitatiu basats en models i els basats en l'històric del procés. La teoria de conjunts difusos pot explicar incerteses associades a la descripció del sistema, ja que descriu les entrades i la classificació de les sortides de l'FDDS. El principal avantatge d'utilitzar la lògica difusa és que pot manejar la incertesa i el comportament no lineal en els sistemes. A més, l'aplicació del programari és relativament fàcil i poc exigent computacionalment. El principal desavantatge de la incorporació de la teoria difusa en els FDDS és que els resultats són menys precisos en comparació amb altres enfocaments.

Els esquemes d'FDDS difusos poden ser: *implícits*, és a dir models difusos de coneixement poc profund, o *explícits*, models difusos de coneixement profund. Els models difusos implícits relacionen els símptomes observats amb les fallades. Els models difusos explícits descriuen el comportament del sistema quan està funcionant correctament o si hi ha fallades.

Cal indicar que la lògica difusa és molt utilitzada en els FDDS, els avantatges de combinar-la amb els conceptes de diagnòstic de fallades basat en models es descriuen a [23 i 61]. En alguns treballs es desenvolupen mètodes basats en lògica difusa per resoldre el problema de la precisió i exactitud en el diagnòstic de les fallades [40, 72]. No obstant això, la majoria dels estudis de diagnòstic de fallades basats en la lògica difusa n'utilitzen només les capacitats d'interpretació i raonament.

Actualment hi ha alguns estudis que combinen les xarxes neuronals amb la lògica difusa per formar xarxes neuronals difuses per al diagnòstic de fallades en sistemes dinàmics no lineals [32, 125]. Aquest mètode combinat permet dissenyar sistemes de diagnòstic que integrin informació quantitativa i qualitativa, tal com es mostra a la figura 2-6 [18].

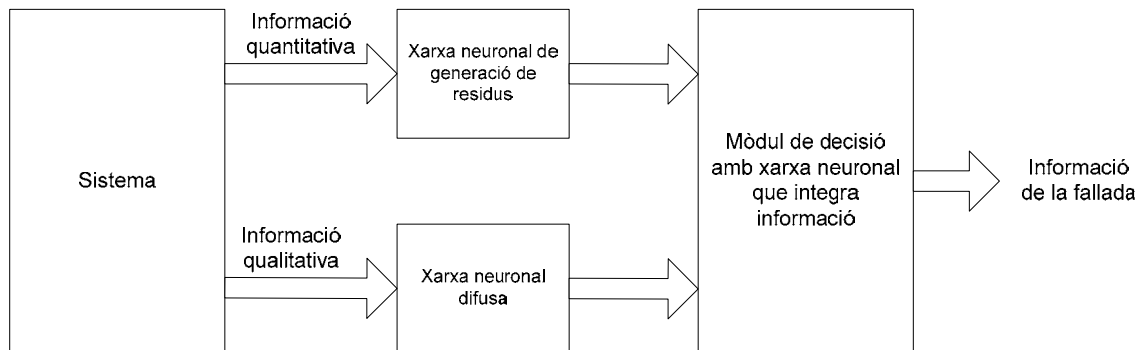


Figura 2-6 Estructura del mètode integrat de diagnòstic de fallades basat en xarxes neuronals difuses [18]

Una altra opció és un esquema de detecció i diagnòstic de fallades que combina la lògica difusa amb els mètodes de diagnòstic de fallades basats en models. Aquest esquema es coneix com el *mètode dels observadors difusos* i es basa en la utilització del model difús de Takagi-Sugeno [132]. Utilitzant aquest model, un sistema es descriu mitjançant un nombre finit de models linealitzats a l'entorn d'un punt de treball. Dins de l'esquema d'observadors difusos, es dissenya un nombre d'observadors lineals locals i s'estima l'estat mitjançant una combinació difusa de les sortides d'aquests observadors. El senyal de diagnòstic (residu) és la diferència entre la sortida real del sistema i la sortida estimada. Aquesta metodologia ha estat utilitzada en el disseny d'observadors difusos per al diagnòstic de fallades en sistemes dinàmics no lineals [24, 41, 129].

Un altre tipus d'observador difús és l'anomenat *observador difús qualitatiu* [148]. Aquest observador es pot dissenyar utilitzant informació qualitativa del procés per produir els residus i es pot utilitzar quan no es disposa de tota la informació quantitativa del procés.

Els punts forts dels FDDS basats en la lògica difusa són:

- Els models difusos poden tenir en compte una gran incertesa i el comportament no lineal dels sistemes.
- Els esquemes difusos d'FDDS són més fàcils de dissenyar perquè les regles difuses tenen un caràcter genèric.
- El coneixement expert disponible sobre els símptomes de les fallades es combina fàcilment amb els coneixements apresos a partir de les dades mesurades.
- El programari que s'aplica a la lògica difusa és computacionalment poc exigent.

Els punts dèbils dels FDDS basats en la lògica difusa són:

- Es generen resultats menys precisos en comparació amb altres enfocaments.
- Les descripcions basades en regles són sovint menys concises que les descripcions quantitatives.

El mètode d'FDDS proposat en aquesta tesi (FIR-FDDS) es fonamenta en la metodologia del raonament inductiu difús (FIR). El FIR consisteix en una metodologia de modelització i simulació qualitativa basada en la lògica difusa. Se centra en l'observació del comportament del sistema en lloc de partir del coneixement de l'estructura interna, de manera que és capaç d'identificar relacions causals i temporals entre les variables del sistema a partir de les dades mesurades d'aquest. Per tant, el mètode d'FDDS que es presenta en aquesta recerca es basa en les dades del procés (històric). Tanmateix, es pot considerar, també, que és un mètode de diagnòstic basat en models qualitius, ja que representa la informació en forma de regles patró de l'estil 'si-llavors' i permet incorporar informació de l'expert en forma de regles. El podem considerar un mètode híbrid que pren algunes característiques dels mètodes de diagnòstic basats en les dades del procés, tant de caixa negra com de caixa gris, i d'altres de mètodes basats en models qualitius.

Els punts forts dels FIR-FDDS són:

- Són fàcils de desenvolupar.
- El raonament és força transparent.
- Tenen una certa capacitat de donar explicacions de les conclusions assolides.
- El coneixement expert disponible sobre els símptomes de les fallades es combina fàcilment amb els coneixements apresos a partir de les dades mesurades.
- Poden tenir en compte una gran incertesa i el comportament no lineal dels sistemes.
- Són molt adequats per als problemes en què els models teòrics de comportament estan molt poc desenvolupats o són inadequats per explicar el desenvolupament observat.
- Són adequats quan les dades d'entrenament són abundants i fàcils de recopilar.
- Són fàcils de desenvolupar i no requereixen una comprensió de la física del sistema que s'ha de modelitzar.

Els punts febles dels FIR-FDDS són:

- No es poden utilitzar per extrapolar més enllà de l'abast de les dades d'entrenament.
- Es necessita disposar de dades d'entrenament en representació del funcionament correcte i del defectuós.
- Els models són específics del sistema per al qual s'han format i poques vegades es poden utilitzar en altres sistemes.

- Les descripcions basades en regles són sovint menys concises que les descripcions quantitatives.

2.4 Rendiment i robustesa dels FDDS

Vist el gran nombre de tècniques emprades per dissenyar un sistema de FDDS, cal disposar d'eines per poder-los avaluar i comparar. En aquest sentit, a la bibliografia trobem dos conceptes fonamentals, el de rendiment i el de robustesa.

2.4.1 Rendiment d'un FDDS

Per provar el rendiment d'un sistema d'FDDS, es pot provocar una fallada i observar-ne la reacció. Si la fallada provocada comporta una resposta encertada de l'FDDS, s'indueix que el sistema dissenyat en fa una bona detecció. D'altra banda, si l'FDDS respon quan no es provoca cap fallada, es considera que s'ha produït una falsa alarma. No totes les fallades es presenten de sobte o persisteixen al llarg del temps després d'haver succeït. El deteriorament molt lent o petits defectes, sovint coneguts com a *fallades incipients*, com ara la tendència o la deriva en un instrument, o *fallades intermitents*, com un mal contacte en un circuit electrònic, s'han d'avaluar d'una manera diferent. Alguns dels criteris emprats per avaluar el rendiment d'un FDDS són [34]: fallades no detectades, rapidesa de la detecció, sensibilitat a les fallades incipients, percentatge de falses alarmes, identificació incorrecta de fallades i robustesa.

Fallades no detectades. Es dona quan s'ha produït una fallada i l'FDDS no l'ha detectada. Una detecció frustrada pot ser acceptable per a fallades poc importants, com per exemple una petita deriva en el senyal d'un sensor relativament poc important, o inacceptable si la fallada té un greu impacte en el funcionament del sistema de control.

Rapidesa de detecció. Suposant que es detecta una fallada amb èxit, la velocitat de detecció pot tenir una importància vital. En algunes aplicacions aeroespacials i d'energia elèctrica, una fallada que persisteix durant uns segons sense que es detecti, s'identifiqui i es corregeixi pot destruir no només el component defectuós, sinó tot el sistema. En altres aplicacions pot ser més convenient disposar d'un detector fiable de fallades menys importants i sacrificar la velocitat en el temps de detecció.

La sensibilitat a les fallades incipients. En alguns sistemes és convenient detectar fallades petites o de desenvolupament molt lent. Això és important en el cas que el sistema d'FDDS tingui com a objectiu la detecció precoç de material defectuós de cara a la realització d'operacions de manteniment. En aquest cas, la rapidesa de detecció pot tenir una importància secundària a la sensibilitat. En altres sistemes poden ser necessàries les dues, la sensibilitat i la rapidesa. Aquest fet comporta el disseny de sistemes d'FDDS més complexos, cosa que requereix possiblement la redundància analítica i de maquinari, per exemple quan es treballa simultàniament amb tècniques informàtiques tolerants a fallades [66].

Percentatge de falses alarmes. Les falses alarmes són generalment indicatives de mals resultats en un FDDS. Fins i tot una petita taxa de falses alarmes durant l'operació normal del sistema de monitoratge pot

ser greu i possiblement perillós, ja que ràpidament porta a temps d'aturada del sistema inacceptables i, possiblement, a la manca de confiança en el sistema de FDDS. El més probable és que, quan es produeix una emergència de debò, els operadors humans ignorin l'alarma perquè han estat alertats en va massa sovint. Hi ha diverses maneres de reduir la taxa de falses alarmes en el disseny d'FDDS. Per exemple, en [34] es descriu un FDDS amb un enfocament adaptatiu en els llindars de detecció de fallades. L'adaptació dels llindars es fa tenint en compte els canvis grans i ràpids en els senyals d'entrada (ja sigui els senyals de control o de pertorbació) del sistema controlat, juntament amb el comportament transitori associat. Aquesta adaptació permet minimitzar la taxa de falses alarmes. Un altre enfocament que es descriu en [142] consisteix en l'ús de models de Markov per a la determinació del llindar, que pot ser una tècnica molt útil quan es pot ajuntar la informació probabilística dels sensors i la dels processos del sistema.

Identificació incorrecta de fallades. En el cas d'una identificació incorrecta, el sistema de detecció notifica correctament que s'ha produït una fallada, però identifica malament el subsistema que ha fallat. Si a continuació existeix un sistema de reconfiguració, es compensarà la fallada equivocada, acció que podria produir conseqüències tan greus com els d'una detecció frustrada.

Per poder avaluar el rendiment d'un sistema d'FDDS caldrà establir una base de fallades del sistema i computar els cinc criteris esmentats anteriorment. Aquesta avaluació també possibilita la comparació entre els diferents sistemes dissenyats per a la detecció i el diagnòstic de fallades d'un sistema/procés determinat. Establir una base de fallades que realment puguin ser produïdes pel sistema real no és una tasca fàcil i està estretament relacionat amb el tema de la robustesa que es presenta a continuació.

2.4.2 Robustesa

La robustesa d'un FDDS és el grau de variació del rendiment quan està afectat per condicions imprevistes. Com que l'objectiu del FDDS és diagnosticar les fallades, la robustesa serà una característica essencial per assolir la seva missió. Les característiques de la robustesa en els sistemes d'FDDS han estat discutides per autors com [15, 35], i les més destacades són la incertesa dels paràmetres, models no lineals o dinàmica incerta, pertorbacions i soroll, i els tipus de fallades.

Incerteses dels paràmetres. Un problema important en l'àmbit de la robustesa dels FDDS es dona quan es treballa amb models no precisos, és a dir, models dels quals es desconeix alguna de les variables físiques i se supleix per un valor estimat. En aquestes circumstàncies, per fer prediccions o s'usen els valors nominals dels paràmetres incerts o s'utilitza algun mecanisme amb capacitat per compensar la incertesa. El resultat és però que els residus o símptomes no són mai nuls i, per tant, indicaran sovint falses alarmes o, si incorporen mesures per reduir les falses alarmes, pot haver-hi fallades no detectades.

Dinàmica incerta. Els sistemes controlats són essencialment no lineals; no obstant això, aquests es poden linealitzar al voltant d'un punt de treball o una trajectòria d'operació. Molts esquemes d'FDDS es basen en la utilització d'aquests models lineals, el resultat dels quals és molt satisfactori sempre que la planta no es desviï gaire del seu punt o trajectòria d'operació nominal. Fora d'aquest rang, les no-linealitats de la planta

produeixen dinàmiques que difícilment poden modelitzar els FDDS, amb la qual cosa s'ocasionaran falses alarmes o no es detectaran algunes fallades.

Pertorbacions i soroll. Els sistemes controlats estan subjectes a pertorbacions, les quals són generalment funcions aleatòries originades per l'entorn. D'altra banda, els sensors utilitzats tenen, en la majoria dels casos, soroll superposat a les mesures. Aquest soroll també és aleatori i procedeix d'una font diferent a les pertorbacions; per tant, normalment són senyals no correlats. La majoria d'eines de processament de senyals que s'utilitzen parteixen de la suposició que les fluctuacions presenten una distribució gaussiana estacionària amb característiques conegudes. Si les pertorbacions i el soroll no són senyals estacionaris, gaussians, i, a més a més, estan d'alguna manera correlacionats, llavors l'esquema d'FDDS funcionarà per sota del nivell esperat.

Tipus de fallades. Un determinat sistema pot tenir un mal funcionament a causa d'un gran nombre de factors: un sensor es pot trencar o patir un canvi del factor d'escala, una tendència pot deixar de ser constant, es poden originar canvis en les característiques d'algun component per causes com són el desgast o la fricció, una part mòbil es pot enclavar en una posició fixa, es pot generar un excés de soroll en els senyals, etc. La majoria d'esquemes d'FDDS s'han dissenyat per detectar i discriminar entre un conjunt de tipus de fallades especificades prèviament, i es pot complicar si s'incrementa el nombre de tipus de fallades. És evident que si succeeix una fallada que no forma part de la base de coneixement de l'FDDS, aquest podrà detectar que succeeix alguna cosa estranya però no serà capaç de reconèixer la fallada. Alguns FDDS, en aquestes circumstàncies, en lloc de donar la fallada per desconeguda, proposen com a hipòtesis la fallada més propera. Per poder reconèixer una fallada desconeguda, l'FDDS necessita poder estimar els errors comesos en les seves prediccions. Moltes metodologies utilitzades en els FDDS no ofereixen capacitats d'autoavaluació, fet que comporta un problema greu d'aquestes eines.

2.5 Comentaris finals

En aquest capítol s'ha presentat una visió panoràmica dels principals mètodes de detecció i diagnòstic de fallades i les definicions bàsiques que estarem emprant al llarg de la tesi. Aquesta revisió ha permès fixar els objectius generals del mètode FIR-FDDS objecte d'aquesta tesi.

També s'han esmentat diferents eines teòriques relacionades amb aquest camp i diferents tipus de tècniques usades per ajudar en el diagnòstic de fallades, i s'han presentat els avantatges i els inconvenients de cada mètode. El FIR-FDDS se situa en la panoràmica dels models de diagnòstic existents i se n'enumeren els avantatges i inconvenients.

Segons [73], durant la dècada de 1990 els mètodes més utilitzats per a la detecció i el diagnòstic de fallades eren els observadors i els estimadors de paràmetres. En les darreres dècades, però, la importància dels mètodes basats en xarxes neuronals i els mètodes híbrids o combinats per a la detecció de fallades ha anat augmentant substancialment. En la majoria d'aplicacions, la detecció de fallades es fa mitjançant la

lògica simple de llindar o d'histèresi. Per al diagnòstic de fallades s'utilitzen, normalment, mètodes de classificació. Per a aquesta tasca, els mètodes més utilitzats són les xarxes neuronals i el raonament basat en la lògica difusa.

En l'últim apartat d'aquest capítol es planteja el tema del rendiment i la robustesa dels sistemes de detecció i diagnòstic de fallades, que en els últims anys està tenint un interès creixent, a causa de la gran demanda de seguretat i fiabilitat en els sistemes dinàmics complexos amb incertesa. Aquest tema s'aborda a l'última part d'aquesta tesi, en què es mostra la robustesa de l'FDSS basat en FIR.

3 Raonament inductiu difús (FIR)

Resum: en aquest capítol es presenta la metodologia del raonament inductiu difús (FIR). Com que el FIR es basa en el *general system problem solver* (GSPS) proposat per Klir, primer es presenten les línies principals del GSPS i després ens endinsem en el FIR. S'aporten nocions sobre l'origen i la implementació del FIR, se'n defineix el significat i se'n descriu detalladament la composició i el funcionament. Finalment, es proposa una nova fórmula de discretització de les dades i se'n demostra la utilitat amb un exemple d'una xarxa d'aigües.

3.1 Introducció

La metodologia del raonament inductiu difús (FIR, de l'anglès *fuzzy inductive reasoning*) sorgeix de l'enfocament del *general systems problem solver* (GSPS) proposat per Klir [81], una eina per analitzar els sistemes generals que permet estudiar els modes conceptuals de comportament dels sistemes dinàmics. El FIR consisteix en una metodologia de modelització i simulació qualitativa de sistemes basada en l'observació del comportament del sistema, en lloc de partir del coneixement de l'estructura interna del sistema. La metodologia ha anat evolucionant al llarg del temps:

— George J. Klir, de la *State University of New York at Binghamton*, introdueix el *General Systems Problem Solver* (GSPS) [81], que sorgeix com a resultat dels seus 20 anys d'estudis en l'àrea de la Teoria General de Sistemes. L'objectiu era desenvolupar una aproximació pròpia que permetés elaborar una teoria de sistemes la generalitat i contingut de la qual estigués equilibrada amb les aplicacions.

— Hugo J. Uyttenhove, l'any 1979, estudiant de doctorat d'en George J. Klir, fa la primera implementació de les idees teòriques del GSPS i l'anomena SAPS (*system approach problem solver*) [137].

— François E. Cellier i estudiants seus de la Universitat d'Arizona, l'any 1987, reelaboren i reimplementen la metodologia i l'anomenen SAPS-II (*system approach problem solver II*). En aquesta etapa s'hi introdueixen tècniques de lògica difusa, però només s'arriben a modelar sistemes acadèmics [30].

— Posteriorment, Àngela Nebot juntament amb altres estudiants de doctorat de la Universitat Politècnica de Catalunya, dirigits per François E. Cellier, de la Universitat d'Arizona, i Rafael M. Huber, de l'Institut de Robòtica i Informàtica Industrial, van continuar estudiant la metodologia, amb l'objectiu d'aplicar-la a sistemes de complexitat real. Concretament, les primeres aplicacions de la metodologia SAPS-II són per resoldre diversos problemes biomèdics i d'enginyeria [37, 96, 101 i 107].

— Actualment, se segueix investigant per millorar la metodologia i l'eficiència de la seva aplicació informàtica. Fruit d'aquest treball continuat són les tesis doctorals llegides subseqüentment [8, 99] i el treball desenvolupat en aquesta tesi.

Els principis bàsics del SAPS-II es descriuen detalladament en la tesi doctoral d'Àngela Nebot [107].

3.2 *General systems problem solver (GSPS)*

En aquesta secció es descriu breument el *general systems problem solver* (GSPS) de George Klir. Per tal d'entendre l'objectiu principal del GSPS s'introdueix i es revisa, en primer lloc, la teoria de sistemes generals (GST, de l'anglès *general systems theory*).

Ludwig von Bertalanffy va concebre la idea de la GST a través de la seva àrea de recerca principal, la biologia, al començament dels anys trenta. Von Bertalanffy va generalitzar, en el marc de la seva teoria dels sistemes oberts, un conjunt de principis per construir la biologia teòrica moderna. La idea de la teoria dels sistemes oberts va partir de la conclusió que el concepte clàssic del *sistema tancat*, usat normalment en física, no era útil i sovint portava a conclusions incorrectes en la camp de la biologia. Des de la seva perspectiva, l'organisme no és una conglomeració d'elements separats sinó un sistema que posseeix organització i completesa. A més a més, aquest sistema canvia constantment, tot mantenint un flux d'energia i informació continu amb l'entorn. La teoria dels sistemes oberts proporciona les eines que serveixen com a base per a la generalització en altres camps. Des de llavors molts investigadors de diferents àrees han contribuït a desenvolupar la teoria dels sistemes generals. Els investigadors més rellevants, són bàsicament: William Ross Ashby, Ludwig Von Bertalanffy, Anatol Rapoport, Norbert Wiener, George Jiri Klir i Lofti Asker Zadeh [82].

Queda clar que la GST és un camp madur que ha estat desenvolupat en els darrers vuitanta anys. Però encara no hem donat cap definició concreta de la GST. Tal com s'esperava, hi ha diverses definicions, donades des de perspectives diferents, en la gran quantitat de literatura que ha estat publicada en aquest camp. Algunes de les definicions que considerem que ajuden a aclarir la idea principal de la GST es presenten a continuació. La primera va ser formulada l'any 1930 per Von Bertalanffy [141]:

General systems theory is a logical-mathematical field whose task is the formulation and derivation of those general principles that are applicable to *systems* in general.

La definició següent, aportada per Boulding el 1956 [19], és probablement la més citada:

General systems theory is a name which has come into use to describe a level of theoretical model building which lies somewhere between the highly generalized constructions of pure mathematics and the specific theories of the specialized disciplines.

Finalment, Klir [83] va donar una definició força significativa:

GST in the broadest sense refers to a collection of general concepts, principles, tools, problems, methods, and techniques associated with systems. Although the name *system* may have different meanings under different circumstances and for different people, it ordinarily stands for an arrangement of certain components so interrelated as to form a whole.

Tenint en compte les definicions prèvies, l'objectiu principal de la GST és formular principis i lleis generals per als sistemes, independentment de les característiques específiques que tinguin, la naturalesa dels elements que els constitueixen i de les relacions que estableixen. Gràcies a la recerca duta a terme es van trobar evidències que algunes propietats dels sistemes no depenen de la naturalesa específica del sistema individual, és a dir, són vàlides per a sistemes de naturalesa diferent, de manera que són, doncs, propietats generals dels sistemes. A conseqüència d'això, apareixen les semblances estructurals o isomorfismes entre diferents camps. Dos sistemes concrets són conceptualment isomòrfics entre ells si ambdós poden ser representats pel mateix model matemàtic. En trobem exemples clars en els camps de la mecànica i els circuits elèctrics. L'isomorfisme entre aquests dos camps porta a la teoria dels circuits generalitzats, que és aplicable també als circuits tèrmics i acústics.

La semblança en la forma d'equacions algebraïques o diferencials és una altra mena d'isomorfisme matemàtic. Quan això es generalitza de manera que inclou qualsevol relació, expressable en equacions o no, llavors el concepte de *sistemes generals* adquireix el significat adient.

Una de les aportacions més significatives a la teoria de sistemes generals és la teoria d'autòmats finits, desenvolupada des dels anys cinquanta per autors com Shannon, Turing i Moore, entre d'altres. Altres investigadors excepcionals van optar per desenvolupar la seva pròpia aproximació a la GST, com l'*state determined system* d'Ashby [14], l'*state-space approach* de Zadeh [146], la *wattled theory of systems* de Wymore [145] o el *general systems problem solver* de Klir [84].

D'aquí al final d'aquesta secció ens centrarem exclusivament en l'aproximació proposada per George Klir, a partir de la qual deriva la metodologia del raonament inductiu difús. En primer lloc, aclarim en quin punt se situa el GSPS dins de l'espectre de totes les teories de sistemes possibles, fent una ullada a la figura 3-1.

Les teories amb el nivell més baix de generalització apareixen a la part baixa de la figura 3-1 i corresponen a la categoria de les teories orientades a la disciplina, anomenades de tipus 1 (T1) en la notació d'Orchard [110]. El segon nivell d'abstracció correspon a les teories de sistemes generalitzats, o de tipus 2 (T2). En aquest nivell apareix una primera generalització mitjançant isomorfismes matemàtics derivats de semblances en la forma d'equacions algebraiques o diferencials. La teoria dels circuits generalitzats, que és aplicable a sistemes mecànics, elèctrics, tèrmics i acústics, és un exemple d'aquest nivell.

El tercer i el quart nivells de l'espectre de la teoria de sistemes s'anomenen *teories de sistemes generals*. Una teoria de sistemes de tipus 3 (T3) ha de satisfer les propietats següents, segons Klir [84]: 1) ha de ser aplicable a tot sistema afinitat i 2) ha de reflectir trets fonamentals dels sistemes.

Poden haver-hi moltes teories de sistemes generals de tipus 3 que capturen diferents trets fonamentals dels sistemes. La integració de totes les teories T3 en un cert instant de temps constituiria la teoria de sistemes generals en progrés. L'objectiu principal del GSPS de Klir és, precisament, aconseguir aquest tipus de teoria, que equilibra la generalitat amb el contingut útil.

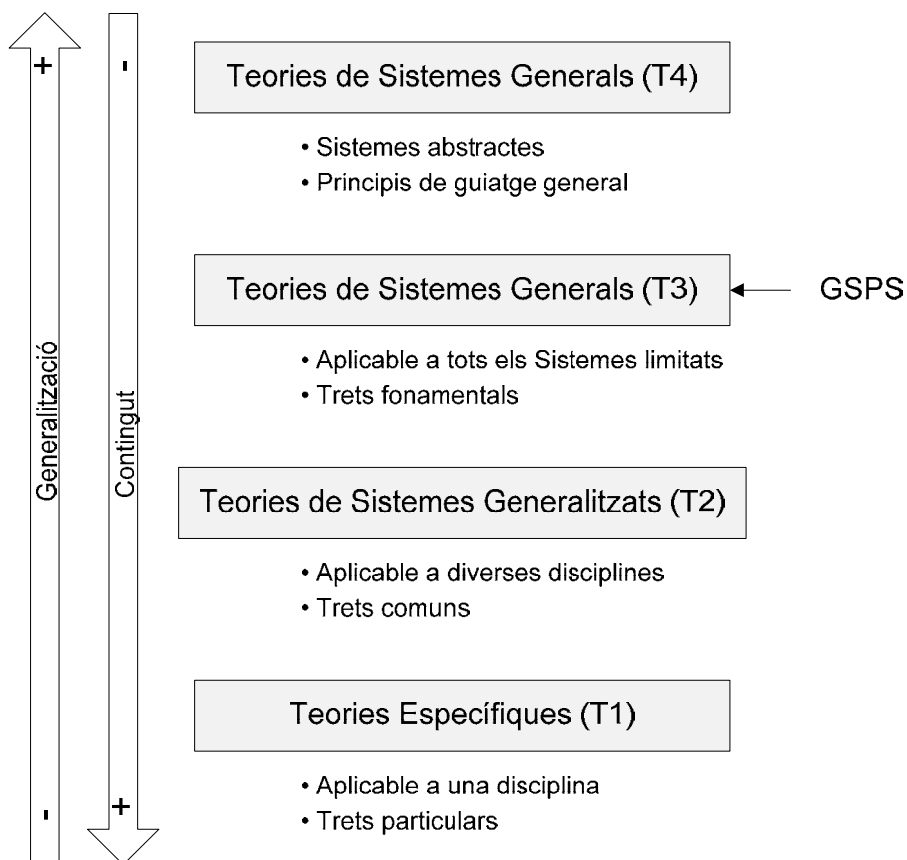


Figura 3-1 GSPS dins l'espectre de les teories de sistemes.

El nivell més alt d'abstracció correspon a la categoria de tipus 4 (T4). En aquest nivell trobem teories de sistemes algebraics abstractes. Segons Orchard, el paper d'aquestes teories és establir les fronteres de la teoria de sistemes generals i especificar principis de guia generals útils per al nivell T3. Alguns exemples d'aquesta categoria són la teoria d'àlgebres booleanes o la teoria de grafs, entre d'altres.

Per endinsar-nos en l'aproximació del *general system problem solver*, començarem aportant-ne una definició. El GSPS es pot definir com un marc conceptual mitjançant el qual es defineixen tipus de problemes dels sistemes juntament amb eines metodològiques per solucionar-los.

La metodologia del GSPS distingeix entre diferents tipus de sistemes caracteritzats per diferents nivells d'abstracció. La figura 3-2 mostra la classificació jeràrquica per nivells epistemològics dels tipus de sistemes fonamentals trobats en àrees de recerca de disciplines diferents, definida per Klir.

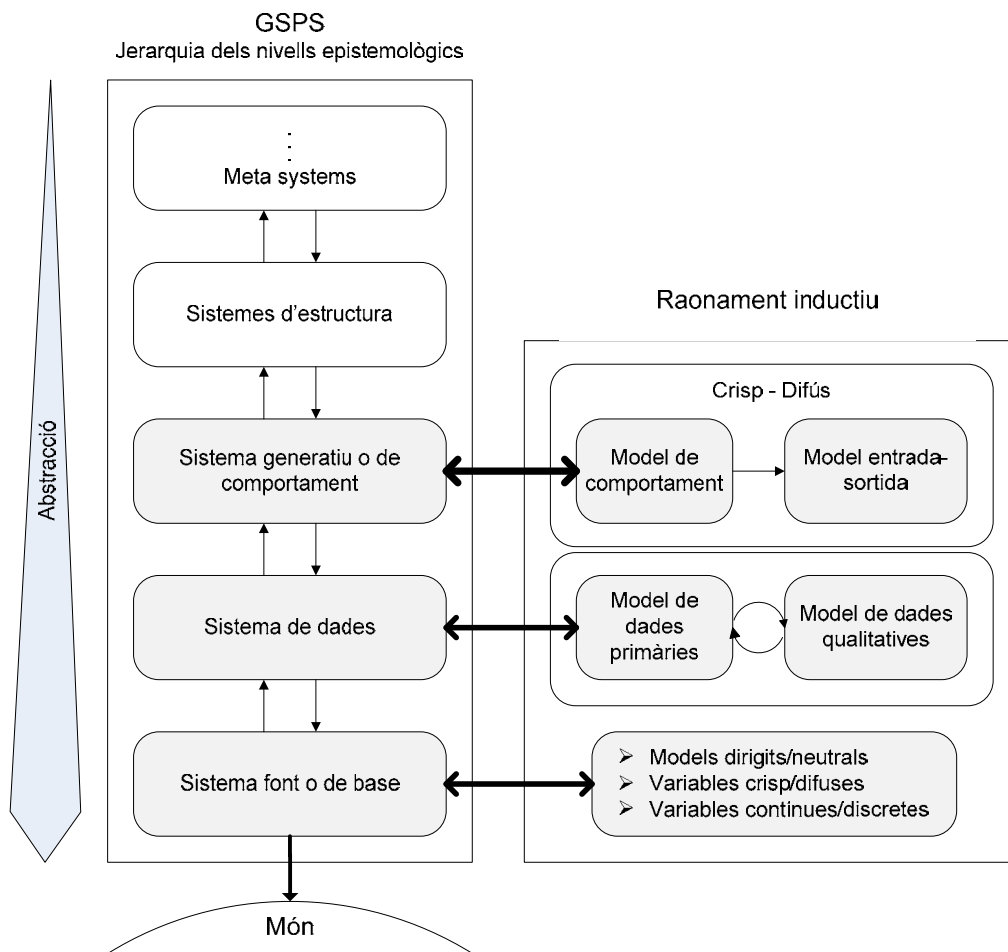


Figura 3-2 Jerarquia de nivells epistemològics de sistemes i la seva relació amb el raonament inductiu difús.

La part esquerra de la figura 3-2 representa la taxonomia del GSPS i aquesta jerarquia és vital per desenvolupar qualsevol paquet organitzat d'eines metodològiques per resoldre problemes de sistemes. En la nostra pròpia terminologia, un sistema és l'entitat física a partir de la qual es poden derivar descripcions matemàtiques d'abstracció variable anomenades *models*. Usant les paraules de Bernard

Zeigler, un sistema no és res més que una font potencial de dades [147]. Per tant, des d'ara als sistemes de Klir els anomenarem *models*.

El GSPS distingeix entre una infinitat de nivells d'abstracció. El model més abstracte és el sistema font o de base (vegeu la figura 3-2). Aquest, simplement, defineix el coneixement referent a quines facetes del sistema real s'han de capturar en la descripció matemàtica. Aquest coneixement consisteix a declarar un conjunt de variables que ha de contenir el model. Els models font poden ser classificats seguint diferents criteris, en funció de les propietats de les variables. Un d'aquests criteris és classificar les variables en variables d'entrada i de sortida. Els models les variables dels quals poden ser classificades en variables d'entrada i de sortida s'anomenen *models directes*, mentre que la resta dels models s'anomenen *models neutrals*. Altres classificacions en aquest nivell són distingir entre variables crisp/difuses o contínues/discretes. La metodologia del raonament inductiu treballa tant amb models directes com neutrals, i no ha de fer una distinció prèvia entre variables crisp/difuses o contínues/discretes. Pujar d'un nivell al següent implica disposar de tot el coneixement dels nivells inferiors i del coneixement propi del nou nivell. Per tant, el model font està inclòs en tots els models dels nivells superiors.

El nivell següent de la jerarquia epistemològica de Klir és el model de dades. Per tal de pujar del nivell del model font al model de dades cal proporcionar dades al model font. Depenent del problema, les dades s'obtenen mitjançant l'observació o el mesurament. En aquest últim cas, cal dur a terme un experiment o més en el sistema real, per la qual cosa cal afegir sensors per capturar les variables incloses en el model. El resultat és un grapat de dades o trajectòries que a hores d'ara encara no contenen cap descripció de les relacions lògiques o causals que connecten aquestes dades entre elles. L'única relació coneguda entre les dades en aquest moment és el temps de mostreig. Un tipus de problema que requereix que les dades siguin mesurades és la modelització del sistema. En altres problemes, com ara el disseny del sistema, les dades s'expressen mitjançant estats. La metodologia del raonament inductiu treballa amb problemes del primer tipus i, per tant, el model de dades es caracteritza per un conjunt de variables mesurades i enregistrades en el temps. La figura 3-2 descriu la correspondència entre els nivells epistemològics del GSPS i la metodologia del raonament inductiu.

En la nostra pròpia terminologia, el model de dades, l'anomenem *model de dades primàries*, perquè les dades encara no han estat processades de cap manera. En la nostra implementació de la metodologia, el model de dades primàries es representa amb una matriu de valors reals, en què cada columna representa la trajectòria d'una variable i cada fila representa el registre d'una dada.

Per tal de seguir pujant en la jerarquia cal processar aquestes dades. En la implementació, el model de dades primàries es processa en un model de dades qualitatives, en el qual cada dada quantitativa (de cada fila) és substituïda per un triplet qualitatiu. Els detalls d'aquest procés s'expliquen en la secció 3.3. Com que el model de dades primàries i el model de dades qualitatives contenen exactament la mateixa

informació, el GSPS no distingeix entre ambdós models i per això estan tots dos situats al mateix nivell epistemològic. Recordem que pujar de nivell implica necessàriament afegir nova informació al model.

Si pugem un nivell més en l'escala epistemològica, trobem el sistema generatiu o de comportament. El model de comportament afegeix relacions lògiques o causals a subconjunts de variables. Ara sabem quin conjunt de variables hem de consultar per inferir coneixement d'una altra variable o conjunt de variables. Tots els models anomenats *d'entrada/sortida* es localitzen en aquest nivell epistemològic. Per tant, aquest nivell involucra coneixement de les característiques relacionals invariants de les variables involucrades, que pot ser exacte (determinista) o aproximat (estocàstic, difús).

Pujant encara més en la jerarquia del GSPS, trobem els models d'estructura, als quals pertanyen la majoria dels models d'equacions diferencials derivats deductivament. Aquí les relacions causals dels models de comportament anteriors es concreten en relacions explícites entre variables. Finalment, el GSPS defineix una infinitat d'esglaons dels anomenats *metamodels*. El primer nivell de metamodels es caracteritza pels models d'estructura variable, és a dir, models que canvien abruptament de comportament com a conseqüència de l'aparició d'un esdeveniment discret [137]. Tanmateix, com que la metodologia FIR no treballa amb aquest nivell de la jerarquia del GSPS, en aquesta tesi no cal explorar-ne les propietats més detalladament.

3.3 La metodologia FIR

El FIR desenvolupa dues tasques principals. La primera és identificar les relacions causals i temporals entre les variables del sistema per construir el model qualitatiu del sistema observat. La segona és predir el comportament futur del sistema a partir de les observacions passades i del model prèviament identificat. Per complir aquestes tasques, la metodologia FIR disposa de quatre funcions bàsiques anomenades: *codificació difusa*, *modelització qualitativa*, *simulació qualitativa* i *regeneració*.

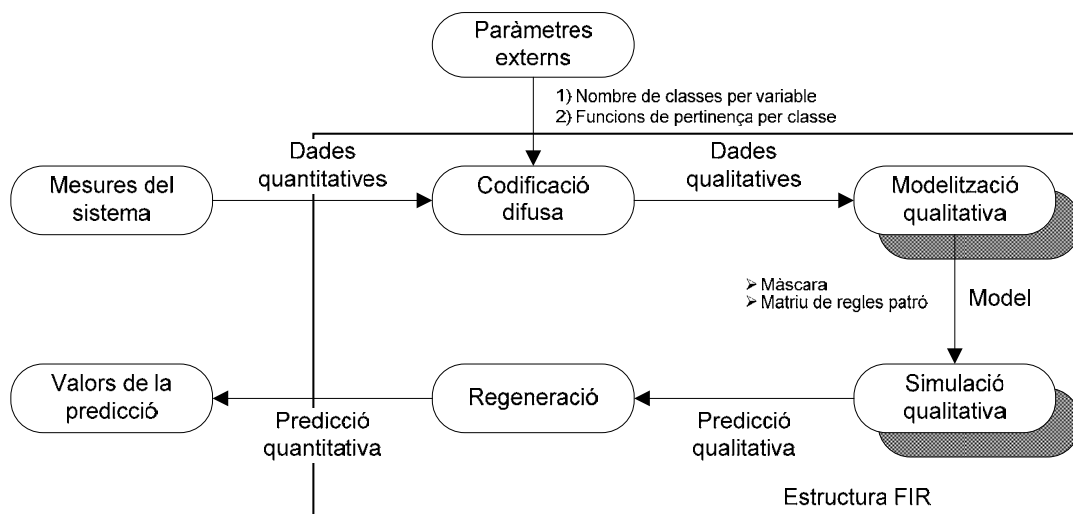


Figura 3-3 Representació esquemàtica de la metodologia FIR

La figura 3-3 mostra les quatre funcions de la metodologia FIR de manera esquemàtica; s'hi ombregen les dues tasques principals. És a dir, la identificació de models qualitatius i l'ús d'aquests en la simulació qualitativa, per tal de predir el comportament futur del sistema en estudi.

Els quatre processos que comprèn la metodologia FIR es descriuen més detalladament a continuació.

3.4 Codificació difusa

El FIR s'alimenta de dades reals enregistrades del sistema. El procés de codificació difusa s'encarrega de convertir els valors quantitius del sistema (dades sense processar) en els valors qualitatius equivalents (dades codificades).

En el procés de codificació difusa, un valor quantitiu es converteix en un triplet qualitatiu en què el primer element del triplet és el valor de la classe, el segon element és el valor de pertinença difusa i l'últim element correspon al valor de costat. El valor de classe correspon al valor codificat de la variable (etiqueta o valor lingüístic). El valor de pertinença (*membership*) permet conèixer en quin grau aquest valor pertany a la classe. El valor de costat permet conservar en el triplet qualitatiu el coneixement complet del valor quantitiu original, de manera que determina amb precisió on es troba el valor qualitatiu, és a dir, a la dreta, al centre o a l'esquerra del màxim de la funció de pertinença. D'aquesta manera, no es perd informació durant el procés de codificació difusa.




Figura 3-4 Procés de codificació de la metodologia FIR.

Per il·lustrar aquest procés considerem que es té un valor quantitiu de 24 °C que indica la temperatura del medi ambient. La codificació difusa d'aquesta variable es fa en cinc classes, amb els valors

qualitatius: fred, fresc, normal, temperat i calent. Cadascuna d'aquestes etiquetes lingüístiques es representa per mitjà d'una funció de pertinença, com es mostra a la figura 3-4. Així, 24 °C correspon a la classe *normal*, amb un valor de pertinença a aquesta classe de 0,7 i un valor de costat de *dreta*, ja que es troba al costat dret respecte al valor màxim de la funció de pertinença. En la metodologia FIR, el punt en què dues classes adjacents es tallen amb un valor de pertinença de 0,5 es denomina *llindar de la classe* (*landmark*). Cal assenyalar que els llindars determinen l'amplitud de les funcions de pertinença corresponents. És a dir, defineixen d'alguna manera la forma (estreta o ampla) d'aquestes funcions.

Un cop definits el nombre de classes i els llindars entre classes, per a cada variable es porta a terme el procés de codificació difusa del FIR de les dades registrades del sistema. Quan finalitza aquest procés, s'obté un triplet de matrius amb el mateix nombre de dades: la primera conté els valors de classe; la segona, els valors de pertinença, i la tercera, els valors de costat.

Per obtenir el valor de la pertinença, es poden aplicar dues fórmules diferents:

— Fórmula gaussiana

$$Pert_i = e^{(-\tau_i(x-\mu_i)^2)}, \quad (3.1)$$

on x és el valor quantitatiu que s'ha de codificar, μ_i és la mitjana algebraica entre els llindars de la classe i i el valor de τ_i es calcula en funció de la posició de la classe: per a la primera i última classe $\tau_i = \ln(0,5) / (\text{Valor}_{\text{llindar superior}} - \text{Valor}_{\text{llindar inferior}})^2$, i per a les classes intermèdies $\tau_i = \ln(0,5) / (\text{Valor}_{\text{llindar superior}} - \mu_i)^2$

— Fórmula triangular

$$Pert_i = \begin{cases} 1 - \left| \frac{\mu_i - x}{d} \right|, & \text{si } \mu_i - d \leq x \leq \mu_i + d \\ 0, & \text{si } x < \mu_i - d \text{ o } x > \mu_i + d, \end{cases} \quad (3.2)$$

on d és la distància entre el valor mitjà de la classe i els llindars.

3.4.1 Propietats que garanteixen la interpretabilitat d'una partició difusa

Suposant que el domini U de la variable x es parteix en un conjunt de E etiquetes definides amb funcions de pertinença triangulars: A_1, A_2, \dots, A_E , es defineixen les propietats següents:

— Completesa, que garanteix que cap punt del domini U no queda fora de la partició difusa: $\forall x \in U, \exists j$ tal que $\mu_{A_j}(x) \geq \delta > 0$.

— Ordenació semàntica, que garanteix l'ordre dels termes lingüístics de la partició: $\forall i < j, a_i < a_j$; a_i i a_j són els punts modals de les etiquetes A_i i A_j .

— Dominància, que impedeix que els punts del domini U tinguin un alt grau de pertinença γ en més de dos termes lingüístics:

$$\forall x \in U, \text{ si } \mu_{A_j}(x) > \gamma > 0, \text{ i } \mu_{A_i}(x) > \gamma > 0$$

$$\text{ llavors } \forall k \in \{1, \dots, E\}, k \neq j \neq i, \mu_{A_k}(x) \leq \gamma, \tag{3.3}$$

En relació amb aquestes propietats, es diu que una partició difusa és forta si compleix la condició següent:

$$\forall x \in U, \sum_{t=1}^E \mu_{A_t}(x) = 1, \tag{3.4}$$

Es pot dir que una partició difusa forta (vegeu la figura 3-5), també anomenada *partició difusa de Ruspini*, posseeix el màxim grau d'interpretabilitat. Per al cas d'una partició difusa definida amb funcions de pertinença triangulars, aquesta partició és forta si el punt de tall de totes les etiquetes es troba a grau 0,5. Evidentment, una partició difusa uniforme sobre l'univers de discurs d'una variable és una partició forta.




Figura 3-5 Exemple d'una partició difusa forta

Aquesta etapa és necessària, ja que en diferents parts de la metodologia cal aplicar processos d'optimització a subconjunts de dades; fent una partició difusa de les dades es redueix enormement l'espai de cerca i s'aconsegueix molta més eficiència. La contrapartida d'aquesta eficiència és una pèrdua d'informació. Per exemple, dir que l'alçada d'una persona es classifica com a *alta* ens dona menys informació que dir que la persona fa 1,95 m d'alçada. Tanmateix, la manera en què el FIR du a terme la codificació difusa fent ús del triplet qualitatiu evita aquesta pèrdua d'informació, típica dels sistemes difusos.

3.5 Modelització qualitativa

El comportament qualitatiu està compost per les tres matrius obtingudes en el procés de codificació difusa, en què cada columna representa una de les variables observades i les files són els registres duts a terme en cada interval de temps. El procés de modelització qualitativa consisteix bàsicament a fer una cerca en aquestes matrius per trobar les relacions causals i temporals més deterministes entre les

variables. Aquestes relacions constitueixen l'estructura del model FIR (que anomenem *màscara òptima*). La màscara és usada per extreure del conjunt de dades d'entrenament les regles qualitatives basades en patrons (o regles patró). La màscara òptima i el conjunt de regles patró que en deriva constitueixen el model FIR que representa el comportament del sistema. Ara descriurem de manera més detallada tot aquest procés.

Tal com acabem de comentar, el primer pas és obtenir l'estructura o màscara que millor representi el sistema dinàmic en estudi. Per fer-ho, s'avaluen totes les possibles màscares i es conclou quina té el poder més elevat de predicció per mitjà d'una mesura de reducció de l'entropia, anomenada *qualitat de la màscara*, Q . Una màscara descriu una relació dinàmica entre les variables qualitatives. La màscara amb el màxim valor de Q és la màscara òptima.

Cada fila d'una màscara representa un instant de temps en funció de l'interval de mostreig. El nombre de files es coneix com a *profunditat de la màscara*. La màscara es representa en forma matricial, tal com es mostra a l'equació 3.5 i està composta per:

- Els antecedents, coneguts com a m -entrades, que indiquen les relacions causals que permeten determinar el valor del conseqüent i que es denoten amb valors negatius.
- El conseqüent, conegut com a m -sortida, que correspon a la variable de sortida que volem predir i que es denota amb un valor positiu.
- Els components nuls, que indiquen quines relacions no són rellevants per predir el valor del conseqüent.

$$\begin{array}{c}
 t/x \\
 t - 2\delta t \\
 t - \delta t \\
 t
 \end{array}
 \begin{array}{c}
 u_1 \quad u_2 \quad u_3 \quad y_1 \\
 \left[\begin{array}{cccc}
 0 & 0 & -1 & 0 \\
 0 & -2 & 0 & 0 \\
 -3 & 0 & 0 & +1
 \end{array} \right]
 \end{array}
 \tag{3.5}$$

La màscara de l'equació 3.5 conté tres m -entrades. En notació de posició, aquesta pot ser escrita com a (3,6,9), que indica que la primera m -entrada es troba a la tercera posició de la màscara si la numerem d'esquerra a dreta i de dalt a baix, que la segona m -entrada està situada en la posició 6 de la màscara, etc. La seqüència en què les m -entrades i la m -sortida són numerades no té cap significat especial. Els termes m -entrada (entrada de la màscara) i m -sortida (sortida de la màscara) s'utilitzen per evitar confusió amb les entrades i les sortides del sistema. El nombre d'elements diferents de zero en la màscara indica el nivell de complexitat d'aquesta. Aquí la màscara té un nivell de complexitat de quatre. En aquest exemple, la primera m -entrada (i_1) correspon a la variable d'entrada del sistema u_3 mostrejada dos intervals de temps anteriors a l'actual, $u_3(t - 2\delta t)$, la segona m -entrada (i_2) correspon a l'entrada del sistema u_2 mostrejada en l'instant de temps anterior a l'actual, $u_2(t - \delta t)$, etc.

Per iniciar el procés de cerca s'introdueix el concepte de *màscara candidata*, equació 3.6, amb la finalitat de trobar entre tot el conjunt de màscares possibles (de cada complexitat fins a arribar a la màxima) la que millor representi el sistema. A partir de la matriu de la màscara candidata, el procés de cerca de la màscara òptima avalua totes les possibles combinacions a través d'un mecanisme de cerca exhaustiva de complexitat exponencial [28] o mitjançant estratègies de cerca genètica o d'arbres de complexitat polinòmica [78].

$$\begin{array}{c}
 t/x \\
 t - 2\delta t \\
 t - \delta t \\
 t
 \end{array}
 \begin{array}{cccc}
 u_1 & u_2 & u_3 & y_1 \\
 \left[\begin{array}{cccc}
 -1 & -1 & -1 & -1 \\
 -1 & -1 & -1 & -1 \\
 -1 & -1 & -1 & +1
 \end{array} \right]
 \end{array}
 \quad (3.6)$$

La màscara candidata conté elements -1 en les posicions en què té una m -entrada potencial i un element $+1$ en les posicions en què té la m -sortida, i s'utilitza el 0 per denotar relacions prohibides o sense significat físic. Una possible màscara candidata per a un sistema de quatre variables és la que permet que el FIR estudiï totes les possibles relacions causals entre les variables del sistema en els diferents instants de temps i la sortida en l'instant t , tal com es mostra a l'equació 3.6.

L'optimitat de la màscara s'avalua respecte a la maximització del seu poder de predicció. S'usa la mesura d'entropia de Shannon [127] per determinar la incertesa associada al pronòstic d'un estat de sortida particular donat qualsevol estat d'entrada legal. L'entropia de Shannon relativa a un estat d'entrada es calcula amb l'equació:

$$H_i = - \sum_{\forall o} p(o|i) \cdot \log_2 p(o|i), \quad (3.7)$$

on $p(o|i)$ és la probabilitat condicional que succeeixi un cert estat o a la m -sortida, tenint en compte que ha succeït l'estat i en el patró de m -entrades. El terme *probabilitat* s'utilitza en un sentit més aviat estadístic més que en un d'estrictament probabilístic. L'entropia total de la màscara es calcula com segueix:

$$H_m = \sum_{\forall i} p(i) \cdot H_i, \quad (3.8)$$

on $p(i)$ és la probabilitat que succeeixi aquest estat d'entrada. L'entropia més alta possible, $H_{m\grave{a}x}$, s'obté quan totes les probabilitats són iguals i una entropia zero correspon a les relacions totalment deterministes.

El terme *reducció d'entropia normalitzada*, H_r , es defineix com a:

$$H_r = 1,0 - \frac{H_m}{H_{m\grave{a}x}} \quad (3.9)$$

$H_r \in [0,1]$, on valors alts indiquen normalment més poder de predicció. Les màscares amb valors de reducció d'entropia alta generen prediccions amb menor incertesa.

D'altra banda, és important tenir en compte la predictibilitat de la màscara que s'està avaluant. La metodologia FIR considera que, des del punt de vista estadístic cal observar, cada estat, com a mínim, cinc vegades [89]. És per això que s'utilitza la ràtio d'observació O_r , com un factor addicional per determinar la qualitat total de la màscara [92].

$$O_r = \frac{5 \cdot n_{5x} + 4 \cdot n_{4x} + 3 \cdot n_{3x} + 2 \cdot n_{2x} + n_{1x}}{5 \cdot n_{leg}}, \quad (3.10)$$

n_{leg} = nombre d'estats legals de m -entrades;

n_{1x} = nombre d'estats de m -entrades observats només una vegada;

n_{2x} = nombre d'estats de m -entrades observats dues vegades;

n_{3x} = nombre d'estats de m -entrades observats tres vegades;

n_{4x} = nombre d'estats de m -entrades observats quatre vegades;

n_{5x} = nombre d'estats de m -entrades observats cinc vegades o més.

Si tot estat legal de m -entrades ha estat observat almenys cinc vegades, O_r és igual a 1,0 i no té cap influència en la qualitat de la màscara. Si no s'ha observat cap estat de m -entrades (és a dir, no hi ha dades disponibles), O_r és igual a 0,0.

La qualitat total d'una màscara, Q , es defineix com el producte de la seva mesura de reducció d'entropia, H_r , i la seva ràtio d'observació, O_r :

$$Q = H_r \cdot O_r. \quad (3.11)$$

Una altra manera de trobar la qualitat és mitjançant la complexitat de la màscara aproximada o de l'aproximació de la màscara [136]. Per trobar la màscara que millor representa la relació entre les variables qualitatives, és a dir, la màscara òptima, el FIR fa una cerca exhaustiva per nivells. En primer lloc, calcula les qualitats de les màscares de complexitat més baixa i guarda la millor d'aquest nivell. Passa al nivell següent de complexitat i es guarda la millor màscara. Es repeteix aquesta cerca per a tots els nivells, fins que arriba a la complexitat màxima especificada pel modelitzador. Per tal de comparar les màscares dels diferents nivells, la complexitat d'una màscara de pes m es defineix com a:

$$C_m = \frac{n_{var.} \cdot depth \cdot compl}{depth_{m\grave{a}x.}}, \quad (3.12)$$

on:

$n_{var.}$ = nombre de variables;

$depth$ = profunditat de la màscara;

$compl$ = complexitat de la màscara (quantitat de valors diferents de zero);

$depth_{m\grave{a}x.}$ = profunditat màxima que pot tenir la màscara (profunditat de la màscara candidata).

Finalment, la mesura de la qualitat Q es defineix a partir del valor normalitzat de l'entropia, H_τ , i la complexitat de la màscara, C_m :

$$Q = \frac{H_\tau}{C_m} \tag{3.13}$$

Per tant, per a qualsevol dels dos mètodes, la màscara òptima és la que té el valor més gran de Q . Un cop identificada la màscara òptima, s'utilitza per obtenir la base de regles patró mitjançant el procés de conversió de patrons dinàmics a patrons pseudoestàtics (vegeu la figura 3-6).

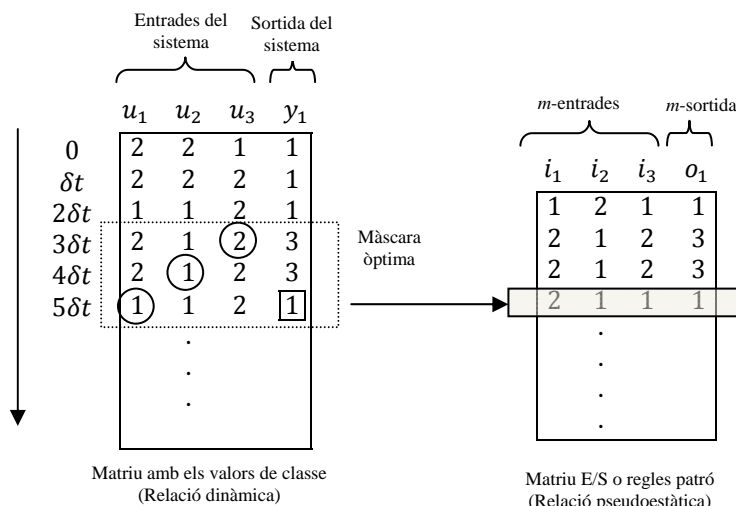


Figura 3-6 Procés per aconseguir la matriu d'E/S (base de regles patró)

La figura 3-6 mostra el procés de conversió de relacions dinàmiques en relacions pseudoestàtiques utilitzant la màscara de l'equació 3.5. A la part esquerra es mostra un fragment de la matriu amb els valors de classe, la primera de les tres matrius que formen el conjunt de dades qualitatives. En l'exemple es mostren les variables d'entrada del sistema: u_1 , u_2 i u_3 , les quals s'han discretitzat en dues classes, mentre que la variable de sortida y_1 s'ha discretitzat en tres classes. El rectangle puntejat simbolitza la màscara que es va desplaçant cap avall, a través de la matriu de valors de classe. Els cercles de la màscara denoten les posicions de les m -entrades, mentre que el quadrat indica la posició de la m -sortida. Els valors de classe es llegeixen a través dels forats de la màscara i es col·loquen en forma consecutiva a la matriu d'entrada/sortida (E/S) o de regles patró. Tal com es veu a la part dreta de la figura 3-6, cada fila

representa una posició de la màscara a través del recorregut que fa per la matriu de valors de classe. Aquests valors s'emmagatzemen a la matriu d'E/S i s'alineen amb l'última fila de la màscara. Cada fila d'aquesta matriu representa un estat qualitatiu pseudoestàtic o regla qualitativa obtinguda a partir de patrons. Per exemple, la regla patró ombrejada de la figura 3-6 es llegeix de la manera següent: «Si la primera m -entrada, i_1 , té un valor de 2 (corresponent a alt); la segona m -entrada, i_2 , té un valor d'1 (corresponent a baix), i la tercera m -entrada, i_3 , té un valor d'1 (corresponent a baix), aleshores la m -sortida, o_1 , pren el valor d'1 (corresponent a baix)».

Tal com s'ha esmentat anteriorment, la màscara juntament amb la base de regles patró configuren el model FIR del sistema en estudi.

3.6 Simulació qualitativa

A partir de la màscara òptima i de la base de regles basada en patrons generada, es prediuen els valors futurs de classe, pertinença i costat. La simulació qualitativa té lloc utilitzant el motor d'inferència que està en el mòdul de simulació qualitativa del FIR. El motor d'inferència utilitza l'algorisme dels 5 veïns més propers (5NN) per generar el valor de predicció més consistent possible amb l'estat actual del sistema. La figura 3-7 mostra aquest procés de manera esquemàtica.

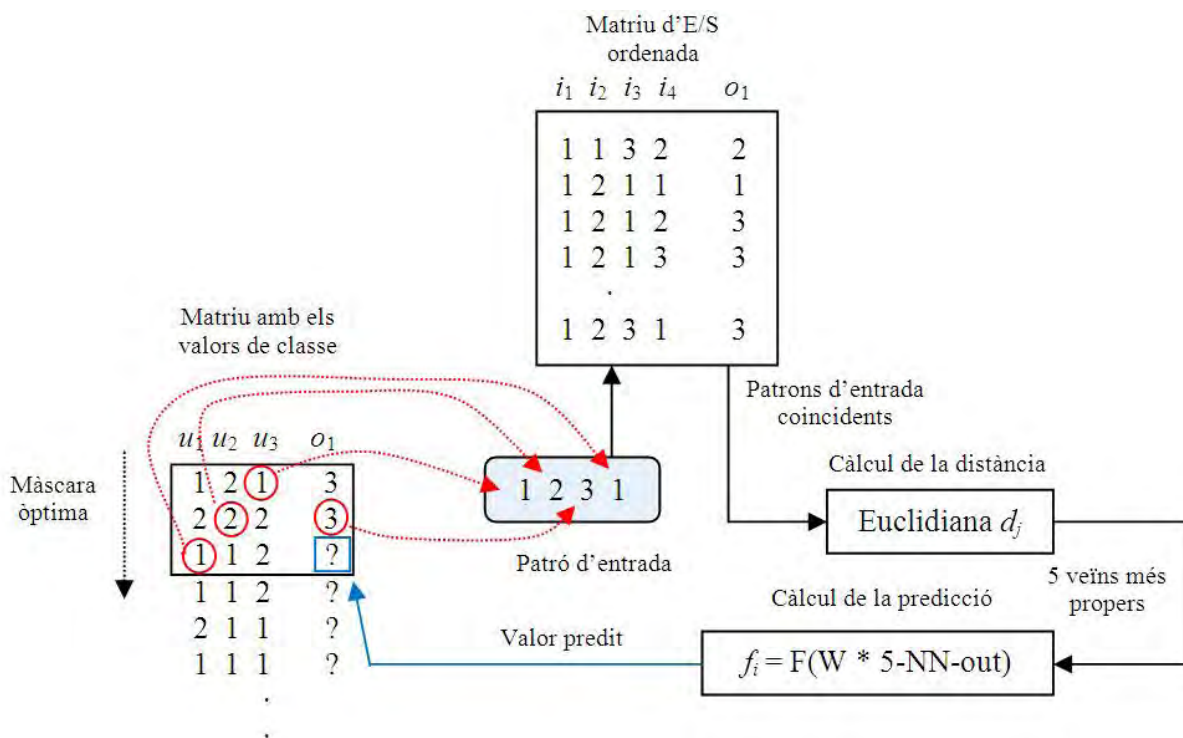


Figura 3-7 Esquema del procés de simulació qualitativa del FIR

La màscara es desplaça per sobre de la matriu qualitativa de classes. Se n'extreuen els valors corresponents a les m -entrades (forats de la màscara) i es forma un patró d'entrada estàtic. Es busquen a la base de regles patró (matriu d'E/S a la figura 3-7) tots els patrons que coincideixin amb el patró d'entrada

actual respecte als valors de classe. Per a tots aquests patrons, se'n calcula la distància respecte al mateix patró i es guarden els 5 que estiguin més propers. Els valors de classe, pertinença i costat de la predicció s'obtenen com una combinació ponderada de les sortides dels 5 veïns més propers seleccionats. El triplet qualitatiu predit es copia a les matrius qualitatives de classe, pertinença i costat, i després es desplaça la màscara una posició cap avall (que correspon a un interval de mostreig) per predir el següent valor.

