



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

Centro Nacional de Investigación
y Desarrollo Tecnológico

Tesis de Doctorado

Neurolocalización de Fallas en un Reactor de
Fermentaciones Alcohólicas Mediante Sistemas
Takagi-Sugeno

presentada por

MC. Alberto Arturo Flores Hernández

como requisito para la obtención del grado de
Doctor en Ciencias Electrónica

Director de tesis

Dr. Juan Reyes Reyes

Codirector de tesis

Dr. Carlos Manuel Astorga Zaragoza

Cuernavaca, Morelos, México. Noviembre de 2019.



Centro Nacional de Investigación y Desarrollo Tecnológico
Departamento de Ingeniería Electrónica

"2019, Año del Caudillo del Sur, Emiliano Zapata"

ESC\FORDOC09


ACEPTACIÓN DEL TRABAJO DE TESIS DOCTORAL

Cuernavaca, Morelos a 16 de octubre de 2019.

Dr. Mario Ponce Silva
Jefe del Departamento de Ingeniería Electrónica
Presente

Los abajo firmantes, miembros del Comité Tutorial de la Tesis Doctoral del alumno **Alberto Arturo Flores Hernández**, manifiestan que después de haber revisado su trabajo de tesis doctoral titulado "**Neurolocalización de fallas en un reactor de fermentaciones alcohólicas mediante sistemas Takagi-Sugeno**" realizado bajo la dirección del **Dr. Juan Reyes Reyes** y codirección del **Dr. Carlos Manuel Astorga Zaragoza**, el trabajo se **ACEPTA** para proceder a su impresión.

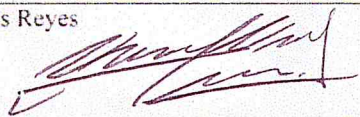
ATENTAMENTE




Dr. Juan Reyes Reyes
CENIDET




Dr. Carlos Manuel Astorga Zaragoza
CENIDET



Dr. Luis Gerardo Vela Valdés
CENIDET



Dr. Carlos Daniel García Beltrán
CENIDET



Dra. Gloria Lilia Osorio Gordillo
CENIDET



Dr. Albino Martínez Sibaja
Instituto Tecnológico de Orizaba

Reciba un cordial saludo.

c.c.p: M.E. Guadalupe Garrido Rivera / Jefa del Departamento de Servicios Escolares.
c.c.p: Dr. Gerardo Vicente Guerrero Ramirez / Subdirector Académico.
c.c.p: Expediente.





Centro Nacional de Investigación y Desarrollo Tecnológico
Departamento de Ingeniería Electrónica

"2019, Año del Caudillo del Sur, Emiliano Zapata"

ESC\FORDOC010

Cuernavaca, Morelos a 31 de octubre de 2019.

M.C. Alberto Arturo Flores Hernández
Candidato al grado de Doctor
en Ciencias en Ingeniería Electrónica
Presente

Después de haber sometido a revisión su trabajo final de tesis titulado **"Neurolocalización de fallas en un reactor de fermentaciones alcohólicas mediante sistemas Takagi-Sugeno"**, y habiendo cumplido con todas las indicaciones que el jurado revisor de tesis le hizo, le comunico que se le concede autorización para que proceda a la impresión de la misma, como requisito para la obtención del grado.

Reciba un cordial saludo.

ATENTAMENTE

EXCELENCIA EN EDUCACIÓN TECNOLÓGICA®
"CONOCIMIENTO Y TECNOLOGÍA AL SERVICIO DE MÉXICO"



Dr. Mario Ponce Silva

Jefe del Departamento de Ingeniería Electrónica

S. E. P.
CENTRO NACIONAL
DE INVESTIGACION
Y DESARROLLO
TECNOLÓGICO

c.c.p.: M.E. Guadalupe Garrido Rivera.- Jefa del Departamento de Servicios Escolares.

c.c.p.: Expediente.

MPS/lrr.

Agradecimientos

Al pueblo de México que mediante la beca otorgada por el Consejo Nacional de Ciencia y Tecnología (CONACYT) hizo posible la realización de mis estudios en el Tecnológico Nacional de México campus Centro Nacional de Investigación y Desarrollo Tecnológico (TecNM/cenidet).

Al cenidet por la influencia en mi formación profesional y personal, mediante dos personas que han fungido el rol de asesores, pero sobretodo de maestros y amigos el Dr. Juan y el Dr. Astorga.

A mi comité revisor de esta tesis doctoral el Dr. Vela, Dr. Carlos Daniel, Dr. Albino y Dr. Quintero, por sus valiosos comentarios durante las presentaciones de avance que enriquecieron este trabajo.

Al DIE por los extraordinarios profesores en su plantel el Dr. Alvarado, Dr. Adam, Dr. Fabricio, Dr. Claudio, Dr. Guerrero, Dr. Madrigal, M.C. Pedro, y a la Dra. Gloria, por su ejemplo de profesionalismo y superación. Al personal de apoyo del DIE la Lic. Lorena, Ing. Alfredo y al profesor Góngora por la calidez y el ambiente familiar.

A mi esposa Wendy por estar a mi lado en todo este proceso de crecimiento brindándome su confianza y amor.

A mis padres Juliana y Arturo, mi hermana Ana Isabel y familiares que me han acompañado y apoyado durante estos años y que cada vez que los veía me recibían con una sonrisa y un cálido abrazo muchas gracias.

A mi amigo Gerardo por las charlas profesionales y de la vida, se te estima bastante Gerar.

A mis amigas Citlaly, Karen, Laura, Marlem y Carmen por sus pláticas y consejos.

A mis amigos Daniel, Beto, Aurelio, Vidal, Alan, Eligio, el Huguito, Edgar, Chente y los Gemelos que hicieron amena y alegre mi estadía en cenidet.

Al personal que conforma el cenidet, Anita, Ing. Mario, Dra. Ana María, Lic. Garrido, Edi y el Huero.

Resumen

En el presente trabajo se desarrolla un sistema neurolocalizador de fallas aplicado a un proceso de fermentación alcohólica. El neurolocalizador permite detectar y localizar las fallas en los sensores correspondientes a la concentración de biomasa c_X , la temperatura del reactor T_r y la temperatura de la chaqueta térmica T_c ; y la falla en el actuador correspondiente al flujo del agente de enfriamiento de la chaqueta térmica F_c .