Per comparar el patró d'entrada actual i tots els patrons de la matriu d'E/S (vegeu la figura 3-7) que coincideixin amb el patró actual en els valors de classe, s'utilitza una funció de normalització sobre cada un dels elements, p_i , del nou patró d'entrada. Hi ha diferents funcions de normalització implementades en el FIR [92], però la més utilitzada és la següent:

$$p_i = Side_i \cdot B \cdot \sqrt{\ln(Memb_i)} + 0,5, \quad (3.14)$$

on $B = 4 \cdot \ln(0,5)^{-1/2}$, $Side$ és el costat i $Memb$ és el valor de la pertinença.

Per a les classes de l'extrem esquerre, la funció es calcula mitjançant l'equació:

$$p_i = C \cdot \sqrt{\ln(Memb_i)}, \quad (3.15)$$

i per a les classes de l'extrem dret:

$$p_i = 1 - C \cdot \sqrt{\ln(Memb_i)}, \quad (3.16)$$

on $C = \ln(0,5)^{-1/2}$. Independentment del rang dels senyals originals, els valors de p_i estan dins del rang 0,0 i 1,0.

Una altra fórmula que s'empra és:

$$p_i = Class_i + Side_i \cdot (1 - Memb_i), \quad (3.17)$$

on $Class_i$ és el valor de la classe.

Els valors p_i corresponents a les diferents variables d'un estat d'entrada es concatenen per formar un vector:

$$p = [p_1, p_2, \dots, p_N], \quad (3.18)$$

assumint que l'estat té N m -entrades. Anomenem el vector p la imatge normalitzada de l'estat d'entrada original. L'anàlisi continua calculant imatges normalitzades per a cada estat d'entrada trobat a la base de regles patró que conté les mateixes classes. Anomenem aquests vectors p_K . Cada vector p_K és diferent, ja que només coincideixen els valors de classe de l'estat d'entrada, però no els valors de pertinença ni els de costat. Finalment, es calcula la norma 2 ($L2$) de les diferències entre el vector p que representa la imatge

normalitzada del nou patró d'entrada i els vectors p_k que corresponen a les imatges normalitzades de les regles patró amb el mateix estat d'entrada:

$$d_k = \|p - p_k\|_2 = \sqrt{\sum_{i=1}^N (p_i - p_{ki})^2}. \quad (3.19)$$

Es conserven les 5 regles patró amb menor d_k , que són els cinc veïns més propers al nou patró d'entrada del qual es vol predir la seva sortida (o conseqüent). La contribució de cada veí a l'estimació de la predicció del nou estat de sortida es du a terme en funció de la seva proximitat. Això s'expressa donant un pes a cada veí en funció de la distància. Els pesos absoluts es poden calcular utilitzant diferents equacions:

— Fórmula de l'Àngela.

$$W_{abs_k} = \frac{(d_{m\grave{a}x.}^2 - d_k^2)}{d_{m\grave{a}x.} \cdot d_k} \quad (3.20)$$

— Fórmula de Budapest.

$$W_{abs_k} = \frac{1}{\frac{d_k}{\sum_{i \forall i} d_i}} \quad (3.21)$$

— Fórmula de Màlaga.

$$W_{abs_k} = \frac{(d_{m\grave{a}x.} - d_k)}{d_{m\grave{a}x.}}, \quad (3.22)$$

on k representa el veí k -èsim i $d_i \leq d_j, i < j; d_{m\grave{a}x.} = d_5$. En el cas que un dels veïns tingui una distància igual a zero, el pes d'aquest veí val 1,0 i el pes dels altres veïns és 0,0. A partir dels valors absoluts dels pesos, es calculen els pesos relatius, que seran nombres entre 0,0 i 1,0, i la seva suma serà sempre 1,0.

$$W_{rel_k} = \frac{W_{abs_k}}{\sum_{\forall k} W_{abs_k}}. \quad (3.23)$$

La predicció de l'estat de sortida a l'espai normalitzat es calcula com una suma ponderada dels estats de sortida dels cinc veïns més propers. D'aquesta manera, l'estat qualitatiu de sortida es pot obtenir utilitzant la fórmula següent:

$$State_{out_{new}} = \sum_{\forall k} W_{rel_k} \cdot (Class_{out_k} + p_{out_k}), \quad (3.24)$$

on $Class_{out_k}$ i p_{out_k} són la classe i la imatge normalitzada dels valors de sortida dels 5 veïns més propers, respectivament. El valor de predicció de classe s'obté mitjançant l'equació següent:

$$Class_{out_{new}} = IFIX(State_{out_{new}}), \quad (3.25)$$

on $IFIX$ és una funció que retorna la part sencera del paràmetre. El valor de predicció de pertinença i de costat s'obtenen utilitzant l'invers de la funció de normalització anterior a partir de:

$$p_{out_{new}} = State_{out_{new}} - Class_{out_{new}}. \quad (3.26)$$

3.7 Regeneració

Finalment, la predicció qualitativa pot ser convertida a dades quantitatives mitjançant el procés de regeneració. Aquest és el procés invers al de la codificació difusa que hem explicat anteriorment.

Després d'obtenir el valor quantitatiu de la predicció, només cal comparar-lo amb les dades originals, cosa que ens permet validar el model qualitatiu. Per calcular l'error de les prediccions generades utilitzem normalment l'error quadràtic mitjà normalitzat per la variància, en percentatge:

$$MSE = \frac{E[(y(t) - \hat{y}(t))^2]}{y_{var}} \cdot 100 \%, \quad (3.27)$$

on y és el valor real i \hat{y} és el valor de predicció, i y_{var} és la variància definida com a:

$$y_{var} = E[y^2(t)] - \{E[y(t)]\}^2. \quad (3.28)$$

No obstant això, hi ha diferents fórmules d'error àmpliament usades en la literatura amb la mateixa finalitat. Per a més detalls de la metodologia FIR, consulteu [28, 105 i 107].

3.8 Mètode millorat de la partició amb igual freqüència

3.8.1 Introducció

La transformació de variables contínues en variables discretes és un problema comú que sorgeix en un gran nombre d'àrees dins del camp de la intel·ligència artificial. L'objectiu és dividir objectivament les dades en grups homogenis de manera que es maximitzi la similitud entre els objectes dins d'un grup i la dissimilitud entre els objectes de grups diferents. El mètode de partició no supervisat suposa que les dades no s'etiqueten amb informació de classe. Aquest és normalment el cas en tractar amb trets dinàmics o variables. Hi ha una gran quantitat de mètodes de partició no supervisats [12, 16 i 91]; un dels més simples és la tècnica de partició amb igual freqüència (EFP, de l'anglès *equal frequency partition*). Consisteix a distribuir les dades del sistema en un nombre predefinit de classes i a mantenir el mateix nombre d'ocurrències en cada classe. El mètode EFP té l'avantatge que és molt simple i, en molts casos,

la distribució de dades obtinguda en les particions o grups és força raonable. Aquest mètode ha estat utilitzat habitualment en el procés de codificació difusa de la metodologia del raonament inductiu difús i, normalment, s'han obtingut bons resultats [22, 28, 106, 105]. Tanmateix, el mètode EFP és sensible a la distribució de les dades, i el mètode de partició només obté bons resultats si la distribució de dades és més o menys uniforme, en el sentit que tots els comportaments possibles del sistema estan representats amb un nombre equiparable d'aparicions.

El FIR, com totes les metodologies de modelització inductiva, es basa en les dades disponibles del sistema que s'està estudiant. Per això cal disposar d'una quantitat rica de dades que representin tots els comportaments possibles del sistema per tal d'identificar un model acurat. Si les dades disponibles de les observacions del sistema representen tots els comportaments possibles (físics) amb un nombre similar d'aparicions, llavors l'ús del mètode EFP dins de la metodologia FIR és realment útil i dona molt bons resultats.

No obstant això, pot succeir que, encara que tots els possibles comportaments estiguessin representats en les dades registrades, cadascun tingui associat un nombre diferent d'aparicions. Per exemple, podria succeir que un comportament concret d'un sistema es registrés amb molta freqüència i que, per tant, es tinguessin moltes dades d'aquesta situació, i que els altres comportaments es registressin poques vegades i que, per tant, estiguessin poc representats en les dades registrades del sistema.

En aquesta secció presentem una millora del mètode EFP que permet reduir, en certa mesura, la dependència de la distribució de les dades. En mostrem la utilitat mitjançant una aplicació de demanda d'aigua en una ciutat determinada.

3.8.2 Mètode millorat de partició amb igual freqüència




Figura 3-8 Paràmetres del mètode EEFP

La idea per millorar el mètode EFP és extremadament simple. El mètode EEFP (*enhanced equal frequency partition*) [53] elimina observacions múltiples d'un mateix patró de comportament determinant

si una observació és significativament diferent d'una altra o no, llavors aplica el mètode EFP al conjunt de patrons significativament diferents amb l'objectiu d'aconseguir un conjunt de llandars o *landmarks* significatiu.

El mètode EEFP ha de tenir en compte dos aspectes pertinents. El primer és decidir quins valors de les dades poden ser considerats iguals. En altres paraules, cal definir un interval, δ , que representi el conjunt d'observacions que són similars i, per tant, que es poden considerar repeticions de la mateixa ocurrència. Això es descriu gràficament a la figura 3-8.

El segon aspecte consisteix a definir el nombre mínim d'observacions similars requerit (mostres que estan dins de l'interval de δ) per tal de considerar que aquest patró de comportament està sobrerrepresentat. Aquest paràmetre, α , també es descriu a la figura 3-8. Si en les dades hi ha un nombre d'observacions similars més gran que α , s'eliminen les observacions redundants. Contràriament, si es troba un conjunt d'observacions similars amb un nombre d'elements inferior a α , es mantenen totes les ocurrències.

Tal com mostra l'exemple de la figura 3-8, tots els valors dins del rang de δ són observacions similars. α indica el nombre mínim d'ocurrències necessàries per assumir que aquest patró de comportament està sobrerrepresentat. És clar en l'exemple que el nombre de valors similars és més gran que α i que, per tant, les observacions redundants (rectangle ombrejat) són eliminades del conjunt de dades.

Es va decidir deixar els valors de δ i α com a paràmetres d'entrada de l'algorisme, perquè els valors adients per a aquests dos paràmetres són molt dependents de les dades. Aquesta solució és útil, ja que permet provar diferents valors d'aquests paràmetres fàcilment i experimentar-hi per trobar els valors més adequats.

Quan s'han eliminat tots els patrons de comportament sobrerrepresentats, s'utilitza el mètode clàssic EFP per determinar els llandars de les classes del conjunt de dades resultant. Els llandars obtinguts s'utilitzen per classificar les dades del sistema original a través de la funció de codificació difusa de la metodologia FIR. Tal com ja s'ha explicat anteriorment, el procés de codificació difusa del FIR converteix els valors quantitius en triplets qualitius.

3.8.3 Sistema de distribució d'aigües

El sistema que s'ha de modelitzar és la xarxa de distribució d'aigües de la ciutat de Sintra (Portugal) [53]. L'objectiu és portar aigua de fonts i rius, per al consum humà, a diferents destinacions on s'ha de subministrar. És fonamental que aquesta aigua arribi als punts de destinació amb una pressió adequada. Per assolir aquests objectius, calen dipòsits d'acumulació a una certa alçada, elements que regulin el cabal (vàlvules) i estacions de bombeig.

Des del punt de vista de control, cal regular bombes i vàlvules, i en els casos en què els dipòsits estan en punts molt alts també cal controlar les turbines que aprofiten l'energia cinètica. L'estat del sistema està

representat pels cabals, les pressions i els nivells dels dipòsits. És una xarxa emmallada i se'n coneix la topologia, la predicció de la demanda, les característiques de les canonades i els nivells dels dipòsits. Mitjançant balanços de càrrega a les malles i els cabals als nusos, es poden calcular les pressions i els cabals en tots els punts. Tenim, així, un model en règim permanent (càlculs instantanis).

Per aconseguir un model pseudodinàmic (en control, es treballa amb un període de mostreig de l'ordre d'una hora) s'encadenen càlculs instantanis successius considerant que les entrades del model són els nivells respecte del temps als dipòsits, els consums i l'estat de les bombes. L'esquema simplificat de la xarxa es mostra a la figura 3-9.

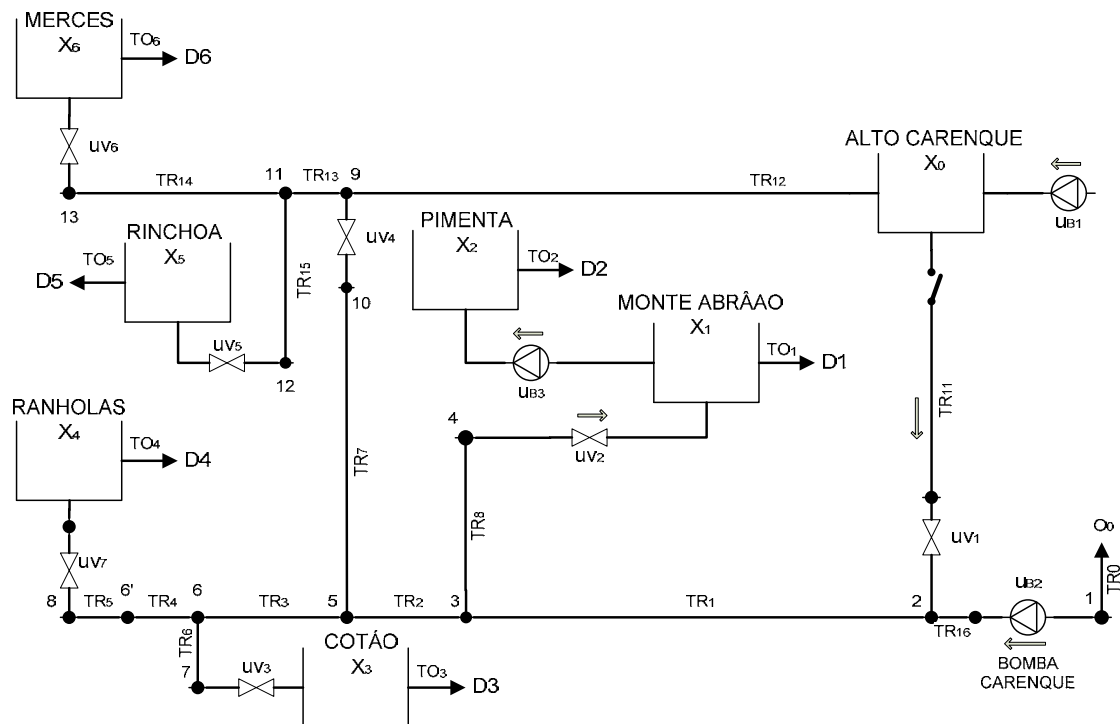


Figura 3-9 Diagrama simplificat de la xarxa de distribució d'aigües de Sintra (Portugal)

El model simplificat d'aquesta xarxa de distribució d'aigües està format per 6 dipòsits que han de ser capaços de donar l'aigua sol·licitada a cadascuna de les demandes. Aquests dipòsits s'anomenen: Monte Abráao, Pimenta, Cotáo, Ranholas, Rinchoa i Mercés. El dipòsit de l'Alto Carenque es considera que és un subministrament inesgotable d'aigua.

Aquesta xarxa de distribució d'aigües va ser utilitzada en el projecte europeu de Waternet Esprit IV, projecte núm. 22186 [67]. L'únic element d'aquesta xarxa de què es disposa són les dades reals de les demandes de cadascun dels dipòsits. Les altres dades, com ara el control de les vàlvules, el nombre de bombes que funcionen i les pressions de cadascun dels nodes, estan extretes d'un simulador creat pel projecte Waternet.

Podem resumir la xarxa d'aigües (figura 3-10) com un sistema en què les entrades són les demandes de la xarxa, el control de les vàlvules i el nombre de bombes en funcionament. Com a sortides del sistema tenim la pressió que hi ha en cadascun dels nodes.




Figura 3-10 Entrades i sortides del sistema de la xarxa de distribució d'aigües de Sintra (Portugal)

Disposem dels resultats de la simulació quantitativa del sistema de tot l'any 1995 i la primera meitat de l'any 1996, amb un període de mostreig d'una hora. Això correspon a 13.128 dades de cadascun dels senyals. Per tal d'aconseguir els models qualitius, utilitzem només les 5.000 primeres dades, mentre que part de les altres s'utilitzen per validar els models.

3.8.4 Codificació difusa de les variables del sistema

El primer pas per obtenir els models de pressió és codificar les variables d'entrada i sortida mitjançant el procés de codificació difusa de la metodologia FIR. Amb aquesta finalitat, s'han utilitzat els mètodes EFP i EEFP per calcular els llimdars de totes les variables del sistema. Les primeres variables que s'han de codificar són les demandes d'aigua. La part superior de la figura 3-11 mostra el senyal de la demanda d'aigua D1 que correspon al dipòsit de Monte Abrâao.

El senyal va des d'un valor de 34 l/s (litres per segon) fins a un valor de 400 l/s, a excepció d'una hora específica en què la demanda és més gran que el límit superior. A la part inferior de la figura 3-11 es mostren les dades ordenades. Aquest gràfic es pot interpretar com la funció de distribució d'un histograma. Per exemple, hi ha 2.000 mostres amb una demanda d'aigua de menys de 200 l/s. El senyal resultant és força lineal, excepte l'interval que conté els valors extrems, situat a la part dreta del gràfic.

Classe	Llimdars D ₁ (EFP)		nº d'elements
1	34	172,3	1.666
2	172,3	244,3	1.666
3	244,3	557,5	1.668

Taula 3-1 Llimdars de les tres classes de la demanda D₁ obtinguts utilitzant el mètode EFP

Es decideix codificar les sis variables de la demanda en 3 classes cadascuna. Tres classes sembla que són suficient per capturar el comportament dinàmic d'aquests senyals. Una vegada s'ha definit el nombre de classes, es pot aplicar tant el mètode EFP com l'EEFP per obtenir els llimdars de les classes. Per calcular els llimdars quan s'utilitza el mètode EFP, cal dividir el senyal ordenat en tres parts, cadascuna de les quals conté el mateix nombre de mostres. Per tant, el llimdar inferior de la classe 1 és el valor més petit del senyal ordenat, el llimdar superior de la mateixa classe és el valor que correspon a un terç del nombre total de mostres, i així successivament. Els llimdars de les 3 classes quan s'utilitza el mètode EFP per al senyal

de la demanda d'aigua del dipòsit D1 es mostren a la taula 3-1, i són representats com a línies horitzontals a la figura 3-11b. La tercera columna mostra el nombre de mostres dins de cada classe.

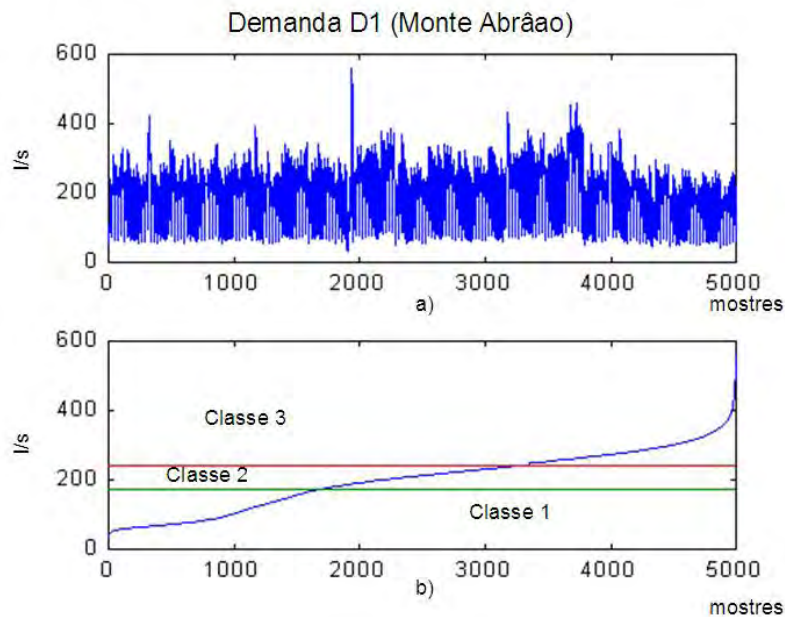


Figura 3-11 Distribució de les dades de la demanda d'aigua de D1 (dipòsit de Monte Abráao). a) Senyal original de la demanda d'aigua; b) senyal ordenat de la demanda d'aigua

Per calcular els llindars quan s'utilitza el mètode EEFP, cal determinar els valors dels paràmetres δ i α (vegeu la figura 3-8). El criteri que s'ha adoptat en aquest cas consisteix a considerar que dues mostres són similars si difereixen menys de l'1 % respecte del rang d'amplitud de totes les observacions. Per tant, el valor δ , en aquest cas, és de l'1 %. D'altra banda, s'ha considerat que un valor α del 10 % és acceptable tenint en compte el nombre total de mostres disponibles.

L'algorisme EEFP s'aplica amb aquests valors dels paràmetres i s'obté com a resultat el senyal original ordenat sense els valors dels patrons de comportament sobrerrepresentats. Els llindars de les classes es calculen a partir del nou senyal mitjançant el mètode EFP, tal com ja s'ha explicat anteriorment. Com es veu al gràfic inferior de la figura 3-11, hi ha poques observacions similars. Per tant, en aquest cas, els llindars obtinguts en aplicar el mètode EFP i l'EEFP són exactament iguals. El mateix procés s'ha utilitzat per obtenir els llindars per als senyals de les altres demandes d'aigua. Tal com ha passat en el cas de l'embassament del Monte Abráao, les dades de la demanda d'aigua per als embassaments de Pimenta, Cotáao, Ranholas, Rinchoa i Mercedes no mostren comportaments excessivament representats i, per tant, l'ús del mètode EFP genera una codificació difusa raonable per a aquests senyals.

Les següents variables d'entrada que s'han de codificar són les 7 vàlvules en les quals es pot regular l'obertura entre el 0 % i el 100 %. Les observacions registrades de la segona vàlvula es presenten a la figura 3-12.

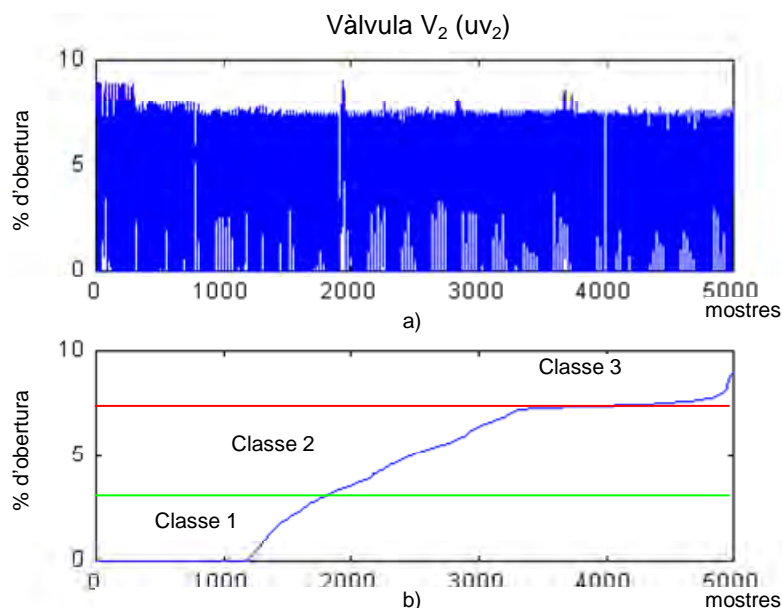


Figura 3-12 Distribució de les dades de la vàlvula 2. a) Senyal original de la vàlvula 2; b) senyal ordenat de la vàlvula 2

A la part superior d'aquesta figura es presenta la trajectòria observada de la vàlvula. Tal com es pot veure, la vàlvula opera amb diferents graus d'obertura entre el 0 % i el 100 %. A la part inferior de la mateixa figura es mostren les dades ordenades. Hi ha un elevat nombre d'observacions (més de 1.000) amb una obertura del 0 %. Per tant, quan s'utilitza el mètode EFP, la codificació difusa es distorsiona a causa de la sobrerrepresentació d'aquest patró de comportament. En aquest cas, es decideix codificar els senyals de les set vàlvules en tres classes, tal com s'ha fet abans amb els senyals de les demandes. La Taula 3-2 mostra els llimars de la segona vàlvula obtinguts amb el mètode EFP.

Classe	Llimars V ₂ (EFP)		nº d'elements
1	0,01	2,68	1.666
2	2,68	7,19	1.665
3	7,19	8,97	1.669

Taula 3-2 Llimars de les tres classes de la vàlvula V₂ obtinguts utilitzant el mètode EFP

En aquest cas, la primera classe representa els valors de fins a un 2,68 % d'obertura, la majoria dels quals corresponen a un 0 % d'obertura. A la figura 3-12b es mostren gràficament aquests llimars. Aquesta situació no és desitjable perquè és evident que es tracta d'una representació excessiva d'aquest comportament del sistema. Els llimars obtinguts amb el mètode EFP per al senyal de la segona vàlvula es mostren a la taula 3-3. L'aplicació del mètode EFP permet obtenir una distribució més representativa de les dades dins de les classes. Ara la classe 1 representa els valors de fins a un 4,73 % d'obertura i és una classe amb una representació més acurada del concepte lingüístic *poca obertura*.

Classe	Llindars V_2 (EEFP)		Núm. d'elements
1	0,01	4,73	2.383
2	4,73	7,28	1.199
3	7,28	8,97	1.418

Taula 3-3 Llindars de les tres classes de la vàlvula V_2 obtinguts utilitzant el mètode EEFP

Les últimes variables d'entrada que cal codificar són l'estat de les bombes. En aquest sistema de distribució d'aigües, només es té accés al control de dues de les tres bombes que hi ha. Aquestes bombes són la U_{B2} , que porta aigua al node 2, i la U_{B3} , que porta aigua al dipòsit de Pimenta (demanda D_2).

Cadascuna d'aquestes bombes té associats dos motors. El control dels motors és del tipus tot o res, és a dir, que només poden estar engegats o parats. Per aquest motiu, la codificació difusa que es proposa per a les bombes és una codificació en tres estats, en què cadascun dels estats representa una de les tres possibles situacions:

- Classe 1 → Cap motor engegat
- Classe 2 → Un motor engegat
- Classe 3 → Dos motors engegats




Figura 3-13 Distribució de les dades de la pressió en el node 5. a) Senyal original de la pressió en el node 5; b) senyal ordenat de la pressió en el node 5

Per tant, en aquest cas, no s'utilitza ni el mètode EFP ni l'EEFP per determinar els llindars d'aquestes tres classes.

La codificació difusa dels senyals de sortida que corresponen a 12 variables de pressió es fa, també, en tres classes. La pressió es mesura en metres de columna d'aigua. La figura 3-13 mostra les dades de distribució de la pressió al node 5.

En aquest node la pressió pren valors entre 70 i 100 metres de columna d'aigua. Si analitzem les dades ordenades (part inferior de la figura 3-13), observem que més d'una tercera part del nombre total de

mostres tenen un valor de 98,8 metres de columna d'aigua. Per tant, si s'utilitza el mètode EFP per calcular els lindars de les classes, els valors de 98,8 es troben en dues classes diferents. Aquesta situació és òbviament indesitjable i no és permesa en el procés de codificació difusa de la metodologia FIR. Aquest és el motiu pel qual el lliandar superior de la classe 2 i el lliandar inferior de la classe 3, que tenen el mateix valor, es modifiquen de manera que totes les observacions 98,8 s'incloguin en la classe 3. Els lindars obtinguts es presenten a la taula 3.4 i es mostren gràficament a la part inferior de la figura 3-13.

Classe	Lliandar N ₅ (EFP)		Núm. d'elements
1	72,74	95,95	1.665
2	95,95	98,70	1.057
3	98,70	98,80	2.278

Taula 3-4 Lindars de les tres classes del node N₅ obtinguts utilitzant els mètodes EFP

També en aquest cas, el mètode EEFP s'utilitza per calcular els lindars de les classes. A causa de l'elevat nombre de mostres repetides en les dades (figura 3-13), s'espera que l'algorisme EEFP aportï una millor distribució de les dades dins de les tres classes. La taula 3-5 conté els lindars obtinguts en utilitzar el mètode EEFP.

Classe	Lliandar N ₅ (EEFP)		Núm. d'elements
1	72,74	93,84	979
2	93,84	96,89	979
3	96,89	98,80	3043

Taula 3-5 Lindars de les tres classes del node N₅ obtinguts utilitzant els mètodes EEFP

En aquest punt, s'han obtingut els lindars de totes les variables d'entrada i sortida. Ara es pot aplicar el procés de codificació difusa de la metodologia FIR a cada variable per tal d'obtenir les representacions qualitatives dels senyals. Tal com s'ha explicat abans, la funció de codificació difusa del FIR converteix cada valor quantitatiu en un triplet qualitatiu que conté la classe, la pertinença i el costat (figura 3-4). Amb les dades qualitatives disponibles, es pot iniciar la identificació dels models qualitatius de la pressió.

3.8.5 Identificació dels models de pressió

El procés d'identificació del model qualitatiu de la metodologia FIR és el responsable de trobar les relacions de causalitat espacial i temporal entre les variables del sistema i d'obtenir el millor model que representi el sistema, tal com s'ha explicat en la secció 3.5

En aquest cas, el procés d'identificació qualitativa del FIR s'utilitza per obtenir dos models per a cadascuna de les 12 variables de pressió. El primer model s'identifica a partir de les dades qualitatives obtingudes utilitzant el mètode EFP per calcular els lindars de les classes, mentre que el segon model s'identifica a partir de les dades qualitatives obtingudes a partir del mètode de classificació EEFP. Una vegada s'han aconseguit els millors models que identifiquen cada variable, s'utilitza la funció de la predicció difusa de la metodologia FIR per predir un subconjunt de les dades no utilitzades en el procés

d'identificació. Els errors de predicció obtinguts pels diferents models es calculen mitjançant l'error quadràtic mitjà en percentatge presentat a l'equació 2.27.

El model de pressió obtingut per al node 5, utilitzant el mètode EFP per calcular els llinars, es descriu a l'equació 3.29.

$$P_5(t)_{EFP} = \tilde{f}(V_4(t); V_6(t); P_5(t - 1); P_5(t - 24)) \quad (3.29)$$

En aquesta fórmula, la màscara (millor estructura del model FIR) es representa en un format d'equació simplificada. L'equació indica que el valor actual de la pressió al node 5 depèn del valor de la quarta vàlvula en l'instant actual, del valor de la vàlvula sis també en l'instant actual i dels valors de la pressió del node 5 una hora abans i un dia abans. En l'equació 3.29, \tilde{f} representa una relació qualitativa. La qualitat associada a aquest model és de 0,7492.

El model presentat a l'equació 3.29 s'utilitza per predir la pressió al node 5 durant tot un dia (24 mostres). No té sentit en aquesta aplicació fer la predicció de més d'un dia, perquè un dia és suficient per al propòsit de controlar les variables d'entrada de manera òptima. La part superior de la figura 3-14 mostra els senyals real i predit de la pressió al node 5 quan s'utilitza el model descrit a l'equació 3.29. La línia contínua representa el senyal mesurat (real), mentre que la línia discontinua representa el senyal predit pel model FIR. L'error MSE percentual (vegeu l'equació 3.29) que s'obté és de 13,31 %.

Com es veu a la figura 3-14, el senyal predit segueix la corba real fins a cert punt. És evident que la predicció obtinguda durant les primeres 9 hores és bastant pobre.

El model de pressió del node 5 obtingut amb el FIR quan s'utilitza el mètode EFP per calcular els llinars es descriu a l'equació 3.30.

$$P_5(t)_{EFP} = \tilde{f}(V_4(t); V_4(t - 15); P_5(t - 1); P_5(t - 24)) \quad (3.30)$$

El model descrit a l'equació 3.30 es diferencia, en un dels components, del model obtingut pel mètode clàssic EFP. Noteu que ara la variable de sortida actual depèn del valor de quinze hores abans de la vàlvula quarta i del valor d'aquesta mateixa vàlvula en l'instant actual. La qualitat associada al nou model és 0,7765, és a dir, lleugerament superior a la qualitat obtinguda pel model anterior.

El nou model s'utilitza per predir les mateixes dades que en el cas anterior, els resultats de predicció es mostren al gràfic inferior de la figura 3-14. Com es veu a la figura, la predicció que s'obté és més precisa i dona com a resultat un error MSE de només el 3,24 %, molt inferior que l'obtingut amb el model FIR, que basa la codificació difusa en el mètode EFP. És evident que l'ús del mètode EFP ajuda a obtenir una distribució de les classes més raonable en aquesta aplicació, la qual cosa comporta una millor discretització i un model més precís.




Figura 3-14 Predicció de la pressió en el node 5: (a) mètode EFP, (b) mètode EEFP

Els errors de predicció calculats pels models de pressió en tots els 12 nodes es mostren a la taula 3-6. La segona columna de la taula conté els errors MSE en percentatge de predicció obtinguts quan s'aplica el mètode EFP per calcular els límits de les classes de totes les variables del sistema. Tenint en compte que els errors estan en percentatge, els resultats obtinguts són força acceptables, excepte als nodes 4, 5 i 9, per

	EFP	EEFP
Node 1	3,0602 %	1,1269 %
Node 2	2,5627 %	1,5212 %
Node 3	2,2279 %	2,5324 %
Node 4	13,3112 %	3,2376 %
Node 5	21,0761 %	3,3052 %
Node 6	3,4005 %	1,2636 %
Node 7	0,9704 %	0,9838 %
Node 8	1,2997 %	0,4703 %
Node 9	13,1315 %	2,0776 %
Node 10	0,4109 %	0,1219 %
Node 11	0,4109 %	0,2103 %
Node 12	0,3999 %	0,2429 %

Taula 3-6 MSE en percentatge de les prediccions de les pressions dels nodes 1-12

als quals dona valors superiors al 10 %. Els resultats obtinguts quan s'utilitza el mètode EEFP es presenten a la tercera columna de la mateixa taula. Tal com es veu, els errors s'han reduït considerablement als nodes 4, 5 i 9. No obstant això, els errors de la majoria dels altres models també són inferiors als obtinguts amb el model FIR amb EFP.

Una descripció més acurada d'aquest sistema s'inclou a [52].

3.9 Conclusions

Aquest capítol estableix les bases de la metodologia del raonament inductiu difús. Es descriuen detalladament els quatre pilars de la metodologia: la codificació difusa, el modelització qualitativa, la simulació qualitativa i la regeneració. La funció de codificació difusa permet convertir els senyals quantitius en els homòlegs qualitius. Aquest procés és el primer pas per obtenir el coneixement qualitatiu sobre el sistema en estudi. L'anàlisi de la màscara òptima permet determinar les relacions causals, tant espacials com temporals, entre un conjunt de variables relacionades. Una màscara òptima pot ser vista com una mena d'extractor de característiques o selector de variables pertinents. Les sortides futures del sistema es poden predir mitjançant el procés de predicció. Aquest procés no obté només el futur valor de classe, sinó també el valor de pertinença i de costat. Finalment, els triplets qualitius de sortida es poden convertir de nou en senyals quantitius mitjançant la funció de regeneració.

En la segona part d'aquest capítol, es presenta una millora, anomenada *mètode EEFP*, del mètode clàssic de la partició amb la mateixa freqüència (EFP). El mètode EEFP permet obtenir una millor distribució de les dades a les classes, mentre que es manté la senzillesa del mètode EFP. El nou algorisme és especialment útil en les situacions en què les diferents conductes del sistema no estan representades en les dades en un nombre similar de successos. Es demostra la utilitat del FIR i del nou mètode de partició de dades mitjançant un exemple complex, la xarxa de distribució d'aigua d'una ciutat de Portugal. Els mètodes EFP i EEFP s'utilitzen en el procés de codificació difusa de la metodologia FIR, i es comparen des del punt de vista del poder de predicció dels models identificats a partir de les dades codificades. En aquesta recerca es demostra que l'ús del mètode EEFP permet a la metodologia FIR sintetitzar els models que millor representen el comportament del sistema. Els errors de predicció obtinguts utilitzant el mètode EEFP són més baixos que els obtinguts quan s'usa el mètode clàssic EFP.

4 Sistema de monitoratge de fallades

Resum: aquest capítol tracta de dues de les tasques principals dels sistemes de monitoratge de fallades (FMS, de l'anglès fault monitoring system): la detecció de fallades i el diagnòstic de fallades. Durant la detecció, l'FMS ha de reconèixer que el comportament del sistema és anormal i, per tant, que no està funcionant correctament. Durant el diagnòstic de fallades, l'FMS ha de concloure quina mena de fallada ha tingut lloc. L'objectiu principal d'aquest capítol és presentar, en el context del sistema de monitoratge de fallades basat en el FIR (FIRFMS), una nova tècnica de detecció anomenada envolupant i una millora del mètode de diagnòstic basat en la mesura d'acceptabilitat del model. Les dues contribucions permetran que el FIRFMS sigui més robust i fiable a l'hora de detectar les fallades i en el procés de diagnòstic. Per demostrar l'eficiència de la tècnica de l'envolupant i de la mesura d'acceptabilitat del model, el FIRFMS millorat s'aplica a tres sistemes d'àrees molt diferents. El primer correspon a un model d'un circuit elèctric utilitzat amb anterioritat amb aquesta finalitat en la literatura. El segon és un sistema biomèdic, el sistema nerviós central de control humà (SNC). És el primer intent d'aplicar el FIRFMS per donar suport a la presa de decisions mèdiques. El tercer correspon a la demanda d'un sistema de distribució d'aigua. El circuit elèctric s'utilitza per demostrar que el nou FIRFMS és superior a l'anterior FIRFMS. El sistema biomèdic i el de demanda d'aigua es presenten per mostrar el bon funcionament del nou FIRFMS.

4.1 Introducció

En els darrers anys s'ha registrat una demanda creixent de sistemes de monitoratge de fallades (FMS) com a conseqüència de l'augment de la complexitat dels sistemes d'enginyeria moderna, que es basen en arquitectures de control cada vegada més complexes i sofisticades. L'augment de la complexitat implica un augment del nombre de possibles fallades i de la freqüència d'ocurrència d'aquestes. En conseqüència, les funcionalitats que es requereix que tingui l'FMS també han crescut amb el temps. Actualment, un FMS ha de ser capaç de (almenys) detectar, identificar i explicar les diferents fallades que poden tenir lloc en un sistema al llarg del temps.

En les últimes dècades, la recerca sobre detecció de fallades i resolució de problemes dels sistemes dinàmics ha adquirit cada vegada més consideració. Aquest desenvolupament s'ha estimulat per tres factors principals:

1. La tendència cap a l'automatització de major complexitat, juntament amb l'exigència que aquests sistemes més complexos ofereixin les mateixes garanties, és a dir, que siguin igual de fiables, segurs i disponibles. Tenint en compte que:
 - La fiabilitat es refereix al comportament del sistema davant de les fallades internes, és a dir, sempre que es detecta una fallada irrecuperable en el sistema, l'FMS ha de dur a terme un tancament correcte del sistema, de manera que ha d'evitar que pateixi cap dany permanent i ha de garantir que no causi cap perill a éssers humans o a l'entorn.
 - La seguretat es refereix al comportament del sistema davant de les fallades externes, és a dir, si l'operador del sistema jutja malament una situació i emet una ordre potencialment perillosa, l'FMS ha d'evitar que el sistema reaccioni d'aquesta manera nociva.

- La disponibilitat es refereix a la quantitat de temps que el sistema està fora de servei per manteniment o reparació. Aquest factor està molt relacionat amb el temps mitjà entre fallades.
2. Les grans tècniques de control introduïdes per la teoria de control modern fan que cada vegada sigui més complicada la tasca del monitoratge de les fallades. El problema és que, a més a més de les tasques principals de control s'ha de garantir l'estabilitat i la precisió de la planta; és una tasca important dels controladors insensibilitzar el comportament del sistema respecte de factors externs incontrolables (supressió de les pertorbacions), així com respecte dels factors interns incontrolables (variabilitat de paràmetres i envelliment). Evidentment, el controlador no té manera de distingir entre aquests factors i les petites anomalies que l'FMS coneix. Així, el sistema de control té una tendència a reduir els efectes mesurables de petites fallades, cosa que contraresta, així, els esforços de l'FMS per detectar fallades. Com més feina té el controlador, més difícil és detectar la primera fallada, llevat que siguin del tipus catastròfic.
 3. Les tècniques derivades de la intel·ligència artificial, com ara els sistemes basats en el coneixement, els sistemes connexionistes i els raonadors qualitius profunds basats en models, han proporcionat als enginyers de sistemes una gamma completa d'eines noves i poderoses que permeten aguditzar la sensibilitat de l'FMS i el poder de resolució; per tant, ofereixen recursos per a un millor i més fiable monitoratge de fallades de plantes cada cop més complexes, per compensar les dificultats abans esmentades, causades per la millora de la tecnologia de control.

Hi ha una intensa activitat investigadora en aquest àmbit, que inclou tant les aproximacions quantitatives com les qualitatives. Les aproximacions quantitatives es basen principalment en tècniques estadístiques, la lògica de primer ordre, la teoria de control, els models matemàtics i la simulació per ordinador [15, 64, 71, 87, 114, 116]. L'inconvenient principal de les tècniques quantitatives és que operen en models de planta quantitius i formulats amb precisió que no sempre estan disponibles. A més, els operadors humans de les plantes solen confiar en el coneixement heurístic, que és més senzill de capturar amb les metodologies qualitatives. Hi ha una gran quantitat de recerca duta a terme en l'àmbit de l'FMS qualitatiu, principalment, fent ús de metodologies de la intel·ligència artificial en les àrees de sistemes experts i de *soft computing* (informàtica tova), és a dir, xarxes neuronals, lògica difusa i algorismes evolutius [13, 20, 31, 58, 79, 98, 134].

En aquest capítol, s'utilitza la metodologia de raonament inductiu difús (FIR) amb la finalitat d'introduir nous enfocaments per detectar i diagnosticar les fallades del sistema. El FIR va ser utilitzat per primera vegada com una metodologia de monitoratge de fallades per A. de Albornoz [37]. Des de llavors, les fases de detecció i de diagnòstic s'han millorat, tal com es mostra en aquest capítol. En aquesta secció, es proporciona una explicació esquemàtica de la detecció i el procés de diagnòstic introduïts per de De Albornoz. A continuació, es presenta la nova tècnica de l'envolupant i la mesura d'acceptabilitat del

model introduïdes en aquesta tesi. Al final del capítol es presenten tres aplicacions en diferents àmbits per demostrar la viabilitat del nou enfocament.

4.2 Sistema de monitoratge de fallades amb FIR

El procés de detecció de fallades mitjançant el raonament inductiu difús, cal descompondre'l en dues fases diferents:

- Fora de línia.
- En línia.

La fase de fora de línia inclou els processos que s'han de dur a terme abans que comenci el procés d'inferència qualitativa, és a dir, els processos de la codificació difusa i la modelització qualitativa descrits en el capítol anterior, així com la caracterització de les fallades de l'FMS que ha de ser capaç de reconèixer. Les principals tasques de la fase de fora de línia són:

- Seleccionar les variables d'entrada/sortida.
- Determinar les relacions causals i temporals de les variables.
- Identificar els models qualitius.

L'única condició per dur a terme aquests processos fora de línia és que s'ha de disposar de coneixement sobre el comportament del sistema.

En la fase en línia, l'FMS està acoblat a un sistema o model dinàmic quantitatiu per tal de dur a terme la tasca de detectar un comportament anòmal del sistema.

4.2.1 Selecció i agrupació causal de les variables

El procés per identificar les variables rellevants pel raonador i la utilització d'aquestes variables constitueixen un dels problemes més importants i difícils de resoldre a l'hora de dissenyar un sistema de supervisió i suport a la presa de decisions. Per resoldre aquest problema, s'ha utilitzat la tècnica d'anàlisi de la màscara òptima, descrita en el capítol 3, que permet identificar els grups de variables causalment relacionades que es poden aïllar com a subsistemes. El coneixement estructural del sistema físic pot ajudar, però els subsistemes identificats no necessàriament han de coincidir amb els subsistemes físics. Les variables que constitueixen un subsistema de raonament són seleccionades mitjançant les metodologies de cerca de les màscares òptimes sobre la base de similituds pel que fa a les característiques de freqüència i a les relacions causals més que sobre la base de la topologia geomètrica.

L'anàlisi de la màscara òptima ja s'ha explicat en el capítol 3; tanmateix, encara no se n'ha tractat l'ús per seleccionar el conjunt mínim de variables més significatives. Aquesta selecció es fa mitjançant una comparació entre les diferents relacions qualitatives possibles, cadascuna amb una combinació diferent de

les variables, és a dir, una comparació entre les diferents màscares òptimes, una per a cada combinació de variables. La màscara amb la millor qualitat no representa el millor model qualitatiu, però sí que representa la relació més forta entre les variables d'entrada i sortida des del punt de vista del poder de predicció. L'objectiu és trobar unes correlacions qualitatives fortes (no lineals) entre les entrades i les sortides, i les correlacions febles entre les entrades, de manera que les relacions que resulten per a les sortides siguin tan deterministes com sigui possible, cosa que evita redundàncies innecessàries entre les entrades altament relacionades.

Si el conjunt de variables seleccionades no representa prou bé el subsistema que caracteritza, les màscares òptimes resultants tenen poques interaccions entre les variables. El mateix es pot observar si les variables triades estan massa fortament correlacionades, ja que, en aquest cas, la complexitat de l'espai de cerca ha crescut significativament, sense que augmenti la quantitat d'informació disponible.

4.2.2 Detecció de fallades

La metodologia FIR prediu el comportament del sistema en termes qualitatius. Aquest comportament es compara amb els valors reals obtinguts d'un model quantitatiu del sistema o del sistema físic en si. Com que la predicció es basa en el comportament recent del sistema, és una mica lent detectar petits canvis en els paràmetres del sistema o una petita deriva en l'estat estacionari, però una fallada transitòria o un canvi estructural es detecten immediatament, ja que el comportament del sistema ja no es pot predir amb la mateixa màscara òptima que s'havia determinat en l'estructura prèvia del sistema.

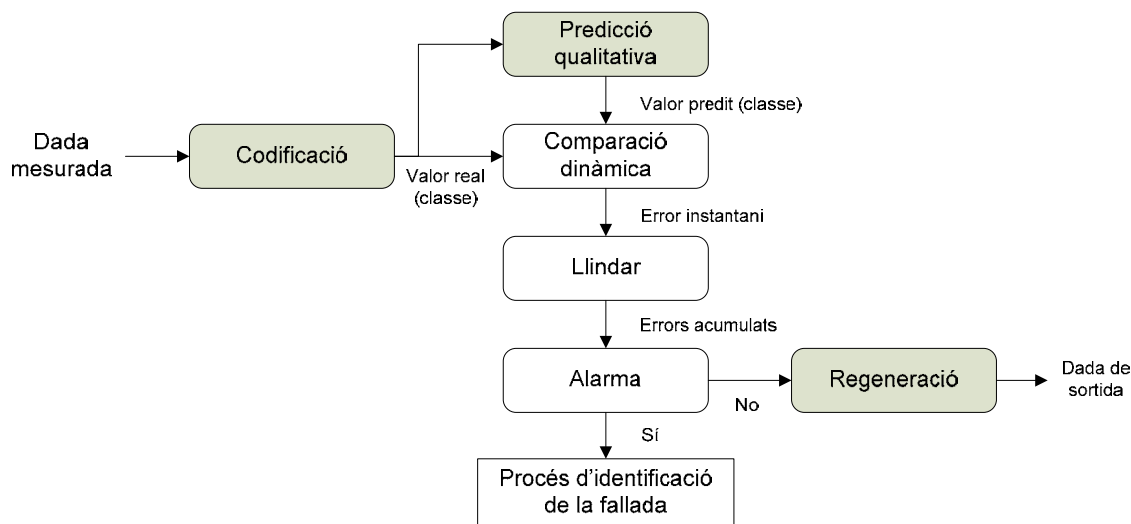


Figura 4-1 Procés de detecció de fallades en FIR (De Alborno)

El procés de detecció de fallades en el context de la metodologia FIR es descriu a la figura 4-1. Les caixes fosques representen els processos del FIR, mentre que els quadres blancs constitueixen el procediment de detecció d'errors. Les dades mesurades en el sistema es converteixen en triplets qualitatius (classe, pertinença i costat) per mitjà del procés de codificació difusa del FIR. El procés de predicció infereix el

valor següent com un triplet qualitatiu a partir de les dades d'entrada qualitatives tot utilitzant el model (la màscara i la matriu de comportament), que representa el comportament actual del sistema. El procediment de detecció funciona de la manera següent:

- La classe del valor de sortida de la predicció es compara amb la classe del valor real de la sortida. La comparació es fa restant la classe del valor real amb la del valor predit. El resultat d'aquesta resta es denomina *error instantani*.
- Els errors instantanis s'emmagatzemen en una matriu a la qual s'aplica un filtre d'error. El filtre d'error acumula els errors instantanis sobre una finestra de temps mòbil amb una grandària predefinida. Aquesta finestra es desplaça sobre la matriu d'error, i els errors instantanis que es troben dins d'aquest interval de temps se sumen per formar l'error acumulatiu.
- El modelitzador ha d'especificar un llindar i quan els errors acumulats el sobrepassen es dispara una alarma per assenyalar que ha tingut una fallada.

4.2.3 Diagnòstic de la fallada

Quan s'ha detectat la fallada, cal diagnosticar-la. Això s'aconsegueix amb la metodologia FIR a través del procés de diagnòstic que es presenta a la figura 4-2. El procediment de diagnòstic de la fallada funciona de la manera següent:

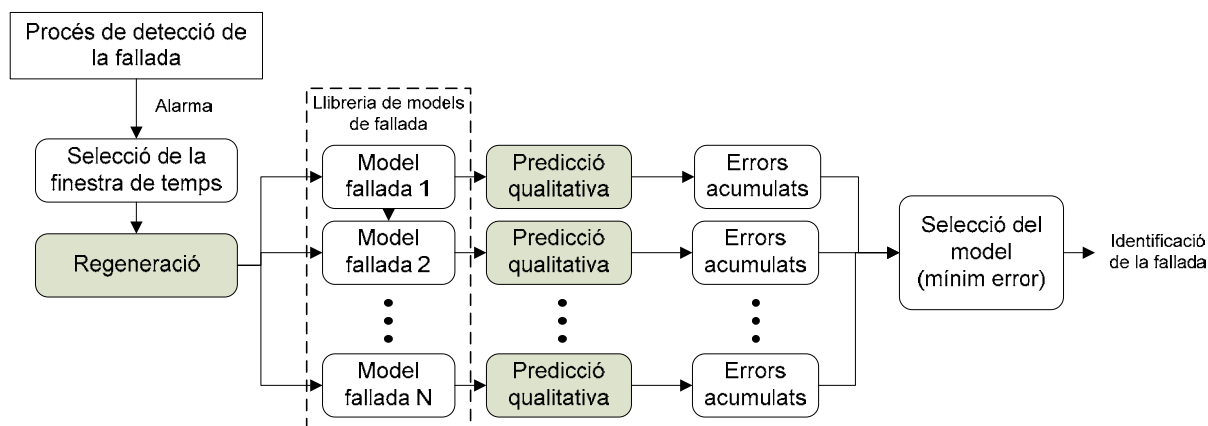


Figura 4-2 Procés de diagnòstic de la fallada de FIR (De Alborno)

- Una vegada que l'alarma s'ha activat, perquè s'ha detectat un comportament anormal, se selecciona una segona finestra de temps. La mida d'aquesta finestra defineix el nombre de valors de predicció que s'utilitzaran per diagnosticar la causa que l'ha generat. Per això, la segona finestra de temps guia la predicció durant el procés de diagnòstic. Com més petita és la finestra de temps, més ràpida és la identificació del model.

- Per a cada model de fallada emmagatzemat a la biblioteca de models de fallada, es fa una predicció del comportament del sistema mitjançant el procés de predicció difusa del FIR de la durada indicada per la finestra de temps escollida.
- La predicció dels errors generats per a cadascun dels processos de predicció s'acumulen. Per tant, cada model de fallada emmagatzemat a la llibreria té associat un error acumulatiu. El model amb el menor error acumulat és el que se selecciona com el que millor representa el nou comportament del sistema i, en conseqüència, la fallada detectada ha estat diagnosticada.

4.2.4 Limitacions del sistema de monitoratge de fallades

En la metodologia introduïda per [37] i explicada breument en aquest apartat, es presenten les bases per dissenyar un sistema de monitoratge de fallades basat en el FIR (FIRFMS). Els resultants que s'aconsegueixen demostraven que el FIR és capaç de detectar i de diagnosticar el desenvolupament d'anomalies que es poden considerar fallades o canvis estructurals, depenent del sistema dinàmic monitorat. També es presentaven algunes aplicacions pràctiques del FIRFMS per demostrar-ne la viabilitat.

Per demostrar que aquesta metodologia donava més bons resultats que un FMS de raonament inductiu *crisp*, es presentava un exemple d'una aeronau. En l'exemple es veia que el FIRFMS es podia utilitzar com a supervisor d'un pilot automàtic per determinar quan té lloc una fallada estructural i la hipòtesi sobre la naturalesa d'aquest mal funcionament.

Els avantatges principals d'un sistema de monitoratge de fallades basat en el raonament inductiu difús sobre un FMS basat en el raonament inductiu *crisp* són:

- El nombre d'errors en els estats predits qualitativament es redueixen d'un terç a menys d'una desena part, i les cadenes d'error pràcticament desapareixen.
- L'FMS *crisp* de vegades té dificultats per discriminar entre diferents tipus de disfuncions; l'FMS difús és capaç de discriminar de manera clara i sense ambigüitats entre els diferents tipus d'errors que fan que l'avió reaccioni de manera similar.
- L'FMS difús és capaç de diagnosticar el mal funcionament en un període de temps de simulació del model quantitatiu molt petit.
- El FIRFMS permet predir un espectre de resposta gairebé contínua, mentre que el *crisp* només és capaç de predir valors discrets.
- El FIRFMS presenta una capacitat de predicció i discriminatòria molt més bona en comparació de l'homòleg *crisp*.

La implementació de l'aproximació per predir totes les estructures possibles demostra que la metodologia FIRFMS és una eina poderosa per caracteritzar l'estructura. La predicció paral·lela de totes les possibles estructures millora l'ús dels escenaris de la llibreria de models qualitius de diverses maneres:

- S'evita la desactivació del simulador qualitatiu en la cerca a la biblioteca. D'aquesta manera, el canvi estructural es pot simular i es pot caracteritzar.
- Un cop ha tingut lloc el canvi estructural, detectar i identificar el model és gairebé instantani. D'aquesta manera, el FIR canvia d'un model estructural a un altre gairebé immediatament, depenent només de l'amplada del filtre de l'error.
- La determinació d'un model qualitatiu capaç de representar el comportament del sistema en tot moment està garantida, independentment de la forma estructural del sistema real.

Es presentava, també, una aplicació d'un circuit elèctric que conté tres interruptors. Aquest és un problema força difícil que es proposa com un problema de referència per identificar l'estructura per mitjà d'algorismes qualitius. Aquest exemple s'utilitza per establir comparacions amb la nova metodologia que es presenta en aquesta tesi.

Tot i que els resultats aconseguits per la metodologia introduïda a [37] van ser molt bons en comparació dels resultats obtinguts mitjançant la metodologia del raonament inductiu *crisp*, hi ha certes limitacions que es detallen a continuació:

- La detecció de les fallades es fa comparant el valor de classe de la sortida de predicció amb el valor de classe de la sortida real. Aquesta detecció, en molts casos, funciona molt bé, però quan el valor de sortida és proper als llindars de les classes pot ser que encara que hi hagi una diferència molt petita del valor real, que hi hagi un canvi de classe i que, per tant, el mètode consideri que hi ha hagut una fallada que realment no ha tingut lloc.
- El temps de detecció és molt gran. Per garantir una detecció correcta, la grandària de la finestra de detecció ha de ser força gran i el filtre d'errors, per evitar falses alarmes, ha de ser excessivament gran.
- El diagnòstic de la fallada s'extreu del model que ha tingut menys errors acumulats dins la finestra temporal i no dóna cap referència de la qualitat del model. Si un model A ha aconseguit x errors i un altre B , $x + 1$, el sistema de monitoratge ens dirà que el model que millor caracteritza la fallada és el model A , però no ens dirà que el model B també s'hi assembla molt i que, per tant, l'elecció entre l'un i l'altre pot ser dubtosa.

La tècnica de l'envolupant i la mesura d'acceptabilitat ofereixen un nou mètode per detectar i diagnosticar fallades dels processos descrits anteriorment. En la secció següent, s'introdueixen aquests dos conceptes nous i s'expliquen més detalladament.

4.3 FIRFMS millorat

Per dessensibilitzar la metodologia FIR en el procés de la detecció de fallades, es proposa un mètode basat en envolupants que ha de permetre reduir la finestra de predicció considerablement. Un cop s'ha detectat la fallada, s'introdueix un nou concepte anomenat *mesura de l'acceptabilitat* que dóna un índex per saber quin és el model de la llibreria que millor prediu, és a dir, el model de la llibreria que s'identifica millor amb el nou comportament del sistema.

4.3.1 Envolupant

La idea d'utilitzar el concepte de l'envolupant per detectar errors va sorgir del fet que, en l'enfocament utilitzat anteriorment, només s'utilitza una part de la informació disponible, la continguda en els valors de classe, mentre que la pertinença i els valors de costat són ignorats. El concepte de l'envolupant es basa en els 5 veïns més propers (valors quantitius), que es calculen dins de la màquina d'inferència del FIR per mitjà de la regla dels k -veïns més propers. Tal com s'ha explicat en la secció del FIR, es calcula una mesura de distància entre el patró d'entrada, per a cada sortida obtinguda de la predicció, i tots els patrons emmagatzemats a la matriu de comportament que coincideixen amb la classe d'aquest patró d'entrada. Els cinc patrons que tenen la distància més petita se seleccionen com els 5 veïns més propers.

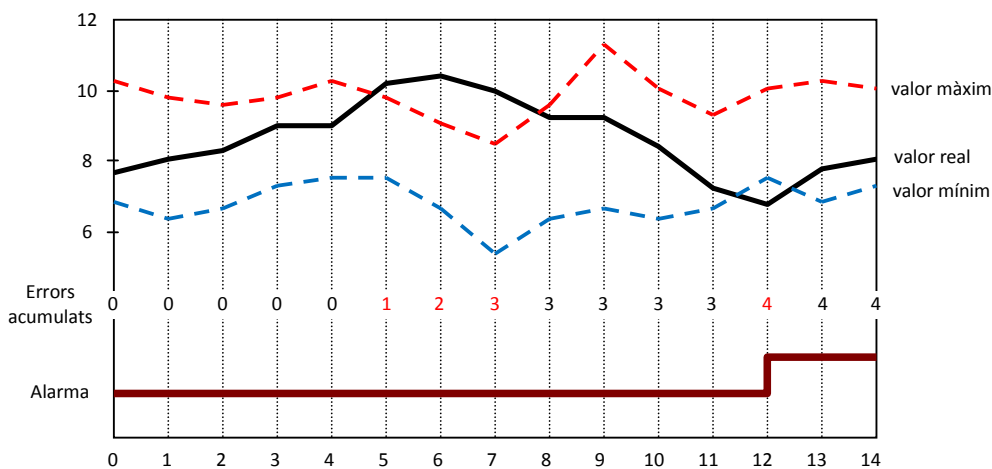


Figura 4-3 Exemple de detecció de fallades pel mètode de l'envolupant (finestra de temps = 15)

Tal com es mostra a la figura 4-3, l'envolupant està composta per un límit superior (valor màxim) i un límit inferior (valor mínim) que delimiten l'àrea en què s'espera que hi hagi el senyal de sortida real. L'envolupant es calcula utilitzant els cinc veïns més propers obtinguts en el procés de predicció difusa de la metodologia FIR. El límit superior s'obté del veí predit que té el valor més alt i el límit inferior correspon al veí predit de valor més baix. Si s'observa la figura 4-3, es pot veure que quan el valor real (línia contínua) sobrepassa els límits especificats per l'envolupant, es comptabilitza un error instantani, la qual cosa significa que el model utilitzat en la predicció ja no representa el sistema en aquell punt de

temps específic. En el procediment de detecció de fallades esmentat a l'apartat anterior, els errors instantanis registrats s'acumulen durant una finestra temporal; quan l'error acumulat supera el llindar especificat, s'activa una alarma i llavors cal determinar la fallada que ha tingut lloc.

Quan l'interval de l'envolupant és molt estret representa que els cinc veïns estan molt a prop els uns dels altres, cosa que significa que la informació disponible sobre el comportament del sistema en aquest moment és molt rica. Al contrari, un interval de l'envolupant molt ample vol dir que no hi ha gaire informació disponible del sistema en aquest moment i que, per tant, els veïns més propers estan molt allunyats els uns dels altres. És important tenir en compte que la metodologia FIR es basa en el comportament del sistema en lloc de basar-se en el coneixement estructural i que, per tant, la quantitat i la riquesa de les dades disponibles del sistema són crucials per assegurar una identificació precisa i fiable del model que el representa.

La figura 4-3 presenta un exemple de la detecció de fallades que utilitza el concepte de l'envolupant amb una finestra de 15 punts de predicció. Les línies puntejades superior i inferior representen el límit superior i inferior de l'envolupant, respectivament, mentre que la línia contínua és el senyal de sortida real. A la part inferior de la figura es mostren els errors instantanis acumulats. Tal com es pot veure, el valor real sobrepassa el llindar superior per primer cop en el punt 5, cosa que causa un error instantani. El mateix succeeix en els punts 6, 7 i 12. El llindar dels errors acumulats especificats en aquest exemple és de 4 i, per tant, l'alarma s'activa en el punt número 12, quan arriba el quart error instantani.