Esta investigación se divide en dos partes principalmente: i) el sistema neurolocalizador de fallas en sensores y ii) el sistema neurolocalizador de fallas en actuadores. Es decir, el neurolocalizador tiene dos estructuras, una dedicada para fallas en sensores y otra para fallas en actuadores.

La estructura del neurolocalizador de fallas en sensores se compone de la siguiente manera:

- I Elaboración de un modelo Takagi-Sugeno del modelo no lineal. La representación del modelo Takagi-Sugeno se elaboró a partir del modelo no lineal del proceso de fermentación alcohólica mediante el enfoque del sector no lineal, dado en la sección 2.5. El modelo Takagi-Sugeno se compone de un conjunto de submodelos lineales que son interpolados entre sí a través de funciones de ponderación, con lo cual se logra una representación exacta del modelo no lineal. El modelo Takagi-Sugeno resultante fue sometido a pruebas mediante simulaciones en lazo abierto variando la entrada de control con el fin de constatar que se ha realizado una buena representación del modelo no lineal. Así mismo, se diseñó una ley de control de temperatura para el proceso de fermentación, la cual se basa en el análisis de estabilidad mediante la teoría de Lyapunov para generar una ley de control por retroalimentación de estados para la entrada del sistema Takagi-Sugeno.
- II Detección de las fallas. La detección de las fallas se realizó mediante un banco de observadores generalizados difusos diseñado en la sección 3, con el cual se elaboró la matriz de incidencia de fallas basada en los residuos y síntomas generados. Para ello, las ganancias de los observadores fueron calculadas a través de la solución de desigualdades lineales matriciales, originadas por el análisis de Lyapunov de la convergencia de los observadores.
- III Localización de las fallas. La red neuronal utilizada para realizar la localización de las fallas en sensores, tiene una estructura en $\mathbb{R}^{n \times m}$ donde la entrada es la matriz de incidencia de fallas, sus pesos sinápticos y el umbral son establecidos por diseño, y su función de activación es estática. La red neuronal fue entrenada a partir del procesamiento de los datos de entrada para localizar las fallas en los sensores correspondientes a la concentración de la biomasa (levaduras) c_X , la temperatura del reactor T_r y la temperatura de la chaqueta térmica T_j .

La estructura del neurolocalizador de fallas que aborda la detección y localización de las fallas en actuadores consta únicamente de una red neuronal dinámica cuya arquitectura es de

6-1 de 6 entradas, es decir, cuenta con seis neuronas en la primera capa o capa de entrada, y una neurona en la capa de salida. Los pesos sinápticos de la red se calculan mediante el algoritmo del gradiente descendiente y su función de activación es una tangente hiperbólica. La red neuronal propuesta permite al neurolocalizador de fallas en actuadores la reconstrucción del modelo no lineal para la extracción de información útil con el fin de determinar la detección y localización de la falla correspondiente al actuador que ejerce sobre el flujo de entrada de la chaqueta térmica F_c .

Ambas estructuras del sistema neurolocalizador fueron analizadas mediante simulaciones realizadas durante esta investigación. Por ejemplo, la simulación 3.5.2 tiene como objetivo la detección y la localización de las fallas en los sensores que miden la concentración de la biomasa (levaduras) c_X , la temperatura del reactor T_r y la temperatura de la chaqueta térmica T_c .

Por último, en el capítulo 4 se dan las conclusiones de esta investigación, así como las observaciones y trabajos que se pueden desprender a partir de esta investigación.

Abstract

In the present work a fault neurolocalizer system was developed applied to an alcoholic fermentation process. The neurolocalizer allows to detect and to locate the faults in the sensors in the to biomass (yeast) concentration c_X , temperature in the reactor T_r and temperature of cooling agent in the jacket T_c ; and the faults in the actuator corresponding to the flow of the cooling agent of the thermal jacket F_c .

This investigation is mainly divided into two parts: i) the fault neurolocalizer system in sensors and ii) the fault neurolocalizer system in actuators. The fault neurolocalizer system has two structures, a function for faults in the sensors and another one for faults in the actuators.

The structure of the fault neurolocalizer system in sensors is composed as follows:

I Elaboration of a Takagi-Sugeno model of the non-linear model. The representation of the Takagi-Sugeno model was developed from the non-linear model of the alcoholic fermentation process through the non-linear sector approach, given in the section ref CasodeEstudio. The Takagi-Sugeno model is composed of a set of linear submodels that are interpolated with each other through weighting functions, which gives an accurate representation of the nonlinear model.

The Takagi-Sugeno model was tested using open-loop simulations by varying the control input in order to verify that an accurate representation was made. Likewise, a law of temperature control for the fermentation process was designed which is based on stability analysis by Lyapunov theory to generate a law of control by the feedback state of the Takagi-Sugeno systems.

II Fault detection. Failure detection was performed using a bank of diffuse generalized observers designed in the section ref Cap5, with which the fault incidence matrix based on the waste and the symptoms generated was elaborated. For this, the observers' gains were calculated through the solution of matrix linear inequalities, originated in the Lyapunov style analysis of the observers' convergence.

III Location of faults. The Neural Network used for the location of sensor faults has a structure in $\mathbb{R}^{n \times m}$ where the input is the fault incidence matrix, its synaptic weights and the threshold are set by design, and its activation function is static. The neural network was trained from the input data to locate the faults in the sensors corresponding to biomass (yeast) concentration c_X , temperature in the reactor T_r and temperature of cooling agent in the jacket T_c .

The structure of the fault neurolocalizer system that addresses the detection and location of actuator faults consists solely of a dynamic neural network whose architecture is 6-1 of 6

inputs, that is, it has six neurons in the first layer or input layer, and a neuron in the exit layer. The synaptic weights of the network are calculated using the descending gradient algorithm and its activation function is a hyperbolic tangent. The proposed neural network allows the neurolocalizer of actuator faults to rebuild the non-linear model for the extraction of useful information in order to determine the detection and location of the fault corresponding to the actuator that exerts on the input flow of the thermal jacket F_c .

Both structures of the fault neurolocalizer system were analyzed by means of simulations carried out during this investigation. For example, the simulation (ref Simulation 5.4) aims to detect and locate the sensors faults to biomass concentration c_X , temperature in the reactor T_r and temperature of cooling agent in the jacket T_c .