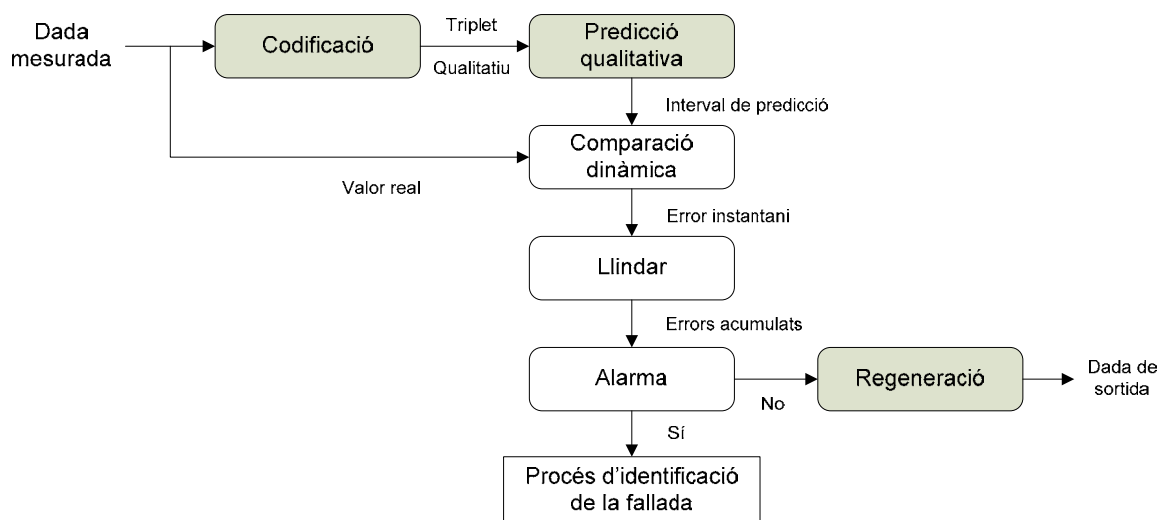


Figura 4-4 Procés de detecció de fallades del FIR (envolupant)

El procés de detecció de fallades basat en el concepte de l'envolupant es descriu a la figura 4-4. Tal com en la figura 4-1, les caixes fosques representen els processos del FIR, mentre que els quadres blancs constitueixen el procediment de detecció de fallades. Tal com en la versió de De Albornoz, les dades mesurades pel sistema es converteixen en triplets qualitatius i el procés de predicció difusa prediu el valor de sortida següent, compost pel triplet de la classe, la pertinença i el costat. No obstant això, en aquest

cas, el procés de predicció difusa també calcula l'interval de l'envolupant que impulsa el procés de detecció. Si el valor real sobrepassa els límits de l'envolupant, el nombre de vegades definit pel llinar, s'activa una alarma i s'inicia el procés de diagnòstic del FIRFMS.

4.3.2 Mesura de l'acceptabilitat

El procés de diagnòstic pot topar amb problemes addicionals que encara no s'han esmentat, per exemple, quan la fallada generada no és prevista i, per tant, no està disponible a la biblioteca de fallades, o quan es generen diferents fallades que tenen trets en comú i que fan que sigui molt difícil de distingir-les. La mesura de l'acceptabilitat ajuda a fer front a aquests problemes. La mesura d'acceptabilitat és un indicador relatiu de quin és el model que millor prediu el nou comportament del sistema. A més a més, aquesta mesura permet determinar de manera fiable quan la fallada no està representada en la llibreria o quan s'identifiquen diferents models per a una mateixa fallada.

Podem definir una mesura de l'acceptabilitat del model i_{th} , utilitzant la fórmula següent:

$$C_i = 1.0 - \frac{I_{a_i}}{I_{a_{m\grave{a}x}}}, \quad (4.1)$$

és a dir, la mesura d'acceptabilitat que tenim en el model i_{th} , C_i , es pot computar mitjançant els errors instantanis (anomenats *indicadors d'alarma*) per a aquest model determinat, I_{a_i} , i el nombre màxim d'alarmes locals possibles (grandària de la finestra de temps), $I_{a_{m\grave{a}x}}$. C_i és una mesura de confiança, és a dir, un valor real dins l'interval $[0, 1]$, en què els valors més grans assenyalen una major confiança.

Malauradament, la fórmula proposada no és suficientment bona, perquè podria passar que hi hagués dos models gairebé perfectes, és a dir, dos models per separat amb C_i i C_j igual a 1,0. En la mesura d'acceptabilitat, és important tenir en compte la dispersió entre els valors de C_i . Això ho podem aconseguir calculant la confiança relativa:

$$C_{rel_i} = \frac{C_i}{\sum_{k=1}^N C_k}. \quad (4.2)$$

Ara bé, si només hi ha un model amb un valor alt de C_i , C_{rel_i} seguirà sent molt alt, però si hi ha altres models amb valors alts de C_i , C_{rel_i} serà molt més petit.

Encara ara la fórmula no és prou bona. Podria passar que no hi hagués cap C_i amb un valor gran, només un, amb un valor petit, mentre que tots els altres fossin zero. En aquest cas, C_{rel_i} estarà sobrevalorat. Per tant, es proposa una fórmula final per a la mesura d'acceptabilitat que captura la qualitat de la selecció del model:

$$Q_i = C_i \cdot C_{rel_i} \quad (4.3)$$

La mesura d'acceptabilitat s'utilitza per millorar el procés de diagnòstic de fallades del FIR que es descriu a la figura 4-5. Les caixes fosques representen els processos del FIR, mentre que els quadres blancs constitueixen el procediment de diagnòstic de la fallada. La primera part del procés funciona exactament com s'ha explicat a la secció de diagnòstic de les fallades d'aquest capítol (vegeu la figura 4-2). S'acumulen els errors generats durant el procés de predicció de cada model de fallades. Per tant, cada model de fallades emmagatzemat a la biblioteca té associat un error acumulatiu, I_{a_i} . Aquest error es fa servir per calcular la mesura d'acceptabilitat del model, tal com s'ha explicat detalladament anteriorment. El model amb la mesura de l'acceptabilitat més alta és seleccionat com el que millor representa la fallada.

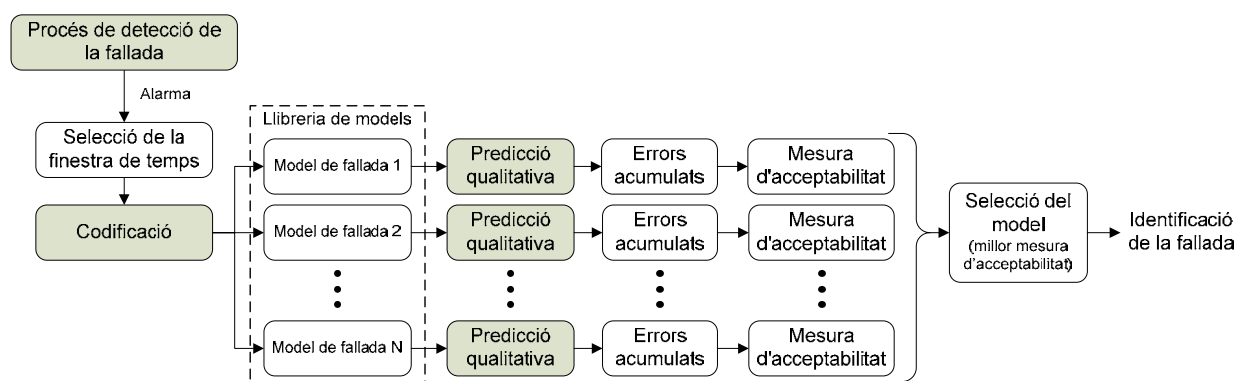


Figura 4-5 Procés de diagnòstic de la fallada en el FIR (mesura d'acceptabilitat)

La utilitat del mètode de l'envolupant i de la mesura d'acceptabilitat es presenta en la secció següent mitjançant aplicant-lo a un circuit elèctric, un sistema biomèdic i un sistema de distribució de demanda d'aigua. El circuit elèctric es fa servir per demostrar que els nous mètodes són millors que els usats anteriorment en el FIRFMS. Els sistemes biomèdic i de distribució de la demanda d'aigua es presenten per mostrar el bon rendiment del FIRFMS millorat.

4.4 Aplicacions

En aquest apartat es presenten tres aplicacions publicades a [49] per demostrar els molt bons resultats aconseguits amb aquesta nova metodologia. La primera aplicació presentada a [54] mostra que es poden detectar els canvis estructurals d'un circuit elèctric. També s'utilitza per comparar les dues metodologies de FMS basades en FIR. En la segona aplicació [55] es busquen els canvis estructurals en el sistema nerviós central de control humà per a diversos patrons de comportament dels pacients i es demostra que la metodologia FIRFMS serveix per detectar anomalies en la conducta del pacient i com a ajut en el procés de diagnòstic dels metges. La tercera aplicació és un sistema de distribució de la demanda d'aigua [53, 52]) en què tenen lloc diverses fuites en la xarxa de distribució.

4.4.1 Circuit elèctric

L'aplicació que es presenta en aquesta secció és un circuit elèctric que conté tres interruptors binaris que permeten definir vuit estructures diferents en funció de les posicions dels interruptors. Es pot considerar que, en règim de treball normal, tots els interruptors estan tancats, i aquesta estructura es representa amb la relació binària 000 (SW3 = 0, SW2 = 0 i SW1 = 0). El circuit elèctric es descriu a la figura 4-6. El senyal d'entrada del circuit, U1, és un senyal binari aleatori amb uns valors compresos entre [0, 0,01] volts. La sortida del circuit és el voltatge mesurat a la resistència R4. El model quantitatiu del circuit ha estat construït utilitzant Dymola [43].

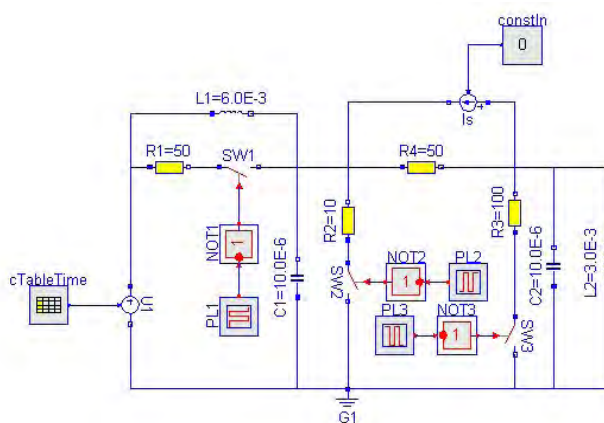


Figura 4-6 Circuit elèctric

L'objectiu principal d'aquesta aplicació és demostrar la viabilitat de la metodologia FIRFMS per detectar i identificar els canvis estructurals en el circuit, és a dir, l'estat qualitatiu del circuit, especificat per l'estat dels tres interruptors. Per tal d'assolir aquest objectiu, el primer pas és obtenir els models qualitius FIR que constitueixen la biblioteca de les fallades (en aquest cas, els diferents estats del circuit). En aquest exemple, s'han seleccionat quatre estructures diferents: 000, 001, 010 i 011. Per a cadascuna, el sistema s'ha simulat durant 0,4 segons a una freqüència de mostreig de 0,0002 segons. Els primers 900 valors s'utilitzen per identificar el model i els últims 100 s'utilitzen per verificar el model. L'error quadrat mitjà percentual s'utilitza per calcular l'error de predicció i es descriu a l'equació 4.4:

$$MSE = \frac{E[(y(t) - \hat{y}(t))^2]}{y_{var}} \cdot 100 \%, \tag{4.4}$$

on y_{var} representa la variància de $y(t)$.

Per tal d'il·lustrar aquest procés, els errors de predicció obtinguts per als conjunts de dades d'identificació dels circuits 000 i 011 es mostren a la figura 4-8 i a la figura 4-7, respectivament.




Figura 4-8 Identificació del model per al circuit 000

Les parts superiors de les dues figures mostren el senyal d'entrada (línia discontinua), així com el senyal de sortida real (línia contínua) i el senyal de sortida de predicció (línia puntejada). En totes dues figures, els senyals de sortida real i de predicció queden superposats i no es poden distingir, a causa de l'alta precisió de la predicció. Aquesta és la raó per la qual l'error de predicció (valor real menys el de predicció), mostrat en les parts inferiors de les dues figures, té un valor molt petit. Els errors MSE calculats mitjançant l'equació 4.4 són $1,2 \times 10^{-5} \%$, $1,1 \times 10^{-5} \%$, $6,3 \times 10^{-7} \%$ i $3,4 \times 10^{-6} \%$ per als circuits 000, 001, 010 i 011, respectivament. Els models FIR (màscare i matrius de comportament) dels quatre circuits s'emmagatzemen a la biblioteca de models de fallades i s'utilitzen per detectar els canvis estructurals esdevinguts en el sistema i durant la identificació de les noves estructures resultants.




Figura 4-7 Identificació del model per al circuit 011

L'experiment descrit a la figura 4-9 s'utilitza per mostrar el rendiment de la tècnica de l'envolupant i de la mesura d'acceptabilitat del model i per comparar-la amb els processos de detecció i identificació usats prèviament a [37]. La part superior d'aquesta figura descriu l'estructura del sistema que es correspon amb cadascun dels quatre models. El model 0 és l'equivalent al circuit que té els tres interruptors a zero. El model 1 té $SW3 = 0$, $SW2 = 0$ i $SW1 = 1$. El model 2 es caracteritza per $SW3 = 0$, $SW2 = 1$ i $SW1 = 0$.

Finalment, el model 3 correspon a $SW3 = 0$, $SW2 = 1$ i $SW1 = 1$. La part superior de la figura 4-9 defineix l'experiment. Es mostregen i s'emmagatzemen les dades mentre el sistema està operant en els quatre modes caracteritzats pels models 0, 1, 2 i 3. El FIRFMS ha de detectar cada canvi estructural del circuit i identificar el model que correspon a la nova estructura amb la màxima precisió possible.

A la part central de la figura 4-9 es presenten els resultats del FIRFMS. El FIRFMS detecta que la primera estructura correspon al model 0. Poc després de la mostra 500, detecta que hi ha un canvi de l'estructura del sistema i determina que el model 1 és el millor model per representar la nova estructura. El FIRFMS detecta un nou canvi estructural just després de la mostra 1.000 i identifica el model 2 com el millor model que representa el sistema durant aquest període. Finalment, a la mostra 1.500, el FIRFMS detecta l'últim canvi en l'estructura del sistema i identifica el model 3 com el que millor reflecteix el comportament del circuit en el període final de la simulació. Tal com es mostra en el dibuix, el FIRFMS comet un error en el període associat al model 3. Detecta un canvi estructural i l'identifica com el model 2 per a la nova estructura, quan, en realitat, no ha tingut lloc cap canvi estructural en el circuit. Això es deu al fet que durant l'última part de la fase de simulació, que correspon a l'estructura 011, alguns dels models de la llibreria de fallades tenen un comportament molt similar.

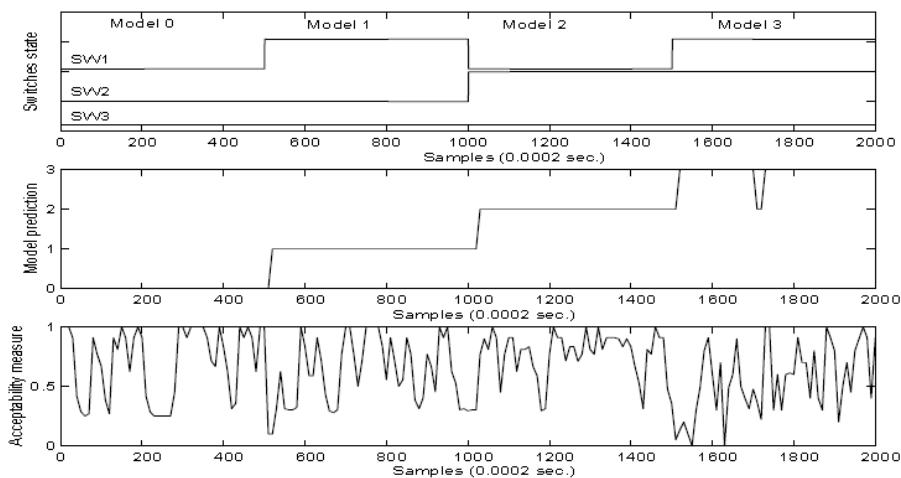


Figura 4-9 Resultat del FIRFMS aplicat al circuit elèctric utilitzant la tècnica de l'envolupant i la mesura de l'acceptabilitat (prova amb $TW = 10$ i $CE = 2$)

La part inferior de la figura 4-9 mostra la mesura d'acceptabilitat del model guanyador, és a dir, el model que millor identifica el sistema en cada moment. Cadascun dels quatre models té una mesura d'acceptabilitat pròpia, però només es mostra la mesura més gran de tots (del model seleccionat, a la part central de la figura). Atès que la mesura d'acceptabilitat varia molt, de mitjana, pren un valor al voltant de 0,6 durant els tres primers segments de la simulació. Durant la fase final, la mitjana de la mesura d'acceptabilitat és inferior, de prop de 0,4. Això és perquè, en aquest segment, diversos models poden explicar raonablement el comportament observat. No obstant això, a excepció d'un error, el FIRFMS tria manera coherent i consistent el model correcte.

Cal comentar que en molts punts la mesura d'acceptabilitat pren el valor 1. Això significa que només hi ha un model que és capaç de predir amb exactitud tots els punts de dades de la finestra de temps associada, mentre que els altres tres models no són capaços de predir cap dels punts de la finestra. En general, la mesura d'acceptabilitat assumeix valors entre 0,25 i 1, corresponent als casos en què alguns models prediuen millor que altres els valors dins la finestra de temps específica, encara que gairebé tots són capaços de predir una part d'aquests valors. En aquests casos, el FIR identifica el model amb el menor nombre d'errors de predicció. Valors de la mesura d'acceptabilitat inferiors a 0,25 signifiquen que, en general, tots els models tenen problemes per predir els valors que integren la finestra de temps actual. Per tant, caldria determinar un llindar en la mesura d'acceptabilitat per indicar que el comportament actual no pot ser representat raonablement per cap dels models que hi ha a la biblioteca de models de fallades. En el nostre exemple, només alguns punts que corresponen a l'últim segment de la simulació tenen valors molt baixos en la mesura d'acceptabilitat i això es deu al fet que el comportament del model 3 del sistema és el més difícil d'identificar, tal com es veurà més endavant.

Una darrera observació relativa a la mesura de l'acceptabilitat: cada vegada que el senyal de sortida real es troba en règim permanent, la mesura d'acceptabilitat pren valors molt petits. La raó és que els quatre circuits tenen un comportament molt similar al voltant de l'estat d'equilibri, perquè el guany s'ha normalitzat a un. El nombre d'errors de predicció obtinguts en aquesta zona és igual de petit per a tots els models i, en conseqüència, la mesura de l'acceptabilitat es distribueix entre tots els models. Aquesta mena de situació podria provocar errors en el procés de detecció si l'operació en règim permanent es manté durant un període de temps llarg.

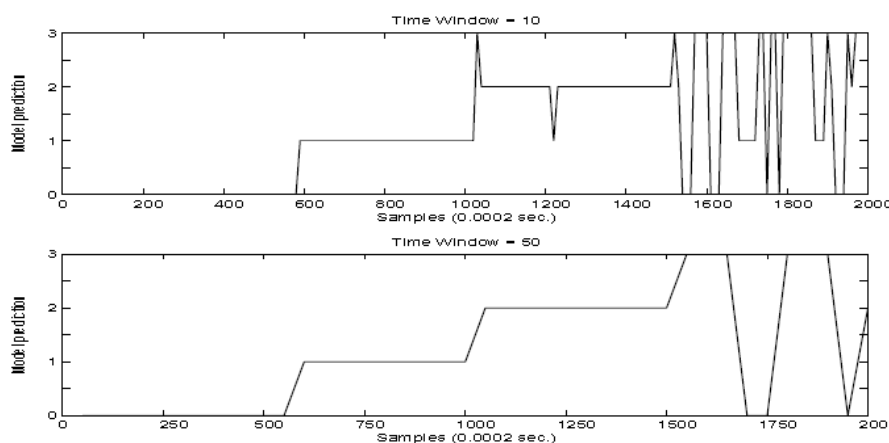


Figura 4-10 Resultat del FIRFMS aplicat al circuit elèctric utilitzant la metodologia de De Albornoz (TW = 10 i 50 mostres; CE = 2)

La part superior de la figura 4-10 mostra els resultats obtinguts quan la metodologia de detecció i de diagnòstic de De Albornoz s'utilitza en el mateix experiment. Tal com es veu a la figura, el sistema de supervisió de fallades és capaç de detectar i d'identificar correctament els dos primers models, encara que es necessita més temps que el nou mètode per detectar el canvi del model 0 al model 1. Però la tècnica no és capaç d'identificar correctament els models 2 i 3. Durant el tercer període de la simulació, l'FMS

comet dos errors, mentre que en el quart i últim segment (que correspon al model 3) l'FMS detecta un gran nombre de canvis estructurals en el circuit i s'identifiquen diversos models, cosa que fa impossible saber què està passant en el sistema. La finestra de temps escollida en aquest experiment (figura 4-9 i la part superior de la figura 4-10) és de 10 mostres i el llindar especificat és de 2 errors acumulats.

Els resultats de De Albornoz es poden millorar si s'augmenta la finestra de temps de 10 a 50 mostres. La part inferior de la figura 4-10 mostra aquests resultats. En aquest cas, els tres primers models s'identifiquen de manera fiable, però l'FMS no és capaç d'identificar correctament el model 3. A més, com a conseqüència de l'augment de la finestra de temps s'incrementa el procés de detecció i l'FMS necessita encara més temps per reconèixer que ha tingut lloc un canvi estructural en el sistema.

4.4.2 Sistema nerviós central de control




Figura 4-11 Senyal de sortida del controlador de la contractilitat miocardiàcia (MC): (a) pacient 1, (b) pacient 2, (c) pacient 3, (d) pacient 4 i (e) pacient 5

L'aplicació que es presenta en aquest apartat és el sistema nerviós central (SNC) de control humà del sistema cardiovascular. El sistema nerviós central controla els sistemes hemodinàmics i genera els senyals de regulació per als vasos sanguinis i per al cor. Aquests senyals es transmeten a través dels nervis simpàtic i parasimpàtic, i generen estímuls en els òrgans corresponents. Tot i que actualment encara no es coneix completament el funcionament de l'SNC de control, diferents autors han postulat models

individuals basats en equacions diferencials per a cadascun dels mecanismes de control que hipotèticament du a terme l'SNC [90, 138].

El sistema nerviós central es compon de cinc controladors: freqüència cardíaca (HR), resistència perifèrica (PR), contractilitat miocardiàica (MC), to venós (VT) i resistència coronària (CR) [138]. Tots aquests controladors són models del tipus SISO (una sola entrada i una sola sortida) conduïts per la mateixa variable d'entrada, la pressió del si carotidi. Les variables de sortida dels models dels controladors no són susceptibles d'una interpretació fisiològica, a excepció de la HR, que és la inversa de la freqüència cardíaca, mesurada en segons entre batecs. Els senyals d'entrada i sortida dels controladors del sistema nerviós central, per a tots els pacients, es van registrar amb una freqüència de mostreig de 0,12 segons a partir de simulacions d'un model d'equacions diferencials. El model s'ha ajustat per representar cinc pacients específics que, segons els experts, pateixen diferents percentatges d'obstrucció de l'artèria coronària, de manera que s'ha generat la pressió auricular dreta, la pressió aòrtica, el flux sanguini coronari i les variables de la freqüència cardíaca del model de simulació d'acord amb les dades mesurades de cada pacient. Per donar una idea del tipus de dades disponibles, a la figura 4-11 es mostren els senyals de la contractilitat miocardiàica dels cinc pacients utilitzats per ajustar el model.

L'objectiu principal d'aquesta aplicació és detectar canvis estructurals en l'SNC de control per a diversos pacients i demostrar la idoneïtat de la metodologia FIRFMS per detectar anormalitats en el diagnòstic i la conducta dels pacients en problemes mèdics reals.




Figura 4-12 Distribució de les dades de prova o experiment per a cadascun dels 5 controladors

Com a primer pas, s'utilitza la metodologia FIR per identificar els models que millor representen el comportament dels cinc controladors de l'SNC per a tots els pacients i que integren la llibreria de fallades. El conjunt d'entrenament consta de 3.000 dades per a cada pacient i cada controlador. Els models de l'SNC obtinguts per a cada pacient es validen utilitzant-los per predir 6 conjunts de dades que representen morfologies específiques, no emprades en el procés d'entrenament. Cadascun d'aquests conjunts de dades de prova conté 600 mostres. Els errors de validació obtinguts són inferiors a 0,001 % per a tots els controladors de gairebé tots els pacients. La fórmula d'error utilitzada és l'MSE en percentatge descrita en l'equació 4.4.

Els models FIR dels cinc controladors de l'SNC, per a tots els pacients, són emmagatzemats a la llibreria de models de fallades per permetre la identificació del cinc pacients amb diferents percentatges d'obstrucció de l'artèria coronària.

Per demostrar la viabilitat de la metodologia FIRFMS per detectar un canvi de pacient i identificar-lo, s'ha dissenyat la prova següent. Per a cada controlador es combinen de manera aleatòria 5 conjunts de 600 dades cadascun, procedents dels diferents pacients, que no han estat utilitzats en el procés d'identificació del model. D'aquesta manera, s'obté un conjunt de prova que conté 3.000 dades (600 mostres per pacient) per a cada controlador, amb la seqüència de pacients que es presenta a la figura 4-12. El primer conjunt de dades de cada controlador correspon al pacient 2, seguit dels pacients 5, 3, 4 i 1. Per tant, aquesta seqüència representa els cinc pacients amb diferents percentatges d'obstrucció de l'artèria coronària.

Una vegada s'ha dissenyat el conjunt de les dades de l'experiment, s'utilitza la metodologia FIRFMS per predir el valor de la sortida dels cinc controladors de l'SNC. El procés de detecció de fallades del FIRFMS ha de detectar els canvis en el SNC de control. Si es detecta un canvi (*fallada*, en la nomenclatura de l'FMS), el procés de diagnòstic de fallades del FIRFMS ha d'identificar el model emmagatzemat a la llibreria de fallades que millor representa el nou comportament.




Figura 4-13 Resultat HR (TW = 10 mostres; CE = 2)

Aquest experiment s'ha dut a terme per a cada un dels cinc controladors de l'SNC: ritme cardíac, resistència perifèrica, contractilitat miocardiàica, to venós i resistència coronària, i els resultats obtinguts es mostren en les figures 4-13, 4-14, 4-15, 4-16 i 4-17, respectivament. La part superior d'aquestes figures presenta el valor real de la sortida (línia contínua) i el valor de la sortida predita (línia discontinua) per a cadascun dels controladors. Els gràfics centrals i inferiors d'aquestes figures presenten la mesura de l'acceptabilitat i el model del pacient identificat pel FIRFMS quan s'ha detectat una fallada, respectivament.

La detecció i el procés de diagnòstic funciona com segueix. Es defineix una finestra temporal de 10 punts de dades (1,2 segons). Tal com es mostra en els resultats, aquest temps és suficient perquè la metodologia

FIRFMS detecti i identifiqui un canvi un canvi de pacient. L'interval de l'envolupant de la predicció es calcula per a cada finestra de temps i els errors instantanis s'acumulen per al model que s'utilitza actualment per a la predicció. Si el nombre d'errors acumulats dins de la finestra temporal és més gran que 2, s'activa una alarma i s'inicia el procés de diagnòstic. El llindar establert per a aquesta aplicació és de 2, que és un valor suficient per al procés de detecció del FIRFMS.

Quan es detecta un canvi estructural, comença el procés de diagnòstic del FIRFMS. Durant els propers 10 punts (mida de la finestra temporal) es fa el procés de predicció difusa del FIR per als cinc models emmagatzemats a la llibreria de models de fallada. Per a cadascun, es calcula la mesura d'acceptabilitat, i el model amb la millor mesura de l'acceptabilitat és identificat com el que millor representa el nou comportament. Un cop seleccionat el nou model, el procés de detecció comença de nou la cerca d'un nou canvi possible (fallada) en el comportament actual.




Figura 4-14 Resultats MC (TW = 10 mostres; CE = 2)

Els resultats mostrats a les figures 4-13, 4-14, 4-15, 4-16 i 4-17 són molt significatius i demostren la utilitat de la metodologia FIRFMS a l'hora de detectar un canvi en el sistema i d'identificar el nou model que representa aquest canvi. Les parts superiors d'aquestes figures mostren que el FIR és capaç de predir amb gran precisió el comportament de tots els pacients per a cada un dels controladors del sistema nerviós central. Per a tots els controladors, la predicció s'inicia amb el model del pacient 1. El FIRFMS detecta que aquest model no representa el comportament actual del sistema, perquè s'arriba al llindar de dos errors i, per aquest motiu, la primera finestra temporal detecta que ha tingut lloc una fallada i s'inicia el procés de diagnòstic del FIRFMS, que conclou que el comportament correspon al pacient 2. Tal com es mostra a la part central de la figura 4-13, el FIRFMS està completament segur que el model del pacient correcte és el 2, perquè la mesura de l'acceptabilitat pren el valor màxim. El FIRFMS detecta una nova fallada quan hi ha un canvi de pacient. En aquest moment, l'error acumulat sobrepassa el llindar de 2 per

al model que s'ha utilitzat fins aquest moment; per tant, el procés de diagnòstic s'inicia de nou i dona com a millor model el pacient 5. Aquest procés es repeteix cada vegada que el FIR detecta un canvi.

Cal remarcar que durant la detecció, la mesura d'acceptabilitat normalment es redueix. Això significa que diversos models emmagatzemats a la llibreria de models de fallades són capaços de predir els punts de dades de la finestra temporal actual, aquest fenomen es pot observar en les figures 4-13, 4-14, 4-15, 4-16 i 4-17, en els que comparant els senyals a simple vista, es fa difícil de caracteritzar els pacients. En aquests casos, s'identifica el model que té la mesura de l'acceptabilitat més alta. És interessant comentar que en molt poques ocasions la mesura d'acceptabilitat pren un valor de zero. Això significa que cap dels models emmagatzemats a la llibreria de fallades no és capaç de predir un sol valor dins de l'envolupant. En el cas d'un empat entre dos o més models, es calcula l'error de predicció dels models dins de la finestra temporal i s'identifica com a millor model el que té el menor error de predicció.




Figura 4-15 Resultats PR (TW = 10 mostres; CE = 2)

En aquesta aplicació, la mesura d'acceptabilitat es calcula només quan el FIRFMS detecta una nova fallada, és a dir, quan té lloc un canvi de pacient. Aquesta és la raó per la qual els gràfics centrals de les figures 4-13, 4-14, 4-15, 4-16 i 4-17 mostren els canvis en la mesura d'acceptabilitat només quan el procés de detecció identifica una fallada i la resta del temps la mesura d'acceptabilitat es manté constant. En les aplicacions del circuit elèctric i de la xarxa de distribució d'aigua, la mesura d'acceptabilitat es calcula (i es representa) en cada pas de temps, encara que només s'utilitza quan té lloc una fallada.




Figura 4-16 Resultats CR (TW = 10 mostres; CE = 2)

Tal com mostra el gràfic inferior de la figura 4-13, els models identificats es corresponen exactament amb la distribució de dades de prova presentada a la figura 4-12 i això demostra que el FIRFMS funciona molt bé en aquesta aplicació. Exactament els mateixos comentaris es poden fer per als controladors PR, MC, CR i VT.




Figura 4-17 Resultats VT (TW = 10 mostres; CE = 2)

És interessant analitzar els resultats obtinguts pel controlador de la resistència coronària que es presenta a la figura 4-16. Tal com es mostra al gràfic inferior d'aquesta figura, la identificació dels diferents models dels pacients és menys clara que en els altres controladors de l'SNC. El FIRFMS detecta la mateixa seqüència identificada per als altres controladors, és a dir, el model del pacient 2, seguit dels models dels

pacients 5, 3, 4 i 1. Tanmateix, en tres llocs el FIRFMS dóna el número de model 1 com el que millor representa el comportament del sistema. Mirant de prop aquests períodes, s'observa que corresponen a llocs on la variable de sortida real té un valor constant d'1,0. Tots els models dels pacients emmagatzemats a la llibreria de models de fallades per al controlador de la resistència coronària contenen llargs períodes amb el valor de la variable de sortida a 1,0. Això significa que tots els models disponibles són capaços de predir amb gran precisió aquests períodes estacionaris i només els pics difereixen entre un pacient i un altre. Com a conseqüència del fet que el procés de detecció inicia sempre la predicció amb el model 1, el FIRFMS no detecta un canvi o una fallada fins que té lloc un pic, cosa que passa després de 10 finestres temporals, aproximadament. El mateix passa en els dos períodes d'abans i de després de la selecció del model 3. Tots dos corresponen a llocs on la variable de sortida té un valor d'1. Per tant, no importa quin és el model seleccionat de la llibreria, perquè tots poden representar aquest període correctament.

L'experiment descrit en aquesta secció no representa un experiment fisiològic significatiu. No obstant això, els resultats mostren que les mesures obtingudes d'un pacient poden ser utilitzades per classificar els pacients en grups de comportament del SNC de control.

4.4.3 Sistema de distribució de la demanda d'aigua

La tercera aplicació és un sistema de distribució de la demanda d'aigua. L'objectiu de la xarxa de distribució d'aigua és portar l'aigua per al consum humà procedent de pous i rius a una ciutat imaginària. Cal que l'aigua arribi als punts de destinació amb un cert flux de pressió. Amb aquesta finalitat, la xarxa està formada per dipòsits d'aigua, vàlvules que regulen la quantitat d'aigua i estacions de bombeig. La figura 4-18 representa un diagrama simplificat de la xarxa de distribució d'aigua.




Figura 4-18 Diagrama simplificat del sistema de demanda d'aigua

Tal com mostra la figura 4-18, l'esquema simplificat de la xarxa de distribució d'aigua està formada de 2 dipòsits (D1 i D2), que han de proporcionar l'aigua sol·licitada de cada demanda. El pantà D1 correspon a una reserva d'aigua inesgotable i està situat en un nivell més baix que la xarxa. Per tant, per tal d'extreure

l'aigua des de l'embassament D1 es necessita una bomba (B1). La bomba B1 està controlada pel nivell de l'aigua del dipòsit D2.

La simulació de la xarxa es fa mitjançant el programari EPANET [124], considerant que els 5 punts de destinació d'aigua tenen demandes periòdiques específiques de 12 hores de durada. Les variables d'entrada que s'han considerat són les pressions als nodes 10, 11, 12 i 21, i el nivell de l'aigua del dipòsit D2. La pressió es mesura en lliures per polzada quadrada i el nivell d'aigua, en peus. La bomba B1 no s'inclou en el conjunt de variables d'entrada, ja que està directament associada al nivell del dipòsit D2 mitjançant una regla de control. La variable de sortida és la pressió de l'aigua al node 22.

L'objectiu principal d'aquesta aplicació és detectar i diagnosticar fallades en la xarxa de distribució d'aigua. Per tal d'assolir aquest objectiu, s'han proposat dos errors diferents. Les vàlvules (V11 i V121) de la figura 4-18 permeten activar aquestes fallades. La primera fallada correspon a una obstrucció a la canonada que uneix els nodes 11 i 12. La segona fallada representa una fuga d'aigua al tub que uneix el node 21 amb el node 31, introduït amb aquesta finalitat. Aquestes fallades se simulen mitjançant les vàlvules V11 i V121. Per tant, el sistema de distribució d'aigua pot dur a terme els escenaris següents:

Escenari 1: la xarxa funciona correctament. La vàlvula V11 està oberta i la V121 està tancada.

Escenari 2: hi ha una obstrucció de la canonada entre els nodes 11 i 12. Ambdues vàlvules (V11 i V121) estan tancades.

Escenari 3: hi ha una fuga d'aigua al node 21. Ambdues vàlvules (V11 i V121) estan obertes.

A la figura 4-19 es mostra una part dels senyals de sortida de cadascun dels diferents escenaris. Es pot observar en aquesta figura que la pressió de l'aigua al node 22 quan la xarxa funciona correctament (escenari 1) és molt similar al senyal de sortida que s'obté quan ha tingut lloc una fuga d'aigua (escenari 3). Només hi ha un petit retard entre els dos senyals a causa de l'efecte de la filtració d'aigua i l'activació de la bomba, com a conseqüència de la reducció de la quantitat d'aigua al dipòsit D2.

Tal com s'ha explicat en les aplicacions anteriors, el primer pas és identificar els models FIR que millor representen el comportament de la xarxa d'aigua en els tres escenaris diferents. El sistema se simula durant un període de temps de 2.400 hores. Les primeres 2.160 dades es fan servir per al procés d'identificació i les últimes 240 hores s'utilitzen com a dades de prova. La mesura de l'MSE que es descriu a l'equació 4.4 es fa servir també en aquesta aplicació. Els errors de validació obtinguts són de 0,0113 % en el primer escenari, d'1,6362 % en el segon escenari i de 0,1073 % en el tercer escenari. Aquests errors són molt més grans que els errors obtinguts en el circuit elèctric i les aplicacions del sistema nerviós central.

Els models FIR (màscare i matrius de comportament) per als tres escenaris s'incorporen a la llibreria de models de fallades per diagnosticar possibles fallades en la xarxa de distribució d'aigua. Amb aquesta finalitat, s'ha dissenyat un experiment que simula diverses fallades a la xarxa, tal com es descriu en el gràfic superior de la figura 4-20.




Figura 4-19 Senyals de sortida per als tres escenaris

Durant les primeres 49 hores la xarxa funciona correctament, sense fallades. A l'hora 50, la canonada entre els nodes 11 i 12 s'obstrueix i no deixa passar aigua. El problema es resol a l'hora 100 i la xarxa torna a funcionar correctament fins a l'hora 150, quan té lloc una fuga d'aigua al node 21. Finalment, a l'hora 200 se soluciona aquest problema i la xarxa torna a funcionar normalment.

En aquesta aplicació s'ha triat una finestra de temps de 10 punts (hores) i un llindar d'un error acumulatiu. Això vol dir que quan té lloc un sol error s'activa la detecció de l'alarma i s'inicia el procés de diagnòstic de fallades.

La part central de la figura 4-20 mostra l'escenari predit pel FIRFMS. És capaç de detectar la fallada molt ràpidament i necessita 10 hores (mostres) per determinar quina fallada ha tingut lloc. El FIRFMS és capaç d'identificar l'escenari de la xarxa de distribució d'aigua perfectament sense cap error. Aquesta és una fita important si es té en compte la semblança entre els escenaris 1 i 3. La part inferior de la figura 4-20 presenta la mesura d'acceptabilitat del model. S'obtenen valors molt baixos quan hi ha molts errors acumulats per als tres models. El valor més baix de la mesura d'acceptabilitat és de 0,15, que correspon, respectivament, a 8, 9 i 7 errors acumulats per a cada un dels models. Cal recordar que la finestra de temps és de 10 mostres i que, per tant, hi pot haver un màxim de 10 errors acumulats, és a dir, que cap dels valors pronosticats no estigui dins de l'envolupant. La mesura de l'acceptabilitat més alta en aquest

exemple s'obté quan els errors acumulats són d'1, 10 i 9 per a cada un dels tres models, respectivament. En aquest cas, aquesta mesura té un valor de 0,81.




Figura 4-20 Resultats del FIRFMS aplicat a la xarxa de distribució d'aigua utilitzant la tècnica de l'envolupant i la mesura de l'acceptabilitat (TW = 10 mostres; CE = 1)

Si el període de 10 hores es considera massa gran per al diagnòstic de les fallades, es pot utilitzar una finestra més petita, cosa que redueix una mica el rendiment de diagnòstic del FIRFMS. La figura 4-21 mostra la predicció del FIRFMS per a la xarxa de distribució d'aigua amb una finestra de temps de 5 mostres i un llindar de 2 errors acumulats.

Tal com es veu a la figura 4-21, el FIRFMS és capaç d'identificar correctament les fallades, a excepció de dos punts (el temps de dues finestres temporals) al principi del model 1, en què prediu el model 3 en lloc de l'1. Cal recordar que els senyals dels escenaris 1 i 3 són molt similars i que això dificulta la identificació. A més, en ambdós casos hi ha un empat en el nombre d'errors acumulats i, per tant, qualsevol dels dos models pot ser escollit com el guanyador. Tal com s'ha comentat abans, quan hi ha un empat entre dos o més models, es pren com a millor model el que aconsegueix l'error de predicció més petit dins de la finestra temporal. En aquest cas, el guanyador no és el model correcte d'aquestes dues finestres de temps, però per a la resta de l'experiment el FIRFMS és capaç de predir l'escenari correcte.




Figura 4-21 Resultats del FIRFMS aplicat a la xarxa de distribució d'aigua utilitzant la tècnica de l'envolupant i la mesura de l'acceptabilitat (TW = 5 mostres; CE = 2)

4.5 Debat i conclusions

En aquest capítol s'han introduït dos conceptes nous en el context del raonament inductiu difús: la tècnica de l'envolupant i la mesura d'acceptabilitat del model, per als sistemes de monitoratge de fallades. Aquests conceptes permeten millorar els processos de detecció i de diagnòstic de fallades del FIRFMS, cosa que redueix significativament el temps necessari per detectar una fallada i augmenta la robustesa del sistema de monitoratge de fallades. En aquest punt, el FIRFMS no és, encara, una eina d'ús senzill que pugui utilitzar qualsevol mena d'investigador; és només útil per a investigadors que estiguin familiaritzats amb el FIR. No obstant això, en els propers capítols es presenta una nova versió amistosa i senzilla del FIRFMS que permetrà que qualsevol mena d'usuari utilitzi aquesta metodologia. L'eina FIRFMS és accessible des de l'entorn de Visual-FIR, ja disponible en MATLAB.

El FIRFMS millorat és capaç de diagnosticar les fallades que s'han generat en el sistema d'una manera més fiable que els algorismes utilitzats anteriorment [37]. L'exemple del circuit elèctric es presenta per demostrar la viabilitat dels nous conceptes i el seu rendiment en comparació del FIRFMS utilitzat anteriorment.

La metodologia del FIRFMS s'aplica per primera vegada a un sistema biomèdic: el sistema nerviós central de control del sistema cardiovascular. La idea d'aquest treball és estudiar la viabilitat i la validesa

d'aquesta metodologia quan s'usa per detectar anomalies en el comportament dels pacients i en el diagnòstic de problemes mèdics reals. Amb aquest objectiu, s'utilitzen els models dels cinc controladors que componen l'SNC per a cinc pacients diferents com a informació disponible per detectar i identificar els pacients amb diferents percentatges d'obstrucció de l'artèria coronària. El FIRFMS ha demostrat la capacitat i l'habilitat per detectar amb precisió i rapidesa un canvi de pacient usant una finestra temporal de només 10 punts i un llindar de 2 errors. Finalment, el FIRFMS s'utilitza per detectar fallades en una xarxa de distribució d'aigua. Amb la metodologia proposada s'aconsegueix detectar amb molta precisió una obstrucció del tub i una fuga d'aigua. La mesura de l'acceptabilitat és una eina molt útil que ajuda a identificar el model que millor representa el comportament de la nova sortida després de detectar una fallada.

5 Plataforma visual del FIR: Visual-FIR

Resum: en aquest capítol es presenta una nova plataforma de la metodologia del raonament inductiu difús (FIR), desenvolupada en l'entorn de programació MATLAB. La nova eina visual, anomenada Visual-FIR, permet identificar models i predir comportaments futurs de sistemes dinàmics en un entorn molt senzill d'utilitzar i molt eficient. Les implementacions anteriors del FIR implicaven desenvolupar, necessàriament, un nou codi per a cada nova aplicació que s'havia d'estudiar. El Visual-FIR resol aquesta limitació i ofereix una aplicació d'alt rendiment. D'altra banda, la plataforma Visual-FIR presenta una nova visió de la metodologia basada en blocs de processos i hi afegeix noves característiques, de manera que augmenta les capacitats generals de la metodologia FIR. Finalment, s'aborda parcialment l'aplicació de referència DAMADICS utilitzant l'enfocament de Visual-FIR.

5.1 Introducció

El nucli de programari de la metodologia del raonament inductiu difús està codificat en C. El FIR opera amb matrius de dades i, per tant, es pot integrar fàcilment com a un grup d'eines (*toolbox*) de MATLAB. En versions anteriors, les funcions FIR es van dissenyar emprant la interfície clàssica de programació de MATLAB. Per utilitzar aquesta metodologia, el dissenyador havia d'escriure funcions de tipus M, en les quals els diferents mòduls FIR s'havien d'anar cridant seguint la seqüència adient. Com que el FIR es pot utilitzar de moltes maneres diferents, la interfície d'usuari s'havia mantingut a un nivell relativament baix de programació. En conseqüència, els programes de FIR sovint consistien en centenars de línies de codi de MATLAB. Aquest enfocament era propens a errors i, en conseqüència, els usuaris trobaven dificultats a l'hora d'emprar aquesta metodologia.

L'experiència adquirida amb les interfícies d'usuari anteriors han demostrat que molts programes d'aplicació variaven relativament poc els uns respecte dels altres. Les diferències més importants se centraven en la preparació de les dades, en el nombre de dades utilitzades com a entrades i en el nombre de dades de sortida que s'havien de predir. Per tant, semblava raonable dissenyar una interfície d'usuari guiada per formularis que oferís prou flexibilitat per ser usada en moltes aplicacions diferents i que evités que els usuaris haguessin de dissenyar i depurar els seus propis programes. Amb aquest objectiu, en aquesta tesi s'ha dissenyat i s'ha desenvolupat una nova plataforma per a la metodologia FIR que té com a base el MATLAB. La nova eina s'anomena Visual-FIR i permet identificar models de sistemes dinàmics i predir comportaments futurs d'aquests d'una manera senzilla i guiada.

El Visual-FIR ofereix una nova perspectiva per dissenyar blocs de processos que permeten tractar les quatre tasques principals de la metodologia FIR, és a dir, codificació difusa, modelització qualitativa, simulació/predicció qualitativa i regeneració, d'una manera senzilla, compacta, eficient i fàcil d'emprar. Cada bloc s'activa quan és necessari i permet seleccionar fàcilment l'opció que interessa per a cada

paràmetre associat a aquesta tasca específica. D'aquesta manera, és molt fàcil per a l'usuari *jugar* amb les opcions dels paràmetres i estudiar com aquests afecten la modelització i la predicció del sistema en estudi.

El disseny de la interfície d'usuari del Visual-FIR està marcada per les noves tècniques de presentació de la informació basades en els sistemes de finestres desenvolupats des de principis de la dècada de 1980 i coneguts com a *interfície gràfica d'usuari* (GUI, de l'anglès *graphical user interface*).

Sovint ens trobem que, a l'hora de programar amb una eina orientada a una temàtica molt determinada, els recursos que aquesta ofereix per solucionar problemes que no són del seu àmbit són insuficients i necessitem coneixements d'enginyeria del programari per acabar d'arrodonir la feina. Aquest és el cas de MATLAB. Aquesta eina, que és, al mateix temps, un potent llenguatge de programació, està orientada al càlcul matemàtic i ofereix tot un seguit de funcions i mètodes per facilitar la solució de problemes numèrics (tractament de vectors i matrius, gràfics, estadística, lògica, etc.). Ofereix, també, una utilitat — que es pot cridar amb el comandament *guide*— amb la qual es poden dissenyar formularis visuals amb el consegüent tractament d'esdeveniments. De fet, el que fa aquesta eina és generar un fitxer amb la descripció detallada de la figura i les propietats de tots els objectes que conté i un altre amb el codi font en MATLAB que dibuixa les interfícies així com el nom de les funcions que es cridaran en els esdeveniments que s'hagin definit.

Hi ha altres mètodes de modelització difusa disponibles que són accessibles a través d'una interfície gràfica d'usuari. Probablement, l'eina més popular és la *toolbox* de MATLAB de lògica difusa [3], així com la plataforma fuzzyTECH [4]. Altres desenvolupaments que cal esmentar són el FLINT [5], el FuzzyCLIPS [6], el FIDE [7] i el KEEL [1]. Aquests desenvolupaments ofereixen eines per crear i aplicar models basats en regles difuses clàssiques, i alguns d'aquests donen suport també a diferents solucions neurodifuses i geneticodifuses. En aquesta introducció aportem una pinzellada d'aquestes plataformes.

5.1.1 MATLAB Fuzzy Logic Toolbox

La *toolbox* (caixa d'eines) de lògica difusa de MATLAB [3] proporciona les funcions, les eines gràfiques i un bloc de Simulink per analitzar, dissenyar i simular sistemes basats en lògica difusa. És una eina que proporciona un entorn informàtic que permet crear i editar sistemes d'inferència difusa manualment, mitjançant l'ús d'eines gràfiques interactives o de funcions de la línia de comandes, o de manera automàtica mitjançant tècniques neuroadaptatives (ANFIS) [76] o de classificació difusa.

Les característiques principals són:

- Interfície gràfica d'usuari especialitzada per construir sistemes d'inferència difusa (Fuzzy Inference Systems [FIS]) i analitzar-ne els resultats (vegeu la figura 5-1).
- Definició de funcions de pertinença per crear sistemes d'inferència difusa.
- Suport per als operadors lògics I, O i NO en la definició de les regles difuses per a l'usuari.

- Facilitat per incloure un sistema d'inferència difusa en un model de Simulink.
- Habilitat per generar codi C que pot ser utilitzat per altres programaris o perquè els motors d'inferència difusos siguin executables independentment.

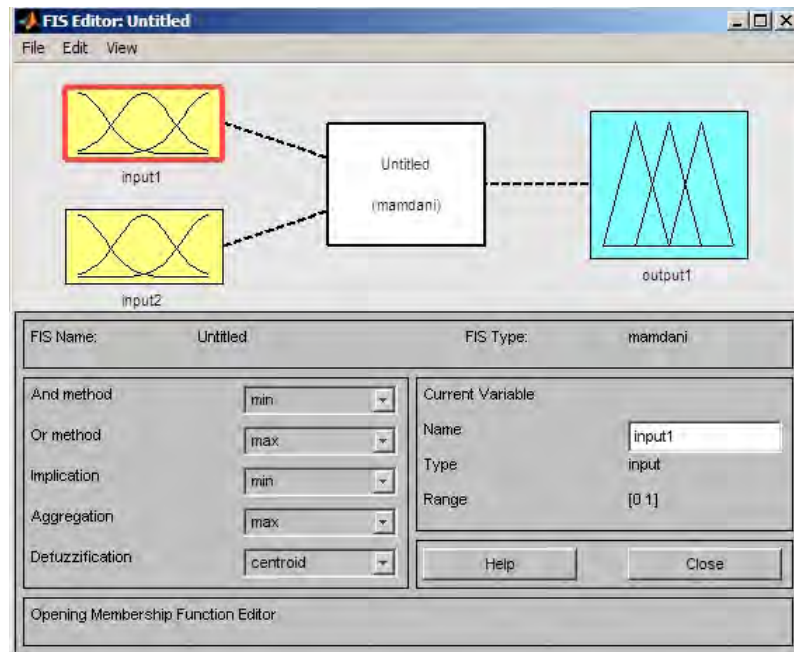


Figura 5-1 Interfície gràfica de la FLT. Pantalla principal.

La *toolbox* permet modelitzar comportaments de sistemes complexos amb regles simples i, a continuació, aplicar aquestes regles a un sistema d'inferència difús. Es pot usar com un motor d'inferència difús independent. Alternativament, es poden utilitzar els blocs d'inferència difusos en Simulink i simular els sistemes difusos dins d'un model integral del sistema dinàmic complet.

5.1.2 FuzzyTech

Aquest entorn és un dels més difusos i complets per desenvolupar sistemes basats en lògica difusa. L'entorn de FuzzyTech va ser desenvolupat per la companyia INFORM Software GMBH i va sorgir del treball d'un grup d'investigadors dirigit pel professor Hans Zimmermann, de la Universitat d'Aquisgrà (Alemanya). Zimmermann és un dels pioners de la lògica difusa a Europa, fundador de la International Fuzzy Systems Association (IFSA), la principal organització internacional per a la investigació i aplicació dels sistemes basats en lògica difusa.

L'entorn FuzzyTech està format per una GUI comuna basada en MS-Windows que permet l'edició gràfica de les variables lingüístiques per a cadascuna de les variables del sistema, amb una precisió seleccionable segons la classe d'implementació final (de 8 a 16 bits).

El FuzzyTech disposa de diversos assistents per facilitar les tasques de disseny més freqüents, com ara l'estructura, les variables i les regles. Inclou una finestra de gestió del projecte amb estructura d'arbre, tal

com mostra la figura 5-2, un sistema personalitzat de generació automàtica de documentació del projecte i un gestor de versions integrat.

L'entorn admet la simulació fora de línia i en temps real. Pel que fa al primer punt, permet la depuració interactiva amb la visualització dels fluxos d'inferència i l'optimització interactiva dels paràmetres del sistema.

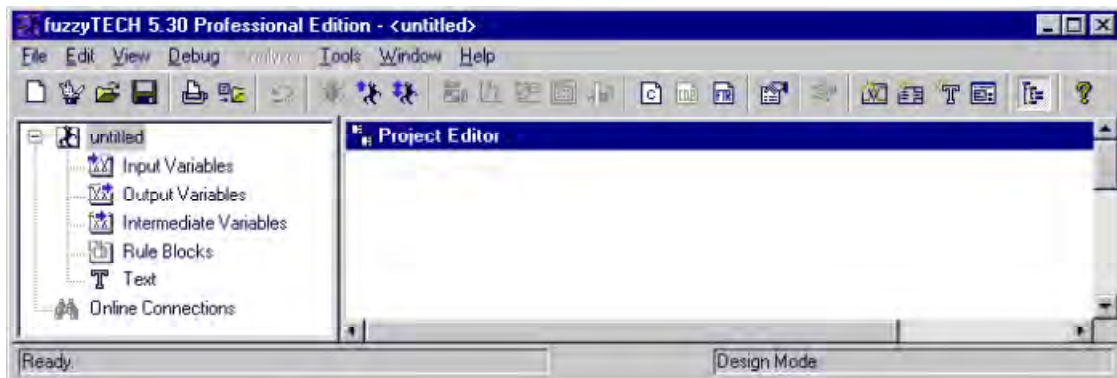


Figura 5-2 Finestra principal de l'editor FuzzyTECH.

Aquesta eina fa servir una representació de nombres difusos mitjançant funcions de pertinença trapezoïdals. Una de les característiques, a la qual el fuzzyTECH presta una atenció especial és la codificació difusa. L'eina ofereix diferents tècniques per al càlcul eficient de la codificació difusa i inclou algunes orientades a la implementació per al maquinari. El fuzzyTECH permet utilitzar alguns dels mètodes de codificació difusa més habituals (*center of average*, *center of area* i *mean of maxima*), així com d'altres d'utilitzats en el reconeixement de patrons (HyperCoM).

Una de les característiques fonamentals del fuzzyTECH és la generació automàtica de codi C. Quan es compila s'obtenen resultats molt eficients, la qual cosa és una característica molt atractiva per desenvolupar aplicacions professionals. A més de versions simplificades amb objectius acadèmics, el fuzzyTECH també ofereix diferents extensions per a sistemes de control encastats i desenvolupaments especials per a la indústria de l'automoció. S'utilitza per controlar motors, electrodomèstics, sistemes antiblocatge (ABS) i predicció borsària, entre d'altres.

5.1.3 FLINT

Els sistemes experts tradicionals treballen sobre la base que tot és vertader o fals, i que en qualsevol norma les condicions satisfetes són utilitzables, és a dir, que les seves conclusions són veritables. Això és bastant simplista i pot conduir a sistemes experts molt fràgils. El FLINT és compatible amb tres tractaments d'incertesa: lògica difusa, actualització bayesiana i factors de certesa.

El FLINT proporciona un editor difús molt fàcil d'utilitzar que permet definir i modificar les funcions de pertinença (vegeu la figura 5-3). L'editor difús genera un codi en Flex o Prolog a través de la interfície gràfica d'usuari.

El FLINT suporta diverses formes estàndard de les funcions de pertinença (trapezoide, triangles, etc.), així com qualsevol forma definida per l'usuari. El FLINT també és compatible amb el concepte de *modificadors difusos*, que sovint es refereix a la cobertura lingüística. Aquests modificadors afecten la funció de pertinença mitjançant la intensificació (concentració) o difusió (dilució) de la seva forma.

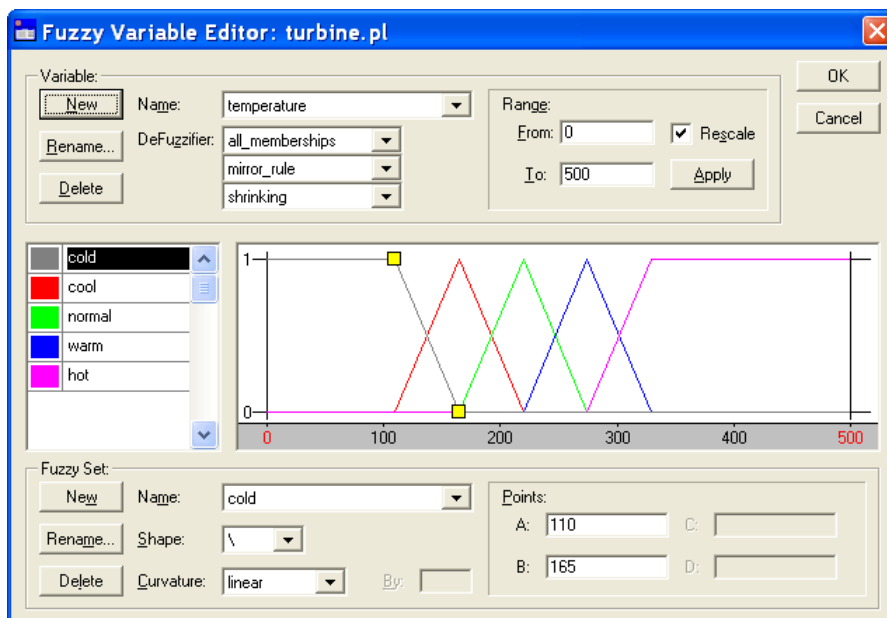


Figura 5-3 Editor de variables difuses del FLINT.

Les regles difuses en FLINT s'expressen mitjançant una sintaxi simple i ordenada. A més, es poden agrupar en una matriu comunament coneguda com a *memòria associativa difusa* (FAM).

El FLINT suporta diverses classes d'operadors matemàtics que es poden combinar per implementar diferents estratègies, incloent-hi mín.-màx., additius i l'enfortiment.

El FLINT admet dues descodificacions estàndard: el mètode de centroide, que es basa en el centre de gravetat, i el mètode de bec, que es basa en el valor difús més alt. A més, el FLINT permet generar un *descodificador discret* definit per l'usuari.

5.1.4 FuzzyCLIPS

El FuzzyCLIPS és una extensió del CLIPS (sistema de producció integrat en llenguatge C), desenvolupat per la divisió de tecnologia de programari del Centre Espacial Lyndon B. Johnson de la NASA seguint la mateixa filosofia i la mateixa sintaxi, i sorgeix com una eina de desenvolupament i suport per als sistemes experts difusos. El sistema integra de manera ponderada els conseqüents per donar una resposta global afectada per la confiança o el nivell d'activació de cadascuna de les regles [26]. El FuzzyCLIPS permet treballar amb raonament exacte, difús o amb una barreja de tots dos, cosa que permet barrejar les regles i els fets d'un sistema expert amb termes normals i difusos [109].

5.1.5 FIDE

L'entorn FIDE (Fuzzy Inference Development Environment) ha estat desenvolupat per la companyia americana Apronix, en col·laboració amb Motorola. Aquest entorn es basa en un llenguatge de descripció de controladors anomenat FIL (fuzzy inference language), que està compost de tres subllenguatges, un per a cadascun dels possibles entorns. El llenguatge FIU (fuzzy inference unit) permet descriure unitats d'inferència difusa formades per conjunts de regles que s'apliquen a les variables, per a les quals es poden definir diversos adjectius.

Les regles en el llenguatge FIU s'expressen en un estil similar a l'anglès natural. També es poden introduir utilitzant una interfície d'usuari semblant a un full de càlcul.

L'entorn FIDE s'estructura basant-se en un editor de textos multifinestra que inclou un compilador de llenguatge FIL. Des d'aquesta aplicació MS-Windows és possible cridar els quatre blocs bàsics que componen l'entorn: *Compiler*, *Debugger*, *Composer* i *RTC*. El bloc *Compiler* compila els fitxers font del llenguatge FIL i genera un codi objecte per a la resta de les aplicacions. L'aplicació *Debugger* té tres eines: *Tracer*, *Analyzer* i *Simulator*. El *Tracer* permet obtenir el valor de les sortides per a uns valors concrets de les entrades i seguir pas a pas el procés d'inferència que genera els valors de sortida. L'*Analyzer* analitza la funció de transferència del sistema i visualitza la funció de sortida des de diverses perspectives. És possible fer una representació tridimensional de la superfície de sortida, o bé visualitzacions bidimensionals i topològiques. Finalment, el *Simulator* simula el comportament dinàmic de les unitats per a unes dades de test.

D'altra banda, l'aplicació *Composer* permet que l'usuari creï sistemes complexos que combinen mòduls difusos amb altres de no difusos, utilitzant l'anomenat FCL. Aquesta eina proporciona un editor gràfic per a dissenyar els sistemes d'inferència.