Finally, the chapter 4 gives the conclusions of this research, as well as the observations and the works that emerge from this investigation.

1. Introducción	1
1.1. Planteamiento del Problema	2
1.2. Justificación	3
1.3. Estado del Arte	4
1.3.1. Sistemas Takagi-Sugeno en la detección y localización de fallas	4
1.3.2. Redes neuronales artificiales en la detección y localización de fallas	6
1.3.3. Sistemas de detección y localización de fallas aplicado en reactores	9
1.3.4. Conclusiones del estado del arte	11
1.4. Objetivos	14
1.4.1. Objetivo general	14
1.4.2. Objetivos específicos	14
1.5. Hipótesis	14
1.6. Estructura de la tesis	14
2. Marco teórico	17
2.1. Modelado Takagi-Sugeno	17
2.1.1. Enfoque del sector no lineal	19
2.1.2. Linealización	22
2.2. Observadores Takagi-Sugeno	25
2.3. Redes neuronales artificiales	28
2.3.1. Estimación de fallas mediante redes neuronales	29
2.3.2. Red neuronal dinámica propuesta	30
2.4. Detección y localización de fallas	33
2.5. Caso de estudio	35
2.5.1. Modelo no lineal de un proceso de fermentación alcohólica	35

3. Neurolocalización de fallas	39
3.1. Modelo Takagi-Sugeno del proceso de fermentación alcohólica mediante el enfoque del sector no lineal	39
3.2. Banco de observadores	51
3.2.1. Diseño de los observadores Takagi-Sugeno	51
3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores	77
3.4. Construcción de la matriz de firmas	88
3.5. Sistema neurolocalizador de fallas en sensores y actuadores	89
3.5.1. Arquitectura y entrenamiento de la red neuronal para la toma de decisiones en la neurolocalización de fallas	89
3.5.2. Sistema neurolocalizador ante la presencia de fallas en los sensores correspondientes a los estados no lineales x_1 , x_5 y x_6	91
3.5.3. Sistema neurolocalizador ante la presencia de la falla f_4 en el actuador F_c	102
3.5.4. Sistema neurolocalizador ante la presencia de fallas en sensores y actuadores	107
4. Conclusiones generales	111
4.1. Conclusiones	111
4.2. Ventajas y limitaciones de esta tesis doctoral	113
4.3. Trabajos futuros	113
Bibliografía	115
A. Anexo A: Términos variables de las matrices $A(x)$ y $B_v(x)$	119
B. Anexo B: Diseño de los observadores O^3, O^4 y O^5	121
B.1. Diseño del observador O^3 correspondiente a la matriz C_i^3	121
B.2. Diseño del observador O^4 correspondiente a la matriz C_i^4	129
B.3. Diseño del observador O^5	136
C. Anexo C: Algunas propiedades de las matrices.	145
D. Anexo D: Sistema neurolocalizador ante la presencia de fallas x_2, x_3 y x_4	147

Nomenclatura

Nomenclatura

Símbolo	Término	Unidad SI
A_T	Área de transferencia de calor	1 m^2
$C_{heat,c}$	Capacidad calorífica del agente de enfriamiento	$4.18 \text{ Jg}^{-1}\text{K}^{-1}$
$C_{heat,r}$	Capacidad calorífica de la biomasa del reactor	$4.18 \text{ Jg}^{-1}\text{K}^{-1}$
c_{O_2}	Oxígeno disuelto en la reacción	3.107 mg/l
c_{O_2EL}	Equilibrio en la concentración de oxígeno en agua destilada	
c_P	Concentración del producto (etanol)	12.515 g/l
c_S	Concentración del sustrato	29.739 mg/l
$c_{S,in}$	Concentración de sustrato en el flujo de alimentación al reactor	60 g/l
c_X	Concentración de la biomasa	0.905 g/l
F_c	Flujo del agente de enfriamiento que entra en la chaqueta térmica	18 l/h
F_{in}	Flujo de alimentación de sustrato entrando al reactor	51 l/h
F_{out}	Flujo de salida del reactor	51 l/h
k_{la}	Coefficiente de transferencia de masas por el oxígeno en función de la temperatura del reactor	
K_p	Constante de inhibición del crecimiento por etanol	0.139 g/l
K_{p1}	Constante de inhibición de la fermentación por etanol	0.070 g/l
K_T	Coefficiente de transferencia de calor	$3.6 \times 10^5 \text{ Jh}^{-1}\text{m}^{-2}\text{K}^{-1}$

Símbolo	Término	Unidad SI
K_S	Término constante del sustrato para el crecimiento de la levadura	1.030 g/l
K_{S1}	Término constante del sustrato para la producción de etanol	1.680 mg/l
T_c	Temperatura del agente de enfriamiento en la chaqueta térmica	27.054 °C
$T_{c,in}$	Temperatura del agente de enfriamiento alimentado a la chaqueta térmica	15 °C
$T_{r,in}$	Temperatura del flujo de alimentación de sustrato en el reactor	25 °C
T_r	Temperatura del reactor	29.573 °C
R_{SP}	Factor de rendimiento del etanol por concentración de glucosa	0.435
R_{SX}	Factor de rendimiento de la biomasa por concentración de glucosa	0.607
r_{O_2}	Tasa de consumo del oxígeno	
V	Volumen del reactor	1000
V_c	Volumen de la chaqueta térmica	50 l

Símbolo	Término	Unidad SI
ΔH_r	Calor de la reacción	518 kJ/molO ₂
μ_p	Tasa máxima específica del producto	1.790 h ⁻¹
μ_X	Tasa máxima específica de crecimiento de la biomasa	
ρ_r	Densidad de la masa de reacción	1080 g/l
ρ_c	Densidad del agente de enfriamiento	1000 g/l
ϕ_i	Funciones de ponderación del modelo T-S	