5.1.6 KEEL

El KEEL (Knowledge Extraction based on Evolutionary Learning) [9] és una eina de programari no comercial escrita en Java per utilitzar algorismes evolutius (AES) en problemes de mineria de dades. Permet executar dins del mateix entorn (execució en línia) o generar el codi per a una execució posterior en diferents màquines (execució fora de línia). La versió actual del KEEL està composta pels mòduls següents:

- Tractament de dades: aquest mòdul conté un seguit d'eines de tractament de dades: importació, exportació, edició i visualització de dades, aplicació de transformacions, etc.
- Experiments: aquest mòdul genera procediments d'anàlisi i avaluació automàtica d'algorismes fora de línia, i proporciona nombroses opcions: Tipus de validació, tipus d'aprenentatge (classificació, regressió, aprenentatge no supervisat), etc.

- Educacional: aquest mòdul executa algorismes en línia. Té una estructura similar a la del mòdul anterior, però permet dissenyar experiments per executar-los pas a pas, amb propòsits educatius.

Aquesta estructura fa que el KEEL sigui interessant per a diferents classes d'usuaris, depenent de les seves necessitats. Des d'un punt de vista general, les principals característiques del KEEL són les següents:

- Inclou algorismes d'aprenentatge de models predictius, de preprocessament (transformació de dades, discretització, selecció d'instàncies i selecció de característiques) i postprocessament, amb una atenció especial a les propostes evolutives.
- Posseeix una llibreria estadística per analitzar resultats d'algorismes. Aquesta llibreria conté tests estadístics per analitzar la bondat dels resultats obtinguts i també per establir comparacions paramètriques i no paramètriques.
- Inclou una llibreria de programació d'algorismes evolutius en Java (Java Class Library for Evolutionary Computation [JCLEC]).
- Ofereix a l'usuari una interfície propera, orientada a l'anàlisi d'algorismes.
- Permet crear experimentacions que contenen múltiples conjunts de dades i algorismes connectats entre si. Els experiments són generats mitjançant *scripts* independents de la interfície d'usuari, per permetre una execució fora de línia o en altres màquines.
- També permet executar experiments en línia, cosa que dona un suport educatiu a la tasca de comprendre el funcionament dels algorismes que inclou.

El mòdul d'experiments és l'encarregat de generar els fitxers i l'estructura de directoris requerida per executar-lo en qualsevol màquina amb Java. Els experiments són modelitzats gràficament, basats en fluxos de dades i representats mitjançant grafs i connexions arc-node. Permeten escollir la mena de validació que s'ha d'utilitzar i la classe d'aprenentatge (regressió, classificació i aprenentatge no supervisat).

5.2 La metodologia FIR mitjançant un exemple

Aquesta secció té com a objectiu mostrar al lector com es desenvoluparia un codi MATLAB que fes servir la metodologia FIR per modelar i predir una fallada en una aplicació centrada en un sistema d'injecció d'una turbina de gas. Aquesta aplicació, basada en un projecte europeu anomenat DAMADICS, és l'objecte d'estudi del capítol 7 d'aquesta tesi, en què s'explica amb profunditat. En aquesta secció, i per guiar el desenvolupament de codi MATLAB que fa ús de la metodologia FIR anterior al Visual-FIR, es treballa amb una sola fallada de la turbina de gas: erosió a la vàlvula SRV (F3).

En la secció següent es torna a fer aquesta tasca però usant la plataforma Visual-FIR, cosa que permetrà adonar-se de la potencialitat de la nova eina desenvolupada en aquesta tesi.

Tal com es descriu en el capítol 3 d'aquesta tesi, la metodologia FIR es compon de quatre etapes principals: codificació difusa, modelització qualitativa (cerca de la màscara òptima i obtenció de la base de regles patró), simulació qualitativa (predicció del comportament futur del sistema) i regeneració. En la figura 5-4 es mostren aquestes etapes de la metodologia FIR mitjançant la pantalla principal de la plataforma Visual-FIR.

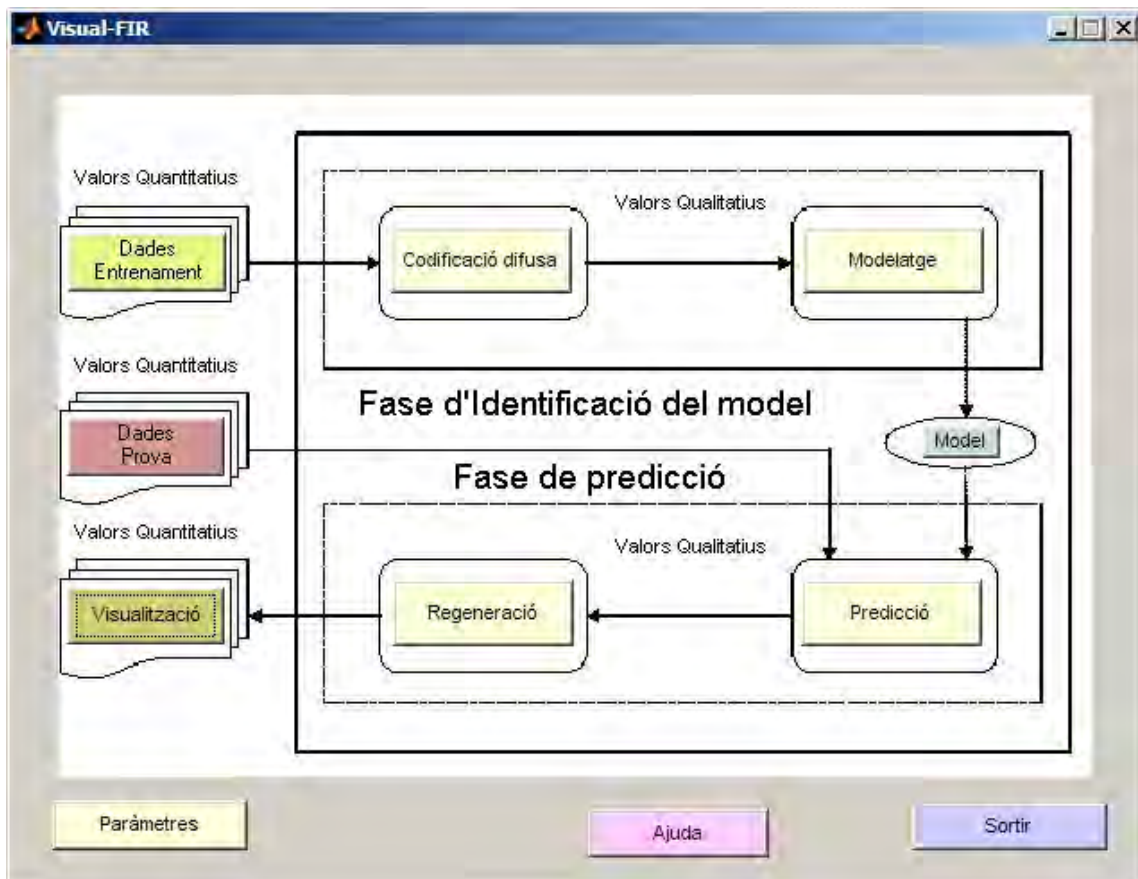


Figura 5-4 Pantalla principal del Visual-FIR amb les quatre etapes de la metodologia FIR.

El primer pas per obtenir un model FIR i fer prediccions de la fallada de la perforació del diafragma, a partir d'ara anomenada F3, és ajustar els paràmetres que intervenen en les quatre etapes de la metodologia FIR. En la figura 5-5 es mostra el codi MATLAB en què els paràmetres del FIR s'inicialitzen amb uns valors per defecte i les dades d'entrenament es carreguen d'un arxiu. Els paràmetres necessaris en totes les etapes es defineixen i s'inicialitzen a la vegada.

El pas següent de la metodologia FIR és la fase d'identificació del model que inclou la codificació difusa i la funció de cerca de la màscara òptima, tal com mostra la figura 5-4. La figura 5-7 presenta una possible implementació FIR d'aquesta etapa per a la fallada F3. L'exemple que ens ocupa és un sistema SISO, en què la variable d'entrada és la sortida de la vàlvula de control (CV) i la variable de sortida

correspon al desplaçament de l'eix normalitzat entre 0 i 1 (X_0), tal com es descriu detalladament en el capítol 4 d'aquesta tesi.

El FIR s'alimenta amb dades mesurades del sistema en estudiar que són convertides a informació difusa a partir d'una funció de codificació difusa. La funció *recode* mostrada en el codi (representada amb el nom *Codificar* en la figura 5-7), converteix els valors quantitius a triplets de valors qualitius, concretament, els valors de classe, pertinença i costat (vegeu el capítol 3).

```

% Inicialització %

clear
global def abs_weight norm_reg meth_search memb_shape miss_data qualms repo confi distance envol

def = 1;           % Predicció: activa el mètode de predicció dels 5 veïns més propers
abs_weight = 1;   % Predicció: activa la fórmula per calcular el pes absolut de cada veí
norm_reg = 2;     % Predicció: activa la fórmula de normalització per a cada veí
meth_search = 1;  % Màscara òptima: activa el mètode de cerca: Exhaustiu (1); Algorisme genètic (2)
memb_shape = 0;  % Codificació Dif.: activa la forma de la funció de pertinença: Gaussiana (0); Triangular (1)
miss_data = 0;   % Tots: activa el valor de dades desaparegudes si existeix
qualms = 1;      % Màscara òptima: activa la fórmula de la mesura de qualitat: Cellier (1); Uyttenhove (0)
repo = 0;        % Tots: si s'activa, es crea un fitxer "REPORT.DAT" amb un informe dels processos:
                 % No activat (0); Activat (1)
confi = 0;       % Predicció: permet activar la fórmula de la confiança de la predicció: No activat (0); Mesura
                 % de proximitat (1); mesura de similitud (2)
distance = 1;    % Predicció: activa la fórmula per calcular la distància entre els 5 veïns més propers
envol = 1;       % Predicció: permet activar el càlcul de l'envolupant de la predicció: No activat (0); Activat (1)

% Dades Entrenament (CV, X)
load ModelF3.mat % Càrrega de les dades d'entrenament del fitxer ModelF3s.mat

```

Figura 5-5 Codi MATLAB per inicialitzar els paràmetres de FIR per a la fallada F3 de DAMADICS.

Per tal de convertir els valors quantitius en triplets qualitius, cal proporcionar a la funció de codificació difusa el nombre de classes en què es vol dividir el domini de les variables, així com els llimdars que han de separar les classes veïnes. Una vegada aquesta informació s'ha introduït, el motor de codificació de FIR du a terme automàticament la codificació difusa de les dades quantitatives. En la implementació presentada en la figura 5-7, les dues variables s'han discretitzat en tres classes i s'ha utilitzat el mètode de partició amb la mateixa freqüència (EFP) per obtenir els llimdars entre classes. Llavors, la funció *recode* es crida dues vegades, una per discretitzar la variable d'entrada i la segona per discretitzar la variable de sortida. Com a resultat, s'obtenen les matrius c , m , i s , les quals es corresponen amb la classe, la pertinença i el costat, respectivament. En aquest punt, el comportament de la trajectòria contínua del sistema s'ha convertit en un comportament episòdic mitjançant la funció *recode*.

$$\begin{array}{cc}
 t/x & CV \quad X_0 \\
 t - 2\delta t & \begin{bmatrix} -1 & -1 \\ -1 & -1 \\ -1 & +1 \end{bmatrix} \\
 t - \delta t & \\
 t &
 \end{array}$$

Figura 5-6 Màscara candidata per a la fallada F3 de DAMADICS.

```

                                % Fase d'identificació del model%
VClasses = [3,3];           % Paràmetre amb el nombre de classes (3) per a la variable d'entrada i de sortida

% Càlcul dels llindars de les funcions de pertinença per a la variable d'entrada utilitzant el mètode EFP
[nfil,ncol] = size(CV);
ord = sort(CV);
class = VClasses(1,1);
p = zeros(class,1);
p(1) = floor(nfil/class);
for i=2:class - 1,
    p(i) = p(1)*i;
end
lm(1,1) = ord(1);
for j=1:class - 1,
    lm(j+1,1) = 0.5*(ord(p(j)) + ord(p(j) + 1));
end
lm(class+1,1) = ord(nfil);
toCV = 1:class;
fromCV = [lm(1:class,1),lm(2:class+1,1)];
[c(:,1), m(:,1), s(:,1)] = recode(CV,fromCV,toCV); % Codificació difusa de les dades d'entrada

% Càlcul dels llindars de les funcions de pertinença per a la variable de sortida utilitzant el mètode EFP
ord = sort(X);
class = VClasses(1,2);
p = zeros(class,1);
p(1) = floor(nfil/class);
for i=2:class - 1,
    p(i) = p(1)*i;
end
lm(1,1) = ord(1);
for j=1:class - 1,
    lm(j+1,1) = 0.5*(ord(p(j)) + ord(p(j)+1));
end
lm(class+1,1) = ord(nfil);
toX = 1:class;
fromX = [lm(1:class,1),lm(2:class+1,1)];
[c(:,2), m(:,2), s(:,2)] = recode(X,fromX,toX); % Codificació difusa de les dades de sortida

% Inici del càlcul de la màscara òptima
mCan = [-1,-1;-1,-1;-1,1]; % Inicialització de la màscara candidata
Complexitat = 5; % Inicialització de la complexitat màxima de la màscara
[mask, hm, hr, qm, mh] = mexfoptmask(c, m, mCan, Complexitat); % Càlcul de la màscara
[io, mio, sio] = iomodel(c, m, s, mask);
[ba,mba,sba] = behavior(io,mio,sio); % Càlcul de la base de regles patró

```

Figura 5-7 Codi MATLAB de la fase d'identificació del model FIR per a la fallada F10 de DAMADICS.

En el procés de modelització, es volen trobar les relacions causals, tant espacials com temporals, entre variables, de manera que el resultat de la matriu de transició d'estat sigui al més determinista possible. Això s'aconsegueix mitjançant la cerca de la màscara òptima, fent servir la funció de FIR *mexfoptmask*. Aquesta funció troba les relacions causals entre les variables del sistema, de manera que es maximitzi el poder de predicció del model partint de la informació del passat, és a dir, obté el millor model (format per una màscara i un conjunt de regles patró) que representa el comportament del sistema.

Per dur a terme aquesta tasca, la funció *mexfoptmask* necessita com a paràmetre d'entrada la màscara candidata. En la figura 5-6 es mostra la màscara candidata, *mCan*, definida en el codi MATLAB presentat en la figura 5-7, per a l'aplicació en estudi.


```

% Fase de simulació qualitativa o predicció. Validació del model FIR obtingut en la fase anterior%

load ModelF3Test.mat % Lectura de les dades de test per validar el model

% Preparació del conjunt de dades de test
t = (0:0.25:400)';
[FilM, ColM] = size(mask); % Dimensions de la màscara
[FilD, ColD] = size(CV); % Dimensions de les dades (files)
minim = min(CV);
maxim = max(CV);
if (minim < fromCV(1,1))
    fromCV(1,1) = minim;
end
if (maxim > fromCV(2,VClasses(1)))
    fromCV(2,VClasses(1)) = maxim;
end
toCV = 1:VClasses(1);
minim = min(X);
maxim = max(X);
if (minim < fromX(1,1))
    fromX(1,1) = minim;
end
if (maxim > fromX(2,VClasses(2)))
    fromX(2,VClasses(2)) = maxim;
end
toX = 1:VClasses(2);
Dades = zeros(FilD, 2);
c = zeros(FilD, 2);
m = zeros(FilD, 2);
s = zeros(FilD, 2);

% Codificació de les dades de test d'entrada i sortida
Dades(:,1) = CV;
[c(:,1), m(:,1), s(:,1)] = recode(Dades(:,1), fromCV, toCV);
Dades(1:FilM-1,2) = X(1:FilM-1);
[c(:,2), m(:,2), s(:,2)] = recode(Dades(:,2), fromX, toX);
c(FilM:FilD, 2) = -1;
m(FilM:FilD, 2) = 0.75;
s(FilM:FilD, 2) = 0;

% Predicció del conjunt de dades de test
[cP,mP,sP] = forecast(c, m, s, ba, mba, sba, mask, VClasses);

% Regeneració del conjunt de dades predites
pred = regenerate(cP(:,2), mP(:,2), sP(:,2), toX, fromX);
pred_sup = regenerate(cP(:,3), mP(:,3), sP(:,3), toX, fromX);
pred_inf = regenerate(cP(:,4), mP(:,4), sP(:,4),toX, fromX);
% Representació dels senyals real i de predicció
plot(t,X,'k',t,pred,'k');
ylabel('X (m) Model F3');
xlabel('Time (s)');
error = mse2(X,pred)

% Representació de l'envolupant
figure
plot(t,X,'k',t,pred_sup,'k',t,pred_inf,'k');
ylabel('X (m) Model F3');
xlabel('Time (s)');

```

Figura 5-8 Codi MATLAB de la fase de predicció de FIR per a la fallada F3 de DAMADICS.

La màscara candidata s'inicialitza a 3 files per tal d'analitzar la relació causal de la sortida en l'estat de temps actual, $X_0(t)$, amb la variable d'entrada, CV , en els tres instants de temps definits: t , $t - \delta t$, $t - 2 \delta t$, i la mateixa sortida en els instants anteriors a l'actual: $t - \delta t$, $t - 2 \delta t$. En aquest cas s'ha establert una complexitat màxima de 5. Després d'aquesta inicialització, es crida la funció *mexfoptmask* per tal d'obtenir les màscares òptimes i subòptimes que representin millor el comportament del sistema. La màscara òptima s'emmagatzema en la variable *mask* i el conjunt de màscares subòptimes, és a dir, les màscares òptimes de cada complexitat, es guarden en la variable *mhis*.

Un cop identificada la millor màscara, es pot aplicar a les matrius de dades qualitatives, prèviament adquirides, per obtenir una base de regles patró que, en la terminologia FIR, s'anomena *matriu de comportament*. Aquesta s'aconsegueix en el codi de la figura 5-8 fent crides consecutives a les funcions *iomodel* i *behaviour*. La funció *iomodel* obté a partir de les matrius de classe, *c*, pertinença, *m*, i costat, *s*, obtingudes en el procés de codificació difusa, i de la màscara, *mask*, obtinguda de la crida a *mexfoptmask*, tres noves matrius de classe, *io*, pertinença, *mio*, i costat, *sio*, que contenen les regles patró. Per tant, la funció *iomodel* converteix el comportament episòdic dinàmic en comportament episòdic estàtic, és a dir, en regles patró. La funció *behaviour* només s'encarrega d'ordenar aquest coneixement i omplir les matrius de comportament.

Una vegada es disposa del millor model FIR, representat per les matrius de comportament i la màscara, es pot dur a terme la fase de predicció, que inclou les funcions de predicció o simulació qualitativa i de regeneració (vegeu la figura 5-8). La figura 5-8 mostra una possible implementació en MATLAB de la fase de predicció de FIR per a l'exemple de la fallada F3.

En la metodologia FIR hi ha implementats diferents mètodes per determinar la funció de normalització i la funció de distància, que s'escullen mitjançant els paràmetres a l'inici del codi (vegeu la figura 5-5).

Tal com es mostra en la figura 5-8, cal, primer, preparar les dades de test per fer la codificació difusa utilitzant la funció *recode*, tal com s'havia fet prèviament amb les dades d'entrenament. Una vegada les dades s'han discretitzat, es crida la funció *forecast*, que permet obtenir el senyal qualitatiu predit, el qual es guarda en els vectors *cP*, *mP* i *sP*, que contenen els valors de classe, pertinença i costat, respectivament. Un cop predit el valor qualitatiu, la funció *regenerate* s'utilitza per calcular el valor quantitatiu corresponent. En aquest moment, és possible comparar les trajectòries simulades amb les mesurades. Al final del codi del programa mostrat en la figura 5-8, es representa l'envolupant obtingut durant el procés de predicció i que emprarà el FIRFMS en l'etapa de detecció i identificació de la fallada.

Les figures 5-5, 5-7 i 5-8 contenen el codi necessari per dur a terme la identificació d'un model FIR i la simulació o predicció d'un sistema de fallades específic. Per a cada sistema o subsistema que es vol modelitzar cal, doncs, escriure codis equivalents. Cal notar que provar diferents combinacions de paràmetres implica, necessàriament, una quantitat no menyspreable de reprogramació

5.3 Plataforma visual del raonament inductiu difús: Visual-FIR

En aquesta secció es presenta la plataforma Visual-FIR mitjançant l'aplicació del sistema d'injecció d'una turbina de gas, utilitzada en l'apartat anterior. L'objectiu és utilitzar el Visual-FIR per identificar dos models del servomotor pneumàtic: el primer, per al comportament normal i, el segon, per a quan té lloc una fallada corresponent a un problema d'obstrucció o d'erosió de la vàlvula. Una vegada identificats els dos models de comportament, serà possible detectar la fallada en temps real utilitzant la funció de l'envolupant de la plataforma Visual-FIR.

Per identificar el model de l'actuador en condicions d'operació normal, s'ha utilitzat un conjunt de 400 dades que corresponen a 50 segons de funcionament. Per validar el model, s'ha utilitzat un conjunt de 1.600 dades. Per identificar i validar el model quan es produeix la fallada, s'han utilitzat conjunts de dades de la mateixa dimensió que en el cas del funcionament normal. Un cop identificats i validats els dos models, s'han generat diferents escenaris de l'actuador, en comportament normal i en fallada, per tal d'explicar la metodologia de detecció i identificació de fallades que utilitza el Visual-FIR.

La pantalla principal de la nova plataforma s'activa des de l'entorn MATLAB mitjançant la instrucció Visual-FIR. En aquesta pantalla es mostren els quatre processos principals de la metodologia FIR, tal com mostra la figura 5-4. A la part superior de la figura 5-4 es presenta la fase d'identificació del model, mentre que a la part inferior s'inclou la fase de predicció, durant la qual el model que ha estat prèviament identificat s'utilitza per estimar el comportament futur del sistema.

Ara descriurem com s'identifica el model i com es valida utilitzant la plataforma Visual-FIR.

5.3.1 Fase d'identificació del model

Per tal d'identificar el millor model a partir de les dades registrades, cal seguir els passos següents de manera seqüencial: configuració dels *Paràmetres*, càrrega de les dades d'entrenament (*Entrenar*), codificació difusa de les dades (*Codificar*) i identificació de la màscara òptima (*Modelatge*). Cadascun d'aquests passos correspon a una comanda determinada de la pantalla principal. Aquests passos es van habilitant de manera seqüencial seguint el curs dels esdeveniments. Una vegada s'han completat tots aquests passos, el model FIR complet compost de la màscara òptima i de les matrius de comportament es visualitzen prement el botó *Model*.

5.3.1.1 Ajust dels paràmetres

Quan s'ha premut el botó *Paràmetres*, es mostra una pantalla amb els 9 paràmetres globals (vegeu la figura 5-9). Tots els paràmetres es poden modificar, cosa que permet diferents opcions d'execució de la metodologia FIR, com ara les maneres diferents de calcular la qualitat de la màscara (*qualms*): amb un 1 es defineix la fórmula de les freqüències i amb un 0, la fórmula de la complexitat (no implementada actualment); la forma de les funcions de pertinença (*memb-shape*), explicades en el capítol 3 de la tesi: un 0 implica la funció gaussiana i un 1, la triangular; les maneres diferents de calcular la distància de

predicció (*distance*) i les equacions de pesos (*abs-weight*); els diferents mètodes de predicció (*def*), que indiquen el mètode que s'escull per fer les prediccions. Actualment, només està implementada l'opció dels 5 veïns més pròxims, i s'ha d'indicar $def = 1$. Estan preparats els valors per a $def = 2$ i $def = 3$ per quan s'implementin mètodes de predicció de *center of area* i *mean of maxima*, respectivament. Es poden definir diferents funcions de normalització per calcular la distància en l'algorisme de la predicció 5NN (*norm-reg*). També hi ha un paràmetre *miss_data* que permet que l'usuari indiqui que hi ha valors perduts (*missing*) en el conjunt de dades enregistrades. S'utilitza per a les funcions de codificació, de cerca de la màscara òptima i de predicció. Si és 0, indica que no hi ha valors perduts en la mostra de dades d'entrada. Si és diferent de 0, el valor que tingui serà el valor *missing* de la mostra, que no pot coincidir amb cap valor de la matriu de classes. El Visual-FIR és capaç de tractar dades que contenen elements perduts de manera eficaç i eficient. Quan s'activa el paràmetre *repo*, s'escriu en el fitxer *report.dat* i en la finestra de

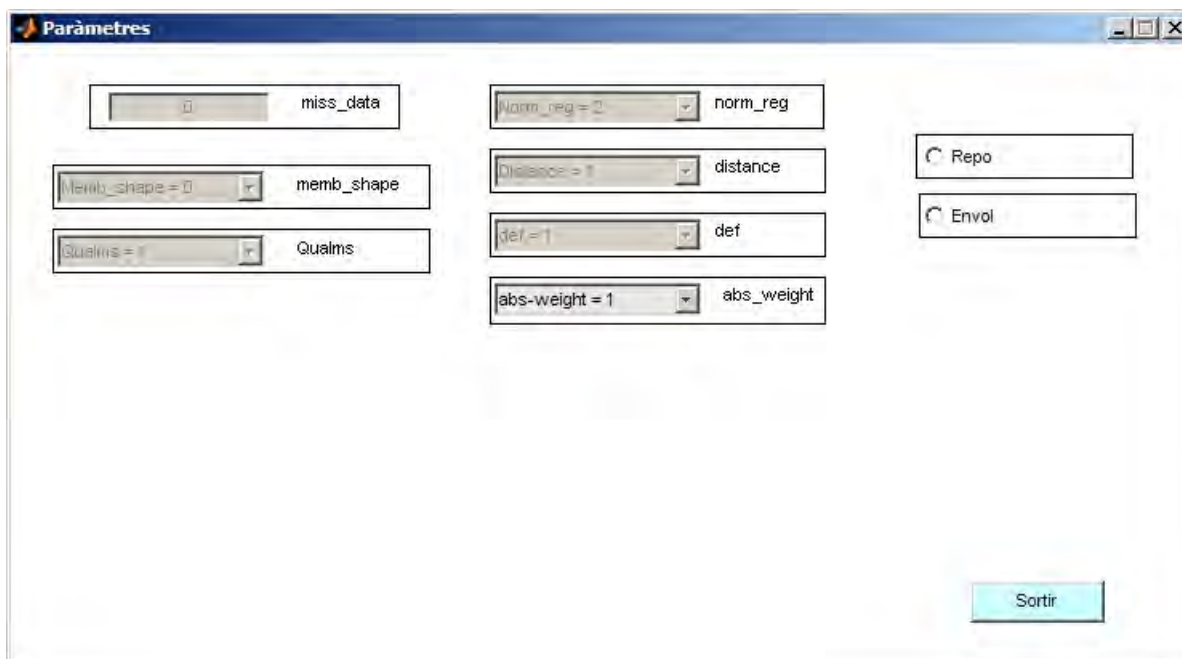


Figura 5-9 Pantalla de configuració dels paràmetres de la plataforma Visual-FIR.

MATLAB la informació relacionada amb la màscara òptima: el valor de l'entropia i la qualitat de cadascuna de les màscares avaluades i, en els processos de predicció, la distància dels 5 veïns més pròxims i la sortida que els correspon en la matriu de comportament de classes per a cadascuna de les prediccions. Aquesta informació és valuosa per valorar la qualitat de les màscares subòptimes respecte a la qualitat de la màscara òptima i per analitzar el conjunt de regles disparades durant la predicció. Finalment, quan s'activa el paràmetre *envol*, explicat en el capítol 4, i s'utilitza l'algorisme 5NN, es calcula l'interval de predicció. Aquest interval és necessari quan s'utilitza el model FIR per detectar fallades. A tots els paràmetres se'ls ha associat un valor per defecte perquè els usuaris no experts puguin procedir sense haver de fer-hi cap canvi. El botó *Paràmetres* és accessible des de totes les pantalles; però

només es permet accedir als paràmetres que són rellevants per a la tasca des de la qual la pantalla dels paràmetres s'ha activat.

En l'aplicació d'estudi s'utilitzen els valors per defecte per a tots els paràmetres, com es mostra a la figura 5-9. El paràmetre *miss-data* té assignat el valor de zero, perquè no hi ha dades perdudes en el conjunt de dades disponibles. Els paràmetres *repo* i *envol* estan desactivats, perquè no es necessita informació addicional del procés de modelització i perquè no es pretén dur a terme la tasca de detecció de fallades en aquest moment. El paràmetre *envol* s'activarà més tard, quan els dos models de funcionament normal i de fallada de l'actuador estiguin disponibles.

5.3.1.2 Dades d'entrenament

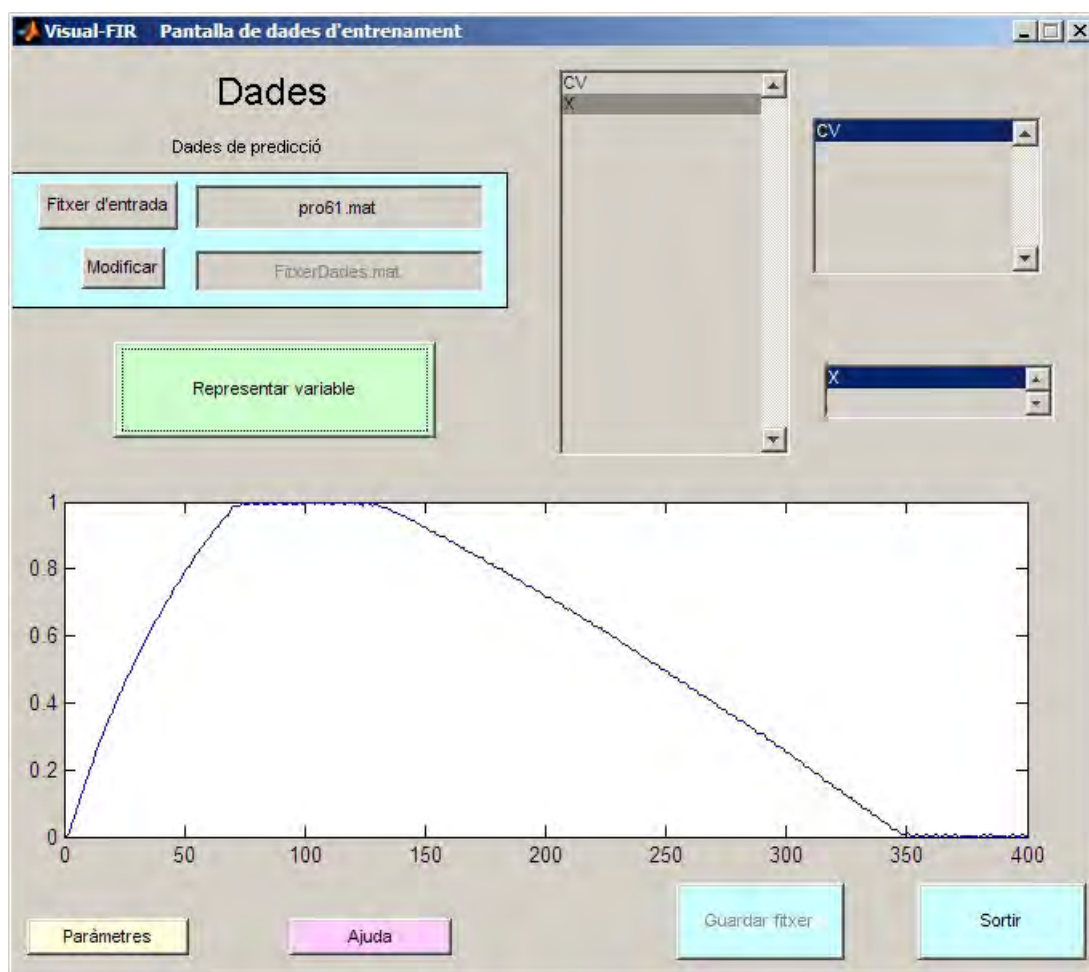


Figura 5-10 Pantalla d'entrada de les dades d'entrenament de la plataforma Visual-FIR.

Abans de començar la fase d'identificació del model, s'ha de carregar el conjunt de dades d'entrenament. Aquest pas es fa amb la comanda *entrenar* de la pantalla d'entrada de dades d'entrenament mostrada en la figura 5-10. Inicialment, l'única opció que està activada és la de carregar les dades d'entrenament d'un arxiu (botó: *Fitxer d'entrada*) i la designació de l'arxiu de sortida (botó: *Modificar*). El fitxer de sortida és un arxiu intermedi utilitzat per transferir les dades d'una pantalla a la següent. Per tant, no cal modificar

el nom per defecte tret que es vulguin guardar diferents combinacions. Els botons *Paràmetres* i *Ajuda* estan disponibles en totes les pantalles i ofereixen a l'usuari informació sobre el procés actual.

Una vegada carregat el fitxer de dades d'entrenament, es llisten a la pantalla els noms de totes les variables emmagatzemades a l'arxiu. Ara, l'usuari ha de decidir quines són les variables que s'han d'utilitzar com a entrades i en quin ordre. Aquesta tasca es completa fàcilment seleccionant una variable i prement >> per incloure-la a la llista de variables d'entrada. Finalment, la variable de sortida se selecciona prement la comanda *Variable de sortida*. Cal tenir en compte que no cal incloure en l'estudi de modelització i predicció totes les variables emmagatzemades a l'arxiu de dades d'entrenament.

Una vegada s'han definit les variables d'entrada i sortida, es poden mostrar, una per una, a la part central de la pantalla de dades d'entrenament. Si s'activa el paràmetre *miss-data*, llavors s'inclou l'opció de mostrar les dades sense els valors perduts. Abans de sortir de la pantalla d'entrenament, cal guardar les dades prement el botó *Guardar fitxer*.

En l'aplicació que ens ocupa, la variable *CV* s'ha seleccionat com a variable d'entrada, mentre que *X* s'ha seleccionat com a variable de sortida. Al gràfic central de la figura 5-10 es visualitza el senyal de la variable *X* i es veu que per identificar el model de l'actuador s'utilitzen 400 dades.

5.3.1.3 Codificar

Les dades ja estan a punt per ser codificades (conversió de dades quantitatives a qualitatives). La finestra de codificació es mostra quan l'usuari activa *Codificar* a la pantalla principal del Visual-FIR. La figura 5-11 mostra la configuració d'aquesta nova pantalla. El primer que cal fer és carregar el fitxer de dades que s'ha guardat en el pas anterior. Per fer-ho, cal pressionar el botó *Llegir*, de manera que, a continuació, es mostra, a la meitat esquerra de la pantalla, la llista de totes les variables (entrades i sortides). Totes aquestes variables tenen associades per defecte 3 classes i l'algorisme de partició amb la mateixa freqüència (EFP). No obstant això, tal com es mostra a la meitat dreta de la pantalla, l'usuari disposa d'un gran nombre d'algorismes de discretització o agrupament de dades, tant jeràrquics com no jeràrquics. Cal indicar que hi ha l'opció *Manual*, que permet que l'usuari defineixi els llimdars de les particions segons els criteris dels experts o la seva pròpia elecció. Quan se selecciona un algorisme, els paràmetres requerits per l'algorisme triat es llisten en el quadre de paràmetres. En l'exemple de l'aplicació, la variable d'entrada *CV* es codifica manualment en 2 classes, perquè és un senyal binari. La variable de sortida, *X*, s'agrupa en 3 classes utilitzant l'algorisme EFP. La primera classe conté els valors de la variable que se situen en l'interval $[0..0,33457]$. Les classes segona i tercera corresponen als rangs de dades $[0,33457..0,79642]$ i $[0,79642..1]$, respectivament.

Els algorismes d'agrupament que estan implementats en aquesta pantalla del Visual-FIR són:

- **Manual:** s'assignen manualment els llimdars de les classes. S'activen les finestres de nombre de classes i els llimdars corresponents.

- *Single linkage*: mètode jeràrquic també anomenat *mètode dels veïns més pròxims* o *de la distància mínima*. S'estableix la distància entre dos grups com la distància mínima entre els individus de cadascun. És a dir, per avaluar la distància entre un grup i un altre, es quantifica la distància de cada element del primer respecte de cada element del segon i la distància més petita de totes és la distància entre grups. Només s'activa la finestra per determinar el nombre de classes que es vol.

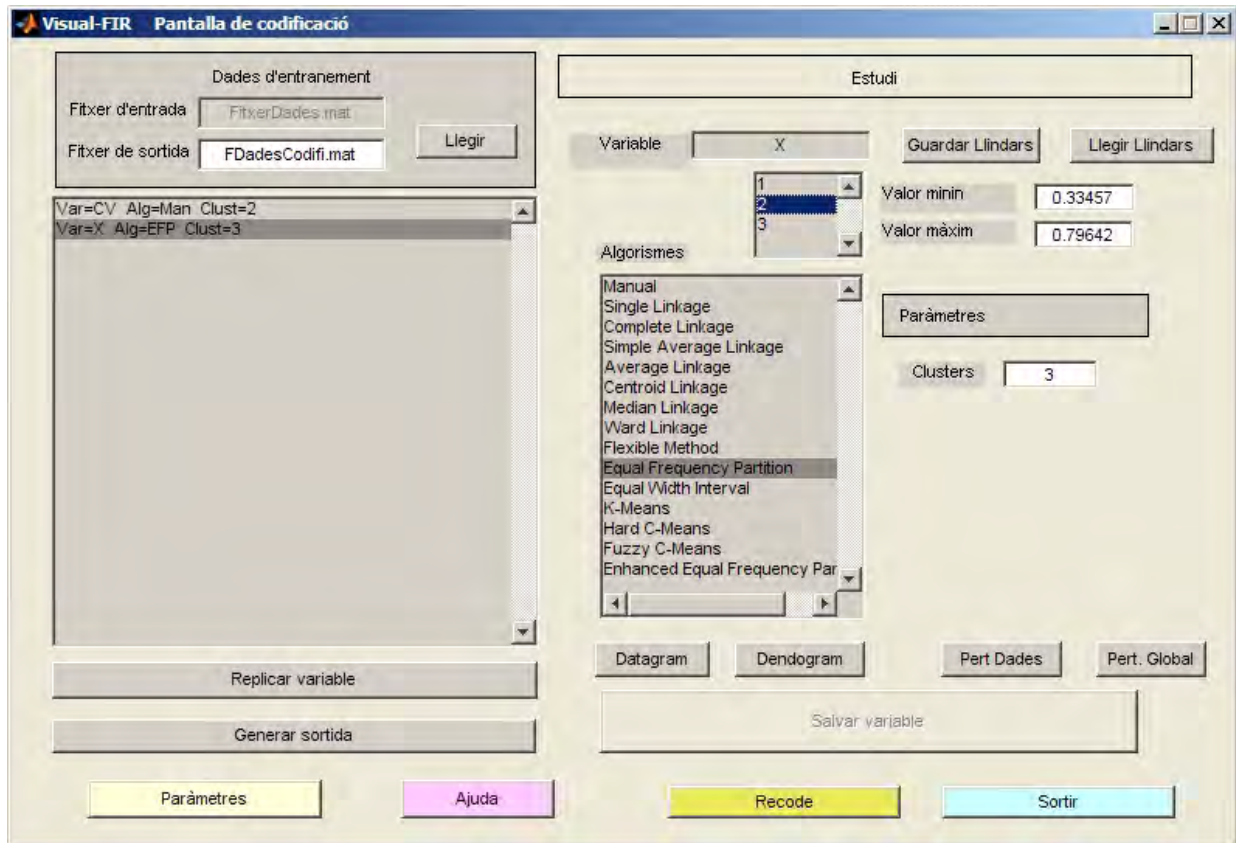


Figura 5-11 Pantalla del procés de codificació difusa de la plataforma Visual-FIR.

- *Complete linkage*: mètode jeràrquic també anomenat *mètode dels veïns més allunyats* o *de la distància màxima*. Aquest cas és molt semblant a l'anterior, ja que s'estableix la distància entre grups a partir de la distància entre dos elements concrets, un per a cada conjunt. La diferència rau en el fet que ara són els elements més allunyats els que compleixen aquesta funció representativa. Només s'activa la finestra per decidir el nombre de classes.
- *Average linkage*: mètode jeràrquic també anomenat *mètode de distàncies mitjanes intragrups*. Es combinen els grups de manera que la mitjana de les distàncies entre tots els parells de subjectes dins el clúster resultant és la més petita possible. Per tant, la distància entre dos grups es pren com la mitjana de les distàncies entre tots els possibles parells de casos dins el grup en qüestió. Només s'activa la finestra per determinar el nombre de classes.
- *Centroid linkage*: mètode jeràrquic en què la distància entre dos grups és la distància entre els centroides respectius, és a dir, la distància entre les mitjanes de cada grup per a totes les variables.

Només necessita el nombre de classes.

- *Median linkage*: mètode jeràrquic en què la mitjana del centroid del grup resultant es calcula segons la mitjana entre els grups, independentment del nombre d'elements que té cadascun. Necessita el nombre de classes.
- *Ward linkage*: mètode jeràrquic que intenta minimitzar la pèrdua d'homogeneïtat que suposa fusionar dos grups a cada iteració. De fet, tota l'anàlisi mira de formar grups amb cohesió interna i que siguin externament aïllats, però la particularitat d'aquest mètode és que utilitza directament un plantejament en aquesta línia. La filosofia del mètode és calcular, per a tots els grups, la mitjana de totes les variables. Posteriorment, per a cada individu, es calcula la distància euclidiana al quadrat respecte d'aquesta mitjana i se suma per a tots els individus. A cada pas els grups que es van formant són els que resulten en un menor increment de la suma global de distàncies al quadrat dins el grup.
- *Flexible method*: algorisme jeràrquic, similar al mètode *simple average*, que permet modificar un paràmetre β per aconseguir diferents agrupacions. Per a $\beta = 0$, aporta el mateix resultat que el mètode *simple average*. S'activen dues finestres, una per definir les classes i l'altra per fixar el valor de β .
- *Equal frequency partition*: algorisme no jeràrquic en què els elements de les classes es classifiquen per una partició que distribueix el mateix nombre d'elements a cadascuna. Només necessita el nombre de classes [54 i 55]).
- *Enhanced equal frequency partition*: algorisme millorat del mètode de la mateixa freqüència explicat en el capítol 3 d'aquesta tesi [53].
- *Equal width interval*: mètode no jeràrquic que divideix el rang de dades en tants intervals com nombre de classes ens demanin, de manera proporcional. Necessita la quantitat de classes en què es vol dividir el rang de dades.
- *K-means*: algorisme de classificació que intenta minimitzar la suma de distàncies de tots els elements respecte del centre. Aquest mètode genera grups de dades força compactes i amb una distribució sovint força bona. S'han de definir el nombre de classes i la quantitat d'iteracions que volem que faci l'algorisme.
- *Hard c-means*: algorisme de classificació que, tal com el *k-means*, intenta trobar el centre del grup minimitzant les distàncies entre els components. En aquest algorisme s'ha de definir el nombre de classes i la quantitat d'iteracions que volem que faci, i s'hi ha d'introduir un paràmetre de tolerància d'acabament que atura el procés de classificació quan la mesura de variació entre les iteracions és menor que aquest valor.

- *Fuzzy c-means*: algorisme de classificació difús que busca el centre dels valors de la classe que minimitzen la funció de dissemblança. Els paràmetres que necessita aquest algorisme són: el nombre de classes, el nombre màxim d'iteracions i el valor del paràmetre d'aturada, i s'hi ha afegit l'exponent difús, que ha de ser superior a 1 i que és una part important de la fórmula utilitzada en aquest mètode.

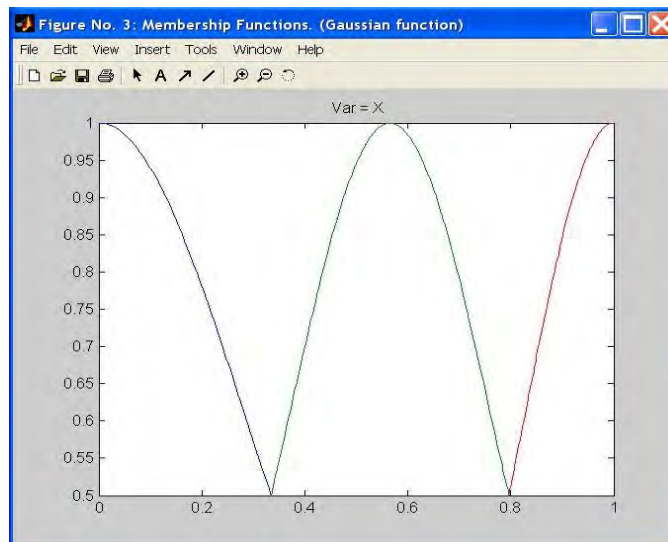


Figura 5-12 Funcions de pertinença de la variable de sortida X obtingudes amb l'opció *data memb* de la pantalla del procés de codificació difusa de la plataforma Visual-FIR.

Cada variable del sistema que apareix al costat esquerre de la pantalla de codificació es pot discretitzar per separat, utilitzant qualsevol dels algorismes que figuren a la part dreta de la pantalla, cosa que permet una discretització *ad hoc* de cada variable. El botó *Replicar variable* permet estendre una determinada configuració a la resta de les variables. La construcció de datagrames i dendrogrames són opcions que s'ofereixen a l'usuari per facilitar-li el procés d'agrupament de dades. Quan totes les variables tenen les estratègies d'agrupament definides, el botó *Generar sortida* calcula el nombre de classes i els llindars corresponents (fronteres entre classes veïnes), informació necessària per a la funció de codificació difusa. A continuació, *Recode* converteix les dades quantitatives en triplets qualitius, cosa que genera els valors de classe, pertinença i costat per a cadascuna de les dades quantitatives del conjunt de variables d'entrenament. També hi ha la possibilitat de veure gràficament la distribució i la forma de les funcions de pertinença generada. Amb aquest fi, després de generar la sortida, es poden utilitzar els botons *Data memb* i *Global memb*. L'opció *Data memb* dibuixa la funció de pertinença de cada classe, utilitzant només les dades d'entrenament disponibles. *Global memb* interpola les dades d'entrenament amb tantes dades com punts necessita per obtenir una funció de pertinença contínua i esmorteïda. Cal dir que les dues representacions són exactament la mateixa si el nombre de mostres en les dades del conjunt d'entrenament és prou gran i aquest conjunt està ben representat. La pantalla es pot tancar amb l'opció *Sortir*. La figura 5-12 mostra les funcions de pertinença de la variable de sortida, X , com a resultat d'utilitzar la comanda *data memb*.

5.3.1.4 Màscara òptima

Un cop les dades s'han codificat, es pot dur a terme el procés de modelització qualitativa (cerca de la màscara òptima). Això s'aconsegueix prement *Modelatge* a la pantalla principal, de manera que es mostra la pantalla de la figura 5-13.

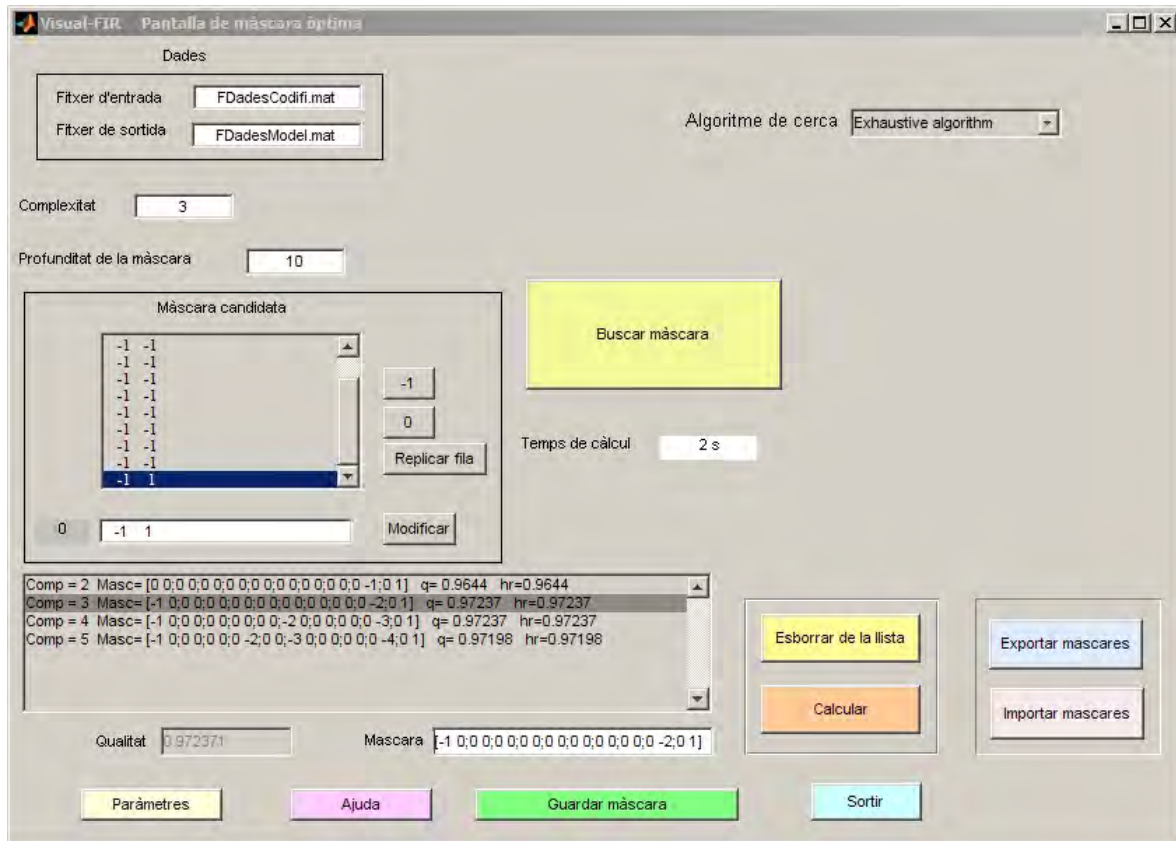


Figura 5-13 Pantalla de cerca de la màscara òptima de la plataforma Visual-FIR.

Tal com s'ha descrit anteriorment, la cerca de la màscara òptima s'inicia amb la definició de la màscara candidata. En aquesta pantalla, en establir la màxima complexitat de la màscara candidata i la profunditat d'aquesta, el Visual-FIR genera la matriu de màscara candidata en l'espai que té reservat. El valor de complexitat per defecte és 5. La profunditat no té cap valor per defecte i cal que l'especifiqui l'usuari. L'usuari pot introduir en la màscara candidata connexions prohibides situant-se a la posició de la matriu on vol prohibir la connexió i substituint el -1 per un valor de zero. Una vegada la màscara candidata està llesta, la cerca de la màscara òptima s'inicia prement el botó *Buscar màscara*. L'algorisme utilitzat per defecte és un algorisme exhaustiu, però es pot optar per fer una cerca genètica mitjançant el desplegable *Algorisme de cerca*. Quan està seleccionat l'algorisme de cerca exhaustiva, es mostra el temps de càlcul estimat per oferir més informació a l'usuari, de manera que si aquest veu que una cerca exhaustiva s'allargaria massa, pot optar per escollir un algorisme genètic per fer la cerca. Quan se selecciona l'algorisme genètic, els paràmetres associats apareixen a la part dreta de la pantalla. L'usuari pot decidir utilitzar els valors predeterminats o canviar-ne alguns o tots. La figura 5-13 mostra la màscara candidata del cas d'estudi. En aquest cas, s'ha escollit una profunditat de 10. El temps de càlcul necessari per

obtenir el model amb una cerca exhaustiva és de prop de 5 segons, pel nombre reduït de variables que intervenen en aquest estudi. Per tant, és raonable utilitzar l'algorisme de cerca exhaustiva en lloc d'un algorisme genètic.

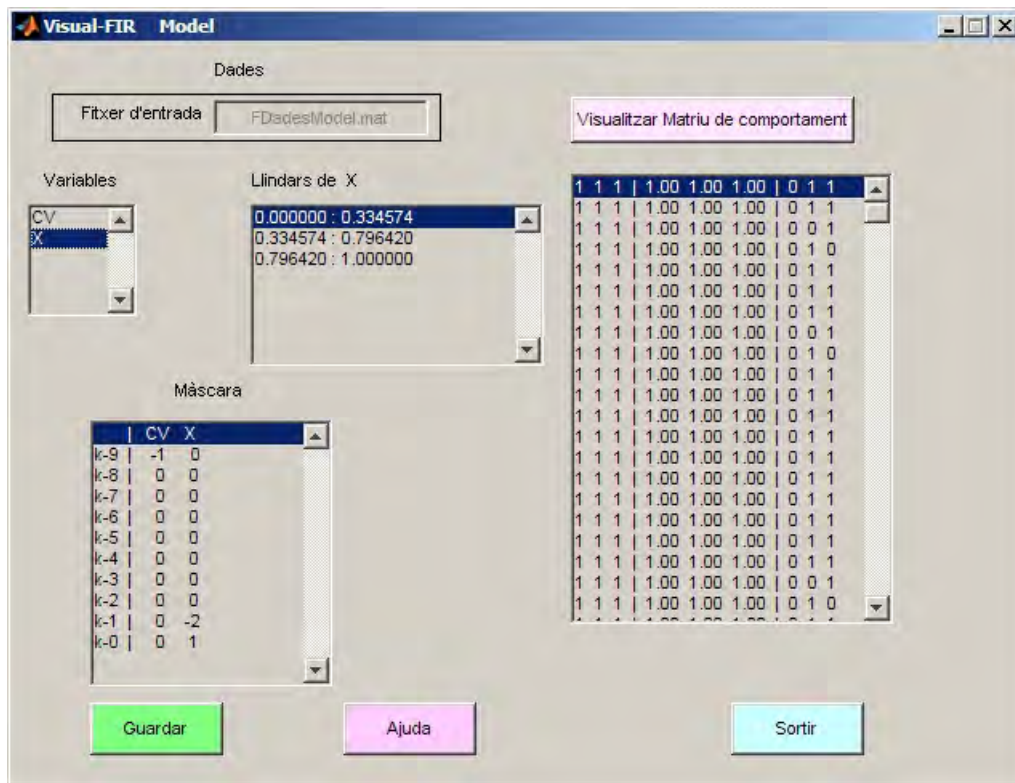


Figura 5-14 Pantalla de visualització del model FIR de la plataforma Visual-FIR.

Una vegada s'ha completat el procés de cerca de la màscara òptima, a la part inferior de la pantalla es mostren la màscara òptima i les subòptimes (màscars òptimes de cada complexitat), i, per a cadascuna, se'n presenta la complexitat, a més de les mesures de qualitat associades. L'usuari pot eliminar les màscars que vulgui prement la comanda *Esborrar de la llista*. També està disponible l'opció d'introduir una màscara de manera manual i calcular-ne la qualitat prement el botó *Calcular*, de manera que s'inclou en la llista de màscars obtingudes. En aquest estudi se selecciona la màscara de complexitat 3, ja que es tracta de la màscara que presenta la qualitat més alta, $Q = 0,9723$, és a dir, és l'òptima. Una vegada l'usuari ha seleccionat la màscara que vol explorar per descriure el comportament del sistema, cal prémer *Guardar màscara*. En aquest instant, la màscara s'utilitza per extreure la base de regles patró a partir de les dades d'entrenament qualitatives gravades. La màscara seleccionada i la base de regles patró (matriu de comportament) donen lloc al model FIR del sistema. El model FIR complet es pot veure prement el botó *Model* de la pantalla principal, de manera que es mostren la màscara, els llindars i la matriu de comportament, tal com recull la figura 5-14.

5.3.2 Fase de predicció

Quan es disposa del model FIR, l'usuari pot validar-lo utilitzant aquest model per predir les dades de test o validació. Un cop estigui validat el model, aquest es pot utilitzar per predir el comportament futur del sistema. La fase de predicció consta de quatre passos, tal com mostra la pantalla principal del Visual-FIR (vegeu la figura 5-4): càrrega de les dades de test, predicció del comportament del sistema, regeneració de les dades i visualització de resultats.

5.3.2.1 Càrrega de les dades de test

La càrrega de les dades de test es fa pressionant el botó *Test*. Seguidament, es mostra la mateixa pantalla presentada en la fase de càrrega de les dades d'entrenament (vegeu la figura 5-10). L'usuari ha de seleccionar el fitxer on estan emmagatzemades les dades de test. Si les variables d'entrada i sortida tenen el mateix nom en el fitxer de dades de test que el que tenien en el fitxer de dades d'entrenament, les variables tant d'entrada com de sortida se seleccionen de manera automàtica, seguint la selecció que ha fet l'usuari en la fase de selecció de dades d'entrenament. Si el nom de les variables és diferent, l'usuari ha de seleccionar de la llista de variables les que han de ser variables d'entrada i l'ordre d'aquestes, així com la variable de sortida. El funcionament d'aquesta pantalla és exactament el mateix que s'ha explicat anteriorment en el pas de dades d'entrenament, però, quan s'activa la comanda de guardar l'arxiu, les dades de prova es discretitzen utilitzant els mateixos paràmetres definits en el procés de codificació difusa. En l'estudi actual s'utilitza un conjunt de 1.600 dades de test per validar el model.

5.3.2.2 Predicció

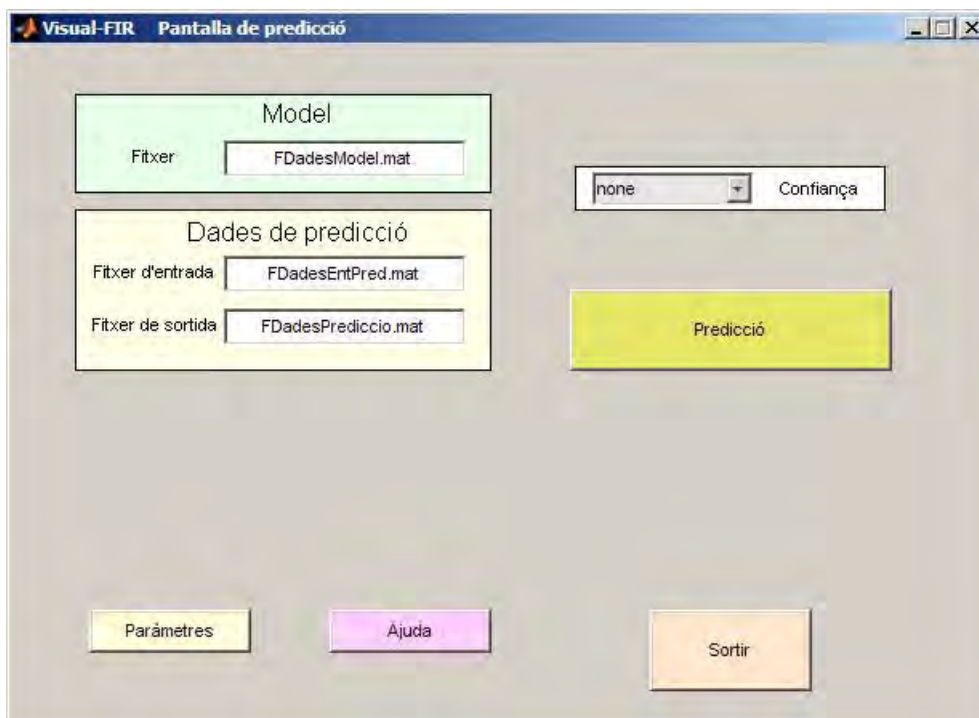


Figura 5-15 Pantalla de predicció de la plataforma Visual-FIR.

Una vegada es disposa de les dades de test qualitatives, es pot fer la predicció. Per fer-ho, cal activar el

botó *Predicció* des de la pantalla principal, de manera que es mostra la pantalla de la figura 5-15. Després de seleccionar les opcions de predicció a la finestra de paràmetres, s'executa l'algorisme corresponent prement el botó *Predicció* de la nova finestra. La comanda *envol* de la pantalla de paràmetres ofereix als usuaris la possibilitat de calcular l'envolupant que s'ha d'utilitzar en l'etapa de detecció i identificació de fallades. La comanda *confidence* [27] de la pantalla de predicció permet que l'usuari obtingui no tan sols el senyal de predicció sinó també la confiança que té l'algorisme en la seva pròpia predicció. Per defecte, la confiança no es calcula. En el cas que l'usuari vulgui obtenir una mesura de confiança de la predicció, pot escollir entre dues opcions: una mesura de proximitat o una mesura de similitud. El senyal de predicció juntament amb els valors de l'envolupant i la confiança, si s'han seleccionat aquestes opcions, es guarden per regenerar-los a partir de la pantalla següent. Si la predicció no es fa perquè els valors d'entrada no es troben en la matriu de comportament (de classe), apareix un missatge d'error que mostra la regla patró que no està disponible. En aquest cas, cal buscar una altra màscara a la pantalla de cerca de la màscara òptima o, si és possible, cal incloure un nombre més gran de dades en el conjunt d'entrenament. Una vegada finalitzat el procés, l'usuari surt de la pantalla de predicció amb la comanda *Sortir*.