Índice de figuras

1-1. Esquema general del sistema neurolocalizador de fallas	3
1-2. Esquema de diagnóstico de fallas basado en RNA mediante el modelo del sistema.	7
1-3. Esquema de diagnóstico de fallas basado en el conocimiento del proceso mediante RNA.	7
1-4. Esquema de diagnóstico de fallas basado RNA mediante el análisis del sistema.	8
1-5. Diagrama de instrumentación de un reactor de tanque agitado con alimentación continua.	11
1-6. Métodos de detección de fallas	12
1-7. Métodos de diagnóstico de fallas	13
2-1. Esquemas de observadores dedicados para fallas en actuadores y sensores.	27
2-2. Esquema de observadores generalizados para fallas en actuadores y sensores.	27
2-3. RNA y RNB	28
2-4. Esquema descriptivo de un sistema con posibles fallas.	33
2-5. Esquema de un reactor de fermentaciones alcohólicas.	37
3-1. Respuesta en lazo abierto del modelo no lineal dado en las Ecs.(2-70) a (2-75) versus el modelo T-S dado en la Ec.(3-17).	44
3-2. Esquema del control de temperatura de un reactor con alimentación continua.	45
3-3. Diagrama a bloques del control de temperatura del proceso de fermentación alcohólica.	46
3-4. Lazo de control de temperatura del proceso de fermentación.	49
3-5. Dinámica de las variables de estado.	50
3-6. Ley de control F_c	51
3-7. Banco de observadores generalizados para fallas en sensores.	56
3-8. Variación de la señal de control $u = F_c$	60

3-9. Esquema representativo de la simulación 5.1.	60
3-10. Respuesta del O^1 ante cambios en la señal de control F_c	61
3-11. Funciones de pertenencia del observador O^1	62
3-12. Dinámica de los errores de estimación del O^1 ante cambios en F_c	63
3-13. Fallas en los sensores del proceso de fermentación alcohólica.	64
3-14. Dinámicas del modelo no lineal y del observador O^1 ante la presencia de fallas.	67
3-15. Dinámica de las señales de evaluación r_γ^1 del O^1	68
3-16. Síntomas s_γ^1 generados a partir de la evaluación de los errores de estimación e_γ^1	69
3-17. Dinámicas del modelo no lineal y del observador O^2 ante la presencia de fallas.	73
3-18. Dinámica de las señales de evaluación r_γ^2 del O^2	75
3-19. Síntomas S_γ^2 generados a partir de la evaluación de los errores de estimación e_γ^2	76
3-20. Comparación de las dinámicas del proceso no lineal y la red neuronal uno.	82
3-21. Error de las dinámicas del proceso no lineal y la red neuronal uno.	83
3-22. Dinámica de la falla f_4	84
3-23. Comparación de las dinámicas del proceso no lineal y la red neuronal uno ante la presencia de la falla f_4	85
3-24. Dinámica de las señales de evaluación r_γ^{RNA1} de la red neuronal uno.	86
3-25. Síntomas S_γ^{RNA1} generados a partir de los errores de estimación e_γ^{RNA1}	87
3-26. Esquema del sistema neurolocalizador de fallas.	89
3-27. Red neuronal para la neurolocalización de fallas.	90
3-28. Dinámica de las fallas en los sensores del proceso de fermentación alcohólica.	93
3-29. Respuesta en lazo abierto del modelo no lineal dado en las Ecs.(2-70) a (2-75) ante la presencia de las fallas f_1, f_2 y f_3	94
3-30. Dinámicas del modelo no lineal y el observador O^3 ante la presencia de las fallas f_1, f_2 y f_3	95
3-31. Residuos generados por la estimación del observador O^3 ante la presencia de las fallas f_1, f_2 y f_3	96
3-32. Síntomas generados por la estimación del observador O^3 ante la presencia de las fallas f_1, f_2 y f_3	97
3-33. Neurolocalización de fallas en sensores del proceso de fermentación alcohólica.	98
3-34. Fallas en sensores del proceso de fermentación alcohólica.	99
3-35. Neurolocalización de fallas en sensores del proceso de fermentación alcohólica.	100
3-36. Dinámicas sobre puestas de las alarmas a_1, a_2 y a_3	101
3-37. Dinámica de la falla f_4 y su repercusión en F_c	102
3-38. Estimación del proceso no lineal con falla en el actuador F_c mediante la red neuronal uno.	103
3-39. Residuos generados por la estimación mediante la red neuronal uno.	104
3-40. Síntomas generados por la estimación mediante la red neuronal uno.	105
3-41. Neurolocalización de fallas en actuadores del proceso de fermentación alcohólica.	106
3-42. Dinámicas de las fallas f_1, f_2, f_3 y f_4	107

3-43. Dinámicas de las alarmas correspondientes a la neurolocalización de las fallas f_1 , f_2 , f_3 y f_4 109

B-1. Dinámicas del modelo no lineal y del observador O^3 ante la presencia de fallas. . 125

B-2. Dinámica de los errores de estimación e_γ^3 del O^3 127

B-3. Síntomas s_γ^1 generados a partir de la evaluación de los errores de estimación e_γ^1 . 128

B-4. Dinámicas del modelo no lineal y del observador O^4 ante la presencia de fallas. . 132

B-5. Dinámica de los errores de estimación e_γ^4 del O^4 134

B-6. Síntomas S_γ^4 generados a partir de la evaluación de los errores de estimación e_γ^4 . 135

B-7. Dinámicas del modelo no lineal y del observador O^5 ante la presencia de fallas. . 139

B-8. Dinámica de las señales de evaluación r_γ^5 del O^5 141

B-9. Síntomas s_γ^5 generados a partir de la evaluación de los errores de estimación e_γ^5 . 142

D-1. Dinámicas de las fallas f_{x_2} , f_{x_3} y f_{x_4} 148

D-2. Dinámicas del modelo no lineal y del observador O^1 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} 149

D-3. Dinámica de las señales de evaluación r_γ^1 del O^1 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} 150

D-4. Síntomas s_γ^1 generados a partir de la evaluación de los errores de estimación e_γ^1 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} 151

D-5. Síntomas s_γ^5 generados a partir de la evaluación de los errores de estimación e_γ^5 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} 152

D-6. Síntomas s_γ^5 generados a partir de la evaluación de los errores de estimación e_γ^5 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} 153

Índice de cuadros

1-1. Estado del arte del diseño de observadores para los sistemas T-S	5
1-2. RNA en el diagnóstico de fallas	9
1-3. Tipos de fallas en reactores	10
1-4. Simbología de instrumentación de un reactor de tanque agitado con alimentación continua bajo la norma ISA	11
3-1. Descripción de las fallas en sensores.	65
3-2. Ruido en las señales de los sensores.	65
3-3. Matriz de firmas. Fallas en sensores y actuadores	88
3-4. Descripción de las fallas en sensores.	92
3-5. Descripción de los ruidos en los sensores del proceso de fermentación alcohólica.	93

CAPÍTULO 1

Introducción

El desarrollo de sistemas híbridos que garanticen el adecuado funcionamiento de los procesos ha atraído la atención de los investigadores en las últimas décadas, como lo refleja el aumento de investigaciones que tratan estos temas [Ali et al. \(2015\)](#). La Federación Internacional de Control Automático (IFAC, por sus siglas en inglés International Federation Automatic of Control), propone en [Isermann and Ballé \(1997\)](#) que para mantener la seguridad y el control de las variables que intervienen en los procesos, es necesario apoyarse en tareas como la detección, aislamiento (localización), identificación, diagnóstico y control tolerante a fallas. Dentro de estas tareas, la detección y la localización de fallas son de sumo interés en la comunidad de control automático. La primera, por el hecho de que entre más rápido se detecte una falla, mejores y oportunas decisiones pueden ser tomadas. La segunda, la localización es trascendental para identificar al componente o los componentes dañados y mantener la seguridad y continuidad del proceso.

El mal funcionamiento de un proceso no está estrictamente relacionado con una falla, sino que también puede ser causado por una avería o mal funcionamiento (disfunción). Cuando se presenta alguna de estas situaciones, el proceso se ve afectado de una manera particular y en una determinada magnitud. Por ejemplo, un automóvil no puede ser vendido si el mecanismo para abrir alguna de sus puertas no sirve. A este evento se le llama comúnmente avería; dado que el automóvil puede realizar su actividad aunque este mecanismo no tenga un funcionamiento correcto. Por otra parte, la medición errónea de un sensor del automóvil se considera como una falla. En cambio, si el mecanismo de tracción del automóvil no tiene un buen desempeño, se dice que existe un mal funcionamiento, razón por la cual el automóvil no puede realizar la función para el que fue diseñado.

Este trabajo doctoral se enfoca en el desarrollo de un sistema de neurolocalización de fallas,

1. Introducción

que comprende las tareas de detección y localización de fallas. El sistema es híbrido al estar compuesto por la teoría de los sistemas Takagi-Sugeno (T-S) y las Redes Neuronales Artificiales (RNA). En este contexto, la teoría de los sistemas T-S permite extraer información útil y producir inferencias a partir de los datos disponibles del proceso. Por otro lado, la teoría de las RNA permite relacionar esta información extraída con una o múltiples fallas en particular, dada su capacidad de adaptación.

El sistema neurolocalizador de fallas fue evaluado mediante la simulación de un proceso de fermentación alcohólica, en el cual se generan fallas que ponen en riesgo el desarrollo del proceso. Dicho proceso se lleva a cabo en un reactor de tanque agitado con alimentación continua. Este proceso es uno de los más utilizados en la industria alimentaria, debido a la gran variedad de productos que se pueden obtener a partir de él. Asimismo, presenta diversos retos de control, tal es el caso del control de temperatura para el seguimiento de una trayectoria, la homogeneidad en el proceso, el control de flujos, el control de las concentraciones de nutrientes, entre otros.

1.1. Planteamiento del Problema

En un proceso de fermentación alcohólica se tienen diferentes lazos de control, por ejemplo, el control del flujo de alimentación del sustrato, el mecanismo de agitación para garantizar la homogeneidad del mosto, el control de temperatura, etc. Para realizar estos los lazos de control, es necesario contar con los sensores que miden las variables involucradas en los lazos de control del proceso, y con los actuadores mediante los cuales se ejercen dichas las leyes de control que permiten el correcto desarrollo del proceso.

La detección y localización de fallas en este tipo de procesos es una tarea vital para obtener el producto deseado, pues una falla en sensores o actuadores se puede ver directamente reflejada en la calidad del producto y, por ende, no obtener el producto que se desea. Por ejemplo, en la elaboración del vino tinto, la fermentación se debe de desarrollar en un rango de $25^{\circ}C$ a $30^{\circ}C$. Supongamos que durante su desarrollo se presenta una descalibración de $-2^{\circ}C$ en el sensor que mide la temperatura del mosto, y registra una lectura de $30^{\circ}C$. En realidad, la temperatura correcta en el mosto es de $32^{\circ}C$, es decir, dos grados más del rango estipulado. Si la fermentación se desarrollase bajo estas condiciones, el producto final no cumpliría con las características deseadas del productor y con ello se generarían pérdidas económicas.

En este contexto, el sistema neurolocalizador de fallas se enfoca en la detección y localización de fallas que se pueden presentar en sensores y actuadores que forman parte de los lazos de control en un proceso de fermentación alcohólica. Por ejemplo, el sistema neurolocalizador para fallas en sensores, la detección de fallas se aborda mediante la generación de señales que

están asociadas a fallas en particular mediante la teoría de los sistemas T-S. Mientras tanto, la localización de fallas se convierte en un problema de análisis y evaluación de dichas señales apoyándose en la capacidad de aprendizaje de las RNA.

Con ello, se genera un sistema híbrido para la detección y localización de fallas, lo cual es la tendencia en la investigación de acuerdo a lo mostrado en [Ali et al. \(2015\)](#), pues el extraer lo mejor de cada rama de investigación hace que se puedan abordar procesos donde es difícil detectar ciertas fallas y localizarlas. Aunque no siempre se puede dar la compaginación de todas las líneas de investigación, hemos visto que los sistemas T-S y las RNA son dos de las líneas de investigación con más compatibilidad. Por lo tanto, el esquema general del sistema neurolocalizador de fallas se muestra en la Fig. 1-1, donde la primera parte está dedicada a la detección de fallas y la segunda a localización de éstas.