5.3.2.3 Regeneració

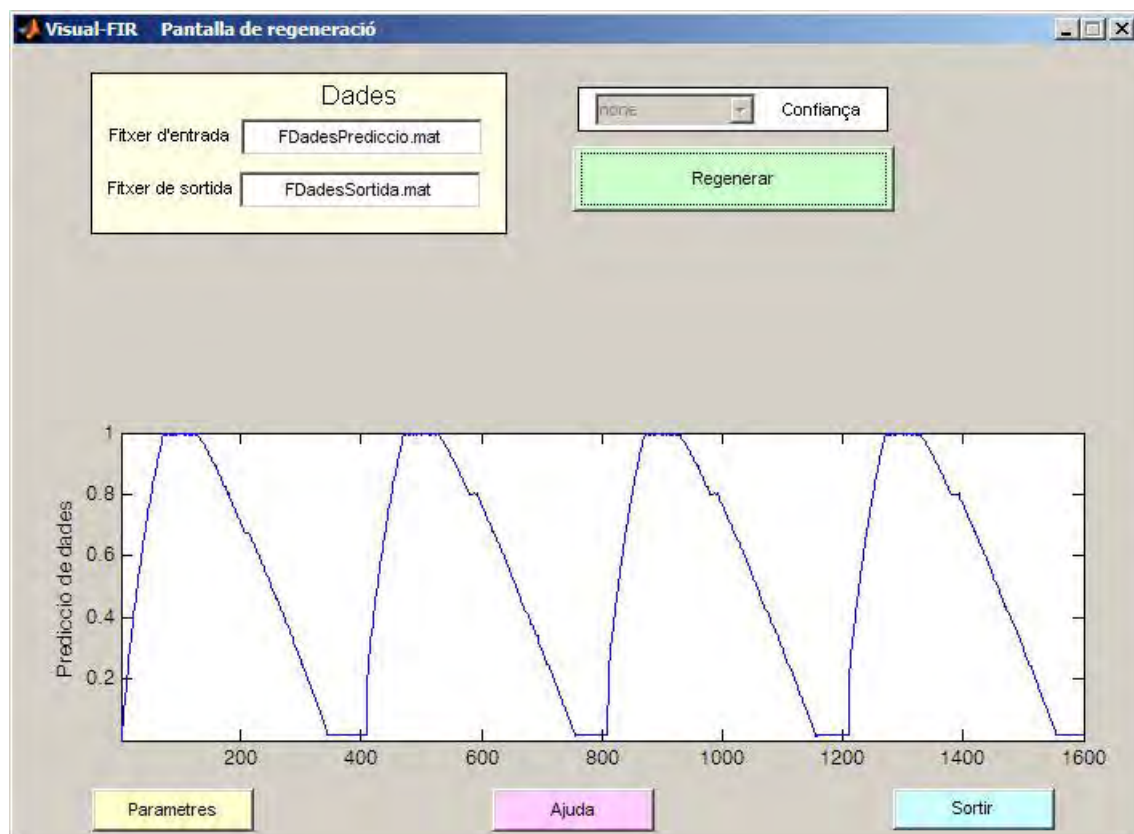


Figura 5-16 Pantalla de regeneració de les dades de test de la plataforma Visual-FIR.

El pas següent de la pantalla principal del Visual-FIR és la regeneració de les dades de prova predites. Aquesta tasca es completa amb la comanda *Regeneració*, ubicada a la pantalla principal del Visual-FIR

(vegeu la figura 5-4). En aquest cas, apareix la pantalla de la figura 5-16 i en prémer el botó *Regeneració* els triplets qualitatius es converteixen en valors quantitius (el procés invers de la codificació difusa). En aquesta pantalla es mostra el senyal de predicció quantitatiu de manera gràfica. L'última cosa que cal fer és visualitzar els resultats d'una manera més completa per comparar el senyal de predicció amb el real i conèixer els valors de les mesures d'error.

5.3.2.4 Visualització de resultats

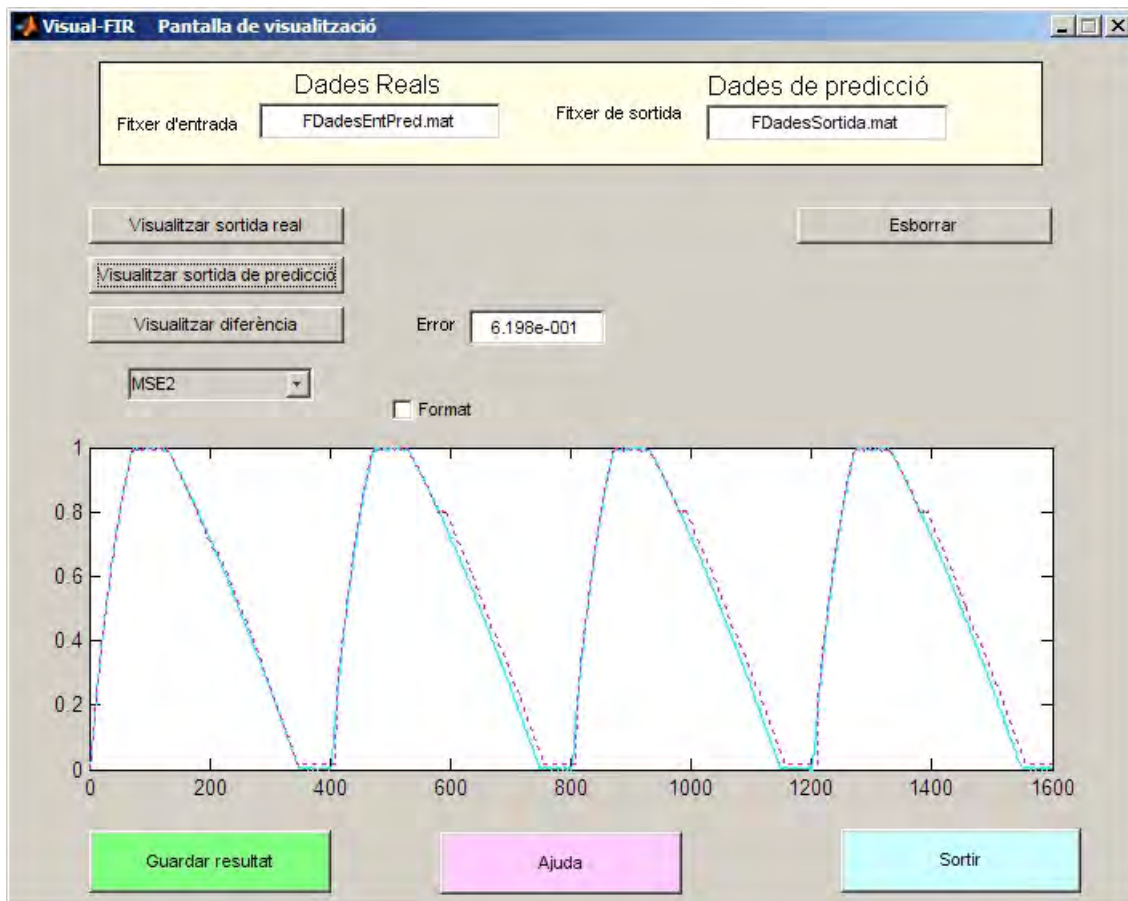


Figura 5-17 Pantalla de visualització de la predicció de les dades de test de la plataforma Visual-FIR.

En aquest punt, s'han finalitzat els processos de predicció i regeneració, i, per tant, l'usuari pot visualitzar els resultats i revisar l'error obtingut quan s'utilitza el model FIR per predir el comportament futur del sistema. Per fer-ho, cal activar la comanda *Visualització* de la pantalla principal del Visual-FIR. La pantalla de visualització es mostra en la figura 5-17. L'usuari pot visualitzar el senyal de sortida real, el senyal de sortida predit i la diferència entre ambdós senyals. Cada vegada que l'usuari accedeix a una d'aquestes opcions, el senyal corresponent s'afegeix a l'àrea de representació. Es permet esborrar els senyals mostrats mitjançant el botó *Esborrar*. L'usuari pot escollir entre diferents fórmules per calcular l'error de predicció del model, de manera que l'error quadràtic mitjà en percentatge (MSE2) és l'equació escollida per defecte. Tal com es mostra en la figura 5-17, la predicció del conjunt de 1.600 dades de test utilitzant el model FIR identificat prèviament té un error MSE2 de 0,6198 % per a l'aplicació en estudi i

el senyal predit segueix les dades de test acuradament durant els 200 segons que dura el període de prova. En aquest moment, el model de comportament normal de l'actuador està disponible.




Figura 5-18 Definició de l'experiment i predicció amb el model FIR que representa el comportament normal de l'actuador i amb el model FIR que representa la fallada F3.

La mateixa seqüència d'etapes, explicada fins ara, s'ha utilitzat per identificar el model de comportament de l'actuador quan es produeixen obstruccions o l'erosió de la vàlvula, és a dir, quan es dona la fallada. En aquest cas, s'ha triat una complexitat de la màscara de 5. L'error MSE2 de predicció del model per a un conjunt de prova de 1.600 punts és de 0,1736 %. Per tant, el model F3 obtingut amb el FIR reflecteix amb exactitud el comportament del sistema quan es produeix la fallada F3. Ara que els dos models estan disponibles, s'utilitzen per detectar la fallada proposada i per determinar el comportament de l'actuador. Per això s'ha dissenyat l'experiment següent: l'actuador funciona correctament durant un període de temps de 160 segons; en aquest moment, té lloc una obstrucció de la vàlvula del servomotor; aquest problema queda resol després de 160 segons de funcionament; a partir de llavors, el sistema exhibeix de nou un comportament normal. La figura 5-18 mostra, en el gràfic superior l'experiment que s'ha dut a terme. En el gràfic del mig es mostra el senyal real i l'envolupant de la predicció obtinguda amb el model FIR pel que fa al comportament normal del sistema. El gràfic inferior presenta el senyal real juntament amb l'envolupant de la predicció obtinguda amb el model FIR de la fallada. Tal com es veu al gràfic del mig de la figura 5-18, els primers 160 segons el senyal real es manté dins de l'envolupant de la predicció obtinguda amb el model FIR quan l'actuador funciona correctament. Contràriament, el senyal real queda

fora de l'envolupant de la predicció obtinguda amb el model FIR quan té lloc la fallada (gràfic inferior). Entre els segons 160 i 320, el model FIR de la fallada és el que manté el senyal real dins de l'envolupant. El senyal surt de l'envolupant obtinguda amb el model de funcionament normal de l'actuador. Finalment, al cap de 320 segons, el model de comportament normal prediu un envolupant que conté completament el senyal real. Per tant, quan el sistema no funciona bé per culpa de la fallada, el model de funcionament normal de l'actuador ofereix una predicció inexacta i el model de la fallada esdevé el que permet obtenir una predicció més precisa. El concepte d'envolupant ja s'ha introduït en el capítol 4 com a part del sistema de monitoratge de fallades del FIR (FIRFMS). Aquí es presenta per demostrar l'ús del paràmetre de l'envolupant.

5.4 Contribució del Visual-FIR a la metodologia FIR

El Visual-FIR proporciona una nova interfície per a la metodologia FIR, de manera que ofereix una plataforma fàcil d'emprar i una implementació amb una eficiència elevada. Aquesta plataforma presenta una nova visió de la metodologia basada en blocs de processos. A més a més, el Visual-FIR aporta noves característiques, de manera que augmenta la capacitat global de la metodologia FIR. Els principals avantatges del Visual-FIR respecte al FIR són:

- Els processos principals de la metodologia estan clarament separats, cosa que fomenta una comprensió senzilla entre els usuaris. S'hi ha introduït la idea dels *blocs de processos*, cosa que permet protegir els paràmetres i les accions associades a cada tasca específica.
- Els usuaris no han d'implementar cap línia de codi, cosa que evita els errors freqüents d'implementació associats a la selecció dels conjunts de dades d'entrenament i validació, entre d'altres.
- Resulta molt fàcil provar combinacions de paràmetres diferents en cadascun dels blocs. El conjunt d'opcions que es poden arribar a estudiar és força gran, fet que no era possible en la versió de la metodologia FIR anteriorment implementada.
- Les pantalles d'entrenament i test/validació simplifiquen enormement la selecció de les variables d'entrada i sortida, així com l'anàlisi visual de les dades. Quan una variable analitzada conté valors perduts (*missing*), l'usuari pot triar l'opció de visualitzar les dades amb o sense valors perduts, cosa que facilita la comprensió de la naturalesa de les dades disponibles.
- L'etapa de codificació difusa s'ha redissenyat, de manera que el nombre de classes i els llimars d'aquestes classes, és a dir, els paràmetres necessaris per dur a terme la codificació difusa, es puguin calcular mitjançant tots els algorismes disponibles a la pantalla de *Codificació*. L'usuari pot estudiar diferents alternatives per tal de determinar els valors adequats d'aquests dos paràmetres de manera eficient. Això ofereix un avantatge significatiu respecte de la versió anteriorment

implementada, ja que el procés de discretització té una influència important en el model obtingut.

- La pantalla de *Cerca de la màscara òptima* ofereix a l'usuari un control complet del procés de modelització. És extremadament fàcil per a l'usuari decidir si és convenient o no fer una cerca exhaustiva en funció del temps estimat necessari per calcular-la. A més, pot estudiar fàcilment el rendiment de qualsevol màscara que no aparegui entre les que estan llistades. Resulta molt senzill excloure de la màscara candidata les relacions que l'usuari no estigui interessat a estudiar, tot convertint-les en relacions prohibides.
- Una vegada s'ha obtingut el model FIR, està disponible per ser consultat a cada moment. L'usuari pot visualitzar la màscara, els límits de les classes i la matriu de comportament que conté la base de regles patró. Això és útil per als investigadors, ja que permet entendre millor els patrons de comportament observats.
- Tal com les pantalles d'entrenament i test/validació, la pantalla de visualització ofereix a l'usuari diverses facilitats per a l'anàlisi visual dels resultats de predicció. Si el conjunt de dades de validació (o prova) conté valors perduts, l'usuari pot escollir l'opció de dibuixar els resultats amb o sense els valors perduts. A més, es disposa de diferents fórmules per calcular l'error de predicció.

L'experiència ha demostrat que utilitzant la interfície anterior la majoria dels usuaris s'abstindrien d'explorar més d'una aproximació de modelització, ja que cada opció requereix un esforç addicional de programació. Els usuaris només canviarien de mètode de modelització si el model obtingut no proporcionés bons resultats. Utilitzant el nou entorn gràfic, els usuaris tendeixen a explorar diferents mètodes, a comparar-los els uns amb els altres i a seleccionar el que ofereix els millors resultats en termes d'eficiència computacional i exactitud de predicció. En el procés, els usuaris aprofundeixen significativament en la comprensió del conjunt de dades disponible i, per tant, dels patrons de comportament obtinguts amb el sistema estudiat.

5.5 Conclusions

En aquest capítol, s'ha presentat la plataforma Visual-FIR. Aquesta nova eina permet accedir a la metodologia FIR d'una manera efectiva i agradable. La metodologia FIR proporciona una aproximació basada en models per predir la dinàmica dels sistemes, amb molt bons resultats quan s'utilitza en aplicacions centrades en les ciències toves (*soft sciences*). L'avantatge del Visual-FIR, respecte d'implementacions FIR anteriors, és que no cal desenvolupar codi i ofereix un entorn guiat, cosa que proporciona una manera intuïtiva i fàcil d'accedir a la metodologia FIR. Evidentment, aquesta millora comporta un preu que cal pagar. Una interfície d'usuari guiada no pot oferir mai la mateixa flexibilitat que una interfície programada. No obstant això, la plataforma Visual-FIR ha demostrat que és prou flexible per a la majoria d'aplicacions. S'espera que la nova interfície obri la metodologia FIR a nous usuaris, ja que permet provar-la en noves aplicacions sense gaire esforç i permet provar ràpidament els

diferents algorismes de modelització en aquestes noves aplicacions, fet que fins ara requeria un procés de reprogramació important.

En aquesta secció, s'ha presentat la plataforma Visual-FIR emprant una aplicació centrada en un sistema d'injecció d'una turbina de gas (DAMADICS). Amb l'objectiu de presentar el procés d'identificació i predicció de la metodologia FIR utilitzant l'entorn Visual-FIR, només s'ha considerat una fallada. En els capítols posteriors s'abraça el DAMADICS amb força profunditat i extensió.

6 Diagrames de blocs en el FIR: el VisualBlock-FIR

Resum: en aquest capítol es presenta la plataforma VisualBlock-FIR, en què s'emmarca el sistema de detecció i diagnòstic de fallades (FDDS, de l'anglès fault detection and diagnostic system) per a plantes no lineals i basat en lògica difusa, presentat en el capítol 4 d'aquesta tesi. El VisualBlock-FIR s'executa en l'entorn Simulink i defineix mòduls gràfics interactius que permeten que l'usuari construeixi models del sistema amb i sense fallades, així com que empri els processos de detecció i diagnòstic de l'FDDS. Aquesta nova eina, basada en blocs (mòduls), és molt pràctica i útil, ja que permet construir el sistema de detecció i diagnòstic de fallades de la planta en estudi com si es tractés del muntatge d'un lego en què cada peça té una funció específica i, per tant, només cal anar ajuntant les peces de manera adient. En la darrera part del capítol es presenta aquest procés per a una fallada d'un sistema d'una pila de combustible. Aquesta aplicació s'aborda més detalladament en el capítol 7 d'aquesta tesi.

6.1 Introducció

En aquest capítol es presenta la plataforma VisualBlock-FIR, que permet crear l'FDDS basat en models que s'ha explicat en el capítol 4. Com que l'FDDS es basa en el raonament inductiu difús (FIR), que està implementat en MATLAB, considerem que és lògic mantenir l'entorn de programació per fer aquest nou desenvolupament.

Tal com s'ha vist en el capítol anterior, la plataforma Visual-FIR permet identificar els models FIR d'un sistema i s'executa, sempre, fora de línia. L'objectiu de l'FDDS és localitzar, aïllar i identificar les fallades d'un sistema en temps real. En el nostre cas, ens interessa implementar un FDDS que sigui capaç de treballar tant amb sistemes reals com amb sistemes simulats, i permetre que es validi el funcionament d'aquests últims.

Les opcions que ofereix MATLAB per aconseguir aquests requisits són diverses. D'una banda, permet implementar sistemes simulats definits mitjançant equacions que es resolen a mesura que se simula tot el sistema. De l'altra, disposa de la *toolbox* de RealTime, que permet adquirir variables externes en temps real. Amb aquestes dues característiques i amb la implementació de la plataforma VisualBlock-FIR, n'hi ha prou per desenvolupar sistemes de detecció i diagnòstic de fallades basats en el FIR amb MATLAB.

Les funcions FIR que cal utilitzar per construir l'FDDS són les funcions de codificació, predicció i regeneració difuses. Tal com es mostra en l'apartat següent, el codi que s'ha d'implementar per construir un sistema de detecció i diagnòstic de fallades basat en el FIR és un codi força repetitiu, en què només canvien les dades referents a la quantitat de classes definides en el procés de discretització i els llinars corresponents a cadascuna d'aquestes classes per a cada variable del sistema. Per tant, és raonable pensar que un eina basada en blocs com el VisualBlock-FIR ha de permetre que qualsevol usuari construeixi de manera senzilla un sistema de detecció i diagnòstic de fallades, sense que hagi de tenir un coneixement gaire profund del FIR.

Per facilitar la utilització del VisualBlock-FIR, aquest s'ha implementat en l'entorn Simulink, una eina gràfica de MATLAB que permet simular sistemes dinàmics no lineals. Amb el Simulink, l'usuari crea els seus models a partir de llibreries de components bàsics, els copia d'una finestra a una altra, estableix les connexions oportunes i atorga valors als paràmetres. L'ús d'aquesta eina només requereix que l'usuari tingui un coneixement mínim de les característiques bàsiques i de la sintaxi de MATLAB (programa que facilita l'ús de variables escalars, vectorials i matricials). No obstant això, el màxim rendiment del Simulink s'obté quan se sap programar blocs propis, quan se sap programar en Matlab i, a més a més, quan s'utilitzen altres *toolboxes* disponibles.

Una característica molt important i útil del Simulink és que permet construir blocs escrits amb altres llenguatges de programació com ara el C o el Fortran. Això ha afavorit notablement la utilització d'aquest entorn en l'àmbit d'aquesta tesi, ja que les funcions bàsiques del FIR estan implementades amb aquests dos llenguatges i, per tant, no ha calgut implementar de nou el codi. En aquest capítol es presenta la llibreria de components desenvolupada en la plataforma VisualBlock-FIR que fa possible que l'usuari creï de manera senzilla sistemes de detecció i diagnòstic de fallades basats en el FIR.

L'estructura d'aquest capítol és la següent: en la secció 2 es justifica la necessitat de fer un pas més cap als diagrames de blocs emprant la fallada d'un sistema de piles de combustible. En la secció 3 es descriu la plataforma VisualBlock-FIR, seguint la mateixa aplicació. En la secció 4 es presenta un cas pràctic de com crear un FDDS mitjançant el VisualBlock-FIR. Finalment, es remarquen les aportacions del VisualBlock-FIR.

6.2 Un pas més cap als diagrames de blocs

Aquesta secció mostra al lector com s'escriuria un codi MATLAB que fes servir la metodologia FIR per construir un FDDS per a un sistema de piles de combustible. Aquesta aplicació s'estudia en profunditat en el capítol 7 [45, 46 i 47]. Per simplificar el desenvolupament del codi MATLAB que empra la metodologia FIR, es treballa amb una sola sortida i una única fallada de la pila de combustible. La variable de sortida λ_{O_2} correspon al flux de sortida d'aire de la pila. El sistema presenta dos llaços de regulació: mitjançant un llaç intern es regula el flux d'hidrogen i mitjançant un llaç extern es regula l'excés d'oxigen, λ_{O_2} , com una mesura indirecta per controlar l'eficiència de la pila de combustible d'automoció.

La fallada #1 representa un increment del fregament en el motor del compressor. Per ajudar a comprendre el codi, aquest s'ha estructurat en diferents parts: la primera part defineix i inicialitza les variables globals i els models FIR; la segona part mostra la fase de detecció de la fallada; la tercera part, que s'executa un cop s'ha detectat la fallada, l'aïlla i la identifica entre tots els models de fallada disponibles.

El primer pas és obtenir, mitjançant el Visual-FIR, els models del sistema que es vol monitorar. En aquest cas s'identifiquen dos models, un que representa la pila de combustible quan funciona correctament i

l'altre que representa el sistema quan ha tingut lloc la fallada #1. La màscara que representa el comportament sense fallades de la variable λ_{O_2} es mostra en l'equació 6.1 i la màscara que representa la fallada #1 es mostra en l'equació 6.2.

$$\begin{array}{c}
 t/x \\
 t - 4\delta t \\
 t - 3\delta t \\
 t - 2\delta t \\
 t - \delta t \\
 t
 \end{array}
 \begin{array}{c}
 I_{fc} \\
 \left[\begin{array}{ccc}
 0 & 0 & 0 \\
 -1 & -2 & 0 \\
 0 & 0 & 0 \\
 0 & 0 & -3 \\
 -4 & 0 & 1
 \end{array} \right]
 \end{array}
 \begin{array}{c}
 V_{CM} \\
 \\
 \\
 \\
 \\
 \\
 \end{array}
 \begin{array}{c}
 \lambda_{O_2} \\
 \\
 \\
 \\
 \\
 \\
 \end{array}
 \quad (6.1)$$

$$\begin{array}{c}
 t/x \\
 t - 4\delta t \\
 t - 3\delta t \\
 t - 2\delta t \\
 t - \delta t \\
 t
 \end{array}
 \begin{array}{c}
 I_{fc} \\
 \left[\begin{array}{ccc}
 0 & 0 & 0 \\
 0 & 0 & 0 \\
 0 & 0 & 0 \\
 -1 & -2 & -3 \\
 0 & 0 & 1
 \end{array} \right]
 \end{array}
 \begin{array}{c}
 V_{CM} \\
 \\
 \\
 \\
 \\
 \\
 \end{array}
 \begin{array}{c}
 \lambda_{O_2} \\
 \\
 \\
 \\
 \\
 \\
 \end{array}
 \quad (6.2)$$

Les variables d'entrada del sistema, que corresponen a les dues primeres columnes de les màscares, són el corrent de la pila I_{fc} (IFC) i la tensió aplicada al compressor V_{cm} (VCM). L'última columna correspon al flux de sortida d'aire (λ_{O_2}), que és la sortida, i la representem en el codi com a O2.

```

                                % Inicialització %
clear;
global qualms repo confi miss_data memb_shape meth_search def abs_weight norm_reg distance envol
def = 1;           % Predicció: activa el mètode de predicció dels 5 veïns més propers
abs_weight = 1;   % Predicció: activa la fórmula per calcular el pes absolut de cada veí
norm_reg = 2;     % Predicció: activa la fórmula de normalització per a cada veí
meth_search = 1; % Màscara òptima: activa el mètode de cerca: exhaustiu (1); algorisme genètic (2)
memb_shape = 0;  % Codificació dif.: activa la forma de la funció de pertinença: gaussiana (0); triangular (1)
miss_data = 0;   % Tots: activa el valor de dades perdudes (missing), si n'hi ha
qualms = 1;      % Màscara òptima: activa la fórmula de la mesura de qualitat: Cellier (1); Uyttenhove (0)
repo = 0;        % Tots: si s'activa es crea un fitxer report.dat amb un informe dels diferents processos:
                % no activat (0); activat (1)
confi = 0;       % Predicció: permet activar la fórmula de la confiança de la predicció: no activat (0); mesura
                % de proximitat (1); mesura de similitud (2)
distance = 1;    % Predicció: activa la fórmula per calcular la distància entre els 5 veïns més propers
envol = 1;       % Predicció: permet activar el càlcul de l'envolupant de la predicció: no activat (0); activat (1)

Dades = load('DadesPila.mat'); % Carrega el fitxer de dades del sistema de piles de combustible
NF = load('ModelNF_O2.mat');  % Carrega el model FIR del sistema (que té com a sortida  $\lambda_{O_2}$ ) sense fallades
F1 = load('ModelF1_O2.mat');  % Carrega el model FIR del sistema (que té com a sortida  $\lambda_{O_2}$ ) de la
                                % fallada #1
errorNF = 8.522e-3;           % Error acumulat en la verificació del model sense fallades
errorF1 = 6.636e-3;           % Error acumulat en la verificació del model de la fallada #1
Llindar = 3;                   % Nombre màxim d'errors dins de la finestra de detecció
ElemFinestraDeteccio = 10;     % Grandària de la finestra de detecció
ElemFinestraIdentificacio = 25; % Grandària de la finestra d'identificació
nModels = 2;                   % Nombre de models dins de la llibreria
Model = 1;                     % Model inicial (sense fallada)
Qualitat = 1;                  % Mesura d'acceptabilitat inicial
    
```

Figura 6-1 Codi MATLAB per inicialitzar les variables globals i els paràmetres per detectar i aïllar la fallada #1 de la pila de combustible.

```

i = ProfMask;                                % Detecció de la fallada
iFDetec = 0; Fallada = 0;
while (Fallada < Llindar) && (i<nDades)
    % Codificar els valors de les entrades a l'instant i
    Elem = i-ProfMask+1:i;
    [c(i,1), m(i,1), s(i,1)] = recode(Dades.IFC(i), NF.fromIFC, NF.toIFC);
    [c(i,2), m(i,2), s(i,2)] = recode(Dades.VCM(i), NF.fromVCM, NF.toVCM);
    c(Elem(ProfMask),3) = 0;
    m(Elem(ProfMask),3) = 1;
    s(Elem(ProfMask),3) = 0;
    % Predicció de la sortida
    [cp, mp, sp] = forecast(c(Elem,:),m(Elem,:),s(Elem,:),NF.ba,NF.mba,NF.sba,NF.mask,NF.VClass);
    c(Elem(ProfMask),3) = cp(ProfMask,3); % Emmagatzema els valors de predicció
    m(Elem(ProfMask),3) = mp(ProfMask,3);
    s(Elem(ProfMask),3) = sp(ProfMask,3);
    preMax = regenerate(cp(ProfMask,4),mp(ProfMask,4),sp(ProfMask,4),NF.toO2,NF.fromO2);
    preMin = regenerate(cp(ProfMask,5),mp(ProfMask,5),sp(ProfMask,5),NF.toO2,NF.fromO2);
    valMax = preMax * (1+errorNF);
    valMin = preMin * (1-errorNF);
    PrediccionNF(i,1) = valMax;
    PrediccionNF(i,2) = valMin;
    if ((Dades.O2(i) > valMax) | (Dades.O2(i) < valMin))
        Fallada = Fallada + 1;          % Comptador de fallades dins la finestra
    end
    [Dades.t(i) Dades.O2(i)-valMin valMax-Dades.O2(i)]
    ModelFallada(i) = Model;
    QualitatFallada(i) = Qualitat;
    i = i + 1;
    iFDetec = iFDetec + 1;
    if (iFDetec == ElemFinestraDeteccio) % Final de la finestra?
        iFDetec = 0; % Inicialitzar el comptador d'elements d'una finestra
        if ( Fallada < Llindar)
            Fallada = 0; % Posada a zero del comptador d'errors d'una finestra
        end
    end
end
end
end

```

Figura 6-2 Codi MATLAB de la fase de detecció de la fallada de la variable λ_{O_2} de la pila de combustible.

En la figura 6-1 es mostra el codi d'inicialització dels paràmetres de les funcions del FIR. Tots s'inicialitzen als valors per defecte, exceptuant la variable *envol*, que s'inicialitza a 1 per aconseguir que la funció de predicció qualitativa *forecast* generi les envolupants de predicció. També es carreguen les dades de la pila, obtingudes fent una simulació i emmagatzemades en un fitxer, per dur a terme la tasca de detecció fora de línia. En aquest exemple es proposa una aplicació fora de línia per facilitar la interpretació del codi, de manera que s'emmagatzemen les dades de la simulació del *benchmark* en un fitxer. Si es volgués fer en temps real (en línia), s'agafarien les dades directament del sistema. Els fitxers *ModelNF_O2.mat* i *ModelF1_O2.mat* contenen tota la informació necessària dels models del sistema quan funciona correctament i del sistema quan té lloc la fallada #1. Concretament, contenen la màscara, la matriu de comportament, el nombre de classes de les variables i els llindars de cadascuna de les dades. Per acabar, s'inicialitzen els paràmetres necessaris perquè l'FDDES dugui a terme les tasques de detecció, aïllament i identificació de la fallada: grandària de la finestra de detecció, nombre màxim d'errors que es poden fer dins de la finestra de detecció abans de considerar que ha tingut lloc una fallada, grandària de la finestra d'identificació i quantitat de models identificats que hi ha emmagatzemats en la llibreria de models.

```

                                % Identificació de la fallada
FalladaNF = 0; FalladaF1 = 0; N_Model = 1; iFIdent = 0;
while (i < nDades)
    % Identificació de la fallada o canvi estructural
    Elem = i-ProfMask+1:i;
    [c(i,1), m(i,1), s(i,1)] = recode(Dades.IFC(i), NF.fromIFC, NF.toIFC);
    [c(i,2), m(i,2), s(i,2)] = recode(Dades.VCM(i), NF.fromVCM, NF.toVCM);
    c(Elem(ProfMask),3) = 0; m(Elem(ProfMask),3) = 1; s(Elem(ProfMask),3) = 0;
    % Predicció per al model NF
    iModel = 1;
    [cp, mp, sp] = forecast(c(Elem,:),m(Elem,:),s(Elem,:),NF.ba,NF.mba,NF.sba,NF.mask,NF.VClass);
    c(Elem(ProfMask),3) = cp(ProfMask,3); m(Elem(ProfMask),3) = mp(ProfMask,3); s(Elem(ProfMask),3) = sp(ProfMask,3);
    preMax = regenerate(cp(ProfMask,4),mp(ProfMask,4),sp(ProfMask,4),NF.toO2,NF.fromO2);
    preMin = regenerate(cp(ProfMask,5),mp(ProfMask,5),sp(ProfMask,5),NF.toO2,NF.fromO2);
    valMax = preMax * (1+errorNF); valMin = preMin * (1-errorNF);
    if ((Dades.O2(i) > valMax) | (Dades.O2(i) < valMin))
        Errors(iModel) = Errors(iModel) + 1;
    end
    PrediccióNF(i,1) = valMax; PrediccióNF(i,2) = valMin;
    % Predicció per al model F1
    iModel = 2;
    [cp, mp, sp] = forecast(c(Elem,:),m(Elem,:),s(Elem,:),F1.ba,F1.mba,F1.sba,F1.mask,F1.VClass);
    c(Elem(ProfMask),3) = cp(ProfMask,3); m(Elem(ProfMask),3) = mp(ProfMask,3); s(Elem(ProfMask),3) = sp(ProfMask,3);
    preMax = regenerate(cp(ProfMask,4),mp(ProfMask,4),sp(ProfMask,4),F1.toO2,F1.fromO2);
    preMin = regenerate(cp(ProfMask,5),mp(ProfMask,5),sp(ProfMask,5),F1.toO2,F1.fromO2);
    valMax = preMax * (1+errorF1); valMin = preMin * (1-errorF1);
    if ((Dades.O2(i) > valMax) | (Dades.O2(i) < valMin))
        Errors(iModel) = Errors(iModel) + 1;
    end
    PrediccióF1(i,1) = valMax; PrediccióF1(i,2) = valMin;
    iFIdent = iFIdent + 1;
    if (iFIdent == ElemFinestraIdentificacio)
        % Avaluar el millor model
        C = 1.0 - Errors/ElemFinestraIdentificacio;
        CK = 0;
        for k = 1:nModels,
            CK = CK + C(k);
        end
        Q = zeros(1,nModels);
        if (CK ~= 0.0)
            Crel = C/CK;
            pp = 0;
            for k = 1:nModels,
                Q(k) = C(k) * Crel(k);
                pp = pp + Q(k);
            end;
            % Normalització del resultat
            Q = Q/pp;
        end;
        % Ordenar els models de més a menys qualitat
        Q1 = [Q;1:nModels]';
        for k = 1:nModels-1
            for l = 1:nModels-1
                if (Q1(l,1)<Q1(l+1,1))
                    temp = Q1(l,:);
                    Q1(l,:) = Q1(l+1,:);
                    Q1(l+1,:) = temp;
                end
            end
        end
        PosModelActual = find(Q1(:,2) == N_Model);
        QualitatModelActual = Q1(PosModelActual,1);
        if(Q1(1,1)> QualitatModelActual)
            PosModelActual = 1;
        end
        Qualitat = Q1(PosModelActual,1); Model = Q1(PosModelActual,2);
        iFIdent = 0;
        Errors = [0 0];
    end
    ModelFallada(i) = Model;
    QualitatFallada(i) = Qualitat;
    i = i + 1;
end
end
    
```

Figura 6-3 Codi MATLAB de la fase d'identificació/aïllament de la fallada de la variable λ_{O_2} de la pila de combustible.

El pas següent de la metodologia correspon a la fase de detecció de la fallada. Per detectar si ha tingut lloc una fallada s'ha de comparar el valor real de la variable de sortida λ_{O_2} amb l'envolupant que s'ha aconseguit de la predicció del model sense fallades en l'instant de temps actual. Tal com s'explica en el capítol 4, si el valor real queda fora d'aquest llinar de predicció, es considera que ha tingut lloc un error. Si el nombre d'errors acumulats dins de la finestra de detecció sobrepassa el límit preestablert pel dissenyador (variable *Llindar* en la figura 6-1), es considera que ha tingut lloc una fallada i que s'ha de passar a la fase següent per determinar de quina fallada es tracta. Per fer la predicció de l'instant t , cal fer la codificació difusa de les variables d'entrada no tan sols en el mateix instant de temps t , sinó també en tants instants anteriors com determina la profunditat de la màscara. En aquest cas, tal com s'observa en l'equació 6.1, la profunditat de la màscara és de 5 files, cosa que correspon a quatre instants de temps anteriors a l'actual. Per tant, es necessiten els quatre instants qualitius anteriors de les variables I_{fc} , V_{cm} i λ_{O_2} per iniciar el procés de detecció de la fallada. Aquests valors s'emmagatzemen durant el procés de predicció en les variables c , m i s , tal com es mostra en la figura 6-2.

Un cop s'ha detectat la fallada, s'activa la fase d'aïllament i identificació. Aquest codi es mostra en la figura 6-3 i està format per dues parts clarament diferenciables. En la primera part es fa la predicció dels elements de la finestra d'identificació per a cadascun dels models. En l'exemple exposat, la llibreria de models de fallada només conté el model que descriu el sistema sense fallades i el model que descriu el sistema sota la fallada #1, per tant, només es fa la predicció d'aquests dos models. Els errors que es van registrant de cadascun dels models s'acumulen en les variables anomenades *PrediccionNF* i *PrediccionF1*, respectivament, per processar-los quan s'exhaureixi la finestra d'identificació. En la segona part d'aquest codi s'avalua quin és el millor model que representa el comportament del sistema en aquests moments. Aquesta avaluació es fa mitjançant el càlcul de la mesura d'acceptabilitat explicada en el capítol 4 d'aquesta tesi. El model que aconsegueix una mesura d'acceptabilitat més alta és el model elegit per caracteritzar la fallada que ha tingut lloc.

Els resultats aconseguits en aquesta simulació es mostren a la figura 6-4. Tal com s'observa en els dos gràfics inferiors la fallada té lloc al cap de 50 segons, que és quan el senyal real surt dels llinars de l'envolupant que ha predit el model sense fallades. En el moment en què es detecta la fallada, comença la predicció per part de tots els models emmagatzemats en la llibreria. És per aquest motiu que la predicció del model de la fallada #1 comença a fer la predicció a partir d'aquest instant (gràfic inferior). Dels dos gràfics superiors de la figura 6-4, el primer mostra el model triat per l'FDSS com a millor candidat de la fallada en cada moment. En aquest cas, veiem que l'FDSS treballa amb el model sense fallades (model anomenat 1, ja que així s'ha definit en el codi de la figura 6-2 mitjançant la variable *Model*) mentre no té lloc cap fallada i al segon 55 (quan identifica la fallada) decideix que el model que millor representa l'estat actual és el de la fallada #1 (model anomenat 2). El segon gràfic mostra la mesura d'acceptabilitat (nivell de confiança) del model triat. Cal comentar que el tram on la mesura d'acceptabilitat del model pren el valor de zero és degut al fet que durant aquest temps la predicció d'ambdós models no s'assembla

gens al senyal real i, per tant, tots dos obtenen el valor màxim d'errors dins de la finestra d'identificació. Com que l'FDSS no pot discriminar entre els dos models, el que fa és mantenir l'últim que hi havia però deixant el nivell de confiança a zero.

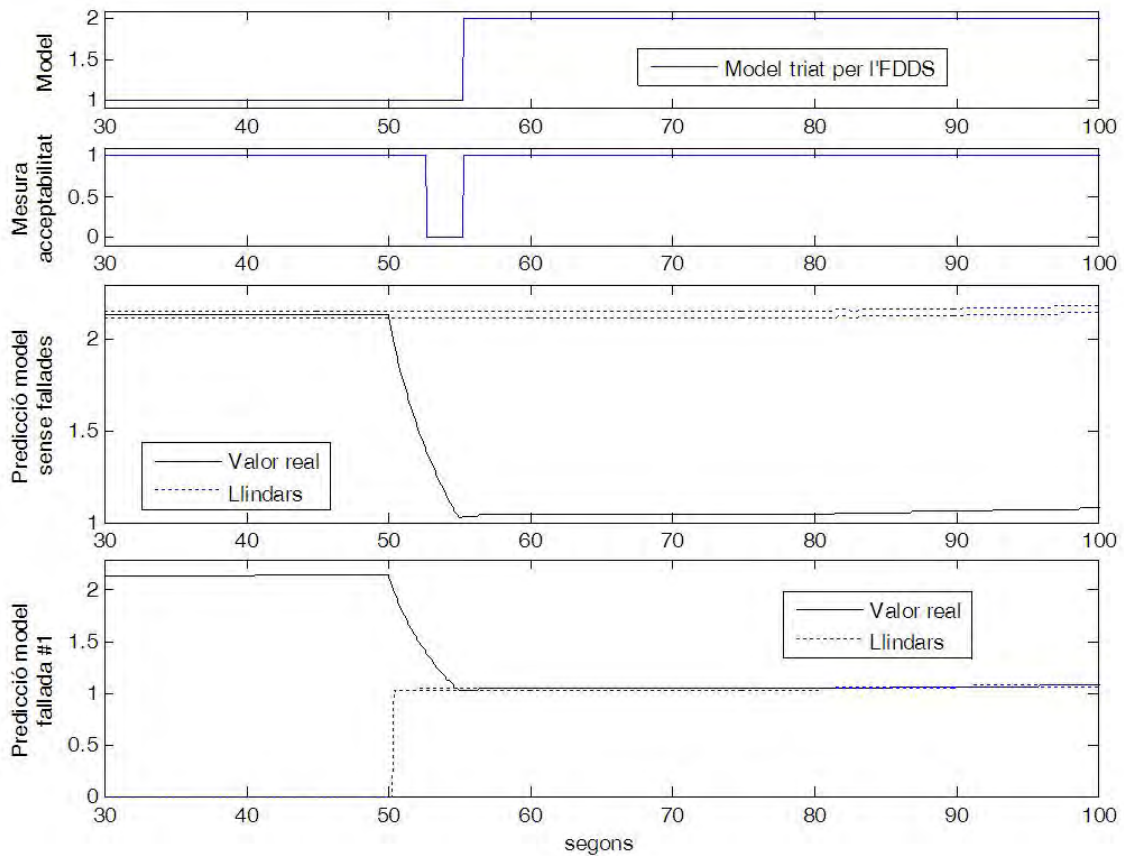


Figura 6-4 Detecció i aïllament/identificació de la variable λ_{O_2} de la pila de combustible.

Tal com s'observa en les figures 6-1, 6-2 i 6-3, cal força codi per aconseguir detectar una única fallada per a una sola variable de sortida, λ_{O_2} . Si el sistema està format per més variables de sortida, s'ha de fer el mateix per a cadascuna i si a més a més es vol identificar més fallades, cal identificar models per a cada fallada i fer la predicció de tots els models, tal com es mostra en el codi de la figura 6-3. De fet, el codi que s'ha de generar per aconseguir fer una detecció sempre és el mateix, l'únic que canvia és, d'una banda, la quantitat de models que hi ha a la llibreria de models de fallada, xifra que farà que hi hagi més o menys blocs de predicció en el codi, i, de l'altra, els paràmetres dels diferents models que s'han de predir (màscara, llindars, etc.). Aquesta particularitat del codi de l'FDSS proposat en aquesta tesi permet que sigui útil aplicar la plataforma Simulink de MATLAB, que està basada en blocs configurables i que facilita construir intuïtivament models de manera gràfica.

6.3 Descripció de la plataforma VisualBlock-FIR

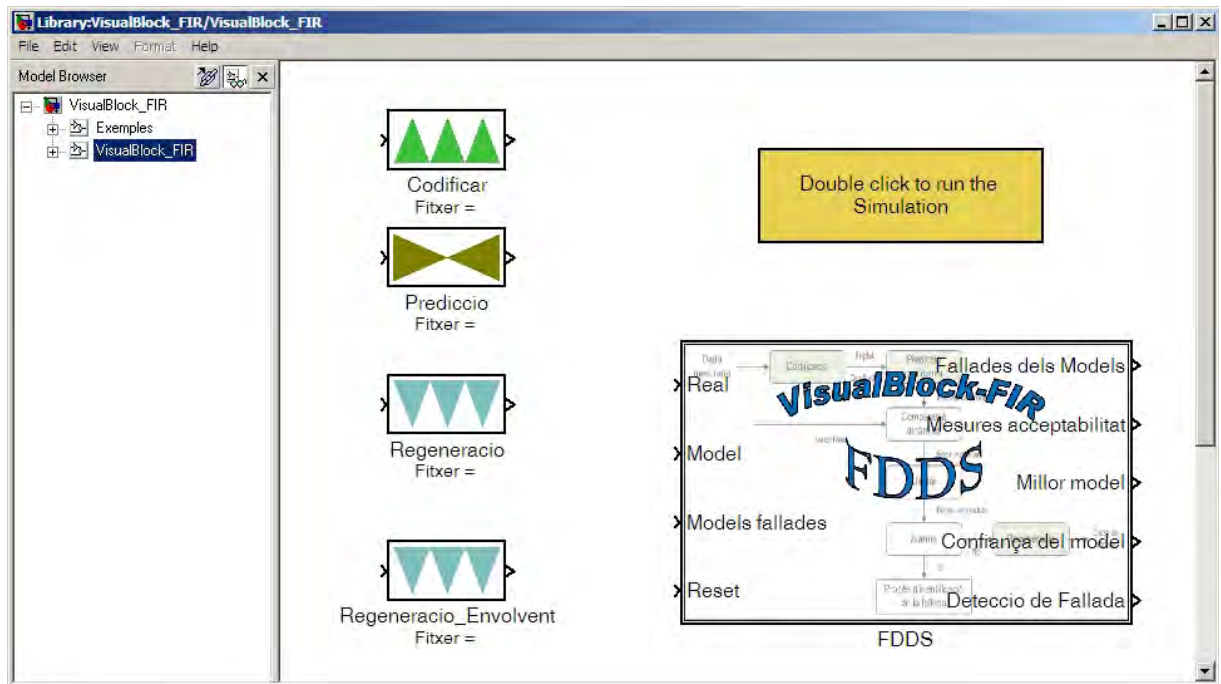


Figura 6-5 Llibreria VisualBlock-FIR.

El VisualBlock-FIR du a terme les tasques de detecció i diagnòstic, explicades en el capítol 4, mitjançant una estructura molt fàcil d'utilitzar que funciona sobre la plataforma Simulink. El Simulink és un entorn gràfic interactiu per modelar, analitzar i simular una gran varietat de sistemes dinàmics (discrets, analògics i híbrids) mitjançant la utilització de diagrames de blocs. Permet incorporar algorismes i sistemes de control que s'hagin desenvolupat en altres llenguatges de programació, prèviament a la utilització del Simulink.

El VisualBlock-FIR està format per diversos mòduls gràfics que tenen la finalitat que es construeixin els models FIR del sistema en funcionament normal (sense fallades) i per a cadascuna de les fallades que es vulguin reconèixer. Aquests models donen com a sortida el senyal de predicció i els límits superior i inferior de l'envolupant. També disposa d'un mòdul per detectar i identificar la fallada que ha tingut lloc. La figura 6-5 mostra la llibreria del VisualBlock-FIR.

Els mòduls del VisualBlock-FIR es poden dividir en dos grups. El primer d'aquests grups està format pels mòduls que ens permeten modelar els diferents sistemes, que són: la codificació difusa, la predicció qualitativa i la regeneració. El segon grup està format per un sol mòdul i és el que desenvolupa les fases de detecció i identificació de les fallades.

Els mòduls són blocs S-Function de primer nivell de la llibreria User-Defined Functions del Simulink. Una S-Function és un segment de codi escrit en el llenguatge nadiu de MATLAB o en altres llenguatges de programació estàndard com ara C o Fortran. El codi desenvolupat s'encapsula dins d'un bloc de Simulink cosa que permet que s'executi per a qualsevol aplicació desenvolupada en aquesta plataforma.

Per implementar aquesta aplicació s'ha triat el llenguatge nadiu de MATLAB, que ha de fer crides a les funcions bàsiques del FIR implementades en C.

Les pantalles de configuració dels mòduls per introduir paràmetres s'han implementat utilitzant la interfície gràfica de MATLAB GUI, que permet una interacció senzilla amb els blocs del Simulink.

6.3.1 Mòduls de modelització

L'objectiu d'aquests mòduls és seguir l'esquema de predicció de la metodologia del raonament inductiu difús (vegeu la figura 6-6).

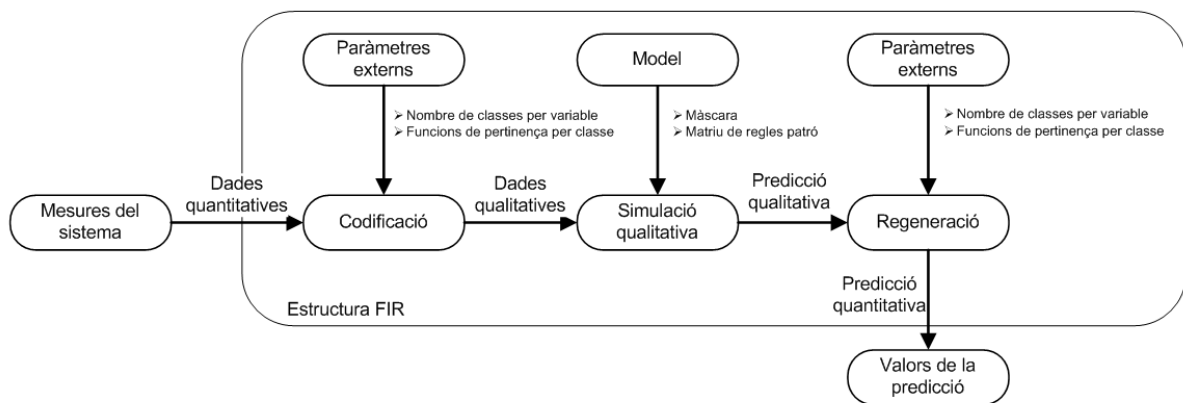


Figura 6-6 Metodologia de predicció del FIR.

En primer lloc, s'han de codificar les dades quantitatives mitjançant el bloc de la codificació difusa. Aquest bloc converteix una dada en un triplet qualitatiu, que es proporciona al bloc de predicció (simulació qualitativa) per predir uns valors qualitius usant el model que s'ha obtingut prèviament mitjançant el procés de modelització qualitativa del Visual-FIR. Finalment, aquesta predicció qualitativa és l'entrada per al bloc de regeneració, que la converteix de nou en un valor quantitatiu.

6.3.1.1 Mòdul de codificació difusa

El mòdul *Codificar* (figura 6-7) correspon a la funció de *Codificació difusa* del FIR. Per tant, necessita una entrada quantitativa provinent d'un generador de senyals (fitxer de MATLAB, model simulat, dispositiu real extern, sensor...) i genera una sortida en forma de triplet qualitatiu (classe, pertinença i costat).




Figura 6-7 Mòdul de codificació difusa

Per fer aquesta codificació difusa, cal saber el nombre de classes de la variable i els llindars que té cadascuna d'aquestes classes. Aquests paràmetres s'aconsegueixen en la fase d'entrenament de la metodologia explicada àmpliament en el capítol 3 d'aquesta tesi. Per tal de facilitar l'aportació dels paràmetres en aquest mòdul, s'ha creat una finestra de configuració (figura 6-8), que s'activa amb el botó dret del ratolí. L'opció *Carregar fitxer* permet seleccionar el fitxer de MATLAB que conté els paràmetres

d'una determinada variable. Aquest fitxer emmagatzema el paràmetre *from* en forma d'una matriu de dues files i *n* columnes, en què *n* és el nombre de classes de la variable que es vol codificar. En el cas de

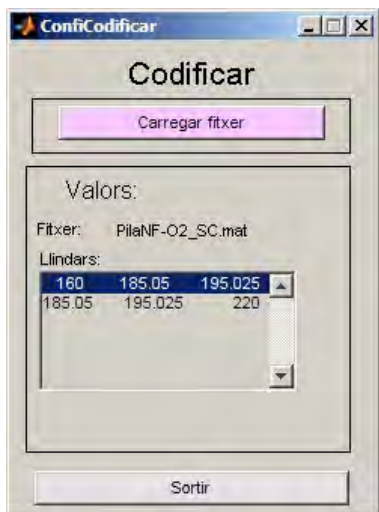


Figura 6-8 Codificar. Finestra de configuració

la figura 6-8 es codifica la variable d'entrada IFC del sistema sense fallades en 3 classes. Les columnes contenen els llindars de cadascuna de les classes. La primera fila conté els valors dels límits inferiors i la segona fila, els valors dels límits superiors. Aquest fitxer es pot crear manualment seguint les directrius anteriors o bé es pot crear de manera automàtica en la pantalla *Model* del Visual-FIR (vegeu el capítol 3).

La funcionalitat *Model* permet guardar tots els paràmetres necessaris per fer la modelització del sistema: crear un fitxer per a cadascuna de les variables del sistema amb el nom seleccionat seguit del nom de la variable i un fitxer amb el model, és a dir, la màscara

i la matriu de comportament. Concretament, en l'exemple que ens ocupa els fitxers que es creen són els següents:

PilaNF-O2 (mòdul de predicció).

- ConIni: estructura amb 3 matrius (classe, pertinença i costat) per definir les condicions inicials del mòdul de predicció.
- VClass: vector de classes. Defineix el nombre de variables i les classes que té cadascuna.
- Mask: màscara del model.
- ba, mba i sba: matrius de comportament (classe, pertinença i costat, respectivament).

PilaNF-O2_VCM (mòdul de codificació difusa).

- from: matriu amb els llindars de la variable VCM (V_{cm}).

PilaNF-O2_IFC (mòdul de codificació difusa).

- from: matriu amb els llindars de la variable IFC (I_{fc}).

PilaNF-O2_O2 (mòdul de regeneració).

- from: matriu amb els llindars de la variable O2 (λ_{O2}).

L'exemple de la pila de combustible té dues entrades externes (IFC i VCM). Per modelitzar aquest sistema es necessiten dos mòduls de codificació difusa, tal com es

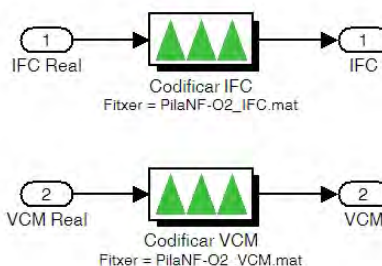


Figura 6-9 Entrades i sortides dels mòduls de codificació difusa.

mostra a la figura 6-9, de manera que s'associï cada mòdul a un fitxer, PilaNF-O2_IFC per al mòdul de la codificació difusa de la variable *IFC* i PilaNF-O2_VCM per al de la variable *VCM*.

6.3.1.2 Simulació qualitativa

El mòdul *Predicció* de la figura 6-10 correspon a la funció de simulació qualitativa del FIR. Les entrades d'aquest mòdul estan formades per totes les variables necessàries per fer la predicció del model que representa. La sortida d'aquest bloc depèn del valor de la variable global *envol* explicada en els capítols 4 i 5. Si *envol* val zero, es genera una sola sortida qualitativa amb el valor de la predicció. Si *envol* val 1, es generen 3 sortides qualitatives: la predicció i les envolupants d'aquesta predicció.



Figura 6-10 Mòdul de simulació qualitativa.

Tal com s'ha vist en el capítol 3, per fer la simulació qualitativa cal disposar de la màscara i la matriu de comportament que modelen el sistema. La funció que fa la predicció també necessita el vector de classes de les variables, tal com mostra la figura 6-12.

En ser una simulació en temps real només s'ha de generar la predicció de la sortida en l'instant actual, és a dir, només cal computar un pas de la simulació qualitativa per a cada mostra que doni el sistema.

Per veure quines són les entrades que necessita aquest mòdul, es pot consultar la màscara que es mostra a la figura 6-11. La màscara està formada per tres columnes, que corresponen a les variables d'entrada (*IFC* i *VCM*) i de sortida (*O2*), i per cinc files, que defineixen la quantitat d'estats anteriors que es necessiten per fer la predicció. La màscara també ens diu que la sortida del sistema és una funció de l'entrada *IFC* en aquest mateix instant de temps i en tres instants anteriors, de l'entrada *VCM* en tres mostres anteriors i de la sortida *O2* en l'instant anterior.

En aquest exemple el bloc de predicció necessita, doncs, com a entrada les variables: *IFC*, *VCM* i *O2*. La figura 6-12 mostra com es donen aquestes entrades al bloc de simulació qualitativa.

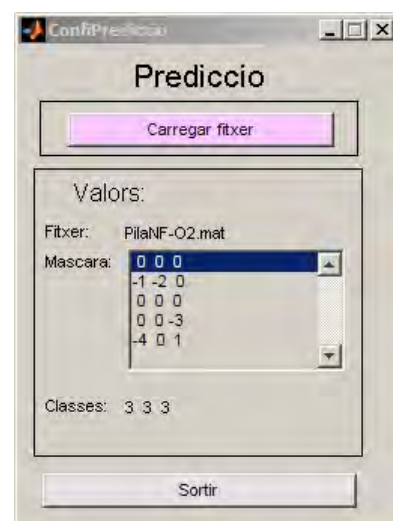


Figura 6-11 Predicció. Finestra de configuració.




Figura 6-12 Entrades i sortides del mòdul de simulació qualitativa.

Les entrades *IFC* i *VCM* corresponen als triplets qualitatius que provenen directament dels mòduls de codificació difusa explicats anteriorment. El senyal *O2* s'extreu de la sortida que ha generat anteriorment el mateix mòdul de predicció; per aquest motiu entre la sortida i l'entrada s'ha de col·locar un mòdul de retenció d'un període de mostreig. Amb aquesta configuració, els senyals que entren al mòdul de predicció són: $IFC(k)$, $VCM(k)$ i $O2(k - 1)$. Els altres valors que necessita per fer la predicció, els ha vist en estats anteriors i els ha de tenir memoritzats per utilitzar-los. La quantitat d'estats guardats és igual al nombre de files que té la màscara menys un.

Per tant, per a l'exemple actual la quantitat de valors que cal memoritzar és de tres variables per quatre estats anteriors. El càlcul de les dimensions d'aquestes matrius es du a terme en la fase d'inicialització de la simulació.

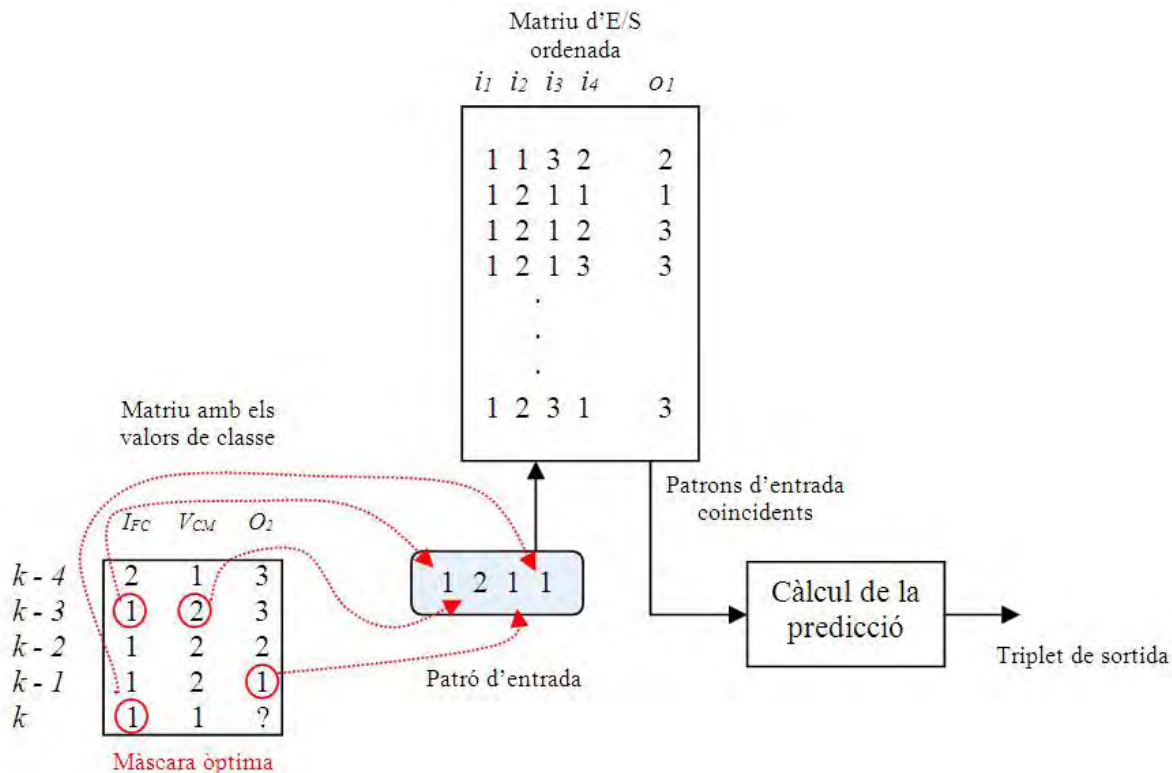


Figura 6-13 Esquema del procés de simulació qualitativa.

Quan cal predir el primer valor, la informació en instants de temps anteriors encara no s'ha pogut memoritzar i és per aquest motiu que un dels paràmetres d'entrada d'aquest mòdul és *ConIni*, que està format per tres matrius: la de classe, la de pertinença i la de costat de dimensions *nvar* per *n_files-1*, extrems de les dades reals però que no han estat utilitzades per buscar el model que es vol simular.

És molt important remarcar que l'ordre d'entrada dels senyals al mòdul de simulació qualitativa és fonamental per aconseguir un funcionament correcte del model FIR. L'ordre en què s'han de donar les entrades està marcat per la màscara del model. En aquest exemple, la variable que s'ha de posar a la primera entrada del multiplexor és *IFC*; la segona, *VCM* i la tercera, *O2*.

6.3.1.3 Regeneració

El mòdul *Regenerar* (figura 6-14) correspon a la funció de regeneració del FIR, que serveix per convertir les dades qualitatives resultants de la funció de predicció en el valor quantitatiu corresponent. Necessita una entrada formada per un triplet qualitatiu i genera una sortida quantitatiua.



Figura 6-14 Mòdul de regeneració.

En aquest mòdul també s'ha d'afegir un fitxer de configuració amb els llimars de les classes de la variable de sortida. Per a aquest exemple, la variable de sortida és el fitxer *PilaNF-O2_O2*, que conté els llimars de les classes de la variable *O2*.

Hi ha un mòdul molt similar, anomenat *Regeneracio_Envolvent*, que funciona igual que l'anterior, però necessita una entrada formada per tres triplets qualitatius (valor de predicció i llimars superior i inferior de la predicció) i genera una sortida amb els tres valors quantitatius regenerats. El fitxer de configuració és el mateix que s'utilitza en el mòdul *Regenerar*, ja que per regenerar els tres valors s'utilitzen els mateixos llimars.

6.3.1.4 Configuració del FIR

Per establir els paràmetres de configuració de les funcions del FIR és necessari un mòdul de configuració dels paràmetres globals del FIR (figura 6-15). Aquest mòdul no té ni entrades ni sortides i si es prem amb el cursor, apareix una finestra de configuració amb els paràmetres globals del FIR que afecten els mòduls de codificació difusa, simulació qualitativa i regeneració.




Figura 6-15 Configuració FIR.

La finestra de configuració, que es mostra en la figura 6-16, permet modificar totes les variables globals de la funció de simulació difusa implementades: *norm_reg*, *abs_weight* i *confi*; així com activar els paràmetres *Envol* i *miss_data*. El paràmetre *Envol* genera l'envolupant del senyal de predicció i és vital a l'hora de detectar i reconèixer les fallades.

El paràmetre *miss_data* permet treballar amb dades que contenen valors perduts en els tres mòduls.

Les variables globals que no estan actualment implementades, *distance* i *def*, es mostren com a caselles desactivades.

Com que aquesta finestra configura variables globals de MATLAB, en principi, només cal executar-la una sola vegada i cada vegada que es vulgui modificar algun dels paràmetres. També és previst que iniciï la detecció/diagnòstic en el moment en què es prem el botó *Inici*, que crida la funció *sim('model')* de MATLAB i inicia la simulació dels models del Simulink. El problema d'iniciar la simulació amb aquesta crida és que, a la pantalla del Simulink, no es mostra l'evolució temporal de la simulació. En canvi, si la simulació s'inicia amb el botó d'inici de la finestra del Simulink (▶), aquesta evolució temporal es pot veure a la part inferior de la finestra.

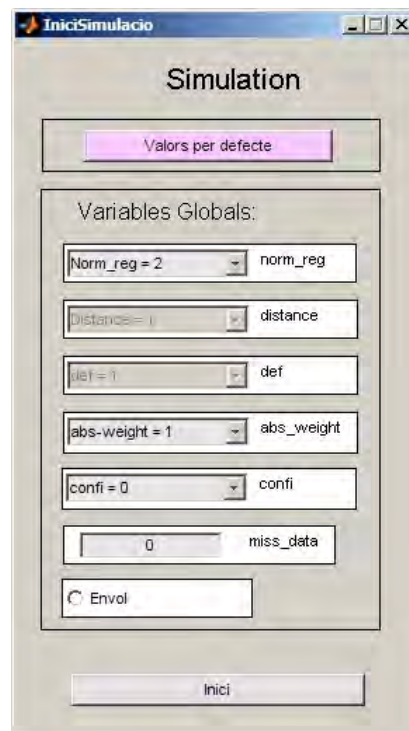


Figura 6-16 Configuració inicial.




Figura 6-17 Model de la variable O2 sense fallades.

L'esquema final del sistema de modelització de la variable O2 en funcionament normal de la pila de combustible es recull a la figura 6-17.

Cal comentar que aquests mòduls funcionen en temps discret i resulta, doncs, necessari configurar adequadament els paràmetres del Simulink. Si el model està connectat a un senyal extern (mesures extretes directament d'una planta) mitjançant el *RealTime* del *Simlink* o a un fitxer per fer simulacions i

proves fora de línia, la configuració del *solver* que s'utilitza ha de ser la que es mostra a la figura 6-18: Type: *Fixed-step*; Solver: *Discrete*. El temps entre mostres depèn del sistema amb el qual s'estigui treballant (en el cas de la figura 6-18 és de 0,1 segons). L'únic que s'ha d'assegurar és que el model sigui prou ràpid per capturar la dinàmica del sistema. En no haver-hi cap equació diferencial dins dels mòduls del FIR, l'únic que cal és que el temps entre execucions del model FIR sigui periòdic i constant.

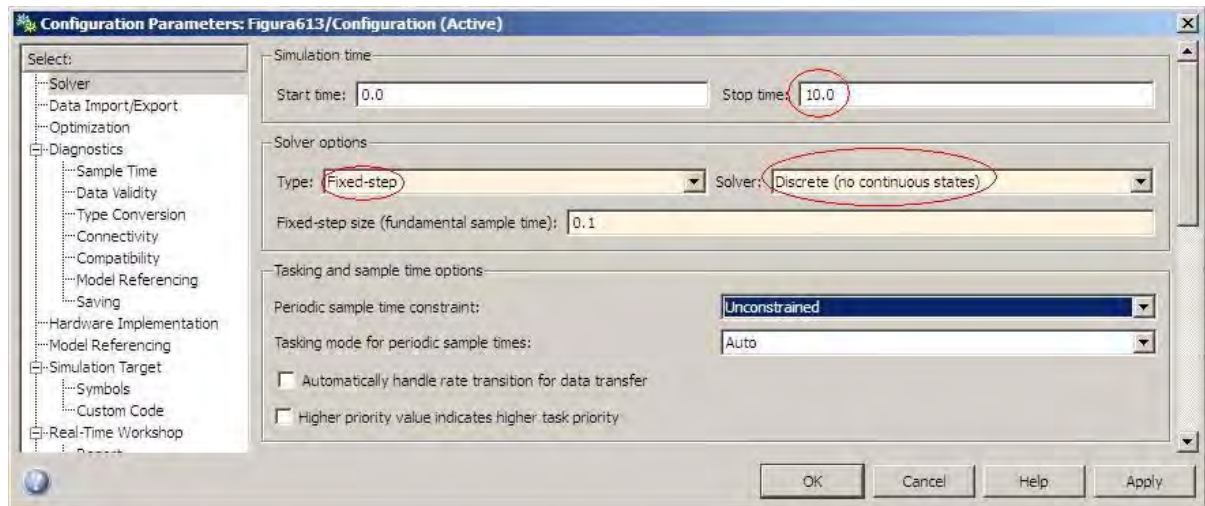


Figura 6-18 Configuració del Simulink.

En el cas que la simulació del sistema en estudi es faci dins del Simulink i que aquest sistema contingui equacions diferencials, aquestes s'han de resoldre amb algun dels mètodes de què disposa el Simulink per resoldre equacions d'aquesta mena. Per treballar amb el mòdul de predicció del FIR en aquest cas, cal discretitzar les dades que arribin al mòdul perquè aquest treballi en temps discret. Aquesta discretització es pot fer fixant un mostreig constant a les entrades dels models del FIR.

La llibreria VisualBlock-FIR disposa d'exemples de diferents formes de connexió dels blocs per facilitar la tasca del dissenyador.

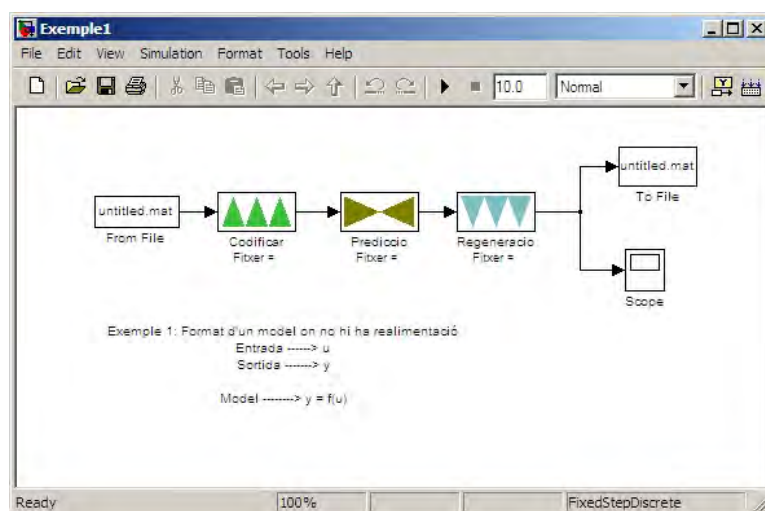


Figura 6-19 Exemple 1. Sense realimentació.

La figura 6-19 mostra un exemple gràfic molt simple d'un model FIR que empra els mòduls de codificació difusa, predicció difusa i regeneració difusa. En aquest exemple no cal realimentar el senyal predit de la sortida. És un sistema en què la sortida només depèn de l'entrada en l'instant de temps actual o en instants anteriors.

Els casos més usats són els sistemes amb més d'una entrada i en què la predicció també depèn de valors predits prèviament. El VisualBloc-FIR disposa d'una llibreria amb diferents exemples gràfics (figura 6-20), amb les configuracions més usades per ajudar l'usuari, com a base, a construir els seus propis dissenys.

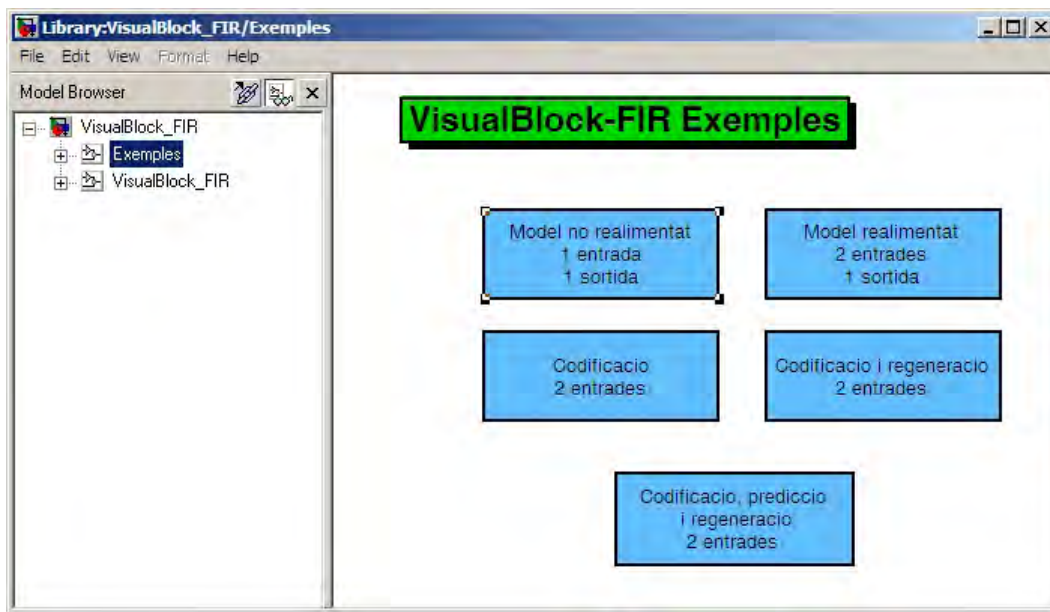


Figura 6-20 Exemples de VisualBlock-FIR.

6.3.2 Mòdul de detecció i diagnòstic de fallades

La detecció i el diagnòstic de les fallades s'ha integrat en un sol mòdul dins de la llibreria del VisualBlock-FIR. Aquest mòdul (figura 6-21) és el responsable de detectar la possible fallada del sistema i, a continuació, aïllar-la i identificar-la. Durant la fase de detecció, el mòdul utilitza el senyal real del sistema i les envolupants del model sense fallades per seguir l'algorisme descrit a la figura 4-4. Un cop detectada la fallada es dispara una alarma a través del senyal de sortida anomenada *Detecció de fallada*.

Immediatament després, s'activa la part del mòdul en què hi ha implementat l'algorisme de diagnòstic de

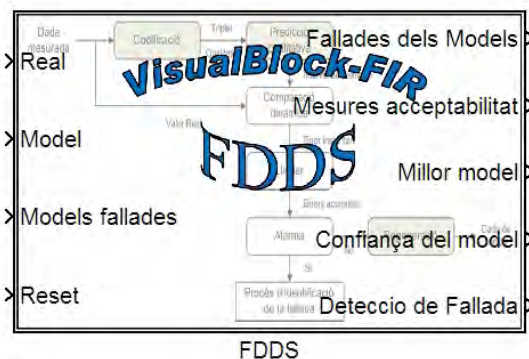


Figura 6-21 Mòdul de detecció i identificació.

les fallades. L'entrada real (*Real*) i els límits inferior i superior de la predicció dels models sense fallades (*Model*) i amb fallades (*Model fallades*) s'utilitzen per seguir l'algorisme de diagnòstic descrit en la figura 4-5. La *Confiança del model* i el *Millor model* són sortides del mòdul. La primera dona la mesura de la confiança de la predicció obtinguda pel millor model que representa una estimació de la bondat del senyal predit. Aquesta mesura és molt útil per als prenedors de decisions, ja que tenen a la seva disposició no tan sols la identificació de la fallada, sinó també la confiança associada a aquesta selecció. La sortida *Mesures acceptabilitat* proporciona la mesura d'acceptabilitat que ha aconseguit cadascun dels models i la sortida *Fallades dels models* subministra la quantitat d'errors acumulats per a cadascun dels models durant la fase de diagnòstic, cosa que s'indica a títol informatiu. L'última entrada del bloc, anomenada *Reset*, serveix per tornar a l'estat de detecció un cop s'ha arreglat la causa de la fallada. Aquesta entrada, que s'activa amb un flanc positiu, retorna el programa de la fase d'identificació a la de detecció de fallades i és útil quan s'utilitza el VisualBlock-FIR per detectar i diagnosticar fallades en un sistema real.

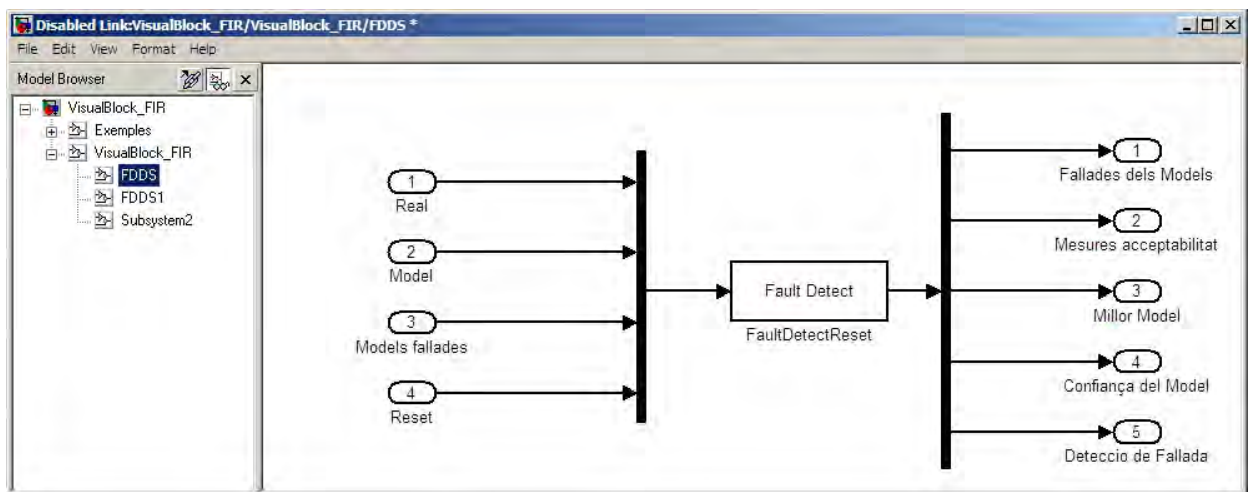


Figura 6-22 Bloc *DetectorFDDS*.

Per aconseguir que un bloc del Simulink tingui més d'una entrada i sortida, s'ha de fer un subsistema com el que es mostra a la figura 6-22. D'aquesta manera, es pot dissenyar el mòdul de detecció i diagnòstic de fallades *FaultDetectReset* amb una S-Function de primer nivell i ajuntar les diferents línies d'entrada amb un multiplexor i separar les sortides amb diferents línies mitjançant un demultiplexor. Cadascun dels nodes de les entrades i sortides del subsistema pot estar dimensionat amb una variable.

Activant el bloc *FDDS* s'obre una finestra del Simulink que permet configurar els paràmetres del bloc de detecció i diagnòstic de les fallades. Aquesta finestra, que es mostra a la figura 6-23, a la part superior conté una descripció breu del que fa aquest bloc. A la part inferior apareixen tots els paràmetres configurables d'aquest mòdul.

- *Llindar d'error*: estableix la quantitat d'errors que s'han de comptar dins de la finestra de detecció per determinar que ha tingut lloc una fallada.

- *Nombre de models*: paràmetre que defineix la quantitat de models que tindrà el sistema de diagnòstic de fallades, $1 + mf$ (nombre de models que representen una fallada). Entre aquests models es determina quin és el que s'ajusta millor a la nova situació del sistema.
- *Elements de la finestra de diagnòstic*: defineix la quantitat d'elements (valors) que es tindran en compte per determinar quin és el model de fallada que caracteritza millor el sistema.
- *Elements de la finestra de detecció*: quantitat d'elements (valors) que utilitza el sistema de detecció de fallades per determinar si ha tingut lloc una fallada.
- *Temps de mostra*: permet fixar el període de mostreig del sistema de detecció de fallades. Posant un valor en aquest paràmetre s'aconsegueix discretitzar el mòdul de detecció. Si es deixa el valor per defecte, -1, el mòdul funciona a la mateixa velocitat que la resta del sistema.

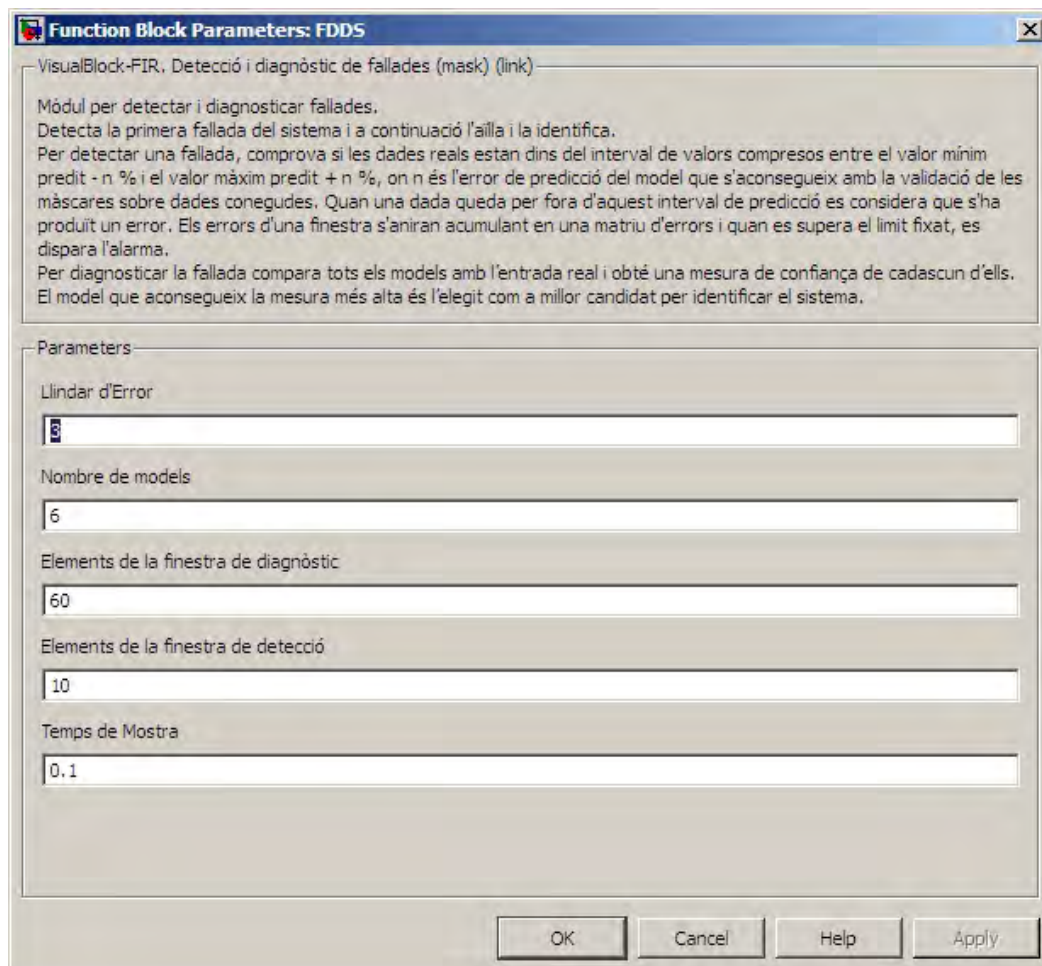


Figura 6-23 Finestra de configuració del *DetectorFallRes*.

La connexió del detector de fallades al sistema es pot fer tal com es mostra a la figura 6-24. El bloc *Sistema real* (verd) proporciona les dades reals de la variable λ_{O_2} . Aquestes dades es poden aconseguir de diferents maneres: 1) del sistema real mitjançant una placa d'adquisició de dades i la llibreria de temps real del Simulink; 2) d'un fitxer que conté les dades extretes del sistema real per fer una simulació fora de

línia; 3) d'un model del sistema implementat amb el Simulink; 4) de qualsevol altre programa de simulació que pugui transferir les dades directament. Aquest bloc està connectat a l'entrada *Real* del detector de fallades. El *Model sense fallades* (blau) és un model FIR que descriu el comportament del sistema sense fallades i permet estimar el valor de la variable λ_{O_2} . Aquest model, que proporciona un envolupant del comportament del sistema i s'utilitza per detectar les fallades, està connectat a l'entrada *Model* del detector de fallades. El bloc taronja està format per la llibreria de models de fallada. Dins d'aquest bloc hi ha tots els models de possibles fallades que es volen tenir en compte en la fase de diagnòstic. En aquest exemple l'entrada de *Reset* està connectada a massa, cosa que significa que no es poden fer reinicialitzacions i tornar a l'estat de detecció de la fallada.




Figura 6-24 Connexió del detector per a l'exemple en estudi de la pila de combustible.

Es considera que el procés d'aïllament/identificació funciona normalment quan es pot determinar que algun dels models de la llibreria de models de fallada s'apropa força al valor real del senyal. Però hi ha dos casos excepcionals que es poden registrar i que no s'han explicat anteriorment:

- Què cal fer si hi ha més d'un model amb la mateixa mesura d'acceptabilitat?

En principi, si dos models de fallada són igual de bons (o de dolents), tant se val quin se seleccioni. Tanmateix, només un correspon a la fallada que realment ha tingut lloc en el sistema.

En la metodologia explicada en el capítol 4 es deia que en la fase de diagnòstic del model, quan hi havia un empat del nombre de valors que quedaven fora de l'envolupant entre els models que millor caracteritzaven la fallada, el que es feia era la predicció de les dades de la finestra amb aquests models i el que s'allunyava menys dels valors reals era el que es triava com a millor model per caracteritzar la fallada. Aquesta manera de resoldre la tria del model en cas d'empat va molt bé quan es fa una detecció fora de línia, ja que es disposa de tota la informació necessària i es pot manipular de la manera que més convingui. No obstant això, quan es vol detectar i identificar fallades en línia tots aquests valors s'han de memoritzar per si s'han d'utilitzar posteriorment per desempatar.

Després d'una anàlisi empírica de diferents casos, s'ha vist que en molt poques ocasions cal aplicar aquesta regla i, per tant, no compensa el cost que comporta tant pel que fa a temps d'execució com a memòria. Per tant, s'ha optat per implementar una solució molt més senzilla i que no comporta cap cost addicional. El que s'ha fet és traspasar la decisió al dissenyador del sistema de detecció de fallades perquè estableixi una prioritat, o importància, dels models dins la llibreria de fallades. El primer model de la llibreria és el més prioritari i l'últim model és el que té menys prioritat, és a dir, el que es creu que té menys probabilitat de succeir. Durant la fase d'ordenació de les mesures d'acceptabilitat dels models, en cas d'empat, els models queden directament ordenats de més a menys prioritaris, pel simple fet que s'avaluen en l'ordre establert a la llibreria, i s'agafa el que queda en el primer lloc de la llista.

- Què cal fer quan cap model de la llibreria no obté una predicció que s'assembli al senyal real?

Aquest és el cas en què tots els models tenen un nombre d'errors igual a la grandària de la finestra de diagnòstic de l'FDDS, és a dir, que ha tingut lloc una fallada desconeguda o que no està implementada dins de la llibreria de fallades i, per tant, el sistema no pot donar-hi cap resposta. El que es fa en aquest cas és deixar com a millor model el que era vigent fins aquell moment però amb una mesura d'acceptabilitat (confiança) de zero.

6.4 Aplicació del VisualBlock-FIR: Cas pràctic

Per mostrar com construir un FDDS en VisualBlock-FIR, es desenvolupa el mateix exemple que s'ha presentat a l'inici del capítol i que s'ha resolt mitjançant un programa realitzat directament en codi Matlab.

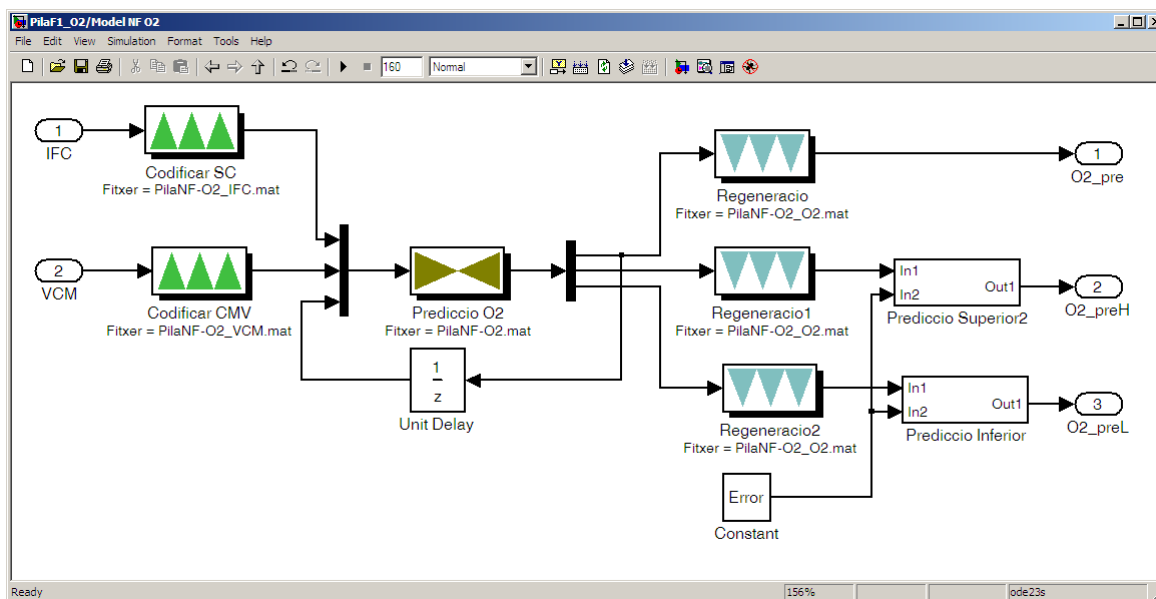


Figura 6-25 Esquema del model sense fallada

Podem partir de la mateixa base, en la que s'han trobat els models de la variable de sortida λ_{O_2} de la pila de combustible pel comportament sense fallada (equació 6.1) i amb la fallada 1 (equació 6.2). En aquest cas, al disposar del simulador fet amb Simulink, podem posar els models directament a l'esquema general enlloc de fer-ho mitjançant un fitxer amb les dades simulades prèviament.

El primer que cal fer, és dissenyar usant les eines del VisualBlock-FIR els dos models de la variable λ_{O_2} . El disseny dels dos models és exactament igual i l'únic que els diferencia són els fitxers associats a cadascun dels mòduls. La figura 6-25 mostra el disseny del model sense fallada.

Pel cas del model sense fallades de la variable λ_{O_2} , els fitxers que s'han d'afegir i que han estat generats automàticament pel VisualFIR, són:

- Pel bloc Codificar de l'entrada I_{fc} , el fitxer PilaNF-O2_IFC.mat
- Pel bloc Codificar de l'entrada V_{cm} , el fitxer PilaNF-O2_VCM.mat
- Pel bloc Predicció O2, el fitxer PilaNF-O2.mat
- Pels tres blocs de Regeneració, el mateix fitxer PilaNF-O2_O2.mat

A on “NF” en el nom dels diferents fitxers significa “non-fault”, és a dir sense fallada.

L'explicació de l'esquema (veure figura 6-25) és molt simple. Totes les entrades del sistema, en aquest cas les variables I_{fc} i V_{cm} han de transformar els valor quantitativus en valors qualitativus. Per fer-ho, el VisualBlock-FIR disposa del bloc Codificar, que necessita com a paràmetres el nombre de classes en que en que es durà a terme la discretització i els llindars de cadascuna d'elles. Un cop es disposa dels valors qualitativus, aquests seran l'entrada del bloc de Predicció, que generarà com a sortida el pronòstic. Per dur a terme aquest procés s'han de proporcionar al bloc de predicció, les dades del model, és a dir, la màscara i la matriu de comportament. Els últims blocs que cal configurar són els tres blocs de regeneració. La primera sortida del bloc de Predicció ens proporciona el valor predit i es connecta al primer bloc de Regeneració per aconseguir el valor quantitativu associat a la predicció actual (aquesta sortida no és necessària per l'elaboració del FDDS). La segona i tercera sortides del bloc de Predicció, proporcionen el límit inferior i superior de l'envolupant, respectivament. Aquestes dues sortides es converteixen en valors quantitativus mitjançant el bloc de Regeneració. La informació que necessita aquest bloc, és el número de classes i els llindars de la variable que cal reconvertir, és a dir la variable de sortida.

Pel cas del model amb la fallada 1 de la variable λ_{O_2} s'ha de fer el mateix, afegint els fitxers:

- Per bloc Codificar de l'entrada I_{fc} , el fitxer PilaF1-O2_IFC.mat
- Pel bloc Codificar de l'entrada V_{cm} , el fitxer PilaF1-O2_VCM.mat
- Pel bloc Predicció O2, el fitxer PilaF1-O2.mat
- Pels tres blocs de Regeneració, el mateix fitxer PilaF1-O2_O2.mat

Per esquematitzar el disseny i facilitar la comprensió, es poden crear dos subsistemes (Model NF O2 i Model F1 O2) que continguin aquest models, quedant de la forma que es mostra a la figura 6-26.




Figura 6-26 Pila de combustible i llibreria de models

Es connecten les entrades del sistema de la pila de combustible I_{fc} i V_{cm} a les entrades dels models, per generar les prediccions de la variable λ_{O_2} sense fallada i amb la fallada 1.

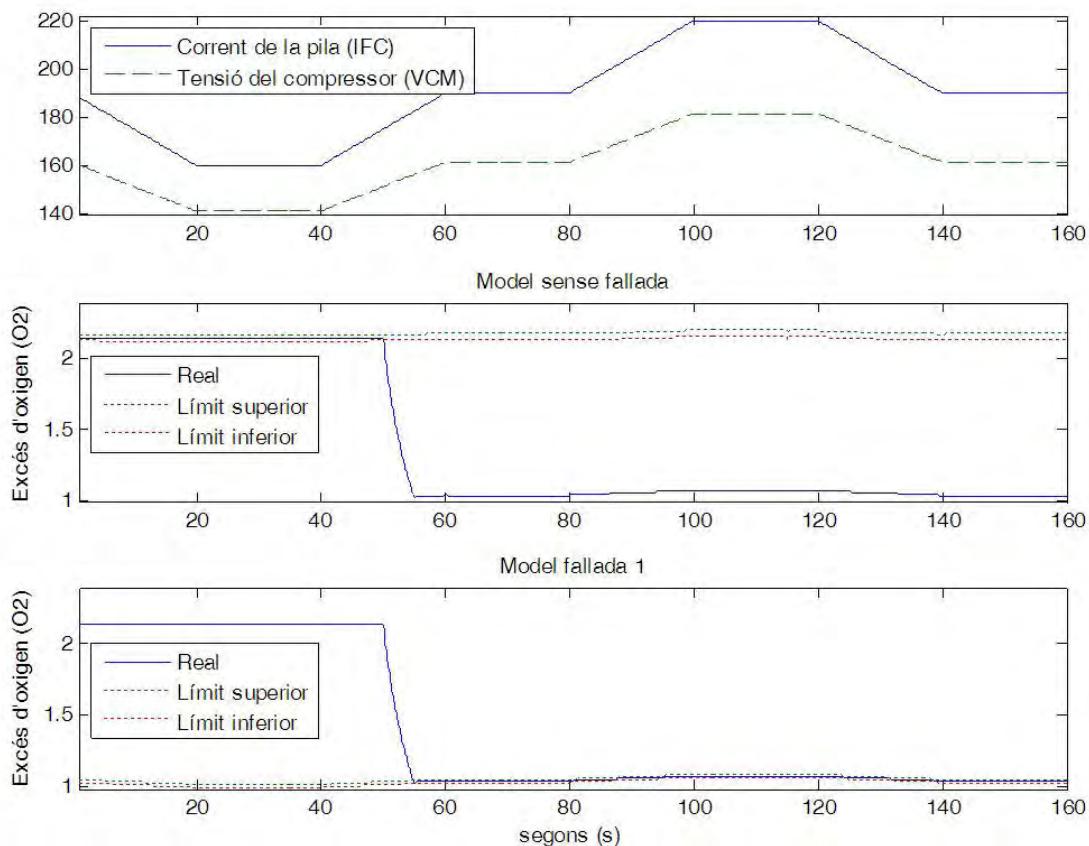


Figura 6-27 Resposta del sistema de predicció de la variable λ_{O_2}

La predicció de la variable λ_{O_2} sense fallada i amb la fallada 1 que s'aconsegueix amb cadascun dels dos models es pot veure a la figura 6-27. En la gràfica superior de la figura, es visualitzen els senyals d'entrada del sistema (entrades de la pila de combustible) I_{fc} i V_{cm} amb una simulació feta durant tot un període (160 segons). Als 50 segons s'introdueix una fallada abrupte causada per un augment de la fricció al motor del compressor, que es correspon a la fallada 1. En la gràfica del mig, que es correspon al model sense fallada, el valor real del senyal queda dins de l'envolupant de la predicció fins que es produeix la fallada. En aquest instant el senyal real fa un transitori per situar-se en la nova zona de treball que es correspon al model de la fallada 1. En la gràfica inferior, es pot observar que després de 5 segons, el senyal real queda dins de l'envolupant generat pel model de la fallada 1. Queda clar que amb els resultats que s'obtenen amb aquesta variable i per aquesta fallada, la detecció i diagnòstic seran molt fàcils de realitzar.

El següent pas pel disseny del sistema de detecció i diagnòstic de fallades, és afegir el mòdul FDDS del VisualBlock-FIR i configurar-lo.

Tal com s'ha dit anteriorment, aquest mòdul té tres entrades de dades. L'entrada Real, serveix per subministrar els valors quantitius de la variable que es vol analitzar. En aquest cas, es connecta directament a la sortida λ_{O_2} de la pila de combustible. L'entrada Model, introdueix al sistema l'envolupant de la predicció del model sense fallades. Aquestes dues entrades serveixen per determinar la detecció de la fallada. L'última entrada, Models de fallada, serveix per donar al FDDS totes les envolupants dels models de fallades. En aquests cas, al tractar-se d'un cas simple, només hi ha l'envolupant de la fallada 1. A l'entrada Model, s'ha de tenir molta cura amb l'ordre en que s'introdueixen els diferents senyals. Sempre ha d'anar primer (entrada 1 del multiplexor), el límit superior de l'envolupant i després (entrada 2 del multiplexor), el límit inferior de l'envolupant. A l'entrada Models de fallada, s'ha de respectar el mateix ordre que l'entrada anterior, i a més a més, s'han d'afegir els diferents models de fallada en l'ordre desitjat, ja que aquest ordre, servirà per determinar el nombre del model en la fase de diagnòstic. El primer serà el model 2, el segon el 3, i així successivament.

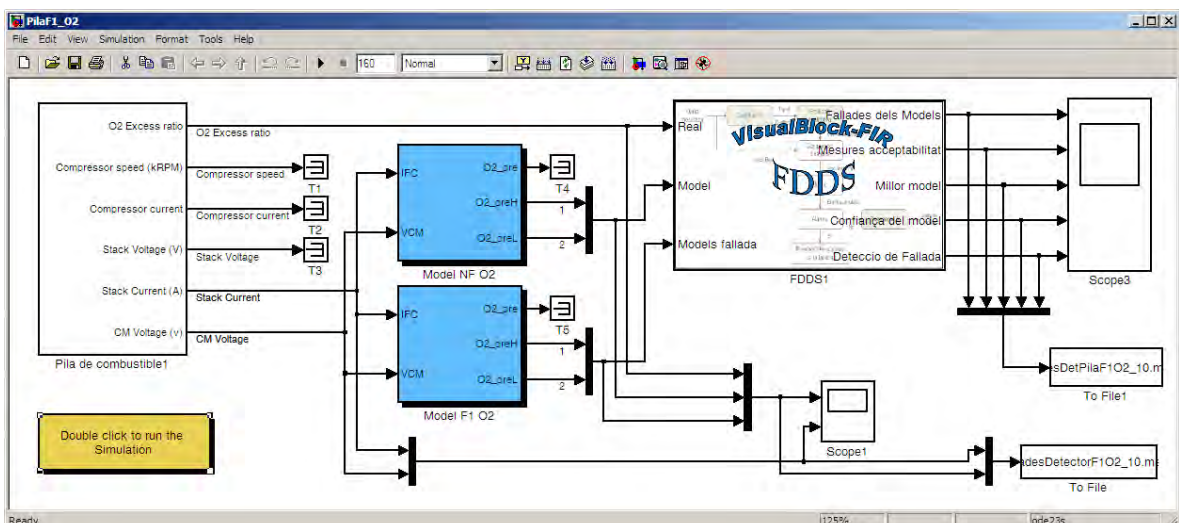


Figura 6-28 Esquema final del FDDS per la variable λ_{O_2}

Un possible esquema final per la detecció de la fallada 1 per la variable λ_{O_2} podria ser el que es mostra a la figura 6-28.

La configuració del mòdul FDDS de VisualBlock-FIR es fa amb la finestra que s'obre al prémer amb el cursor del ratolí sobre el mòdul.

En aquesta finestra (figura 6-29) es defineixen els mateixos valors que s'havien usat en la inicialització dels paràmetres, en el codi manual, per detectar i diagnosticar la fallada #1 (figura 6-1).

Llindar = 3;

Nombre de models = 2;

Elements de la finestra de diagnòstic = 25;

Elements de la finestra de detecció = 10;

A més a més, es fixa el temps de mostra d'aquest bloc per garantir que l'acció del FDDS només es farà cada 0,1 segons i, així, poder posar qualsevol temps de simulació (sempre que sigui més petit) en el Simulink.

Si es fa una simulació sense fallades durant 140 segons, els resultats que s'aconsegueixen del FDDS

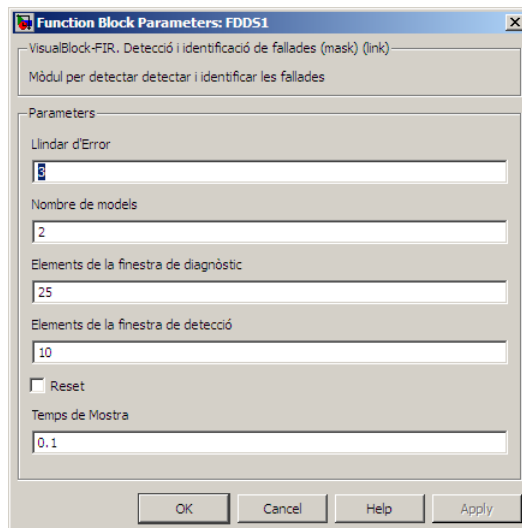


Figura 6-29 Configuració del FDDS




Figura 6-30 Diagnòstic del FDDS amb una finestra de diagnòstic de 25 punts (2,5 segons)

són molt bons, doncs el senyal real de la variable λ_{O_2} no surt mai de l'envolupant generada pel model de predicció sense fallades. Per aquest motiu, no es detecta cap fallada i el mòdul de diagnòstic de fallades no s'activa.




Figura 6-31 Quantitat d'errors per a cada model

Si es fa la mateixa simulació i als 50 segons es genera la fallada #1 al simulador de la pila de combustible, els resultats que s'aconsegueixen amb el *FDDS* configurat amb els paràmetres exposats anteriorment, són els que es mostren a la figura 6-30. En aquesta figura, es mostren les sortides que defineixen el diagnòstic de la fallada. La gràfica superior mostra que a l'instant 56,9 segons el *FDDS* ha determinat que la fallada que s'havia produït es corresponia a la fallada #1. Només ha tardat 6,9 segons per fer el diagnòstic. La gràfica inferior mostra la mesura d'acceptabilitat per aquest diagnòstic. Val la pena comentar, que entre l'instant de temps de 54,4 i el 56,8 segons aquesta mesura val zero, ja que durant aquest temps, no hi ha cap valor de la variable real que quedi dins dels dos intervals de predicció, per tant, la quantitat d'errors dins la finestra de diagnòstic pels dos models és 25, tal i com es pot observar a la figura 6-31. Les gràfiques superior i inferior de la figura 6-31 mostren la quantitat d'errors (valors que queden fora de l'interval de predicció), dels models sense fallades i amb la fallada #1, per a cadascuna de les finestres de diagnòstic, respectivament. En aquest cas es comencen a comptar els errors a partir de la detecció de la fallada.

La fallada es detecta molt ràpidament. S'ha establert una finestra de detecció de 10 punts (1 segon) i en el moment en que hi ha tres punts dins d'aquesta finestra que queden fora de l'envolupant es considera que

s'ha produït una fallada. A l'instant de temps de 50,3 segons detecta la fallada i comença la fase de diagnòstic per esbrinar quina és la fallada que s'ha produït.

Per tal d'analitzar els resultats obtinguts pel FDDS, es pot provar el que succeeix configurant-lo amb diferents paràmetres. Els paràmetres que podem modificar són:

- Llindar
- Elements de la finestra de diagnòstic
- Elements de la finestra de detecció

El llindar depèn de la dimensió de la finestra de detecció. Com més precís sigui el model, més petits podran ser el llindar i la finestra de detecció, ja que la probabilitat de que un valor quedi fora de l'interval serà molt petita. Com més petit sigui aquest valor, més ràpid es detectarà la fallada.

El valor d'aquest dos paràmetres haurà de ser més gran si el model del comportament sense fallades no és molt precís o hi ha pertorbacions al senyal real. En el primer cas, s'haurà d'intentar assegurar que si hi ha petites variacions entre el senyal real i el predit dins de la finestra de detecció, aquestes quedin encobertes pel valor del llindar. Com més gran sigui el llindar més valors podran quedar fora de l'envolupant sense que es produeixi la detecció d'una fallada, i, per tant, més difícil i costós serà detectar-la. El cas de les pertorbacions, es força similar, si s'augmenta el llindar podrem filtrar algun dels valors que queden fora de l'envolupant, a costa de retardar la detecció.

L'altre paràmetre que es pot modificar és la quantitat d'elements de la finestra de diagnòstic. Com més gran sigui aquesta finestra, més temps tardarà el FDDS en diagnosticar la fallada que s'ha produït, però serà molt més fiable, ja que haurà analitzat moltes més dades. Com més petita sigui aquesta finestra, el diagnòstic serà molt més ràpid, però segurament no tan fiable. Sempre acabarà depenent del sistema que s'estigui analitzant.

En aquest exemple en concret els models que s'han aconseguit són molt bons, la variable analitzada té un comportament molt diferent entre el funcionament sense fallada i el de la fallada #1 i, a més a més, no hi ha soroll. Rebaixant els valor d'aquest paràmetres amb:

Llindar = 2 (0,2 s)

Elements de la finestra de diagnòstic = 10 (1 s)

Elements de la finestra de detecció = 5 (0,5 s)

s'aconsegueixen els mateixos resultats que en el cas anterior, però a una velocitat més alta, doncs es detecta la fallada amb 0,2 segons i es diagnostica en 4,9 segons.

Resulta molt difícil reduir encara més el temps de diagnòstic ja que sempre hi haurà el transitori entre el funcionament normal i el funcionament en fallada, que en aquests cas i al tractar-se d'una simulació, s'ha

potgut accelerar. Si es tractes d'un cas real, el temps que hi hauria entre un estat i l'altre condicionaria moltíssim aquest temps de diagnòstic i s'haurien de posar estats intermedis per poder veure la deriva de la sortida.

6.5 Aportacions del VisualBlock-FIR

En aquest capítol s'ha desenvolupat una nova eina basada en la metodologia explicada en el capítol 4. Aquesta metodologia, que ja s'ha demostrat que funciona correctament per detectar i identificar les fallades en sistemes complexos, s'ha integrat en l'entorn del Simulink per facilitar-ne l'ús.

El VisualBlock-FIR és una eina de programari que allibera els investigadors de tota la càrrega de desenvolupament de codi i que els permet centrar-se en l'anàlisi de nous models i comparar-los amb altres d'existents.

Ofereix avantatges rellevants:

- 1) Allibera del treball de programació i aporta la facilitat de crear nous sistemes utilitzant blocs del Simulink i modificant esquemes preexistents, afegint-hi o traient-ne variables.
- 2) Amplia el rang de possibles desenvolupadors de l'FDDS. És un programari molt senzill d'utilitzar, amb una gran quantitat de propostes ja implementades, de manera que es redueix considerablement el nivell de coneixement i experiència necessari per dissenyar i desenvolupar un FDDS basat en el FIR per a una planta concreta.
- 3) Tal com es mostra en el capítol següent, aquesta nova eina s'ha provat amb èxit en diferents aplicacions per detectar i diagnosticar fallades en sistemes com ara la pila de combustible [47] i la vàlvula de DAMADICS [50].

6.6 Conclusions

En aquest capítol s'ha presentat la plataforma VisualBlock-FIR. Aquesta nova eina permet implementar de manera ràpida i senzilla FDDS potents. El VisualBlock-FIR treballa sota l'entorn gràfic del Simulink de MATLAB i està format per diferents blocs que implementen les funcions bàsiques del FIR (la codificació difusa, la simulació qualitativa i la regeneració), així com el bloc de detecció i diagnòstic de fallades.

La gran versatilitat que té aquesta nova eina permet fer qualsevol desenvolupament i, gràcies a la senzillesa, es poden implementar grans FDDS formats per moltes variables d'entrada i sortida.

Tal com es mostra en el capítol següent, el VisualBlock-FIR es pot utilitzar en un ventall molt ampli d'aplicacions en què es vulgui detectar i aïllar/identificar fallades.

7 Aplicacions

Resum: en aquest capítol es posa a prova el VisualBlock-FIR FDDS mitjançant dues aplicacions industrials i es demostra que aquesta nova metodologia és molt útil per detectar i diagnosticar fallades en sistemes complexos. La primera aplicació correspon al problema de referència (benchmark) de la vàlvula automàtica DAMADICS, en què es presenten quatre fallades de petita i mitjana magnitud que s'aconsegueixen detectar i diagnosticar de manera molt ràpida i eficient. En la segona aplicació s'usa el VisualBlock-FIR en una pila de combustible simulada, en què es tracten cinc fallades diferents que és capaç de detectar i diagnosticar eficientment. La pila de combustible és un sistema més gran que el DAMADICS, format per quatre variables de sortida, i serveix per comprovar que el VisualBlock-FIR pot tractar grans sistemes de manera eficient. En les dues aplicacions es compara, amb èxit, el rendiment d'aquesta eina amb el d'altres metodologies similars. A la darrera part del capítol es prova la robustesa de la nova eina afegint soroll blanc, en diferents magnituds, a les sortides de la pila de combustible.

7.1 Introducció

En aquest capítol el VisualBlock-FIR s'utilitza per detectar i diagnosticar fallades en dues aplicacions complexes. La primera consisteix en una vàlvula industrial controlada amb un servomotor pneumàtic. Es tracta d'un cas d'estudi (*benchmark*) proposat en el marc de treball de la Xarxa Europea de Formació d'Investigadors (FP5-RTN-1999-00392), coneguda amb el nom de DAMADICS (de l'anglès *development and application of methods for actuator diagnosis in industrial control systems*). [50]. És, doncs, un simulador, implementat en Simulink, d'un actuator industrial amb un comportament no lineal, el qual permet simular diferents estats anòmals. En l'aplicació es mostra que el VisualBlock-FIR detecta i identifica quatre d'aquests estats anòmals.

La segona aplicació emprada és un sistema de generació d'energia basat en cel·les de combustible [47]. Com en el cas anterior, es tracta d'un cas d'estudi basat en un sistema FCS (de l'anglès *fuel cell system*) creat per fer proves de diagnòstic de fallades. El model inicial utilitzat va ser desenvolupat i implementat en Simulink per [120] i adaptat per diagnosticar diferents fallades en la tesi doctoral d'Albert Rosich publicada recentment [122].

Aquests sistemes són molt complexos i impliquen fenòmens tèrmics, hidràulics i electroquímics. A més a més, requereixen un conjunt d'elements auxiliars (vàlvules, compressors, sensors, reguladors, etc.) perquè la cèl·lula de combustible funcioni en el punt òptim. Per tots aquests motius, aquest sistema és molt vulnerable a les avaries que poden ocasionar una parada o un dany permanent de la cel·la. En aquest capítol s'estudien cinc possibles fallades de la pila i, a més a més, s'estudia la robustesa davant del soroll del VisualBlock-FIR FDDS.

7.2 DAMADICS

7.2.1 Descripció del sistema

El cas d'estudi [2] és un actuator industrial format per una servovàlvula de fluid accionada per un posicionador intel·ligent, com es mostra a la figura 7-1.

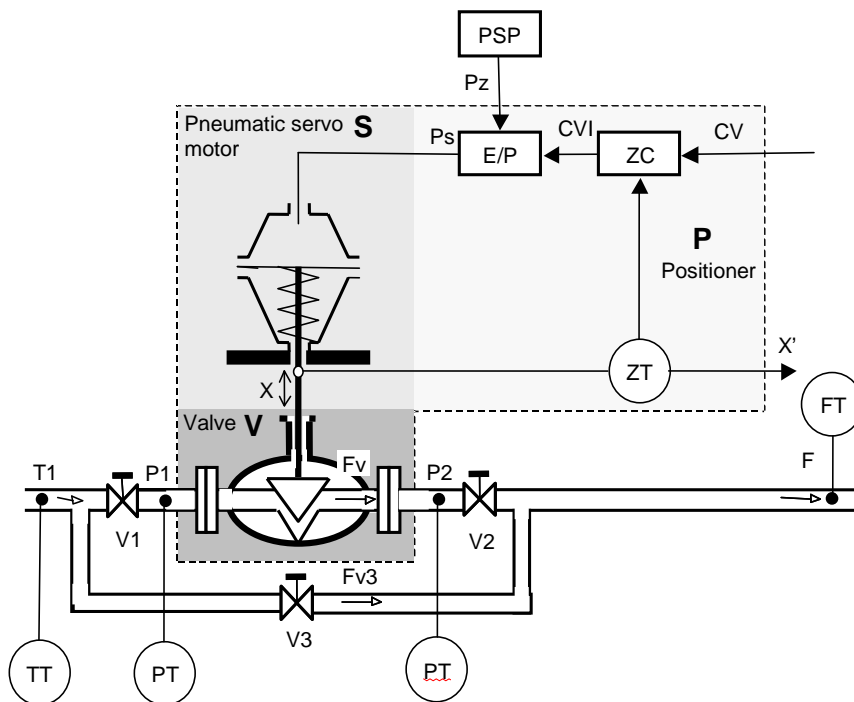


Figura 7-1 Representació esquemàtica del sistema DAMADICS.

Les parts principals de l'actuator són la vàlvula de control (V), el servomotor pneumàtic (S) i el posicionador (P). A part, hi ha altres components auxiliars, com ara la pressió de subministrament del posicionador (PSP), el convertidor electropneumàtic (E/P), les vàlvules de desconnexió (V1 i V2) i la vàlvula de pas (V3), i pot tenir accés a les mesures provinents del transmissor de pressió (PT), el transmissor de cabal (FT), el transmissor de temperatura (TT), el transmissor de posició (ZT), la pressió de la cambra pneumàtica del servomotor (Ps) i la sortida del controlador (CVI).

En general, aquestes vàlvules es controlen mitjançant un controlador de posició (P) de la tija i s'utilitza un transductor capaç de mesurar el desplaçament físic d'aquest. La sortida del controlador, CVI, és una sortida d'intensitat, generalment no mesurada, que actua en un servomotor pneumàtic responsable de fer augmentar o fer disminuir la pressió a la cambra de la vàlvula. Un augment de pressió Ps provoca un desplaçament de la tija, cosa que fa augmentar o fa disminuir (depèn de la mena d'assentament) el flux que circula per la canonada.

Aquest sistema, modelitzat en Simulink, va ser desenvolupat per testar tècniques de detecció i diagnòstic de fallades, i permet simular l'efecte de diferents fallades primàries que poden tenir lloc en aquesta mena d'actuadors industrials. En [131] hi ha una especificació detallada d'aquest cas d'estudi amb una

descripció de totes les fallades que es poden simular. Un aspecte que cal destacar és que les fallades provocades són de diferents nivells i tenen característiques diferents. Es poden provocar fallades de petita, mitjana i gran amplitud, així com fallades de creixement progressiu conegudes amb el nom de *fallades incipients*.

Hi ha força treballs de recerca sobre el disseny de FDDS que usen el *benchmark* DAMADICS. Entre les últimes aportacions cal destacar [108], en què es detecten i es diagnostiquen les fallades abruptes mitjançant tècniques de reconeixement de patrons basades en una estructura jeràrquica de diagnòstic. S'estudien diferents mètodes d'extracció de característiques per retenir la informació temporal i per reduir la dimensionalitat en cada branca de la jerarquia. Utilitzen xarxes neuronals com a classificadors locals i utilitzen la lògica difusa per aconseguir un senyal de decisió per a cada fallada. Aconsegueixen detectar les fallades $f_1, f_2, f_7, f_8, f_{10}, f_{11}, f_{12}, f_{13}, f_{15}, f_{16}, f_{17}, f_{18}$ i f_{19} amb uns temps entre 1 i 214 s, i identifiquen la majoria d'aquestes fallades. En un altre estudi [88] es proposa un nou sistema basat en l'*artificial immune system* i que està inspirat en la recent teoria del *natural killer cell immune*, i aconsegueixen uns temps de detecció força bons per a les fallades f_1, f_7 i f_{17} del *benchmark*. A [85] es presenta un sistema FDD basat en tècniques de *soft computing*, en particular, amb xarxes neuronals i xarxes neurodifuses, en què es mostra l'efectivitat de la detecció en les fallades f_4 i f_{17} del *benchmark*.

Per posar a prova la solidesa de l'enfocament VisualBlock-FIR, s'han simulat quatre fallades de les que estan definides en el fitxer DABLib del *benchmark* de DAMADICS. Aquests avaries afecten diverses parts de l'actuador industrial. Dues de les fallades estudiades pertanyen al servomotor pneumàtic; la tercera, a la vàlvula de control, i la quarta, al posicionador. Concretament, s'han seleccionat les fallades següents:

- f_{10} : perforació del diafragma del servomotor. Fallada causada per la fatiga del material d'aquest diafragma.
- f_{11} : fallada de la molla del servomotor. Fallada causada per la fatiga o corrosió del material de la molla.
- f_7 : obstrucció de la vàlvula de control. Fallada provocada per un esdeveniment mecànic extern que bloqueja la tija del servomotor.
- f_{13} : fallada del sensor de la tija del posicionador. Fallada causada pel desgast de la capa de plàstic del potenciòmetre, pel desgast de l'escombreta del potenciòmetre, per una ruptura per fatiga del cableatge o per la fallada electrònica del desplaçament.

Per a tots els experiments duts a terme, excepte en el cas de la fallada f_{11} , s'estudien escenaris de fallades de petita i mitjana amplitud. Per tant, estem avaluant set fallades que reconeixem com a: $f_{10s}, f_{10m}, f_{11}, f_{1s}, f_{1m}, f_{13s}, f_{13m}$, en què el subíndex s es refereix a una fallada de petita amplitud i el subíndex m , a una fallada de mitjana amplitud. S'han triat aquestes fallades seguint el treball de [118], en què es presenta un sistema de detecció de fallades basat en observadors d'interval i en què s'empren aquestes fallades per provar la

robustesa de la metodologia. Amb l'objectiu de comparar l'aproximació desenvolupada en aquesta tesi doctoral amb altres metodologies, vam decidir estudiar el rendiment del VisualBlock-FIR FDDS fent servir aquestes mateixes fallades.

7.2.2 Identificació dels models FIR del sistema en funcionament normal i en fallada

Per aplicar el VisualBlock-FIR al cas d'estudi, el primer que cal fer és identificar els models FIR qualitatiu que constitueixen els models de la llibreria de fallades i el model FIR del sistema quan funciona correctament. Per tant, cal identificar vuit models diferents abans que el VisualBlock-FIR estigui preparat per fer el diagnòstic de les fallades. La correspondència numèrica dels 8 models que es farà servir al llarg del capítol es recull a la taula 7-1.

Model	Sense fallada	f_{1s}	f_{1m}	f_{10s}	f_{10m}	f_{11}	f_{13s}	f_{13m}
Representació numèrica	#1	#2	#3	#4	#5	#6	#7	#8

Taula 7-1 Equivalència entre els models i la representació numèrica donada al Simulink.

Per a cadascun d'aquests escenaris, el sistema se simula durant 400 segons amb un període de mostreig de 0,25 segons, de manera que s'obtenen 1.600 dades. Els primers 200 segons (800 dades) s'utilitzen per identificar els models FIR i els darrers 200 segons (800 dades) s'utilitzen per provar la qualitat de cadascun dels models.

$$MSE = \frac{E[(y(t) - \hat{y}(t))^2]}{y_{var}} \cdot 100 \tag{7.1}$$

Per a cada model, es calcula l'error quadràtic mitjà en percentatge de la predicció, segons l'equació (7.1).

	#1	#2	#3	#4	#5	#6	
t/x	$CV \ x$	$CV \ x$	$CV \ x$	$CV \ x$	$CV \ x$	$CV \ x$	
$t - 4\delta t$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 \end{bmatrix}$	
$t - 3\delta t$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	
$t - 2\delta t$	$\begin{bmatrix} 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -2 & 0 \end{bmatrix}$	
$t - \delta t$	$\begin{bmatrix} -2 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & -2 \end{bmatrix}$	$\begin{bmatrix} 0 & -2 \end{bmatrix}$	$\begin{bmatrix} 0 & -2 \end{bmatrix}$	$\begin{bmatrix} 0 & -3 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$	
t	$\begin{bmatrix} 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & 1 \end{bmatrix}$	$\begin{bmatrix} -3 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 & 1 \end{bmatrix}$	
		#7	#8				
t/x		$CV \ x$	$CV \ x$				
$t - 7\delta t$		$\begin{bmatrix} 0 & -1 \end{bmatrix}$	$\begin{bmatrix} 0 & -1 \end{bmatrix}$				
$t - 6\delta t$		$\begin{bmatrix} -2 & 0 \end{bmatrix}$	$\begin{bmatrix} -2 & 0 \end{bmatrix}$				
$t - 5\delta t$		$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$				
$t - 4\delta t$		$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$				
$t - 3\delta t$		$\begin{bmatrix} -3 & 0 \end{bmatrix}$	$\begin{bmatrix} -3 & 0 \end{bmatrix}$				
$t - 2\delta t$		$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$				
$t - \delta t$		$\begin{bmatrix} 0 & 0 \end{bmatrix}$	$\begin{bmatrix} 0 & 0 \end{bmatrix}$				
t		$\begin{bmatrix} -4 & 1 \end{bmatrix}$	$\begin{bmatrix} -4 & 1 \end{bmatrix}$				

Per identificar cadascun d'aquests models, fem servir la plataforma Visual-FIR, que ens ha de permetre obtenir la màscara òptima i el conjunt de regles patró que millor representen el sistema tenint en compte el conjunt de dades d'identificació disponible, en què l'entrada del sistema, *CV*, correspon al senyal de control que proporciona el controlador proporcional (*P*) del sistema i la sortida *x* és el desplaçament de la tija del posicionador. Les màscares obtingudes dels models #1 al #8 són les presentades en l'equació (7.2).

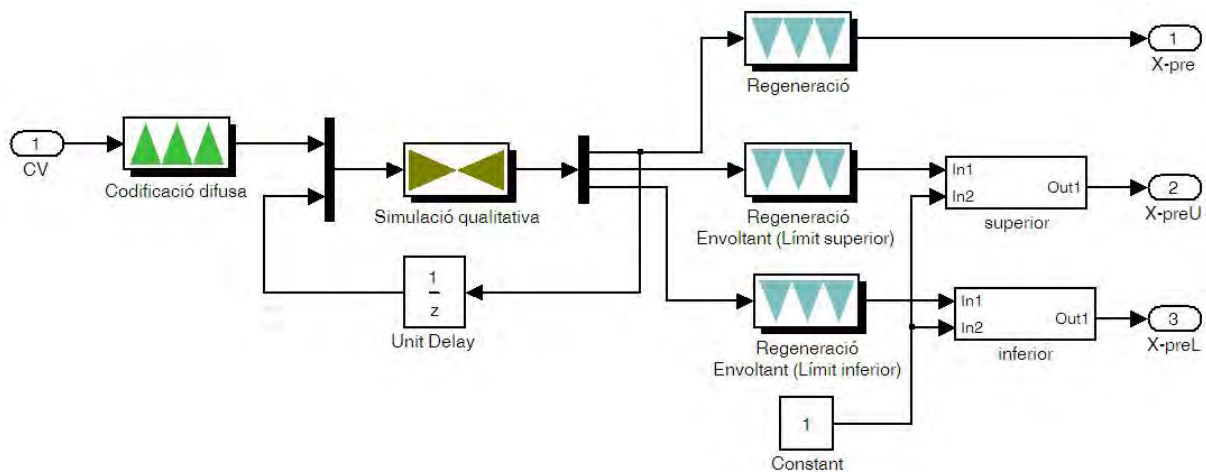


Figura 7-2 Esquema de predicció per al sistema en funcionament correcte desenvolupat en Simulink que empra el model FIR identificat prèviament amb el Visual-FIR.

La figura 7-2 mostra la representació gràfica de com s'utilitza el VisualBlock-FIR per predir la sortida, *X-pre*, i les envoltants superior, *X-preU*, i inferior, *X-preL*, quan la vàlvula està funcionant correctament; empra els mòduls de codificació difusa, simulació qualitativa o predicció i regeneració del FIR. Es construeixen esquemes similars per a la resta de models FIR que identifiquen les fallades.