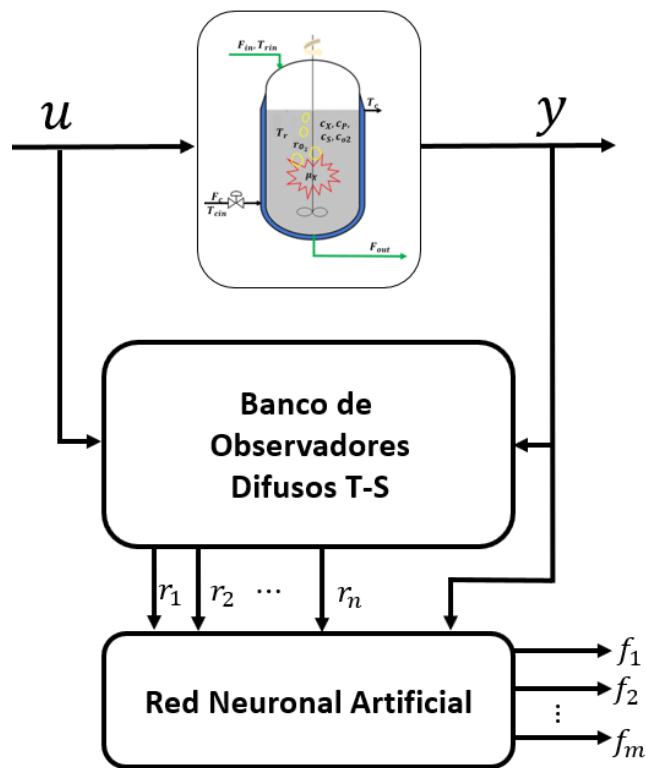


Figura 1-1.: Esquema general del sistema neurolocalizador de fallas

1.2. Justificación

La combinación de diferentes especialidades permite la creación de sistemas híbridos, los cuales resultan una opción poderosa al aplicarse en procesos complejos. El diseño del sistema neurolocalizador de fallas desarrollado en esta tesis doctoral consiste en conjuntar la teoría de sistemas Takagi-Sugeno y las redes neuronales artificiales.

1. Introducción

Por un lado, los sistemas T-S permiten abordar la detección de fallas mediante una aproximación del sistema no lineal, realizada mediante la transformación del sistema no lineal a un sistema T-S. El sistema T-S consiste en un subconjunto de modelos lineales interpolados por funciones de ponderación. A partir de este subconjunto de modelos, se puede desarrollar un banco de observadores difusos para la generación de residuos y así realizar una detección oportuna de la falla o fallas que se pudieran presentar.

Por otra parte, las RNA permiten realizar el reconocimiento de patrones y síntomas que se relacionen a una clase en particular de comportamientos mediante funciones de activación estáticas o dinámicas aunado a un algoritmo de aprendizaje. El uso de RNA posibilita realizar la múltiple localización de fallas en el caso que se presenten fallas simultáneas. Esto las hace una herramienta poderosa para aplicarlas en procesos industriales, donde garantizar la seguridad del personal y la confiabilidad del producto son una de las tareas primordiales.

1.3. Estado del Arte

En el estado del arte, se muestran algunos de los trabajos de investigación relevantes en el desarrollo de este tema doctoral. Primeramente, se hace mención a los sistemas T-S y cómo han sido utilizados en tareas como detección de fallas. En seguida, se presenta el uso de las RNA para las tareas antes mencionadas. Después, se presenta de que manera los sistemas T-S y RNA han sido utilizadas para la detección y localización de fallas en reactores y bioreactores. Por último, se concluye con un esquema el cual muestra la estructura general del sistema neurolocalizador propuesto en este tema doctoral.

1.3.1. Sistemas Takagi-Sugeno en la detección y localización de fallas

Los sistemas difusos T-S en tareas como la detección y localización de fallas se utilizan en gran medida para el modelado de procesos no lineales, ya que gracias a la representación lineal de los submodelos que lo componen permiten el uso de teoría existente para sistemas lineales. Por ejemplo, en [Thumati et al. \(2014\)](#) proponen un sistema de detección de fallas para una clase de sistemas T-S, tomando como caso de estudio un sistema de dos tanques acoplados. El diseño del sistema de detección de fallas parte del modelado T-S para el diseño de un observador con capacidad de aprendizaje de fallas en línea. Este observador se utiliza para la generación de residuos, donde una falla la declaran activa si el residuo generado supera un umbral elegido a priori.

En la tabla [1-1](#), se muestran algunas investigaciones en las cuales se basan en sistemas T-S para el diseño de un observador y realizar tareas como la detección, localización, aislamiento y diagnóstico de fallas.

Tabla 1-1.: Estado del arte del diseño de observadores para los sistemas T-S

Tipo de observador	Objetivo	Sistema	Aspectos relevantes	Ref.
Obs. de modos deslizantes	Diseñar un observador robusto ante incertidumbres	Ejemplo académico	Entradas desconocidas e incertidumbres	Akhenak et al. (2007)
Obs. por modos deslizantes	Aproximar la tasa de crecimiento del sustrato	Sistemas afines	Diseño de un Obs. Luenberger	Bergsten et al. (2002)
Obs. difuso	Estimación de estados	Sistema de Lorenz	Variables desconocidas	Ichalal et al. (2012)
Luenberger	Diseño de observadores para los modelos locales TS	Ejemplo académico	Función cuadrática de Lyapunov	Lendek et al. (2010)
Obs. para sistemas no lineales descriptor	Fallas en actuadores	Modelo descriptivo	Observadores proporcional multi-integral	Hamdi et al. (2013)

De la tabla 1-1 se ratifica que los observadores diseñados a partir de un modelo T-S cumplen con la función de un sensor virtual, y que partir de ellos se pueden diseñar lazos de control, como el control tolerante a fallas activo. Otros trabajos reportados en la literatura, muestran diferentes ventajas del uso de sistemas T-S. A continuación, se muestran algunas investigaciones que parten de la representación T-S del sistema para el desarrollo de un sistema FDD.

- En [Ahmadizadeh et al. \(2014\)](#) diseñan un sistema de detección de fallas para una clase de modelos T-S inciertos, donde las consideraciones son entradas desconocidas y retardos variantes en el tiempo. El sistema de detección de fallas se diseña tal que las entradas desconocidas son completamente desacopladas para generar las señales de los residuos mediante un filtro. Concluyen con un ejemplo numérico con el cual evalúan la efectividad de su método.
- En [Nagy-Kiss et al. \(2014\)](#) diseñan un observador robusto para sistemas no lineales modelados mediante sistemas T-S, considerando entradas desconocidos e incertidumbre de parámetros como variables de estado auxiliares. El método se valida a través de un ejemplo numérico.
- En [Nagy-Kiss et al. \(2015\)](#) se aborda un procedimiento sistemático para hacer frente a la estimación del estado e incertidumbre en los parámetros de proceso no lineal mediante el diseño de observadores para sistemas T-S. La evaluación residual es robusta de acuerdo con una señal de ruido manejada por el enfoque H_∞/H_1 .