Els MSE obtinguts per a cadascun dels 8 models FIR en predir els conjunts de prova formats per 800 punts es mostren a la taula 7-2.

Sense fallada	f_{1s}	f_{1m}	f_{10s}	f_{10m}	f_{11}	f_{13s}	f_{13m}
$1,059 \cdot 10^{-1} \%$	$1,57 \cdot 10^{-1} \%$	3,7 %	$0,95 \cdot 10^{-1} \%$	7,34 %	$1,15 \cdot 10^{-1} \%$	$3,36 \cdot 10^{-2} \%$	$2,5 \cdot 10^{-2} \%$

Taula 7-2 Error quadràtic mitjà en percentatge (MSE) de predicció dels conjunts de dades de prova, formats per 800 punts (200 segons), obtinguts amb els diferents models FIR identificats per a cada fallada.

Aquests errors de predicció són molt baixos, la qual cosa significa que els models obtinguts representen amb molta precisió cadascun dels comportaments del sistema.

Els models FIR de les set fallades, així com el model de la vàlvula funcionant correctament, s'emmagatzemen en la llibreria de models de fallades que s'utilitza durant la fase de diagnòstic del VisualBlock-FIR (vegeu la figura 7-3).

7.2.3 Detecció i diagnòstic de les fallades

Quan es disposa del model FIR del sistema en funcionament correcte i dels models FIR de les diferents fallades, és el moment de construir el sistema de diagnòstic de fallades amb el VisualBlock-FIR. La figura 7-3 presenta un exemple d'aquest model que està format pels mòduls següents:

- El mòdul generador de dades; en aquest cas, el *benchmark* DAMADICS explicat en l'apartat anterior.
- El mòdul *Model sense fallades*, que conté l'esquema de predicció del sistema quan funciona correctament (vegeu la figura 7-2).
- El mòdul *Llibreria de models de fallades*, que conté els models FIR de totes les fallades.
- Finalment, el mòdul *FDSS*, que és el responsable de detectar una fallada del sistema i, a continuació, aïllar-la i identificar-la.

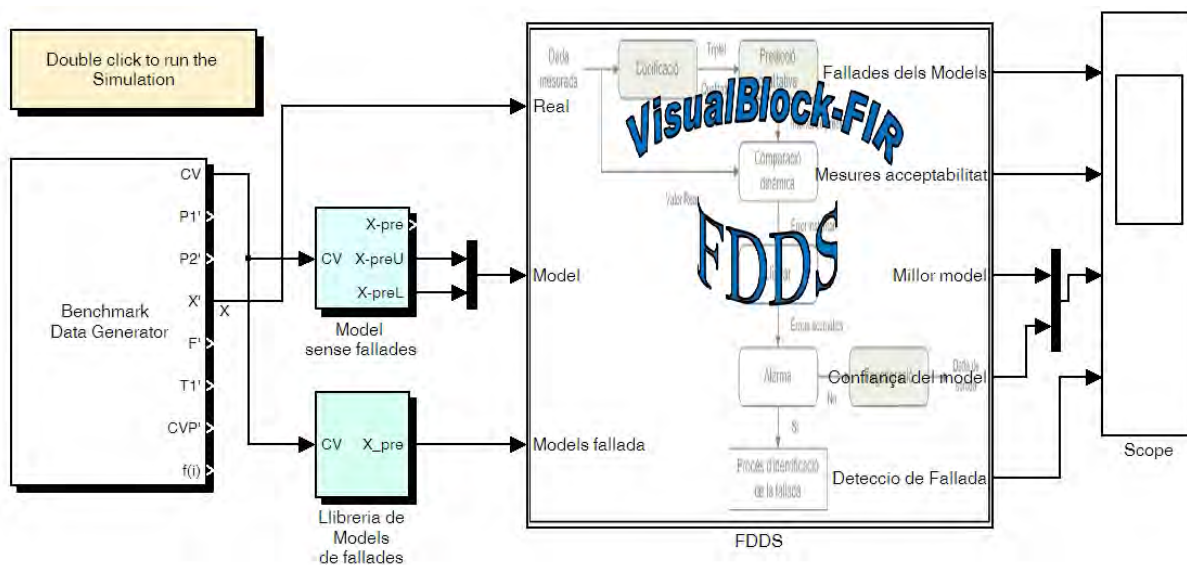


Figura 7-3 Model de detecció i diagnòstic de fallades de VisualBlock-FIR per al sistema DAMADICS.

Tal com s'ha explicat en el capítol 4, durant la fase de detecció, el mòdul utilitza les entrades reals i les envoltants del model de funcionament normal (sense fallades) per seguir l'algorisme descrit a la figura 4-4, és a dir, que compta les vegades que el valor real queda fora de l'envolupant formada pels límits superior i inferior predits pel model FIR sense fallada.

Quan el nombre d'errors arriba al límit prèviament especificat per l'usuari, s'activa la sortida *Detecció de fallada* de l'FDSS (vegeu la figura 7-3). En aquest moment, s'executa l'algorisme de diagnòstic. Les entrades reals i les envoltants obtingudes de la predicció dels models situats en la llibreria de models de fallada s'utilitzen per acomplir l'algorisme de diagnòstic descrit en la figura 4-5, i es calculen les mesures d'acceptabilitat per a cada model de fallada. El model que té més acceptabilitat és el que se selecciona com el model que millor representa aquesta fallada.

7.2.4 Fallada 10 (f_{10}): perforació del diafragma del servomotor

Aquesta fallada s'introdueix a l'instant de temps equivalent a 200 segons. Les figures 7-4 i 7-5 mostren els resultats del procés de detecció del VisualBlock-FIR per a les fallades d'amplitud petita f_{10s} (#4) i mitjana f_{10m} (#5), respectivament. Es veu en el gràfic inferior d'ambdues figures que la detecció té lloc gairebé de manera instantània. En la detecció s'ha considerat que cal que tinguin lloc tres errors per indicar una fallada; per tant, la finestra de detecció s'ha establert a 3. Per als dos nivells de fallades f_{10s} i f_{10m} , el VisualBlock-FIR només ha necessitat 0,75 segons per determinar que la vàlvula no estava funcionant correctament. Per tant, l'alarma s'activa a l'instant de temps 200,75 segons. Cal remarcar que durant els primers 200 segons el senyal real se situa completament dins l'interval de l'envolupant obtinguda per al model sense fallada.




Figura 7-4 Detecció i diagnòstic de la fallada f_{10s} amb VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.

Una vegada activada l'alarma, comença el procés de diagnòstic. En aquest exemple, s'ha utilitzat una finestra d'identificació de 400 dades (corresponents a 100 segons) per identificar la fallada que té lloc, concretament, del segon 201 al segon 300. Els gràfics centrals de les figures 7-4 i 7-5 indiquen numèricament (vegeu la taula 7-1) el model que millor representa el comportament del sistema en cada finestra d'identificació. El model #1 correspon al model del sistema quan funciona correctament. Durant els primers 200 segons, el VisualBlock-FIR utilitza el model #1 per detectar si es registra una fallada.

En el moment en què s'activa l'alarma del detector de fallades el procés de diagnòstic mira, al llarg d'un període de 100 segons, el comportament de les variables del sistema amb tots els models, el model sense fallada i els set models de fallada. En finalitzar aquest període de temps, se selecciona el model amb la mesura d'acceptabilitat més alta. Tal com s'observa a la figura 7-4, es tria el model #4, corresponent a la fallada f_{10s} , ja que és el que millor representa el nou comportament i, per tant, és el que s'utilitza fins que el sistema torna a funcionar correctament perquè la fallada s'ha reparat o fins que es detecta una altra fallada.

Cal esmentar que s'ha triat un període de 100 segons perquè es correspon amb un període complet del senyal. Si l'objectiu és reduir el temps d'aïllament i identificació, es poden triar períodes més petits. En alguns casos, però, resulta necessari treballar amb un període complet, tal com es veurà més endavant en el cas de les fallades f_{11} , f_1 i f_{13} , ja que les valls d'aquests senyals són indistingibles de les valls del senyal que representa el comportament normal del sistema.

El procés de diagnòstic fa un treball excel·lent, de manera que conclou, sense cap dubte, que f_{10s} és la fallada que pateix el sistema. Resultats semblants s'obtenen amb la fallada f_{10m} , tal com es mostra en la figura 7-5.




Figura 7-5 Detecció i diagnòstic de la fallada f_{10m} amb el VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.

En ambdós resultats, s'observa que des del segon 300 fins al 600, el senyal real es manté dins de l'envolupant dels intervals obtinguts per als models de les fallades f_{10s} i f_{10m} , respectivament.

Els gràfics del mig mostren les mesures d'acceptabilitat. En el cas de la fallada f_{10m} (figura 7-5), aquesta mesura assumeix valors molt alts durant els 600 segons que dura l'assaig. Això significa que el comportament del sistema quan té aquesta fallada difereix força del comportament del sistema quan pateix qualsevol de les altres fallades. Per tant, el procés de diagnòstic del VisualBlock-FIR és molt fiable en aquest cas. En el cas mostrat en la figura 7-4 el diagnòstic diu que es tracta de la fallada #5, que correspon a la fallada que realment s'ha generat, però la mesura d'acceptabilitat pren valors màxims de 0,5. Això significa que hi ha models d'altres fallades que aconseguixen predir correctament part del comportament del sistema real en aquest període de 100 segons i que el model #5 és el que prediu correctament més punts d'aquest interval.

7.2.5 Fallada 11 (f_{11}): fallada de la molla del servomotor




Figura 7-6 Detecció i diagnòstic de la fallada f_{11} amb el VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.

La figura 7-6 mostra la detecció i l'aïllament/identificació de la fallada f_{11} (#6). Tal com es veu en el gràfic inferior d'aquesta figura, la detecció es porta a terme molt ràpidament, després de tan sols 0,75 segons. El procés de diagnòstic també mostra un bon rendiment, ja que escull la fallada f_{11} entre els 7 models de fallada que s'emmagatzemen a la llibreria de models. S'observa que, en aquest cas, la mesura d'acceptabilitat és menor que en el cas de la fallada f_{10} ; això és degut al fet de que el comportament de la fallada f_{11} és molt similar al comportament del sistema quan funciona correctament i al de la fallada f_{13} .

No obstant això, encara que la mesura d'acceptabilitat del model de la fallada f_{1l} és força baixa (0,25), és el model que té la mesura d'acceptabilitat més elevada del conjunt de models de la llibreria; per tant, el VisualBlock-FIR té més confiança en la decisió que la fallada f_{1l} és la que realment ha tingut lloc.

7.2.6 Fallada 1 (f_1): obstrucció a la vàlvula de control




Figura 7-7 Detecció i diagnòstic de la fallada f_{1s} amb el VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.

Les figures 7-7 i 7-8 mostren els resultats del procés de detecció del VisualBlock-FIR quan tenen lloc fallades de petita f_{1s} (#2) i mitjana f_{1m} (#3) amplitud al cap de 200 segons. En ambdós casos el comportament del sistema en les valls dels senyals és el mateix tant quan té lloc la fallada com quan el sistema funciona correctament; per tant, les fases de detecció i identificació de les avaries són més complicades en aquest cas. Els gràfics superiors de les figures 7-7 i 7-8 mostren què les prediccions obtingudes mitjançant el model del sistema quan està funcionant correctament i les prediccions amb els models de les fallades f_{1s} i f_{1m} són molt precises. En el cas de fallada f_{1m} , la detecció és gairebé instantània, tal com mostra el gràfic inferior de la figura 7-8. El procés de detecció necessita més temps per detectar la fallada f_{1s} (gràfic inferior de la figura 7-7). En aquest cas, es necessiten 7,25 segons perquè en aquest període els dos senyals (el del sistema quan funciona correctament i el del sistema afectat per la fallada f_{1s}) exhibeixen comportaments gairebé idèntics.

Dels experiments que es mostren a les figures 7-4, 7-5, 7-6, 7-7 i 7-8, es pot concloure que el VisualBlock-FIR desenvolupa una bona feina a l'hora de detectar la fallada, ja que aquesta es detecta en menys d'un segon, a excepció de la fallada f_{1s} , en què l'FDDS necessita 7,25 segons. El VisualBlock-FIR també obté bons resultats en la fase de diagnòstic, ja que en cada decisió identifica el model de fallada sense cap error.

En el món real, la identificació de la fallada podria donar lloc a una intervenció de l'operari per corregir-la o bé, depenent de la gravetat, per recomanar una aturada del sistema.




Figura 7-8 Detecció i diagnòstic de la fallada f_{1m} amb el VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.

7.2.7 Fallada 13 (f_{13}): fallada del sensor de la tija del posicionador

Les figures 7-9 i 7-10 mostren els resultats del procés de detecció del VisualBlock-FIR per a les fallades de petita f_{13s} (#7) i mitjana f_{13m} (#8) amplitud. Una vegada més, la detecció es porta a terme molt ràpidament, en menys d'un segon. No obstant això, el diagnòstic de la fallada, en aquest cas, resulta molt més difícil.

Tal com es mostra en el gràfic central de la figura 7-9, el procés de diagnòstic arriba a la conclusió que la fallada que ha tingut lloc és la f_{11} (#6) algunes vegades i la f_{13s} (#7) altres vegades. La raó d'aquesta confusió és que els comportaments de les dues fallades són molt similars. La mesura d'acceptabilitat




Figura 7-9 Detecció i diagnòstic de la fallada $f_{1.3s}$ amb el VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.




Figura 7-10 Detecció i aïllament/identificació de la fallada $f_{1.3m}$ amb el VisualBlock-FIR.

Temps de la finestra de detecció = 2,5 s; errors acumulats = 3; temps de la finestra d'identificació = 100 s.

(gràfic central) confirma aquest fet i mostra valors molt baixos, cosa que significa que no hi ha un model únic que representi amb exactitud el comportament real del sistema.

La mateixa anàlisi s'ha fet per a la fallada f_{13m} . La representació central de la figura 7-10 mostra que el procés de diagnòstic commuta entre les fallades f_{11} (#6), f_{13s} (#7) i f_{13m} (#8). En aquest cas, el problema torna a ser que els tres models que representen aquestes fallades presenten comportaments molt similars.

S'ha de tenir en compte que les figures 7-9 i 7-10 presenten la simulació de 1.200 segons en lloc dels 600 segons simulats en les altres fallades. Aquesta ampliació del temps de simulació permet mostrar amb més claredat el rendiment del procés de diagnòstic d'aquestes fallades específiques.

El problema associat a aquesta fallada és que forma part d'un llaç de control. Si consideréssim coneguda la variable de sortida del controlador (CVI), com és el cas quan fem servir el simulador fet amb el Simulink, es podria agafar com una entrada de l'FDDS i aquesta fallada es podria identificar correctament, cosa que hem provat i hem confirmat. Tanmateix, en la realitat aquesta variables és dins del sistema posicionador de la vàlvula i, per tant, no és accessible.

7.2.8 Rendiment del VisualBlock-FIR vs. la metodologia dels observadors d'interval

En aquesta secció s'utilitza el temps de detecció per mesurar la qualitat dels resultats dels escenaris de fallada presentats en aquesta recerca i ens centrem exclusivament en la detecció. En la taula 7-3 es presenten aquests temps per a cadascuna de les fallades presentades anteriorment.

De la taula 7-3 es pot concloure que el VisualBlock-FIR és un bon sistema de detecció de fallades i que és capaç de detectar les fallades de petita i mitjana amplitud en molt poc temps. Tal com ja s'ha dit anteriorment, totes les fallades, excepte una, es detecten en menys d'un segon.

Nom de la fallada	Detecció	
	Temps de detecció	Moment de la detecció
f_{10s}	0,75 s	200,75 s
f_{10m}	0,75 s	200,75 s
f_{11}	0,75 s	200,75 s
f_{1s}	7,25 s	207,25 s
f_{1m}	0,75 s	200,75 s
f_{13s}	0,75 s	200,75 s
f_{13m}	0,75 s	200,75 s

Taula 7-3 Temps de detecció obtinguts en la fase de detecció de fallades del VisualBlock-FIR.

Aquests resultats són força significatius quan es comparen amb els publicats en [118]. La taula 7-4 presenta els temps de detecció obtinguts amb la metodologia basada en observadors d'interval no lineals. Aquesta és una aproximació que fa servir un model d'interval no lineal en lloc dels clàssics lineals, cosa

que permet que els envolupants de sortida siguin menys conservadores i puguin detectar fallades de petita i mitjana amplitud.

Nom de la fallada	Índex de rendiment	
	Temps de detecció	Moment de la detecció
f_{10s}	—	—
f_{10m}	2 s	202 s
f_{11}	2 s	202 s
f_{1s}	—	—
f_{1m}	3,3 s	203,3 s
f_{13s}	—	—
f_{13m}	2 s	202 s

Taula 7-4 Temps de detecció obtinguts en la fase de detecció de fallades de la metodologia d'observadors d'interval. Els guions representen temps que no es poden computar d'acord amb la definició donada en el *benchmark* DAMADICS [125].

Com s'observa en la taula anterior, tres de les set fallades tenen un guió que representa temps que no es poden computar d'acord amb la definició donada en el *benchmark*. Això significa que el sistema pot detectar la fallada, però poc després no detecta cap fallada i així successivament. És a dir, el sistema dubta de si hi ha fallada o no n'hi ha.

Els temps de detecció que s'aconsegueixen amb el VisualBlock-FIR són molt inferiors als obtinguts amb la metodologia dels observadors d'interval.

7.2.9 Comparació dels rendiments en la detecció i el diagnòstic amb metodologies afins

No és possible fer una comparació sòlida entre els resultats obtinguts en aquesta recerca i els publicats en l'edició especial sobre DAMADICS de la revista *Control Engineering Practice* (Elsevier), a causa del fet que cada article presenta diferents criteris d'avaluació del diagnòstic i treballa amb un conjunt diferent de fallades. No obstant això, creiem que és útil fer un comentari sobre tres articles que estan directament relacionats amb el nostre enfocament. A [135] es proposa un FDDS basat en un observador neurodifús de múltiples models (NFMM). Aquesta recerca és molt interessant i tracta les fallades abruptes petites i mitjanes $f_1, f_2, f_7, f_{13}, f_{17}, f_{18},$ i f_{19} . La tècnica neurodifusa és capaç de detectar i diagnosticar totes les fallades estudiades. [21] presenta un altre enfocament basat en el raonament qualitatiu, juntament amb xarxes neuronals difuses (QRFNN). Aquesta recerca intenta fer front a les fallades abruptes i incipients, però conclou que les fallades incipients són indetectables. Pel que fa a les fallades abruptes, la metodologia presentada és capaç de diagnosticar amb una exactitud màxima les fallades $f_2, f_7, f_{10}, f_{11}, f_{13}, f_{17}, f_{18},$ i f_{19} . No obstant això, el sistema de diagnòstic de fallades no és capaç de fer front als escenaris de les fallades f_1, f_8 i f_{12} . La metodologia EUIO-GP, basada en observadors i que fa ús de programació genètica, és la més restrictiva, ja que només aconsegeix detectar les fallades f_1, f_7, f_{13}, f_{18} i f_{19} , però no és

capaç d'identificar-les. La taula 7-5 resumeix les capacitats de detecció i diagnòstic d'aquestes metodologies i del VisualBlock-FIR.

VB-FIR: VisualBlock-FIR

NFMM: Neuro-Fuzzy Multiple-Model observer

EUIO-GP: Extended Unknown Input Observer with Genetic Programming

QRFNN: Qualitative Reasoning coupled with Fuzzy Neural Networks

Aproximació	Amplitud	f_1	f_2	f_7	f_8	f_{10}	f_{11}	f_{12}	f_{13}	f_{17}	f_{18}	f_{19}
VB-FIR	Petita	DI				DI	—		DI*			
	Mitjana	DI				DI	—		DI*			
	Gran						DI					
NFMM	Petita	DI	DI	DI			—		DI	DI	DI	DI
	Mitjana	DI	DI	DI			—		DI	DI	DI	DI
	Gran											
EUIO-GP	Petita	D		D			—		D		D	D
	Mitjana	D		D			—		D		D	D
	Gran											
QRFNN	Petita	ND	ND	ND	ND	ND	—	ND	ND	ND	ND	ND
	Mitjana	D		DI	ND	DI	—	D	DI		DI	DI
	Gran	D	DI	DI	ND	DI	DI	D	DI	DI	DI	DI

DI: fallada detectada i diagnosticada.

DI*: fallada detectada i parcialment diagnosticada (identifica una reducció del conjunt de fallades).

D: fallada detectada, però no diagnosticada.

ND: fallada no detectada.

—: fallada que no pot tenir lloc.

: fallada no utilitzada en l'estudi.

Taula 7-5 Resultats de diferents FDDS per al sistema de referència DAMADICS.

Algunes de les conclusions que s'extreuen de la taula 7-5, són les següents:

- L'EUIO-GP no és capaç d'aïllar/identificar cap de les fallades estudiades.
- El VB-FIR i l'NFMM són capaços de detectar i diagnosticar la fallada f_1 , mentre que l'EUIO-GP i el QRFNN no són capaços de diagnosticar aquesta fallada. Per tant, el VB-FIR i l'NFMM sembla que tenen més poder de diagnòstic que els enfocaments l'EUIO-GP i el QRFNN en aquest cas concret.
- L'NFMM és capaç de detectar i diagnosticar correctament les fallades que s'han utilitzat per als propòsits del *benchmark*. El VB-FIR també és capaç de detectar i diagnosticar les fallades utilitzades per a la finalitat de referència, malgrat que hi ha una fallada que només es pot diagnosticar parcialment.
- L'enfocament QRFNN es prova amb un major nombre de fallades que les altres metodologies i té com a principal limitació que no aconsegueix detectar ni identificar fallades incipients (definides com a *small*).
- Cal tenir en compte que per tal d'obtenir comparacions entre metodologies fonamentades caldria aplicar tots els FDDS que es presenten a la taula 7-5 al mateix conjunt de fallades. D'altra banda, caldria utilitzar el mateix conjunt d'índexs de rendiment per a tots els FDDS.

7.3 Sistema de piles de combustible

7.3.1 Descripció del sistema

Les piles de combustible són dispositius electroquímics que converteixen l'energia química d'un combustible gasós directament en electricitat. Se'ls considera una font potencial de futures energies estacionàries i mòbils [119].

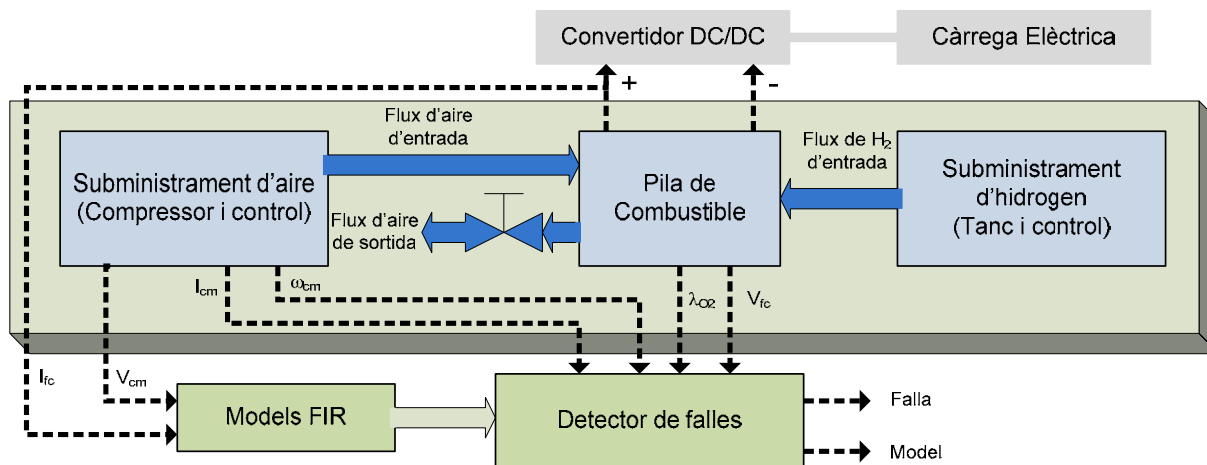


Figura 7-11 Esquema del sistema de la pila de combustible.

El sistema utilitza el model no lineal proposat per Pukrushpan *et al.* [119] per representar el comportament d'una pila de combustible de membrana d'intercanvi de protons (PEM). Els principals components del sistema (tal com mostra la figura 7-11), són la pila de combustible, el compressor, el col·lector d'aire, el col·lector d'hidrogen i el col·lector de retorn. El sistema d'alimentació d'aire (compressor i col·lector d'aire) té com a principal objectiu mantenir constant la pressió parcial de l'oxigen al càtode.

La majoria de la potència parasitària (potència perduda, és a dir, la diferència entre la potència de les piles i la potència del motor) per a un sistema de piles de combustible d'automoció es gasta en el compressor d'aire; per tant, és important per determinar el flux d'aire apropiat. L'excés de flux d'aire es reflecteix en la proporció d'excés d'oxigen final, definit com la relació entre l'oxigen subministrat i l'oxigen utilitzat en el càtode (7.3).

$$\lambda_{\sigma_2} = \frac{O_2 \text{ subministrat}}{O_2 \text{ reaccionat}} \tag{7.3}$$

El model inclou els fenòmens transitoris del compressor, la dinàmica dels col·lectors de l'ànode i del càtode, les pressions parcials dels reactius i la humidificació de la membrana. La tensió de la pila V_{fc} es calcula a partir del corrent de càrrega I_{fc} , les pressions parcials d'hidrogen i oxigen, la temperatura de la

pila i el contingut d'aigua de la membrana. En les condicions d'operació normal, es parteix de la hipòtesi que es fa un control perfecte de la temperatura de la pila i de la humidificació de l'aire a l'entrada del càtode de la pila. La temperatura atmosfèrica i la pressió són considerades pertorbacions externes del sistema.

El sistema presenta dos llaços de regulació: mitjançant un llaç intern es regula el flux d'hidrogen i mitjançant un llaç extern es regula l'excés d'oxigen, λ_{O_2} , com una mesura indirecta per controlar l'eficiència de la PEM, tal com es proposa a [119 i 123]. L'objectiu del control de flux d'hidrogen és minimitzar la diferència de pressió del càtode i l'ànode. La regulació de λ_{O_2} s'aconsegueix manipulant el flux de sortida d'aire del càtode i la tensió aplicada al compressor V_{cm} , per aquest motiu el model incorpora una servovàlvula d'àrea variable, A_v , a la sortida del conducte d'aire. El corrent de la pila, I_{fc} , es considera una pertorbació coneguda del sistema. El sistema disposa, a més a més, de mesures del corrent del compressor, I_{cm} , i de la seva velocitat, ω_{cm} . La figura 7-11 mostra un esquema del sistema PEM, juntament amb les variables disponibles per controlar i supervisar el sistema.

En aquest apartat s'utilitza el VisualBlock-FIR per detectar i diagnosticar les fallades d'aquest sistema de piles de combustible [47]. Tal com en l'aplicació anterior, es tracta d'un cas d'estudi creat per fer proves de diagnòstic de fallades. El model inicial utilitzat va ser desenvolupat i va ser implementat en Simulink per [120], i va ser adaptat per diagnosticar diferents fallades en la tesi publicada recentment [122].

Hi ha uns quants treballs que s'han centrat en el disseny de FDDS per a sistemes de piles de combustible, com ara [56 i 121]. A [56] es presenta un sistema de diagnòstic de fallades basat en models (sobre la base de la teoria del control i la modelització matemàtica), que s'utilitza per detectar i identificar un augment de la fricció i l'escalfament del motor del compressor. A [121] es dissenya una xarxa bayesiana (basada en dependències probabilístiques) per detectar fallades del ventilador d'aire del sistema de refrigeració, de la línia d'alimentació d'hidrogen i d'un augment del pas de combustible.

Per posar a prova la solidesa de l'enfocament del VisualBlock-FIR, s'han simulat cinc fallades de les definides en el *benchmark* de la pila de combustible PEM. Aquestes avaries afecten diverses parts de la pila i s'han seleccionat les fallades següents:

- f_1 : fallada causada per un augment de la fricció al motor del compressor.
- f_2 : fallada causada per un sobreescalfament del motor de compressió.
- f_3 : fallada causada per un augment de la resistència del flux d'aigua a causa del bloqueig dels canals o dels desbordaments a la capa de difusió.
- f_4 : fallada deguda a una fuga d'aire al col·lector de subministrament d'aire.
- f_5 : fallada causada per un augment del valor de tensió per sota del qual el motor del compressor no s'encén.

Cada model de fallades té com a variables d'entrada I_{fc} i V_{cm} , i com a variables de sortida I_{cm} , ω_{cm} , λ_{O2} i V_{fc} . Com que cada model FIR només pot tenir una sola sortida, cal identificar quatre models per a cadascuna de les fallades proposades.

7.3.2 Identificació dels models FIR del sistema en funcionament normal i en fallada

Tal com en el *benchmark* DAMADICS, el primer pas és obtenir els models FIR qualitatius que constitueixen la llibreria de models de fallades. En aquest cas, s'han d'identificar 4 conjunts de models, que es corresponen amb cadascuna de les variables de sortida i que identifiquem com a M_X , de manera que X és l'identificador d'una de les variables de sortida: I_{cm} , ω_{cm} , λ_{O2} o V_{fc} . Cada M_X consta de 6 models, corresponents al model de funcionament normal i a cadascuna de les 5 fallades considerades. La taula 7-1 mostra el número identificatiu dels models del conjunt M_X amb cadascuna de les 5 fallades estudiades.

Model	Sense fallada	f_1	f_2	f_3	f_4	f_5
Número identificatiu	#1	#2	#3	#4	#5	#6

Taula 7-6 Equivalència entre els models i la representació numèrica assignada en el VisualBlock-FIR.




Figura 7-12 Senyals d'entrada a la pila.

Per a cadascun d'aquests escenaris, el sistema se simula considerant tres períodes complets del senyal de 160 segons cadascun, és a dir, 480 segons de temps de simulació, amb una freqüència de mostreig de 0,1 segons, tal com es mostra en la figura 7-12. D'aquesta manera, es generen 4.800 punts de dades. Els primers 320 segons (3.200 punts de dades) són utilitzats pel Visual-FIR per identificar el model i els

Per a cadascun dels 24 models FIR identificats s'obtenen uns errors quadràtics inferiors al 0,35 % (vegeu la taula 7-7). Aquests errors de predicció són molt baixos, la qual cosa significa que els models obtinguts representen amb precisió cadascun dels comportaments del sistema. Els models FIR són emmagatzemats en la llibreria de models de fallades i s'utilitzen durant la fase d'identificació de fallades del VisualBlock-FIR.

7.3.3 Detecció i diagnòstic de les fallades

El model de simulació construït per detectar i diagnosticar fallades es mostra en la figura 7-13. Aquest consta de 3 mòduls:

- El mòdul generador de dades, que simula el comportament del sistema. El simulador del sistema de la cèl·lula de combustible de tipus PEM utilitzat ha estat descrit a [118] i ha estat modificat a [55] i ha estat resolt amb el solucionador (de l'angles *solver*) d'equacions diferencials del tipus ode23.
- El mòdul models, que conté tots els models FIR del sistema. Està format pels quatre models en funcionament correcte (sense fallades) de les variables I_{cm} , ω_{cm} , λ_{O2} i V_{fc} , i tota la llibreria de models de fallades, que conté els models FIR de les 5 fallades per a totes les variables de sortida. Tots els models descrits a l'equació (7.4) es mostren a l'esquema del subsistema de models (figura 7-14). Cadascun dels subsistemes (Pila NF, Pila F1, ..., Pila F5) està format pels models de les quatre variables de sortida dels sistema, tal com es mostra en la figura 7-15 per al model del sistema sense fallades.
- Finalment, el mòdul FDDS, que és el responsable de detectar una fallada del sistema i, a continuació, de diagnosticar-la. La figura 7-16 mostra l'estructura d'aquest mòdul, que està formada per un bloc FDDS de VisualBlock-FIR per a cadascuna de les variables de sortida.

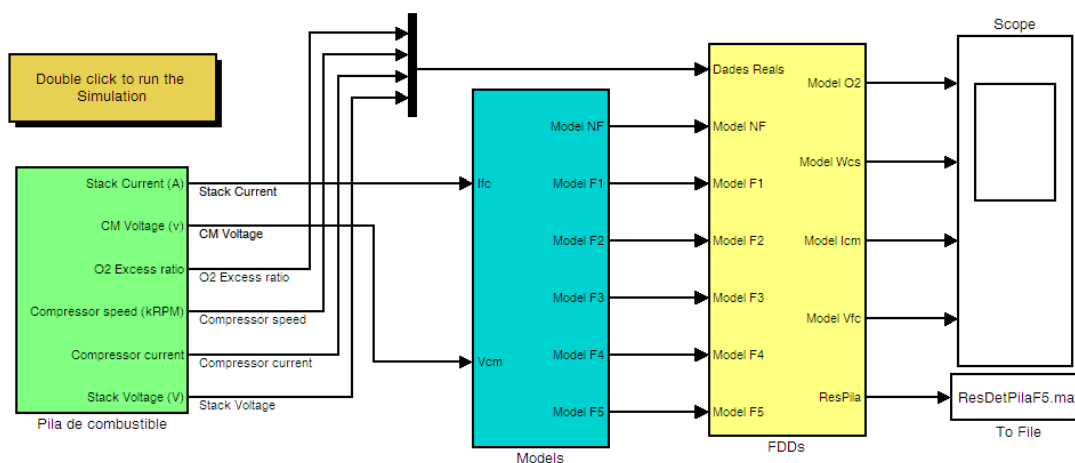


Figura 7-13 Model de detecció i diagnòstic de fallades del VisualBlock-FIR per al sistema de piles de combustible PEM.

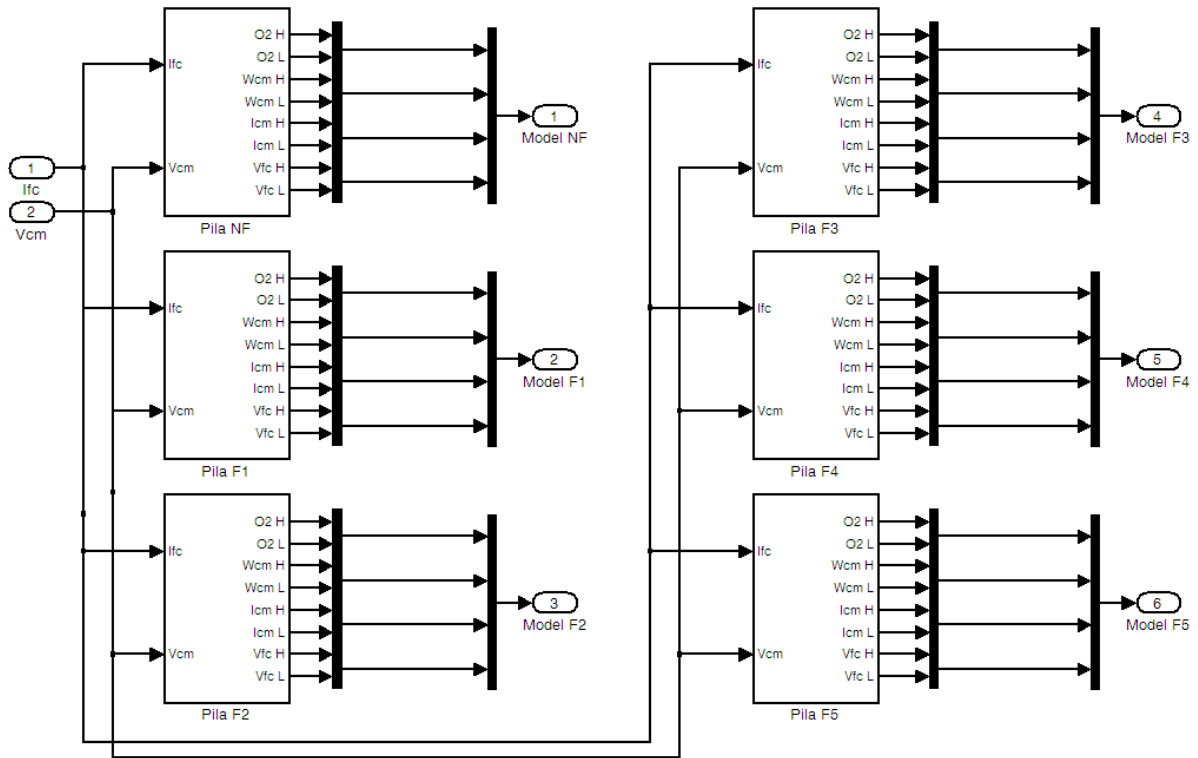


Figura 7-14 Contingut del mòdul models format pels 5 models FIR de fallada i el del funcionament correcte (ModelNF).

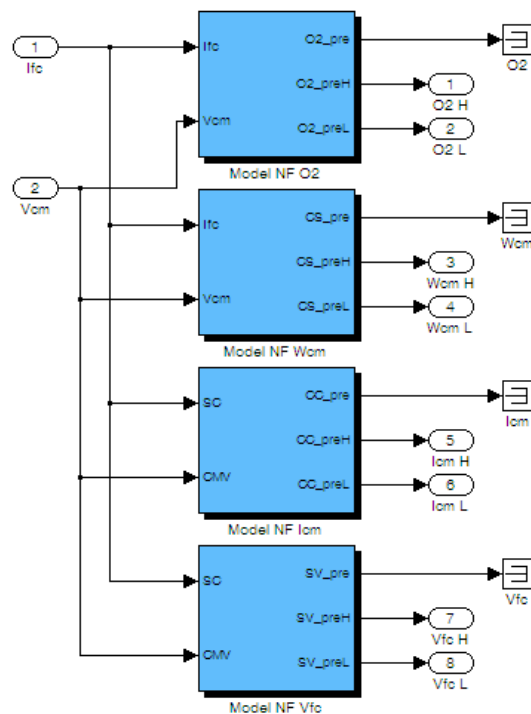


Figura 7-15 Contingut del mòdul Pila NF, amb les quatre sortides del sistema. És a dir, conté els 4 models FIR, un per a cada variable de sortida, del sistema quan funciona correctament.

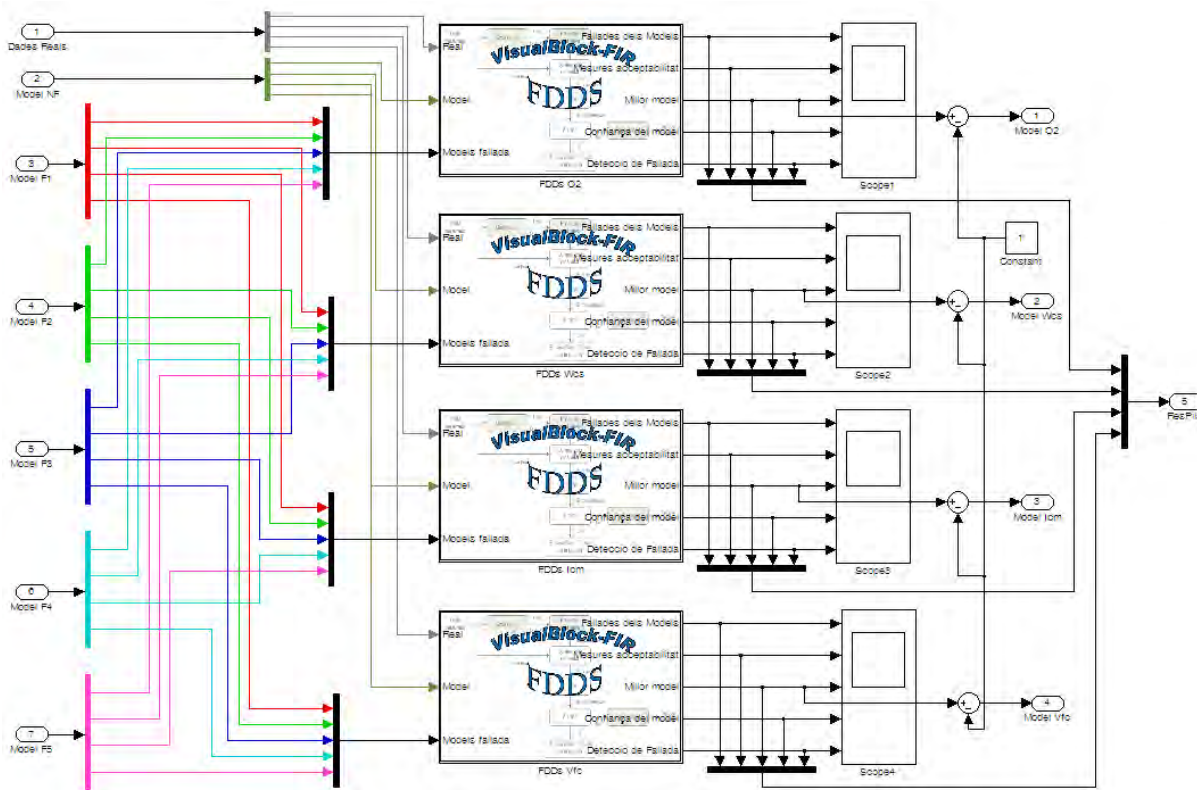


Figura 7-16 Contingut del mòdul FDDS format pels sistemes de detecció i diagnòstic de fallades de les quatre variables de sortida.

La informació que proporciona a l'operari aquest sistema de detecció i diagnòstic de fallades és, en primer lloc, si creu que ha tingut lloc una fallada en el sistema, cosa que es plasma en alguna(es) de les variables de sortida. En el cas que s'hagi registrat aquesta fallada, li dirà de quina fallada es tracta i quina és la fiabilitat d'aquesta predicció, per a cadascuna de les sortides de manera independent. Si totes les sortides prediuen la mateixa fallada, quedarà molt clara la decisió sobre quina és la fallada que ha succeït. En cas de discrepància entre les diferents sortides, l'operari del sistema haurà de decidir quina és la fallada que té més probabilitat d'haver tingut lloc.

Per a tots els casos, es defineix que són necessaris tres errors acumulats per activar una alarma en una finestra de detecció d'un segon (10 mostres) i una finestra d'identificació de 6 segons (60 mostres) per determinar quina és la fallada que s'ha generat.

7.3.4 Fallada f_1 : augment de la fricció al motor del compressor

La fallada f_1 s'introdueix en l'instant de temps de 150 segons, quan la planta està funcionant correctament. La figura 7-17 mostra els resultats de la detecció i del diagnòstic de fallades obtinguts amb el VisualBlock-FIR per a cadascun dels 6 models $M_{\omega_{cm}}$. Els valors màxims i mínims de les envolupants es representen amb línies de punts i les dades reals, amb una línia contínua. El temps que tarda el sistema a detectar que ha tingut lloc una fallada a la variable de sortida ω_{cm} és de 0,5 segons i el temps de diagnòstic de la fallada, dient que es tracta de la f_1 , és de 6 segons. Els models FIR identificats són molt

precisos (marquen uns errors de predicció molt baixos) i, per tant, la part superior i la part inferior de l'envolupant són, en ambdues figures, gairebé indistingibles.




Figura 7-17 Detecció i diagnòstic de la fallada f_i amb el VisualBlock-FIR per al conjunt de models $M_{\omega_{cm}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.

En la figura 7-17 s'observa, també, que a partir del segon 156 les envolupants de la fallada #1 contenen totalment el senyal real, cosa que significa que el model de la fallada #1 representa el comportament real de la planta. Per contra, les envolupants dels models de les altres fallades i del model de la planta quan funciona correctament no contenen el senyal real.

La figura 7-18 mostra el temps de detecció i de diagnòstic i la mesura d'acceptabilitat per a cadascuna de les variables de sortida. El VisualBlock-FIR, per detectar que ha tingut lloc una fallada, només necessita 0,4 segons (4 mostres) per a les variables λ_{O_2} i I_{cm} , 0,5 segons per a la variable ω_{cm} i 0,8 segons per a la variable V_{fc} . A més, només calen 6 segons per assegurar que ha tingut lloc la fallada #1 en les quatre sortides. En aquesta aplicació s'obtenen unes mesures d'acceptabilitat de 1 (valor màxim).




Figura 7-18 Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_1 .

7.3.5 Fallada f_2 : sobreescalfament del motor de compressió

La mateixa anàlisi es pot fer per a la fallada #2 (figura 7-19). La fallada f_2 s'introdueix també en l'instant de temps de 150 segons. En aquest cas, per a la variable de sortida $M_{\lambda_{O_2}}$, el VisualBlock-FIR necessita 0,6 segons per detectar que la planta no està funcionant correctament, tal com es veu en el gràfic superior de la figura 7-19. En el moment en què té lloc la fallada el senyal real surt dels llindars de l'envolupant generada per al model en funcionament normal i s'activa l'alarma de la detecció de la fallada. L'FDDS conclou, al cap de 6 segons, que ha tingut lloc la fallada f_2 , ja que és la que s'assembla més al nou comportament d'aquesta variable de sortida. El VisualBlock-FIR no té cap problema per localitzar la fallada, ja que, tal com s'observa a la figura, totes les prediccions obtingudes per als altres models són molt diferents de la del comportament real.

La figura 7-20 mostra la resposta de l'FDDS per a aquesta fallada, és a dir, la detecció, el diagnòstic i la mesura d'acceptabilitat per a cadascuna de les quatre sortides. El VisualBlock-FIR només necessita, per detectar la fallada, 0,4 segons (4 mostres) per a la variable I_{cm} , 0,6 segons per a la λ_{O_2} , 0,9 segons per a la ω_{cm} i 1,5 segons per a la V_{fc} . A partir de cada detecció s'inicia la fase de diagnòstic per a cadascun dels FDDS.




Figura 7-19 Detecció i diagnòstic de la fallada f_2 amb el VisualBlock-FIR per al conjunt de models $M_{\lambda_{O_2}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.




Figura 7-20 Resposta per a les quatre variables de sortida del VisualBlock-FIR FDSS per a la fallada f_2 .

7.3.6 Fallada f_3 : augment de la resistència del flux d'aigua




Figura 7-21 Detecció i diagnòstic de la fallada f_3 amb el VisualBlock-FIR per al conjunt de models $M_{I_{cm}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.

Si es du a terme el mateix experiment per a la fallada f_3 , el comportament de les variables velocitat del compressor, ω_{cm} , i voltatge de la pila, V_{fc} , és molt similar al comportament d'aquestes variables quan no hi ha cap fallada. A la figura 7-21 s'observa que el senyal real de la variable V_{fc} se situa dins de l'envolupant tant quan el sistema funciona correctament com quan té lloc la fallada f_3 . Aquesta és la raó per la qual el VisualBlock-FIR no és capaç de detectar la fallada f_3 en l'anàlisi de les variables ω_{cm} i V_{fc} , tal com queda reflectit a la taula 7-8. No obstant això, la fallada f_3 es detecta i es diagnostica ràpidament quan s'analitzen les variables λ_{O_2} i I_{cm} .

A la figura 7-22 s'observa la resposta de l'FDSS per a aquesta fallada. La sortida λ_{O_2} detecta la fallada amb un temps de 0,4 segons i la diagnostica amb 6 segons. Les sortides ω_{cm} i V_{fc} , no les detecta i això s'indica amb un símbol d'interrogant en la figura. La sortida I_{cm} , la detecta en 0,4 segons i fa un primer diagnòstic erroni al cap de 6 segons, ja que diu que la fallada que s'ha registrat és la f_4 . Al cap de 12 segons modifica el diagnòstic i diu que es tracta de la fallada f_3 . S'observa que durant el temps que fa la predicció errònia la mesura d'acceptabilitat es redueix. Això vol dir, tal com s'ha comentat anteriorment, que l'FDSS dubta entre dos o més models. Per trobar el motiu d'aquesta errada en el diagnòstic és útil examinar la quantitat de valors predits que queden fora dels intervals de predicció per a cadascun dels models. En la finestra de temps de predicció el model de la f_4 té dos valors fora de l'interval i el model f_3

n'hi té 3, tots els altres models tenen molts més errors. Per tant, l'FDDS conclou que el model que millor representa el comportament del sistema en aquest moment és el model de la fallada f_4 , amb una mesura d'acceptabilitat de 0,5083. En la següent finestra de temps el model de la fallada f_4 té tres valors que queden fora dels llinars de predicció i el model de la fallada f_3 no en té cap que quedi fora, tots el valors queden dins de l'envolupant. L'FDDS diagnostica, llavors, el model de la fallada f_3 com el que millor identifica el comportament d'aquesta sortida amb una mesura d'acceptabilitat, primer, baixa, de 0,5255, que, a partir dels 180 segons, augmenta i queda molt propera a 1, en distanciar-se una mica la predicció dels dos models.




Figura 7-22 Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_3 .

7.3.7 Fallada f_4 : fuga d'aire al col·lector de subministrament d'aire

La figura 7-24 mostra els resultats de detecció i diagnòstic del VisualBlock-FIR per a la fallada f_4 . Tal com es veu en aquesta figura, és capaç de detectar la fallada a les sortides λ_{O_2} i V_{fc} en 0,3 segons i 0,4 segons, respectivament, i només necessita sis segons per determinar de quina fallada es tracta. La fallada a la sortida I_{cm} , la detecta en 0,4 segons i fa un diagnòstic erroni al cap de 6 segons. Al cap de 30 segons modifica el diagnòstic i assenjala que la fallada f_4 és la que millor identifica el comportament del sistema. Tanmateix, no és capaç de detectar la fallada per a la variable de sortida velocitat del compressor, ω_{cm} , ja que la sortida real és molt similar al comportament del model sense fallada i no surt cap valor fora del llinar de predicció.

A la figura 7-23 es mostren les envolupants de predicció de la variable de sortida $M_{V_{fc}}$, en què es veu la fase de detecció i diagnòstic de la fallada f_4 .

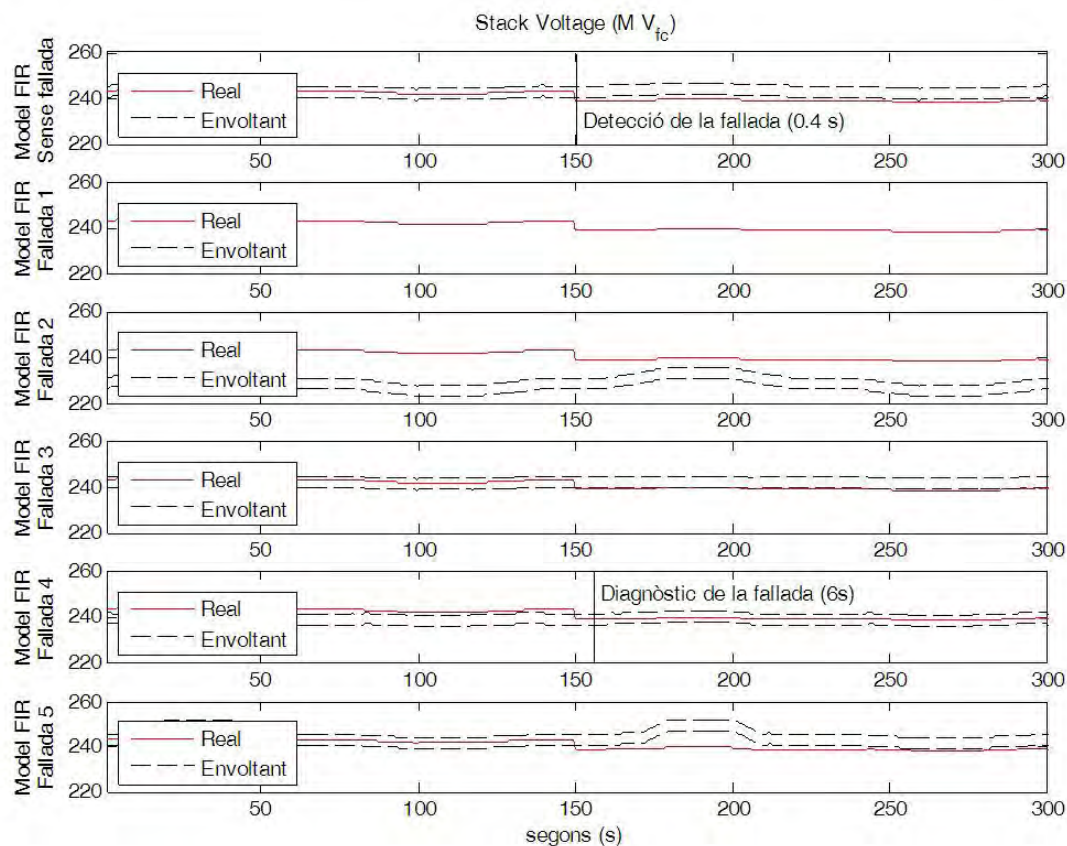


Figura 7-23 Detecció i diagnòstic de la fallada f_4 amb el VisualBlock-FIR per al conjunt de models $M_{V_{fc}}$. Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.




Figura 7-24 Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_4 .

7.3.8 Fallada f_5 : increment de la tensió mínima del motor del compressor

Finalment, la fallada f_5 s'ha de comentar amb més detall pel fet que la detecció i el diagnòstic amb els models M_X és molt més difícil que en les fallades anteriors, com es constata en l'última fila de la taula 7-8. El VisualBlock-FIR necessita entre 22 i 25 segons per detectar la fallada i entre 28 i 31 segons per diagnosticar-la.




Figura 7-25 Detecció i diagnòstic de la fallada f_5 amb el VisualBlock-FIR per al conjunt de models M_{ω_c} . Temps de la finestra de detecció = 1 s; errors acumulats = 3; temps de la finestra d'identificació = 6 s.

Això és degut al fet que el comportament dels senyals de les variables de sortida per a aquesta fallada és realment molt similar al comportament de les sortides quan el sistema funciona correctament i al comportament d'aquestes quan tenen lloc altres fallades, com ara la f_3 i la f_4 , sobretot durant el semiperíode positiu del senyal. Durant el semiperíode negatiu els senyals de sortida es comporten de manera diferent i, per tant, és possible identificar la fallada que ha tingut lloc durant l'anàlisi d'aquest semiperíode. La figura 7-25 mostra els resultats de la detecció i el diagnòstic de la fallada f_5 obtinguts pel VisualBlock-FIR per al senyal de sortida M_{ω_c} . Tal com en els experiments anteriors, s'introdueix una fallada a la planta a l'instant de temps 150 segons. El VisualBlock-FIR detecta la fallada al cap de 23,5 segons i la diagnostica al cap de 179 segons.

Com a conseqüència de la similitud entre els senyals de sortida dels models de la llibreria de fallades i els del mateix model sense fallades del sistema, la mesura d'acceptabilitat que s'aconsegueix en el diagnòstic

d'aquesta fallada és bastant petita. En la figura 7-26 es mostra la informació proporcionada per tots els mòduls. Com a resultat d'avaluar la informació obtinguda amb els models $M_{\omega_{cm}}$, aquest mòdul ens indica que la fallada és f_5 però amb una mesura d'acceptabilitat de 0,25, fet que ens indica que en aquest tram hi ha quatre models que poden explicar el comportament actual del sistema.




Figura 7-26 Resposta per a les quatre variables de sortida del VisualBlock-FIR FDDS per a la fallada f_5 .

7.3.9 Comparació dels rendiments en la detecció i el diagnòstic amb metodologies afins

El resum de resultats quant a temps de detecció i diagnòstic obtinguts amb el VisualBlock-FIR FDDS en aquesta aplicació es mostren a la taula 7-8.

	Temps de detecció				Temps de diagnòstic			
	$M_{\lambda_{O2}}$	$M_{\omega_{cm}}$	$M_{I_{cm}}$	$M_{V_{fc}}$	$M_{\lambda_{O2}}$	$M_{\omega_{cm}}$	$M_{I_{cm}}$	$M_{V_{fc}}$
f_1	0,4	0,5	0,4	0,8	6	6	6	6
f_2	0,6	0,9	0,4	1,5	6	6	6	7
f_3	0,4	—	0,4	—	6	—	6/12	—
f_4	0,3	—	0,4	0,4	6	—	6/30	6
f_5	22,7	23,5	22,3	25,3	28	29	28	31

Taula 7-8 Resultats en segons del VisualBlock-FIR per a les cinc fallades. Temps de la finestra de detecció = 1 s; temps de la finestra d'identificació = 6 s; errors acumulats = 3. El valor de 6 segons marcat de color vermell en les fallades f_3 i f_4 indica que s'ha diagnosticat incorrectament una fallada al cap de 6 segons i que es diagnostica de nou correctament al cap de 12 i 30 segons, respectivament.

Aquests resultats es comparen favorablement amb els temps de detecció i diagnòstic obtinguts per altres sistemes. Aquest és el cas de la metodologia basada en els càlculs de residus presentats a [56 i 123], amb la qual s'obtenen els indicadors comparant les entrades i sortides del sistema amb unes relacions analítiques del model d'aquest. La innovació d'aquesta metodologia és que es basa en la caracterització

de la sensibilitat de fallada residual relativa. Respecte als resultats obtinguts, es necessiten més de 2 segons per detectar les fallades f_1 i f_2 i més de 30 segons per diagnosticar cadascuna de les dues primeres fallades. No hi ha resultats específics que es presentin en el treball relacionats amb la resta de les fallades estudiades; per tant, no es pot fer cap comparació respecte a les altres fallades.

També es compara favorablement amb els temps de detecció obtinguts per la tècnica presentada a [121], en què se cerquen les fallades que tenen lloc en un sistema de piles de combustible real mitjançant una xarxa bayesiana. Les fallades no són les mateixes, perquè es tracta de dades aconseguïdes d'un sistema real, però són similars. L'única referència temporal que exposen en l'article és que tarden uns 20 segons a detectar una avaria en el sistema de refrigeració de la pila i assenyalen què aquesta fallada és una de les que es tarda més temps a detectar. Aquests temps són molt més grans que els que necessita el VisualBlock-FIR per detectar aquesta mena de fallades.

7.4 Anàlisi de robustesa del VisualBlock-FIR

	Soroll afegit	% increment de l'envolupant	Detecció				Diagnòstic			
			$M_{\lambda_{O_2}}$	$M_{\omega_{cm}}$	$M_{I_{cm}}$	$M_{V_{fc}}$	$M_{\lambda_{O_2}}$	$M_{\omega_{cm}}$	$M_{I_{cm}}$	$M_{V_{fc}}$
f_1	0,1 % (60 dB)	0 %	0,4	0,5	0,4	0,8	10	10	10	10
	1 % (40 dB)	0 %	0,4	0,5	0,4	0,9	10	10	10	10
	3,5 % (30 dB)	2,5 %	0,5	0,7	0,4	0,8	10	10	10	10
	10 % (20 dB)	8 %	0,7	1,4	0,5	1,7	10	11	10	11
f_2	0,1 % (60 dB)	0 %	0,6	0,9	0,4	1,8	10	10	10	11
	1 % (40 dB)	0 %	0,5	1,3	0,4	2,0	10	11	10	11
	3,5 % (30 dB)	2,5 %	0,7	1,6	0,5	2,3	10	11	10	12
	10 % (20 dB)	8 %	2,3	2,7	0,7	7,6	12	12	10	17
f_3	0,1 % (60 dB)	0 %	0,4	—	0,5	—	10	—	10	—
	1 % (40 dB)	0 %	0,4	—	0,4	—	10	—	10	—
	3,5 % (30 dB)	2,5 %	0,4	—	0,6	—	10	—	10	—
	10 % (20 dB)	8 %	0,6	—	19,6	—	10	—	29	—
f_4	0,1 % (60 dB)	0 %	0,3	—	0,4	0,4	10	—	10	10
	1 % (40 dB)	0 %	0,3	—	0,4	0,4	10	—	10	10
	3,5 % (30 dB)	2,5 %	0,3	—	0,5	0,7	10	—	10	10
	10 % (20 dB)	8 %	0,6	—	45,0	—	10	—	54	—
f_5	0,1 % (60 dB)	0 %	22,8	23,4	22,3	25,3	32	33	32	35
	1 % (40 dB)	0 %	22,6	23,5	22,4	24,7	32	33	32	34
	3,5 % (30 dB)	2,5 %	23,5	23,6	22,7	25,9	33	33	32	35
	10 % (20 dB)	8 %	25,9	33,0	23,6	—	35	41	33	—

Taula 7-9 Resultats en segons del VisualBlock-FIR per a les cinc fallades amb soroll blanc uniforme de 60, 40, 30 i 20 dB afegit als senyals de sortida. Finestra de detecció = 1 segon; finestra de diagnòstic = 10 segons; errors acumulats = 3.

En aquest apartat s'analitza la robustesa del VisualBlock-FIR a partir de l'aplicació de les piles de combustible, ja que és el sistema més complex tractat en aquesta tesi. Per tal d'estudiar la robustesa del mètode desenvolupat, s'afegeix soroll blanc uniforme a les sortides de les quatre variables del sistema. La robustesa es prova en cadascuna de les cinc fallades i amb diferents nivells de soroll. És important aclarir

que el soroll no està inclòs en els senyals utilitzats per identificar els models FIR, és a dir, els models FIR s'identifiquen a partir de dades sense soroll, i es posen a prova per a la detecció i el diagnòstic en un ambient de soroll.

En aquests experiments la finestra de temps de detecció s'estableix en un segon, tal com s'ha fet en la secció anterior, mentre que la finestra de temps d'identificació s'ha augmentat de 6 a 10 segons, i els errors acumulats necessaris per activar una alarma es mantenen en tres.