1. Introducción

- En [Ichalal et al. \(2009\)](#) proponen un esquema de diagnóstico para sistema no lineal descritos por modelos T-S donde se abordan dos casos para el diagnóstico. El primero consiste en utilizar el conocimiento a priori de entradas y salidas del sistema. En el segundo caso suponen que las funciones de ponderación dependen del conocimiento de los estados no medibles del sistema. Los resultados los muestran a través de ejemplos numéricos.
- En [El-koujok et al. \(2012\)](#) proponen un algoritmo basado en datos de múltiples sensores para el diagnóstico de fallas. Éste se basa en la evolución de múltiples modelos T-S construidos con cada salida estimada del sensor usando un modelo derivado de la medición de entrada-salida disponible.

El modelado T-S es una herramienta poderosa en el diseño sistemas de detección, localización, diagnóstico y control tolerante a fallas dado que su representación permite el uso de teoría de sistemas lineales en procesos no lineales que puedan ser expresados de forma difusa T-S.

1.3.2. Redes neuronales artificiales en la detección y localización de fallas

El uso de las RNA en los sistemas detección y diagnóstico de fallas en las últimas décadas se ha intensificado, debido a que son una interesante alternativa a los sistemas clásicos cuando la situación del proceso se vuelve compleja. En estos casos, las RNA pueden extraer información útil del sistema a partir de un entrenamiento con datos históricos, mediante algoritmos de aprendizaje con un poco o casi nulo conocimiento a priori del sistema bajo estudio para representar su dinámica, [Verde et al. \(2013\)](#). Otra de sus características es que son robustas con respecto a datos incorrectos o pérdida de datos, [Patan \(2008\)](#). En tareas de detección, localización y diagnóstico de fallas, las RNA se pueden emplear de tres maneras, [Patan \(2008\)](#), siendo las siguientes:

- **Enfoque basado en modelo**, utiliza generalmente los resultados de la teoría de control y se basan en la estimación de parámetros y estados del sistema. Al utilizar este enfoque es esencial tener una representación matemática del proceso. Por lo general, es a través de ecuaciones diferenciales, pero también se pueden usar RNA para la identificación y generación de un modelo del proceso. En la Fig. (1-2) se muestra el esquema de diagnóstico de fallas usando RNA basado en el enfoque por modelo donde una de las principales formas de extraer características del sistema con fallas es mediante la generación de residuos. Entonces, la RNA evalúa los residuos generados y los relaciona con las fallas del sistema.

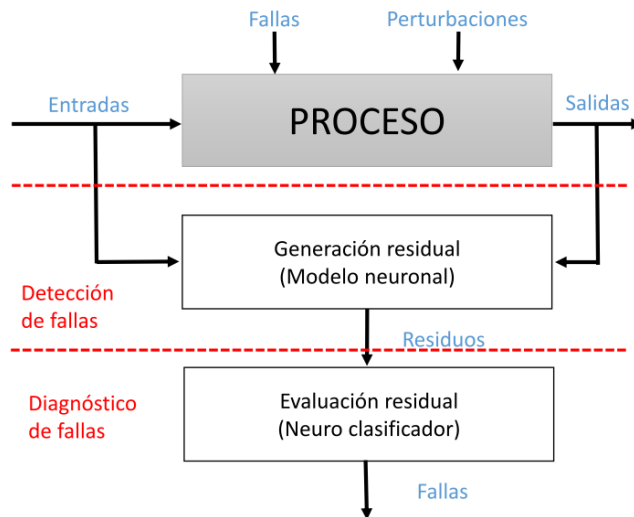


Figura 1-2.: Esquema de diagnóstico de fallas basado en RNA mediante el modelo del sistema.

- **Enfoque basado en el conocimiento**, este enfoque se puede formular mediante dos formas:
 - La primera consiste en una base de reglas, donde las fallas son usualmente diagnosticadas trazando síntomas hacia atrás a lo largo de sus trayectorias de propagación.
 - La segunda es mediante simulaciones cualitativas, donde los modelos cualitativos de un proceso son usados para predecir el desarrollo del proceso bajo condiciones de operación normal y en varias situaciones de falla, Patan (2008).

Este enfoque se genera por la persona experta en el proceso o es necesario tener un conocimiento cualitativo a priori del proceso. En la Fig. (1-3) se muestra el esquema general de este enfoque.

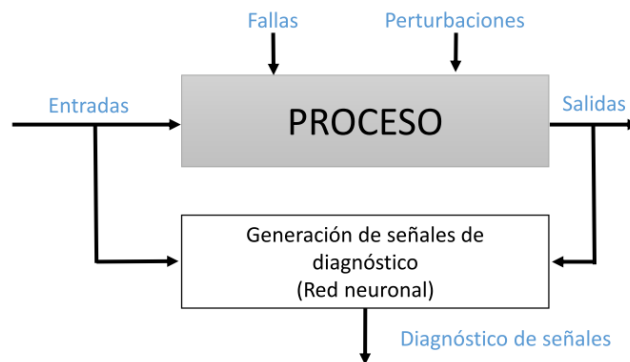


Figura 1-3.: Esquema de diagnóstico de fallas basado en el conocimiento del proceso mediante RNA.

1. Introducción

- **Enfoque basado en el análisis de datos**, es necesario obtener datos operativos del proceso en condiciones normales y anormales. Por ello, existen dos métodos principales dentro de este enfoque:
 1. Cuando la RNA únicamente requiere del conocimiento de los datos que contengan fallas y síntomas de ellas para su entrenamiento.
 2. Cuando se utiliza la RNA para identificar el proceso mediante los síntomas de las fallas que pueden ser variaciones en las mediciones del proceso. A través del entrenamiento, las relaciones entre las fallas y sus síntomas pueden ser descubiertos y almacenados como los pesos de la red.

En la Fig. 1-4, se muestra la técnica del análisis de datos mediante una RNA con clasificador de patrones, es decir, donde las firmas de las fallas se extraen de datos operacionales del proceso, a través de métodos estáticos multivariados tal como el análisis de componentes principales.