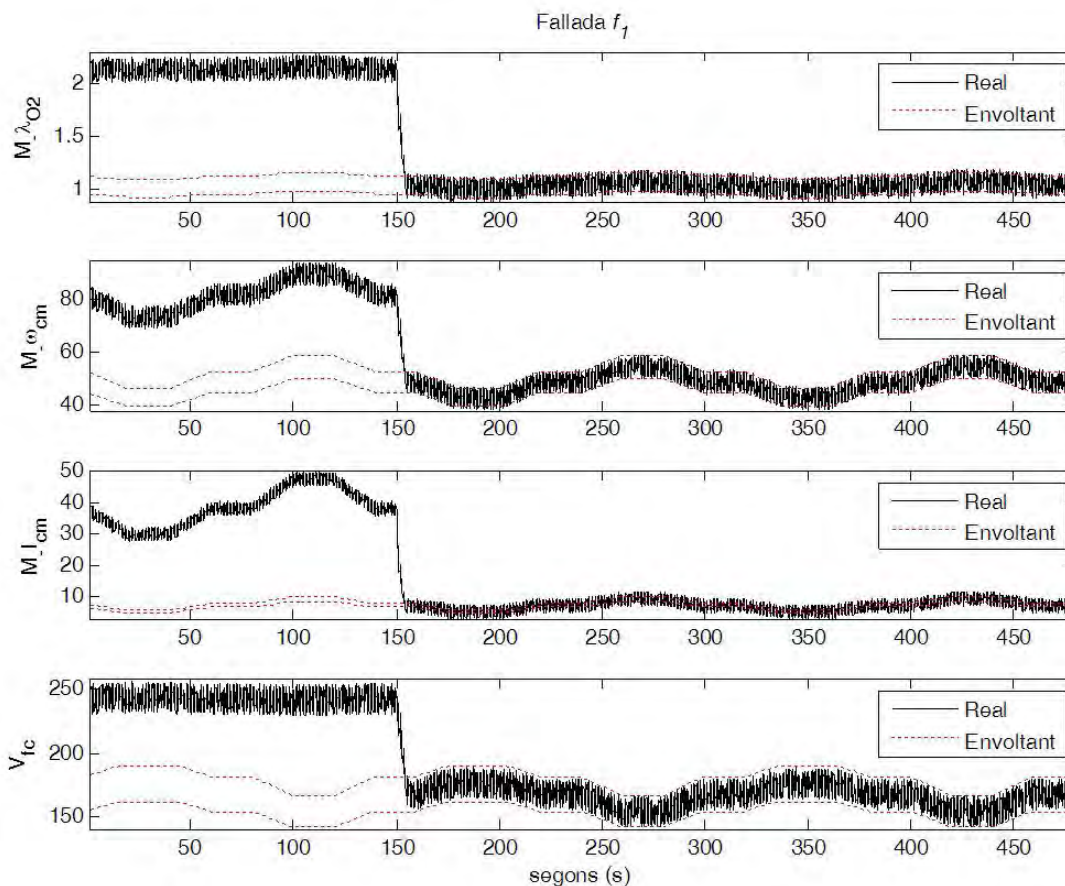


Figura 7-27 Envolupant de la fallada f_1 amb un increment del 8 %, quan s'afegeix als senyals de sortida un soroll del 20 dB.

La taula 7-9 mostra els temps de detecció i diagnòstic que necessita el VisualBlock-FIR per a totes les fallades i els quatre nivells de soroll estudiats, 60, 40, 30 i 20 dB. Si es comparen els resultats de la detecció de les taules 7-8 i 7-9, es veu fàcilment que el temps de detecció, quan s'afegeix un soroll de 60 dB i 50 dB al senyal, és gairebé el mateix que el temps de detecció que ha necessitat el VisualBlock-FIR quan no hi ha cap soroll en el senyal. Això té sentit, ja que el soroll afegit de 60 dB i 50 dB correspon només a un 0,1 % i un 1 % de soroll afegit als senyals, respectivament. Quan el soroll s'incrementa, el temps que necessita el VisualBlock-FIR per detectar la fallada també s'incrementa. No obstant això, el temps de detecció quan s'afegeix un soroll del 3,5 % i un del 10 % al senyal continua sent acceptable i molt baix si es compara amb els resultats obtinguts en treballs anteriors [60].

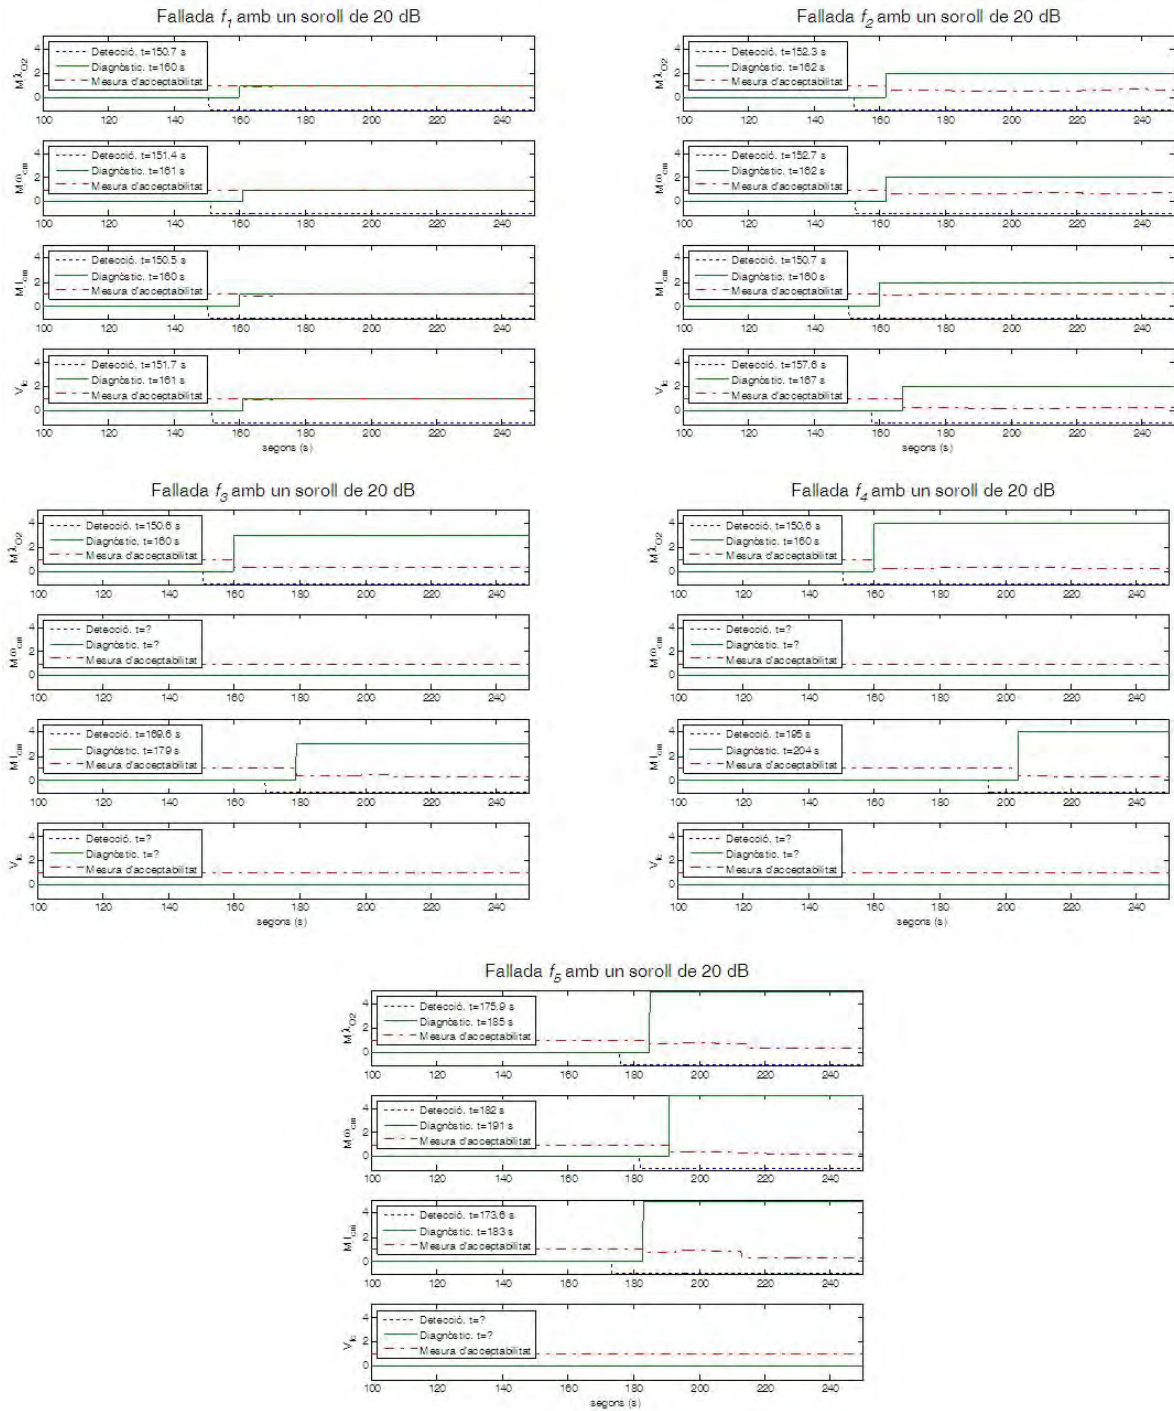


Figura 7-28 Resposta del VisualBlock-FIR FDDS amb un soroll de 20 dB.

Cal dir que quan s'augmenta el percentatge de soroll per sobre de l'1% l'envolupant del senyal també s'incrementa d'un determinat percentatge (tercera columna de la taula 7-9). S'ha de recordar que les dades utilitzades per trobar els models no contenen soroll i, per tant, els envolupants segueixen sent tant estrets com es mostrava en l'apartat 7.3. La figura 7-27 mostra les envolupants del senyal obtingudes per a la fallada f_1 quan s'afegeix al senyal de sortida un increment de 20 dB. En aquest cas, el percentatge d'increment de l'envolupant és del 8 %, cosa que permet fer la detecció i el diagnòstic.

Si es comparen els resultats del diagnòstic de les dues taules, 7-8 i 7-9, s'observa que el temps del diagnòstic augmenta de 6 a 10 segons, quan s'afegeix el soroll als senyals de sortida. Això es deu al fet que la finestra de temps d'identificació ha augmentat de 6 a 10 segons, tal com s'ha explicat anteriorment, amb la finalitat d'obtenir un bon rendiment del diagnòstic. Per tant, no és possible identificar les fallades en menys d'aquest temps. No obstant això, els temps d'identificació obtinguts per a totes les fallades són realment molt bons i, sens dubte, menors que els temps reportats per altres mètodes [60] per a la mateixa aplicació.

A la figura 7-28 es mostra la resposta de les cinc fallades de l'FDDS del VisualBlock-FIR quan s'afegeix una pertorbació als senyals de sortida del sistema de 20 dB.

7.5 Conclusions

En aquest capítol es demostra, amb les dues aplicacions proposades: el simulador de la vàlvula industrial controlada amb un servomotor pneumàtic (DAMADICS) i el simulador del sistema de generació d'energia basat en cel·les de combustible, que el VisualBlock-FIR funciona molt bé, de manera que detecta i diagnostica les fallades molt ràpidament.

En l'apartat 7.2 s'apliquen els processos de detecció i diagnòstic per fer front a les fallades del problema de referència DAMADICS. Es detecten amb molta precisió quatre fallades diferents de la part del servomotor pneumàtic, del control de la vàlvula i de la tija del posicionador. Aquestes fallades s'han escollit amb l'objectiu de fer comparacions fiables entre el VisualBlock-FIR i la metodologia basada en els observadors d'interval presentada en el treball de [118]. Els resultats mostren que el VisualBlock-FIR és capaç de detectar més ràpidament i amb més precisió el conjunt de fallades estudiades amb un temps de detecció inferior a un segon en tots els casos menys en la fallada f_{1s} . El diagnòstic no s'ha pogut comparar amb els models passius basats en els observadors d'interval perquè aquesta metodologia no du a terme la tasca de diagnòstic per a aquesta aplicació. El diagnòstic en el VisualBlock-FIR es compara amb els resultats obtinguts per un observador de múltiples models neurodifús (NFMM), un observador ampliat d'entrades desconegudes amb programació genètica (EUIO-GP, de l'anglès *extended unknown input observer with genetic programming*) (i una aproximació basada en el raonament qualitatiu juntament amb xarxes neuronals difuses (QRFNN, de l'anglès *approach based on qualitative reasoning coupled with fuzzy neural networks*). Tanmateix, les comparacions no són completes, ja que cada treball de recerca treballa amb un subconjunt diferent de fallades. No obstant això, es pot veure que el VisualBlock-FIR desenvolupa la tasca de diagnòstic de manera similar a l'NFMM, i ambdós mètodes presenten un millor rendiment que l'EUIO-GP i el QRFNN.

En l'apartat 7.3 s'aplica l'FDDS del VisualBlock-FIR a un sistema de piles de combustible. En aquest cas, s'estudien cinc fallades: l'augment de la fricció al motor del compressor, quan el motor del compressor pateix un sobreescalfament, un augment de la resistència al flux d'aigua a causa del bloqueig

dels canals o per un desbordament a la capa de difusió, una fuga d'aire al col·lector d'alimentació i, finalment, un augment del valor de la tensió per sota del qual el motor del compressor no respon. Durant les primeres quatre fallades s'aconsegueix un temps de detecció de menys d'un segon i mig i s'obté un diagnòstic correcte en menys de 7 segons. La detecció de fallades i la identificació de l'última fallada és més difícil a causa del comportament similar de les variables de sortida de la velocitat del compressor, ω_{cm} , i la tensió de la pila, V_{fc} , amb el senyal de la planta quan funciona correctament. Per a aquesta fallada, els temps de detecció se situen entre 22 i 25 segons i els temps d'identificació, entre 28 i 31 segons. Aquests resultats són molt favorables quan es comparen amb els obtinguts per altres FDDS, com ara l'aproximació de la computació de residus [60].

En l'últim apartat s'estudia la solidesa del VisualBlock-FIR mitjançant la incorporació de diferents nivells de soroll als senyals de sortida. Els temps de detecció i de diagnòstic s'incrementen lleugerament amb la presència de soroll. No obstant això, el rendiment segueix sent molt bo per a valors de 60, 40 i 30 dB.

Amb aquestes aplicacions considerem que queda àmpliament demostrat que el VisualBlock-FIR FDDS és una eina efectiva i molt robusta.

8 Conclusions i treball futur

Resum: en aquest últim capítol es presenten les conclusions i les aportacions derivades d'aquesta tesi. En primer lloc, es presenten les conclusions generals i es remarquen les aportacions d'aquest treball. L'apartat següent presenta el resum dels resultats obtinguts en aquesta tesi doctoral i, finalment, es comenten alguns aspectes sobre futurs treballs que segueixen la línia de recerca exposada en aquesta tesi. Per acabar, es fa una llista de totes les contribucions científiques, en forma de publicacions, derivades d'aquesta recerca, així com els projectes de recerca en què s'ha participat durant el desenvolupament de la tesi.

8.1 Conclusions generals i aportacions

L'objectiu principal d'aquesta tesi, tal com s'esmentava en el primer capítol, era reduir tant com fos possible la sensibilitat de la metodologia FIR, és a dir, maximitzar-ne la robustesa, de manera que fos una eina cabdal per desenvolupar una metodologia que permetés crear sistemes de detecció i diagnòstic de fallades (FDDS) robustos i eficients. La conclusió general que s'extreu d'aquesta tesis és que s'ha aconseguit desenvolupar una bona eina per detectar i diagnosticar fallades en sistemes dinàmics complexos. Creiem, doncs, que s'ha assolit l'objectiu principal d'aquesta recerca i això ha estat gràcies a les aportacions específiques següents:

1. El nou mètode *enhanced equal frequency partition* (EEFP) per determinar els *landmarks* associats a cada classe en el procés de discretització de les variables quantitatives.
2. Desenvolupament de la plataforma Visual-FIR. Es tracta d'una eina de MATLAB que permet identificar models FIR i predir comportaments futurs de sistemes dinàmics en un entorn molt eficient i senzill d'utilitzar.
3. Creació de la metodologia FIR Fault Detection and Diagnosis System (FIRFDDS). Aquesta metodologia consisteix a monitorar en temps real la semblança entre el comportament de la planta real i el del model FIR d'aquesta mitjançant la tècnica de detecció desenvolupada anomenada *envelopant*. Per fer el diagnòstic s'estudia la semblança entre el comportament de la planta real i el dels models FIR de les possibles fallades usant la mesura d'acceptabilitat del model, proposada en aquesta recerca.
4. Desenvolupament de la plataforma VisualBlock-FIR. Es tracta d'una eina de MATLAB que consisteix en un conjunt de blocs Simulink que permeten aplicar la metodologia FIRFDDS d'una manera senzilla i amigable.
5. Estudi de la robustesa del FIRFDDS davant de la presència de soroll. Es comprova que la metodologia proposada en aquesta tesi és capaç de fer front a les perturbacions que hi ha en els

senyals que provenen d'una planta real, mitjançant la inclusió de soroll blanc en una aplicació industrial.

8.2 Resum dels resultats obtinguts

En aquest apartat es resumeixen els resultats obtinguts en aquesta tesi doctoral, capítol per capítol.

En el capítol 3 es descriu la metodologia del raonament inductiu difús en detall, fent èmfasi en el seu origen, que parteix de la *general systems theory*, en general, i del *general systems problem solver* definit per Klir, en particular. En aquest capítol es presenta una millora del mètode de partició de variables *equal frequency partition*, que és un mètode no supervisat molt simple i àmpliament utilitzat. El nou mètode, anomenat *enhanced equal frequency partition*, permet reduir, en certa mesura, la dependència en la distribució de les dades

En el capítol 4 es presenta l'aportació metodològica principal d'aquesta tesi, que és la base per dissenyar sistemes de detecció i diagnòstic de fallades basats en FIR. El FIRFDDS és capaç de detectar i diagnosticar les anomalies de desenvolupament que es poden considerar fallades o canvis estructurals, depenent del sistema dinàmic monitorat. Es presenta una nova tècnica de detecció basada en l'envolupant del senyal de predicció de FIR i, a més a més, es proporciona una mesura d'acceptabilitat del model per determinar la qualitat del diagnòstic que es duu a terme. Es presenten alguns exemples pràctics del funcionament del FIRFDDS per demostrar la viabilitat i l'eficiència de la metodologia proposada.

En el capítol 5 es presenta una de les eines desenvolupades en aquesta tesi, el Visual-FIR, que permet identificar models de sistemes dinàmics i simular-los en un entorn senzill i amigable. El Visual-FIR ofereix una implementació d'alta eficiència i presenta una nova visió de la metodologia basada en blocs de processos. A més, afegeix noves característiques que permeten augmentar les capacitats generals de la metodologia FIR i reduir-ne la sensibilitat. Es demostra que és fàcil d'emprar i que funciona bé, amb el problema de referència DAMADICS.

En el capítol 6 es presenta la segona eina desenvolupada en aquesta tesi, el VisualBlock-FIR, que permet crear sistemes de detecció i diagnòstic de fallades basats en la metodologia proposada en el capítol 4 d'aquesta tesi, de manera senzilla i amigable. El VisualBlock-FIR proporciona una llibreria de blocs a l'usuari que li permetran fer simulacions en temps real de la metodologia FIR, així com definir el propi FIRFDDS per detectar i diagnosticar les fallades del procés que vol monitorar o controlar. És una plataforma molt pràctica i útil, ja que permet construir el sistema de detecció i diagnòstic de fallades de la planta en estudi com si es tractés del muntatge d'un *lego* en què cada peça té una funció específica i només cal anar ajuntant les peces de manera adient.

En el capítol 7 es posa a prova la metodologia de detecció i diagnòstic de fallades proposada en aquesta tesi, així com les plataformes Visual-FIR i VisualBlock-FIR, mitjançant dues aplicacions concebudes per a aquest propòsit: una pila de combustible i el problema de referència DAMADICS. Els resultats que

s'aconsegueixen són molt bons si es comparen amb altres aproximacions i es demostra que és una bona eina per tractar les fallades dels sistemes industrials complexos. També es posa a prova la robustesa del FIRFDDS afegint soroll blanc als senyals de sortida del sistema, de manera que s'aconsegueix un rendiment elevat.

8.3 Treball futur

Resoldre diversos problemes que encara no s'han solucionat permetria millorar el FIRFDDS. Aquestes millores es comenten a continuació:

- Tot i que la capacitat de computació actualment és molt gran, ja que el maquinari de computació està molt desenvolupat i l'entorn de programació de MATLAB permet fer una gran quantitat de càlculs, l'aplicabilitat de la predicció de totes les estructures de fallades per l'FDDS queda limitada pel nombre de models qualitius que es poden calcular en paral·lel. Una solució podria ser agrupar fallades relacionades en un sol model per representar el comportament de més d'una fallada.
- Una altra possible millora seria que s'aconguís automatitzar l'ajust dels paràmetres del FIRFDDS. La configuració de l'FDDS es basa a definir la grandària de les finestres de detecció i la de diagnòstic, així com la quantitat de valors que han de quedar fora de l'envolupant, dins de la finestra de detecció, per considerar que ha tingut lloc una fallada. Actualment, l'ajust d'aquests paràmetres es fa de manera heurística, amb l'ajut d'un expert que analitza els senyals de sortida de la planta o pel mètode de prova i error.
- La metodologia aplicada només pot diagnosticar les fallades si la sortida resultant s'assembla a alguna sortida del bloc de predicció de la llibreria de models de fallada. Si no s'assembla a cap dels senyals predits, només pot dir que està detectant una fallada però no la pot identificar. Aquesta situació es dona en dos casos diferents, quan la fallada real no es correspon amb cap de les previstes o quan s'esdevenen dues fallades o més de manera simultània. El primer cas és difícil de resoldre si no es disposa d'informació addicional. Pel que fa al segon cas, una possible solució és obtenir la predicció de la combinació de diferents fallades de la llibreria.
- Una altra situació consisteix a determinar la tendència d'una fallada. És sabut que hi ha moltes fallades que no tenen lloc de cop, sinó que es van desenvolupant molt a poc a poc, com, per exemple, el desgast d'una peça, la sedimentació, etc. En aquests casos, en el moment en què es detectés que ha tingut lloc una fallada, seria molt útil disposar d'una tècnica per predir la tendència del senyal avaluada, de manera que permetés determinar el temps que trigarà a assolir un límit determinat, fet que es coneix amb el nom de *temps de vida útil*.
- Un altre punt interessant en què cal treballar és què passa quan hi ha més d'un model de sortida del sistema i el FIRFDDS diagnostica per a cadascun fallades diferents. Faltaria un bloc que fos capaç

de recollir la informació dels diferents FDDS i que proporcionés una sortida única informant sobre quina és la fallada més probable. Aquest és el cas de l'aplicació de la pila de combustible utilitzada en aquesta tesi, que té quatre sortides, però en cap dels casos considerats no s'ha donat la situació que es diagnosticuessin fallades diferents, només hi ha hagut casos en què un dels quatre models ha identificat correctament la fallada mentre que els altres no l'han detectada.

- Finalment, cal comentar, que, a causa de la situació econòmica actual i de les conseqüències que se'n deriven, cada vegada serà més difícil disposar d'entorns de programació de pagament; per tant, seria interessant desenvolupar la metodologia presentada en un entorn de programació lliure. Concretament, s'ha pensat que un entorn podria ser Scilab. Scilab és un llenguatge de programació d'alt nivell per al càlcul científic de lliure distribució. Està disponible en múltiples sistemes operatius i ha estat desenvolupat per l'Institut National de Recherche en Informatique et Automatique (INRIA) i l'École Nationale des Ponts et Chaussées (ENPC) des del 1990. Actualment, és una eina molt potent i permet fer quasi el mateix que MATLAB.

Tot i que queden aspectes que encara no s'han abordat, estem molt entusiasmats amb les possibilitats de l'enfocament triat. Creiem fermament que la metodologia FIR ofereix grans oportunitats per fer front a una sèrie de temes *candents* de la intel·ligència artificial aplicada, temes difícils que, fins ara, altres metodologies no han estat capaces de dominar. És per això que l'esforç de recerca continuarà.

8.4 Contribucions científiques

Fins ara aquesta recerca ha proporcionat diverses contribucions d'interès per a la comunitat científica. A continuació, es presenten les publicacions que s'han dut a terme.

8.4.1 Articles en revistes internacionals indexades

- Escobet, A.; Nebot, A.; Cellier, F. "Fault diagnosis system based on fuzzy logic: application to a valve actuator benchmark". *Journal of Intelligent and Fuzzy Systems*, 2011, vol. 22, núm. 4, p. 155-171. <doi: 10.3233/IFS-2011-0473>
- Escobet, A.; Nebot, A.; Cellier, F. "Visual-FIR: A tool for model identification and prediction of dynamical complex systems". *Simulation Modelling Practice and Theory*, 2008, vol. 16, núm. 1, p. 76-92. ISSN 1569-190X
- Nebot, A. ; Mugica, V; Escobet, A. "Ozone prediction based on meteorological variables: a fuzzy inductive reasoning approach". *Atmospheric Chemistry and Physics Discussions*, 2008, p. 12343-12370, <http://www.atmos-chem-phys-discuss.net/8/12343/2008/acpd-8-12343-2008.html>
- Escobet, A.; Nebot, A.; Cellier, F. "VisualBlock-FIR for fault detection and identification: Application to the DAMADICS benchmark problem". *Lecture Notes in Computer Science*, 2007,

vol. 4827, p. 1173-1183. ISSN 0302-9743

- Escobet, A.; Nebot, A.; Cellier, F. “Fault detection and identification using FIRFMS”. *International Journal of General Systems*, 2007, vol. 36, núm. 3, p. 347-374. ISSN 0308-1079

L'article següent està en procés de revisió:

- Escobet, A.; Nebot, A.; Mugica, F. “Fuzzy fault diagnosis in fuel cell power systems”. *Journal of Energy Engineering -ASCE* 2012, en procés de revisió.

8.4.2 Articles en congressos internacionals

- Escobet, A.; Nebot, A.; Mugica, F. “Robust fault detection and identification in a fuel cell system via fuzzy models”. *Proceedings CSCS-18: 18th International Conference on Control Systems and Computer Science*, p. 150-257, maig 2011, ISBN 2066-4451
- Escobet, A.; Nebot, A. “Fault detection and identification in a fuel cell system”. *Artificial Intelligence Research and Development: Proceedings of the 12th International Conference of the Catalan Association for Artificial Intelligence*, p. 399-408, octubre 2009, ISBN 0922-6389
- Nebot, A.; Mugica, V.; Escobet, A. “Modeling ozone behavior during MILAGRO campaign applying fuzzy techniques”. *Proceedings of the Second MILAGRO Science Conference (digital)*, México DF, 2007
- Escobet, A.; Nebot, A.; Cellier, F. “Visual-FIR: A new platform for modelling and prediction of dynamical systems”. *Proceedings of the 2004 Summer Computer Simulation Conference*, p. 229-234. San Jose, Califòrnia, A. G. (ed.), 2004.
- Escobet, A.; Huber, R.; Nebot, A.; Cellier, F. “Enhanced equal frequency partition method for the identification of a water demand system”. *Proceedings of the 2000 AI, Simulation and Planning in High Autonomy Systems Conference*, p. 209-215, Tucson, 2000, ISBN 1-56555-194-XX
- Jensen, E.; Escobet, A.; Nebot, A.; Caminal, P. “Definition of a depth of anaesthesia index using fuzzy inductive reasoning”. *Proceedings of the First Joint BMES/EMBS Conference: Serving Humanity Advancing Technology*, p. 920-920, Atlanta, 1999, IEEE, ISBN 780356748
- Escobet, A.; Nebot, A.; Cellier, F. “Model acceptability measure for the identification of failures in qualitative fault monitoring systems”. *Proceedings of the 13th European Simulation Multiconference ICQFN99*, p. 339-347. Szczerbicka, H. (ed.) Society for Computer Simulation, Warsaw, 1999, ISBN 1-56555-172-9
- Escobet, A.; Nebot, A.; Vallverdú, M. “A qualitative fault monitoring system to support medical decisions: an application to the central nervous system”. *Proceedings of the ICSC Congress on Computational Intelligence Methods and Applications. International Symposia on Soft Computing*

in Biomedicine, p. 536-542, ICSC, NY, 1999, ISBN 3-906454-18-5

8.4.3 Reports de recerca

- Escobet, A.; Nebot, A. “Detecció de fallades en un sistema de piles de combustible”, report de recerca LSI-10-1-R, Departament de Llenguatges i Sistemes Informàtics, Universitat Politècnica de Catalunya, Barcelona, febrer de 2010.
- Nebot, A.; Mugica, V.; Escobet, A. “Visual-FIR for ozone modeling and prediction”, report de recerca LSI-07-17-R, Departament de Llenguatges i Sistemes Informàtics, Universitat Politècnica de Catalunya, Barcelona, abril de 2007.
- Escobet, A.; Nebot, A. “Detecció i identificació de falles en una xarxa de distribució d'aigües”, report de recerca LSI-01-20-R, Departament de Llenguatges i Sistemes Informàtics, Universitat Politècnica de Catalunya, Barcelona, febrer de 2001.
- Escobet, A.; Mirats, J. M. “Model quantitatiu i qualitatiu d'un dipòsit d'aigua: estudi comparat”, report de recerca IRI-Dt-9702, Institut de Robòtica i Informàtica Industrial, Universitat Politècnica de Catalunya, Barcelona, 1997.
- Escobet, A.; Mirats, J. M. “Model quantitatiu i qualitatiu d'un motor de corrent continu: estudi comparatiu”, report de recerca IRI-Dt-9703, Institut de Robòtica i Informàtica Industrial, Universitat Politècnica de Catalunya, Barcelona, 1997.

8.4.4 Participació en projectes de recerca

Aquesta tesi s'ha desenvolupat en el marc dels projectes de recerca següents:

- Investigador principal: Dr. Joseba Quevedo. Títol: “System Health Management and Reliable Control of Complex Systems (SHERECS)”, Comissió Interministerial de Ciència i Tecnologia (CICYT DPI2011-26243). Entitat participant: Departament d'Enginyeria de Sistemes, Automàtics i Informàtica Industrial, Universitat Politècnica de Catalunya, Barcelona. Duració, des del 2012 fins al 2015. Pressupost: 336.380,00 €
- Investigadora principal: Dra. Gabriela Cembrano. Títol: “Análisis y diseño de estrategias de control óptimo distribuido aplicadas a la gestión de sistemas de agua de gran escala (WATMAN)”, Comissió Interministerial de Ciència i Tecnologia (CICYT DPI2009-13744). Entitat participant: Departament d'Enginyeria de Sistemes, Automàtics i Informàtica Industrial, Universitat Politècnica de Catalunya, Barcelona. Duració, des del 2010 fins al 2013. Pressupost: 196.020,00 €
- Investigador principal: Dr. Alfredo Vellido. Títol: “Diseño de un sistema de apoyo a la decisión en Oncología clínica basado en métodos avanzados de *soft computing*”, Comissió Interministerial de Ciència i Tecnologia (CICYT TIN2006-08114). Entitat participant: Departament de Llenguatges i

Sistemes Informàtics, Universitat Politècnica de Catalunya, Barcelona. Duració, des del 2006 fins al 2009. Pressupost: 133.100 €

- Investigadora principal: Dra. Àngela Nebot. Títol: “Metodologías híbridas de *soft computing* y su aplicación a la detección de anomalías en estaciones depuradoras de aguas residuales ”, Comissió Interministerial de Ciència i Tecnologia (CICYT DPI2002-03225). Entitat participant: Universitat Politècnica de Catalunya, Barcelona. Duració, des del 2002 fins al 2005. Pressupost: 120.830 €
- Investigadora principal: Dra. Àngela Nebot. Títol: “Metodologías híbridas para el análisis de fallos en sistemas dinámicos complejos”, Comissió Interministerial de Ciència i Tecnologia (CICYT TAP99-0747). Entitat participant: Universitat Politècnica de Catalunya, Barcelona. Duració, des del 1999 fins al 2002. Pressupost: 80.102,9 €
- Investigador principal: Dr. Rafael M. Huber. Títol: “Seguridad de funcionamiento en sistemas dinámicos”, Comissió Interministerial de Ciència i Tecnologia (CICYT TAP96-0882). Entitat participant: Universitat Politècnica de Catalunya, Barcelona. Duració, des del 1996 fins al 1999.

9 Bibliografía

- [1] KEEL, *Knowledge Extraction based on Evolutionary Learning*. <http://www.keel.es/> ed. 2009.
- [2] DAMADICS. <http://diag.mchtr.pw.edu.pl/damadics/> ed. 2002.
- [3] Fuzzy Logic Toolbox. <http://www.mathworks.com/products/fuzzylogic/> ed.
- [4] FuzzyTECH. <http://www.fuzzytech.com/> ed.
- [5] FLINT toolkit. <http://www.lpa.co.uk/fln.htm> ed.
- [6] FuzzyCLIPS. http://ai.iit.nrc.ca/IR_public/fuzzy/ ed.
- [7] FIDE. <http://www.aptronix.com/fide/whatfide.htm> ed.
- [8] ACOSTA, J., NEBOT, A. and FUERTES, J.M.; Aprendizaje de particiones difusas para razonamiento inductivo. Barcelona: Universitat Politècnica de Catalunya, 2006. 293 p.
- [9] ALCALÁ-FDEZ, J., SÁNCHEZ, L., GARCÍA, S., DEL JESUS, M.J., VENTURA, S., GARRELL, J.M., OTERO, J., ROMERO, C., BACARDIT, J., RIVAS, V.M. FERNÁNDEZ, L.C. and HERRERA, F.; KEEL: a software tool to assess evolutionary algorithms for data mining problems. *Soft Computing-A Fusion of Foundations, Methodologies and Applications* 2009, vol. 13, nº 3, p. 307-318.
- [10] ALCORTA GARCIA, E. and FRANK, PM.; Deterministic nonlinear observer-based approaches to fault diagnosis: a survey. *Control Engineering Practice* 1997, vol. 5, nº 5, p. 663-670.
- [11] ALEXANDRES GARCÍA, MG.; Arquitectura tolerante a fallos basada en agentes inteligentes para el control de un robot móvil. 2007.
- [12] ANDERBERG, M. R.; Cluster analysis for applications. Academic press New York, 1973.
- [13] ARMENGOL, J., TRAVÉ, L., VEHÍ, J. and DE LA ROSA, J.; A survey on interval model simulators and their properties related to fault detection. *Annual reviews in control* 2000, vol. 24, p. 31-39.
- [14] ASHBY, WR.; An introduction to cybernetics. Chapman & Hall London, 1956.
- [15] BASSEVILLE, M. and NIKIFOROV, I.V.; Detection of abrupt changes: theory and application. Prentice-Hall, Inc., 1993.
- [16] BEZDEK, J. C. and EHRlich, R.; FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences* 1984, vol. 10, nº 2-3, p. 191-203.

- [17] BLANKE, M., FREI, C.W., KRAUS, F., PATTON, R.J. and STAROSWIECKI, M.; What is fault-tolerant control? In Preprints of 4th IFAC Symposium on Fault Detection Supervision and Safety for Technical Processes, SAFEPROCESS'2000, pages 40-51, Budapest, Hungria, 2000.
- [18] BLÁZQUEZ, L. F. and DE MIGUEL, L. J.; Diagnóstico automático de fallos para sistemas dinámicos no lineales. *Reporte de Investigación, Dpto.Ingeniería de Sistemas y Automática, Universidad de Valladolid, España., url: www.ceaiifac.es/actividades/jornadas/XXIV/documentos/.../78.pdf* 1999.
- [19] BOULDING, K. E.; General systems theory-the skeleton of science. *Management science* 1956, vol. 2, nº 3, p. 197-208.
- [20] BOULLART, L., KRIJGSMAN, A. and VINGERHOEDS, R.; Application of artificial intelligence in process control: lecture notes Erasmus intensive course. Pergamon Press, Oxford, 1992.
- [21] CALADO, J.M.F., SÁ DA COSTA, J.M.G., BARTYS, M. and KORBICZ, J.; FDI approach to the DAMADICS benchmark problem based on qualitative reasoning coupled with fuzzy neural networks. *Control Engineering Practice* 2006, vol. 14, nº 6, p. 685-698.
- [22] CARVAJAL, R. and NEBOT, A.; Growth model for white shrimp in semi-intensive farming using inductive reasoning methodology. *Computers and Electronics in Agriculture* 1998, vol. 19, nº 2, p. 187-210.
- [23] CASTILLO, I., EDGAR, T.F. and DUNIA, R.; Nonlinear model-based fault detection with fuzzy set fault isolation. IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society, 2010. p. 174-179.
- [24] CASTILLO-TOLEDO, B., DI GENNARO, S. and ANZUREZ-MARIN, J.; On the fault diagnosis problem for non-linear systems: A fuzzy sliding-mode observer approach 1. *Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology* 2009, vol. 20, nº 4, 5, p. 187-199.
- [25] CAYRAC, D., DUBOIS, D. and PRADE, H.; Handling uncertainty with possibility theory and fuzzy sets in a satellite fault diagnosis application. *Fuzzy Systems, IEEE Transactions on* 1996, vol. 4, nº 3, p. 251-269.
- [26] CAZORLA, M.A., COLOMINA, O., ESCOLANO, F., GALLARDO, D., RIZO, R. and SATORRE, R.; Laboratorio de Inteligencia Artificial. *Publicaciones de la Universidad de Alicante* 1998.
- [27] CELLIER, F. E., LÓPEZ, J., NEBOT, À. and CEMBRANO, G.; Confidence measures for predictions in fuzzy inductive reasoning. *International journal of general systems* 2010, vol. 39, nº 8, p. 839-853.
- [28] CELLIER, F. E., NEBOT, À., MUGICA, F. and DE ALBORNOZ, Á.; Combined qualitative/quantitative simulation models of continuous-time processes using fuzzy inductive reasoning techniques. *International Journal of General Systems* 1996, vol. 24, nº 1, p. 95-116.
- [29] CELLIER, FE.; Continuous system modeling. Anonymous Anonymous revised by Anonymous Springer, 1991.
- [30] CELLIER, F. E. and YANDELL, D. W.; SAPS-II: a new implementation of the systems approach problem solver. *International journal of general systems* 1987, vol. 13, nº 4, p. 307-322.

-
- [31] CHAN, C.W., HONG JIN, CHEUNG, K.C. and ZHANG, H.Y.; Fault detection of systems with redundant sensors using constrained Kohonen networks. *Automatica* 2001, vol. 37, n° 10, p. 1671-1676.
- [32] CHEN, J., ROBERTS, C. and WESTON, P.; Fault detection and diagnosis for railway track circuits using neuro-fuzzy systems. *Control Engineering Practice* 2008, vol. 16, n° 5, p. 585-596.
- [33] CHEN, J. and PATTON, R. J.; Robust model-based fault diagnosis for dynamic systems. 1999.
- [34] CLARK, R.; State estimation schemes for instrument fault detection. In PATTON, R, FRANK, P and CLARK, R. *Fault Diagnosis in Dynamic Systems - Theory and applications*. London: Prentice Hall, 1989. p. 21-45.
- [35] CLARK, RN.; A simplified instrument failure detection scheme. *Aerospace and Electronic Systems, IEEE Transactions on* 1978, n° 4, p. 558-563.
- [36] DAVIS, R and HAMSCHER, W.C.; Model-Based Reasoning: Troubleshooting. DTIC Document, 1988.
- [37] DE ALBORNOZ,; A. Inductive reasoning and reconstruction analysis: two complementary tools for qualitative fault monitoring of large-scale systems. PhD Thesis, UPC, Barcelona, 1996.
- [38] DE KLEER, J. and WILLIAMS, B. C.; Diagnosing multiple faults. *Artificial Intelligence* 1987, vol. 32, n° 1, p. 97-130.
- [39] DE KLEER, J. and BROWN, J. S.; A qualitative physics based on confluences. *Artificial Intelligence* 1984, vol. 24, n° 1-3, p. 7-83.
- [40] DE MIGUEL, L. J. and BLÁZQUEZ, L. F.; Fuzzy logic-based decision-making for fault diagnosis in a DC motor. *Engineering Applications of Artificial Intelligence* 2005, vol. 18, n° 4, p. 423-450.
- [41] DING, S.X.; Model-based fault diagnosis techniques: Design schemes, Algorithms, and Tools. Springer Verlag, 2008.
- [42] DU, Z., JIN, X. and YANG, Y.; Fault diagnosis for temperature, flow rate and pressure sensors in VAV systems using wavelet neural network. *Applied Energy* 2009, vol. 86, n° 9, p. 1624-1631.
- [43] ELMQVIST, H.; Dymola–dynamic modeling language–user’s manual v 6.0. *Dynasim AB, Lund, Sweden* 2006.
- [44] ESCOBET, A., NEBOT, À. and CELLIER, F. E.; Fault diagnosis system based on fuzzy logic: Application to a valve actuator benchmark. *Journal of Intelligent and Fuzzy Systems* 2011, vol. 22, n° 4, p. 155-171.
- [45] ESCOBET, A., NEBOT, À. and MUGICA, F.; Robust Fault Detection and Identification in a Fuel Cell System via Fuzzy Models. Bucarest (Rumania) ed. Proceedings of the 18th International Conference on Control Systems and Computer Science, 2011. 250-257 p. ISBN 2066-4451.
- [46] ESCOBET, A. and NEBOT, À.; Detecció de fallades en un sistema de Piles de Combustible. Vol. LSI-10-1-R. 2010. p. 1-39.
- [47] ESCOBET, A. and NEBOT, À.; Fault Detection and Identification in a Fuel Cell System. IOS Press, 2009. p. 399-408.

- [48] ESCOBET, A., NEBOT, À. and CELLIER, F. E.; Visual-FIR: A tool for model identification and prediction of dynamical complex systems. *Simulation Modelling Practice and Theory*, 1 2008, vol. 16, n° 1, p. 76-92.
- [49] ESCOBET, A., NEBOT, A. and CELLIER, F.; Fault detection and identification using FIRFMS. *International Journal of General Systems* 2007, vol. 36, n° 3, p. 347-374.
- [50] ESCOBET, A., NEBOT, A. and CELLIER, F. E.; VisualBlock-FIR for Fault Detection and Identification: Application to the DAMADICS Benchmark Problem. *Lecture Notes in Computer Science* 2007, vol. 4827, p. 1173-1183.
- [51] ESCOBET, A., NEBOT, A. and CELLIER, F. E.; Visual-FIR: A new platform for modeling and prediction of dynamical Systems. *SIMULATION SERIES* 2004, vol. 36, n° 4, p. 229-234.
- [52] ESCOBET, A. and NEBOT, À. Detecció i identificació de falles en una xarxa de distribució d'aigües. Vol. LSI-01-20-R. Report intern. Universitat Politècnica de Catalunya, 2001.
- [53] ESCOBET, A., HUBER, R.M., NEBOT, À. and CELLIER, F.E.; Enhanced Equal Frequency Partition Method for the Identification of a Water Demand System. 2000. p. 209-215.
- [54] ESCOBET, A., NEBOT, A. and CELLIER, F.E. Model Acceptability Measure for the Identification of Failures in Qualitative Fault Monitoring Systems. Citeseer, 1999. p. 339-347.
- [55] ESCOBET, A., NEBOT, A. and VALLVERDU, A.; A Qualitative Fault Monitoring System to Support Medical Decisions: An Application to the Central Nervous System. In Proc. of the SCB'99, International ICSC Symposium on Soft Computing in Biomedicine, Rochester, NY. 1999. p. 536-542.
- [56] ESCOBET, T., FEROLDI, D., DE LIRA, S., PUIG, V., QUEVEDO, J., RIERA, J. and SERRA, M.; Model-based fault diagnosis in PEM fuel cell systems. *Journal of Power Sources* 2009, vol. 192, n° 1, p. 216-223.
- [57] ESTRADA-FLORES, S., MERTS, I., DE KETELAERE, B. and LAMMERTYN, J.; Development and validation of “grey-box” models for refrigeration applications: A review of key concepts. *International Journal of Refrigeration* 2006, vol. 29, n° 6, p. 931-946.
- [58] FAGARASAN, I., PLOIX, S. and GENTIL, S.; Causal fault detection and isolation based on a set-membership approach. *Automatica* 2004, vol. 40, n° 12, p. 2099-2110.
- [59] FEKIH, A., XU, H. and CHOWDHURY, F.; Neural networks based system identification techniques for model based fault detection of nonlinear systems. *International Journal of Innovative Computing, Information and Control* 2007, vol. 3, n° 5, p. 1073-1085.
- [60] FEROLDI, D., SERRA, M. and RIERA, J.; Performance improvement of a PEMFC system controlling the cathode outlet air flow. *Journal of Power Sources* 2007, vol. 169, n° 1, p. 205-212.
- [61] GARCÍA, F. J., IZQUIERDO, V., DE MIGUEL, L.J. and PERÁN, J.R.; Fault-diagnostic system using analytical fuzzy redundancy. *Engineering Applications of Artificial Intelligence* 2000, vol. 13, n° 4, p. 441-450.
- [62] GEFEN, D. and STRAUB, D.; A Practical guide to factorial validity using PLS-graph: Tutorial and annotated example. *Communications of the Association for Information Systems* 2005, vol. 16, n° 1, Article 5.

- [63] GERTLER, J. and CAO, J.; Design of optimal structured residuals from partial principal component models for fault diagnosis in linear systems. *Journal of Process Control* 2005, vol. 15, n° 5, p. 585-603.
- [64] GERTLER, J.; Fault detection and diagnosis in engineering systems. CRC, 1998.
- [65] GERTLER, J.; Fault detection and isolation using parity relations. *Control Engineering Practice* 1997, vol. 5, n° 5, p. 653-661.
- [66] GOMM, J., WILLIAMS, D. and HARRIS, P.; Detection of Incipient Process Faults using Approximate Parametric Models. Vol. 8. Oxford Pergamon Press, 1993. p. 25-30.
- [67] GRECO, M.; *WATERNET simulation users manual*. Technical report WATERNET Project, ESPRIT-IV No. 22186. 1997.
- [68] HE, Q. P., QIN, S. J. and WANG, J.; A new fault diagnosis method using fault directions in Fisher discriminant analysis. *AIChE Journal* 2005, vol. 51, n° 2, p. 555-571.
- [69] HIMMELBLAU, D.M.; Fault detection and diagnosis in chemical and petrochemical processes. Elsevier Scientific Pub. Co., 1978.
- [70] ISERMANN, R.; Fault-diagnosis systems: an introduction from fault detection to fault tolerance. Springer Verlag, 2006.
- [71] ISERMANN, R.; Model-based fault-detection and diagnosis-status and applications. *Annual Reviews in control* 2005, vol. 29, n° 1, p. 71-85.
- [72] ISERMANN, R.; On fuzzy logic applications for automatic control, supervision, and fault diagnosis. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on* 1998, vol. 28, n° 2, p. 221-235.
- [73] ISERMANN, R.; Supervision, fault-detection and fault-diagnosis methods--an introduction. *Control Engineering Practice* 1997, vol. 5, n° 5, p. 639-652.
- [74] ISERMANN, R. and BALLE, P.; Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice* 1997, vol. 5, n° 5, p. 709-719.
- [75] ISERMANN, R.; Fault diagnosis of machines via parameter estimation and knowledge processing--Tutorial paper. *Automatica* 1993, vol. 29, n° 4, p. 815-835.
- [76] JANG, J. S. R.; ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on systems, man and cybernetics* 1993, vol. 23, n° 3, p. 665-685.
- [77] JENSEN, E., ESCOBET, A., NEBOT, À. and CAMINAL, P.; Definition of a depth of anaesthesia index using fuzzy inductive reasoning (FIR). Vol. 2. IEEE, 1999. 920 vol. 2 p.
- [78] JEREZ, T and NEBOT, A.; Genetic algorithms vs. classical search techniques for identification of fuzzy models. Citeseer, 1997. p. 769-773.
- [79] KANDEL, A.; Fuzzy expert systems. CRC Press, Inc. Boca Raton, FL, USA, 1992.
- [80] KAY, H.; SQSIM: a simulator for imprecise ODE models. *Computers & Chemical Engineering* 1998, vol. 23, n° 1, p. 27-46.

- [81] KLIR, G.J. and ELIAS, D.; Architecture of systems problem solving. Plenum Pub Corp, 2003.
- [82] KLIR, G.J.; Applied general systems research: recent developments and trends. Plenum, 1978.
- [83] KLIR, G. J. and KARNOPP, D.; Trends in general system theory. *Journal of Dynamic Systems, Measurement, and Control* 1972, vol. 94, p. 342.
- [84] KLIR, G.J.; An approach to general systems theory. Van Nostrand Reinhold, New York, 1969.
- [85] KORBICZ, J. and WITCZAK, M.; On fault detection under soft computing model uncertainty. In Proc. of 17th World Congress of the International Federation of Automatic Control - IFAC'08 2008. p. 7901-7906.
- [86] KORBICZ, J., KOSCIELNY, J.M. and KOWALCZUK, Z.; Fault diagnosis: models, artificial intelligence, applications. Springer Verlag, 2004.
- [87] KUMAMARU, K., SAGARA, S. and SODERSTROM, T.; Some statistical methods for fault diagnosis for dynamical systems. *Fault Diagnosis in Dynamic Systems-Theory and Applications*, 1989. p. 439-475.
- [88] LAURENTYS, C.A., PALHARES, R.M. and CAMINHAS, W.M.; A novel Artificial Immune System for fault behavior detection. *Expert Systems with Applications* 2011. V. 38, Issue 6, p. 6957-6966.
- [89] LAW, A.M. and KELTON, W.D.; Simulation modeling and analysis. McGraw-Hill New York, 1991.
- [90] LEANING, M.S., PULLEN, H.E., CARSON, E.R. and FINKELSTEIN, L.; Modelling a complex biological system: the human cardiovascular system 1. Methodology and model description. *Transactions of the Institute of Measurement & Control* 1983, vol. 5, n° 2, p. 71-86.
- [91] LI, C. and BISWAS, G.; Finding behavior patterns from temporal data using hidden markov model based unsupervised classification. *Proceedings of the 1999 CIMA: Computational Intelligence Methods and Applications (Rochester, NY, June 22-25)* 1999, p. 266-272.
- [92] LI, D.H. and CELLIER, F.E.; Fuzzy measures in inductive reasoning. IEEE Press, 1990. p. 527-538.
- [93] LI, W., SHAH, S. L. and XIAO, D.; Kalman filters in non-uniformly sampled multirate systems: for FDI and beyond. *Automatica* 2008, vol. 44, n° 1, p. 199-208.
- [94] LIAO, S. H.; Expert system methodologies and applications—a decade review from 1995 to 2004. *Expert Systems with Applications* 2005, vol. 28, n° 1, p. 93-103.
- [95] LINDSKOG, P.; Fuzzy Identification from a Grey Box Modeling. *Fuzzy model identification: Selected approaches* 1997, p. 3-50.
- [96] LÓPEZ, J.; Time Series Prediction Using Inductive Reasoning Techniques. UPC, 1999.
- [97] MANGOUBI, R.S.; Robust estimation and failure detection: A concise treatment. Springer-Verlag New York, Inc., 1998.
- [98] MILLER, W.T., SUTTON, R.S. and WERBOS, P.J.; Neural networks for control. MIT press, 1995.

- [99] MIRATS TUR, J.M.; Qualitative modelling of complex systems by means of fuzzy inductive reasoning. Variable selection and search space reduction. PhD Thesis. Universitat Politècnica de Catalunya, 2001.
- [100] MONTMAIN, J. and GENTIL, S.; Causal modeling for supervision. *Intelligent Control/Intelligent Systems and Semiotics, 1999. Proceedings of the 1999 IEEE International Symposium on*, p.231-236, 1999
- [101] MUGICA, F. Diseño Sistemático de Controladores Difusos Usando Razonamiento Inductivo. Phd Thesis. UPC, 1995.
- [102] NEBOT, À., MUGICA, F., CASTRO, F. and ACOSTA, J.; Genetic fuzzy system for predictive and decision support modelling in e-learning. *Fuzzy Systems (FUZZ), 2010 IEEE International Conference on*, p.1-8, 18-23 July 2010.
- [103] NEBOT, A., MUGICA, V. and ESCOBET, A.; Ozone prediction based on meteorological variables: a fuzzy inductive reasoning approach. *Atmos.Chem.Phys.Discuss* 2008, vol. 8, p. 12343-12370.
- [104] NEBOT, A, MUGICA, F and ESCOBET, A. Modeling ozone behavior during MILAGRO campaign applying fuzzy techniques. Proceedings of the Second MILAGRO Science Conference (digital), Mexico D.F. México, 2007
- [105] NEBOT, A., CELLIER, F. E. and VALLVERDÚ, M.; Mixed quantitative/qualitative modeling and simulation of the cardiovascular system. *Computer methods and programs in biomedicine* 1998, vol. 55, n° 2, p. 127-155.
- [106] NEBOT, A., CELLIER, F. E. and LINKENS, D. A.; Synthesis of an anaesthetic agent administration system using fuzzy inductive reasoning. *Artificial Intelligence in Medicine* 1996, vol. 8, n° 2, p. 147-166.
- [107] NEBOT, A.; Qualitative modeling and simulation of biomedical systems using fuzzy inductive reasoning. PhD Thesis. Barcelona: Llenguatges i Sistemes Informàtics, Universitat Politècnica de Catalunya, 1994.
- [108] OLIVEIRA, A.R.C. and SÁ DA COSTA, J.M.G.; Hierarchic Fault Diagnosis by Pattern-Recognition Approaches Applied to DAMADICS Benchmark. Vol. 18. 2011. p. 7737-7742.
- [109] ORCHARD, RA.; FuzzyCLIPS Version 6.04 A User's Guide. ERB-1054, National Research Council of Canada, 1998.
- [110] ORCHARD, T. and WOODBURY, M.A.; A missing information principle: Theory and applications. Proc. 6th Berkeley Symp. Math. Statist. Probab. Vol. 1. 1972. p. 697-715.
- [111] PALADE, V., PATTON, R.J., FAISEL, J.U., QUEVEDO, J. and DALEY, S.; Fault diagnosis of an industrial gas turbine using neuro-fuzzy methods. Proc. of the 15th IFAC World Congress. Barcelona. 2002. p. 2477-2482.
- [112] PALMA, L.B., COITO, F.V. and DA SILVA, R.N.; Combined approach to fault diagnosis based on principal components and influence matrix. IEEE International Workshop on Intelligent Signal Proc, 2005. p. 171-176.
- [113] PATTON, R.J., FRANK, P.M. and CLARK, R.; Issues of fault diagnosis for dynamic systems. Springer Verlag, 2000.

- [114] PATTON, R.J. and KANGETHE, S.; Robust fault diagnosis using eigenstructure assignment of observers. *Fault Diagnosis in Dynamic Systems, Theory and Application*, Prentice Hall, New York, 1997. p. 99-154.
- [115] PATTON, R.J., UPPAL, F. and LOPEZ-TORIBIO, C.; Soft computing approaches to fault diagnosis for dynamic systems: a survey. *Proc. of the 4th IFAC Symposium SAFEPROCESS'00* 2000. p. 198-211.
- [116] PAU, L.F.; Failure Diagnosis and Performance Monitoring. *Control and Systems Theory* 1981.
- [117] PUIG, V., WITCZAK, M., NEJJARI, F., QUEVEDO, J. and KORBICZ, J.; A GMDH neural network-based approach to passive robust fault detection using a constraint satisfaction backward test. *Engineering Applications of Artificial Intelligence* 2007, vol. 20, n° 7, p. 886-897.
- [118] PUIG, V., STANCU, A., ESCOBET, T., NEJJARI, F., QUEVEDO, J. and PATTON, R.J.; Passive robust fault detection using interval observers: Application to the DAMADICS benchmark problem. *Control Engineering Practice* 2006, vol. 14, n° 6, p. 621-633.
- [119] PUKRUSHPAN, J. T., PENG, H. and STEFANOPOULOU, A. G.; Control-oriented modeling and analysis for automotive fuel cell systems. *Journal of dynamic systems, measurement, and control* 2004, vol. 126, p. 14-25.
- [120] PUKRUSHPAN, J.T.; Modeling and control of fuel cell systems and fuel processors. 2003.
- [121] RIASCOS, L. A. M., SIMOES, M. G. and MIYAGI, P. E.; A Bayesian network fault diagnostic system for proton exchange membrane fuel cells. *Journal of Power Sources* 2007, vol. 165, n° 1, p. 267-278.
- [122] ROSICH, A. Sensor Placement for Fault Diagnosis based on Structural Models: Application to a Fuel Cell Stack System. PhD Thesis. Barcelona: UPC, 2011.
- [123] ROSICH, A., NEJJARI, F. and SARRATE, R.; Fuel Cell System Diagnosis based on a Causal Structural Model. 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes. Barcelona. 2009. p. 534-539.
- [124] ROSSMAN, L.A.; Manual del Usuario de EPANET Versión 1.1 e. *Traducción al castellano. Grupo de Mecánica de Fluidos. Universidad Politécnica de Valencia* 1997.
- [125] SALAHSHOOR, K., KORDESTANI, M. and KHOSHRO, M.S.; Fault detection and diagnosis of an industrial steam turbine using fusion of SVM (support vector machine) and ANFIS (adaptive neuro-fuzzy inference system) classifiers. *Energy* 2010, vol. 35, n° 12, p. 5472-5482.
- [126] SELIGER, R. and FRANK, P.M.; Robust residual evaluation by threshold selection and a performance index for nonlinear observer-based fault diagnosis. In *Proc. of Int. Conf. on Fault Diagnosis: TOOLDIAG'93*. Apr 1993, p. 496-504.
- [127] SHANON, C.E.; A mathematical theory of communication, Part I and II. *Bell Syst Tech J* 1948, vol. 27, p. 379-423.
- [128] SIMANI, S., FANTUZZI, C. and PATTON, R.J.; Model-based fault diagnosis in dynamic systems using identification techniques. Springer New York, 2003.

- [129] SONG, H. and ZHANG, H.; Fault diagnosis based on fuzzy observer for uncertain nonlinear systems. Preprints of the 5th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS'2003, Washington, D. C., USA, p. 759-764, 2003.
- [130] STAROSWIECKI, M. and COMTET-VARGA, G.; Analytical redundancy relations for fault detection and isolation in algebraic dynamic systems. *Automatica* 2001, vol. 37, n° 5, p. 687-699.
- [131] SYFERT, M., BARTYS, M. QUEVEDO, J. and PATTON, R.J.; Development and application of methods for actuator diagnosis in industrial control systems (DAMADICS): A benchmark study. V-th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes. Vol. 3. 2003.
- [132] TAKAGI, T. and SUGENO, M.; Fuzzy identification of system and its applications to modelling and control. *IEEE Trans.Syst., Man, and Cyber* 1985, vol. 1, p. 116-132.
- [133] TAN, S.C., LIM, C.P. and RAO, M.V.C.; A hybrid neural network model for rule generation and its application to process fault detection and diagnosis. *Engineering Applications of Artificial Intelligence* 2007, vol. 20, n° 2, p. 203-213.
- [134] TAN, W.W. and HUO, H.; A generic neurofuzzy model-based approach for detecting faults in induction motors. *IEEE Transactions on Industrial Electronics* 2005, vol. 52, n° 5, p. 1420-1427.
- [135] UPPAL, F. J., PATTON, R. J. and WITCZAK, M.; A neuro-fuzzy multiple-model observer approach to robust fault diagnosis based on the DAMADICS benchmark problem. *Control Engineering Practice* 2006, vol. 14, n° 6, p. 699-717.
- [136] UYTENHOVE, H.J.J.; Computer-aided systems modelling: An assemblage of methodological tools for systems problem solving. 1978.
- [137] UYTENHOVE, H.J.J.; SAPS—System Approach Problem Solver. *Computing and Systems Consultants.Inc..Binghamton, NY* 1979.
- [138] VALLVERDÚ, M., CREXELLS, C. and CAMINAL, P.; Cardiovascular responses to intrathoracic pressure variations in coronary disease patients: a computer simulation. *Technical and Health Care, European society for engineering and medicine*, 1993.
- [139] VENKATASUBRAMANIAN, V., RENGASWAMY, R. and KAVURI, S. N.; A review of process fault detection and diagnosis:: Part II: Qualitative models and search strategies. *Computers & Chemical Engineering* 2003, vol. 27, n° 3, p. 313-326.
- [140] VENKATASUBRAMANIAN, V., RENGASWAMY, R., YIN, K, and KAVURI, S. N.; A review of process fault detection and diagnosis:: Part I: Quantitative model-based methods. *Computers & Chemical Engineering* 2003, vol. 27, n° 3, p. 293-311.
- [141] VON BERTALANFFY, L.; The history and status of general systems theory. *Academy of Management Journal* 1972, JSTOR. vol. 15, n° 4, p. 407-426.
- [142] WALKER, BK.; Fault detection threshold determination using Markov theory. 1989.
- [143] WILLSKY, A. S.; A survey of design methods for failure detection in dynamic systems. *Automatica* 1976, Elsevier. vol. 12, n° 6, p. 601-611.
- [144] WITCZAK, M.; Soft Computing-Based FDI. *Modelling and Estimation Strategies for Fault Diagnosis of Non-Linear Systems*. Springer, 2007, p. 31-46.

- [145] WYMORE, A.W.; A watted theory of systems. *Trends in General System Theory*, GJ Klir (Ed.), John Wiley, New York 1972.
- [146] ZADEH, L.A. and DESOER, C.A.; Linear system theory. McGraw-Hill New York, 1963.
- [147] ZEIGLER, B.P., PRAEHOFER, H. and KIM, T.G.; Theory of modeling and simulation. Academic press New York, 2000.
- [148] ZHUANG, Z. and FRANK, P.M.; Qualitative observer and its application to fault detection and isolation systems. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering* 1997, vol. 211, n° 4, p. 253-262.