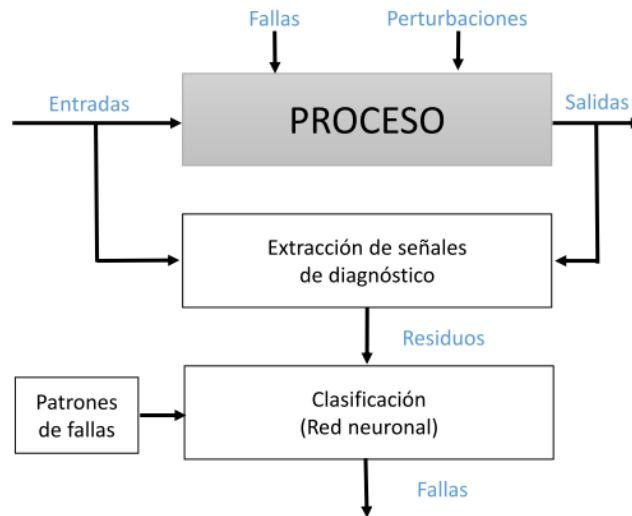


Figura 1-4.: Esquema de diagnóstico de fallas basado RNA mediante el análisis del sistema.

Las RNA se pueden utilizar en función al estudio realizado para cumplir con las tareas de detección, localización y diagnóstico de fallas y mediante el enfoque que sea conveniente para el estudio. Algunos ejemplos tomados de la literatura se presentan en la tabla 1-2.

Tabla 1-2.: RNA en el diagnóstico de fallas

Referencia	Descripción	RNA Empleada	Enfoque
Duan and Liu (2011)	Propusieron un sistema de diagnóstico de fallas en transformadores de potencia llenos de aceite	Red tipo Elman	Mediante el modelado del sistema
Luzar et al. (2012)	Realizan localización de fallas en sensores y actuadores	RNA dinámica	Modelo e identificación del sistema
Mirea and Patton (2008)	Desarrollan un FDI, donde la red se encarga de la clasificación de residuos	RNA recurrente Wavelet	
Tayarani-Bathaie et al. (2014)	Proponen un FDI para un motor a reacción de aviones	Perceptrón multicapa	Hacen la identificación del sistema

De la tabla [1-2](#) se concluye que mediante sus funciones de activación, algoritmo de aprendizaje y entrenamiento con datos del sistema con y sin falla son capaces de reconstruir la dinámica del sistema y diagnosticar una falla. También, las RNA más utilizadas son del tipo prealimentadas y recurrentes, las cuales se usan en el reconocimiento de patrones y para reconstruir la dinámica del proceso.

Por otro lado, la investigación realizada en [Ali et al. \(2015\)](#) se enfoca en la recopilación de investigaciones donde utilizan los sistemas de inteligencia artificial como estimadores de parámetros no medibles en procesos de ingeniería química. Primeramente se hace la clasificación del tipo de sistema de inteligencia artificial (RNA, sistemas difusos T-S, algoritmos genéticos, sistemas expertos y sistemas híbridos). Para los resultados del uso de RNA como estimadores de parámetros, primero realizan una clasificación de los tipos de RNA que se han utilizado. Posteriormente, a través de una tabla muestran el objetivo de cada investigación, proceso de aplicación, ventajas y desventajas; y como conclusión de su investigación muestran en forma gráfica que la tendencia y la implementación práctica del uso de inteligencia artificial como estimadora de parámetros en procesos químicos va en aumento.

A partir del estudio mostrado sobre las RNA, se dice que dada su capacidad de adaptación tienen la ventaja de que pueden ser utilizadas en la generación de síntomas y residuos para la detección de fallas o en la evaluación de éstos, que conllevaría a la localización y diagnóstico de una falla o múltiples fallas.

1.3.3. Sistemas de detección y localización de fallas aplicado en reactores

La automatización de un proceso implica que sus componentes desarrollen de manera satisfactoria su tarea, es decir, que los dispositivos funcionales de la planta estén libres de falla.

1. Introducción

Aunque esto sería un caso ideal, en la realidad esto no se puede garantizar en su totalidad. En el caso de un reactor, las fallas se pueden presentar en actuadores, sensores y en componentes. En el tabla 1-3, se muestra un panorama de la literatura sobre la detección y diagnóstico fallas en diferentes tipos de reactores.

Tabla 1-3.: Tipos de fallas en reactores

Componente	Tipo	Descripción	Referencia
Sensores	Multiplicativa	Temperatura	Geetha and Jerome (2013)
	Abruptas	T_r y T_j	Pierrri et al. (2008)
	Aditiva	T_j	Martínez-Guerra and Mata-Machuca (2014)
	Aditiva	T_r	Janarthanan and Prakash (2006)
	Aditiva	T_{rin} y T_{jin}	Gowthami and Vijayachitra (2015)
Actuadores	Aditiva	Válvula de Temperatura	Geetha and Jerome (2013)
	Abrupta	Temperatura-Concentración	Liu et al. (2010)
	Aditiva	Bomba de alimentación	Zhang and Hoo (2011)
Proceso	Aditiva	Concentración del reactante	Sawattanakit and Jaovisidha (1998)
	Aditiva	Concentración en la entrada del reactante	Martínez-Guerra and Mata-Machuca (2014)
	Aditiva	Área de transferencia de calor su- cia	Bahmanpour et al. (2007)
	Aditiva	Tasa de flujo de alimentación del reactor	Gowthami and Vijayachitra (2015)

Debido a que el mantenimiento del control de la temperatura en reactores es una de las tareas principales, los sistemas de detección y diagnóstico de fallas se han enfocado en fallas en sensores y en actuadores utilizados para realizar el control sobre ella. En la Fig. 1-5 se muestra el diagrama de instrumentación de un reactor de alimentación continua y en el tabla 1-4 la correlación los componentes de acuerdo a la simbología de la norma ISA (que por sus siglas en inglés Instrument Society of America). Por ejemplo, supongamos que se presenta una falla en la válvula que controla el flujo de entrada a la camisa térmica, que en el diagrama de instrumentación se representa por (FC/200). Esta falla sería en un actuador que se encuentra en el lazo de control de la temperatura del reactor. Así como estas fallas repercuten en un lazo de control, se hace énfasis en las fallas ocurridas en concentraciones de sustrato y reactante que se encuentran en el flujo de alimentación al reactor. Por lo tanto, las fallas en sensores y actuadores sobre los lazos de control para variables críticas son las más atacadas debido a la repercusión que tienen sobre el producto final.

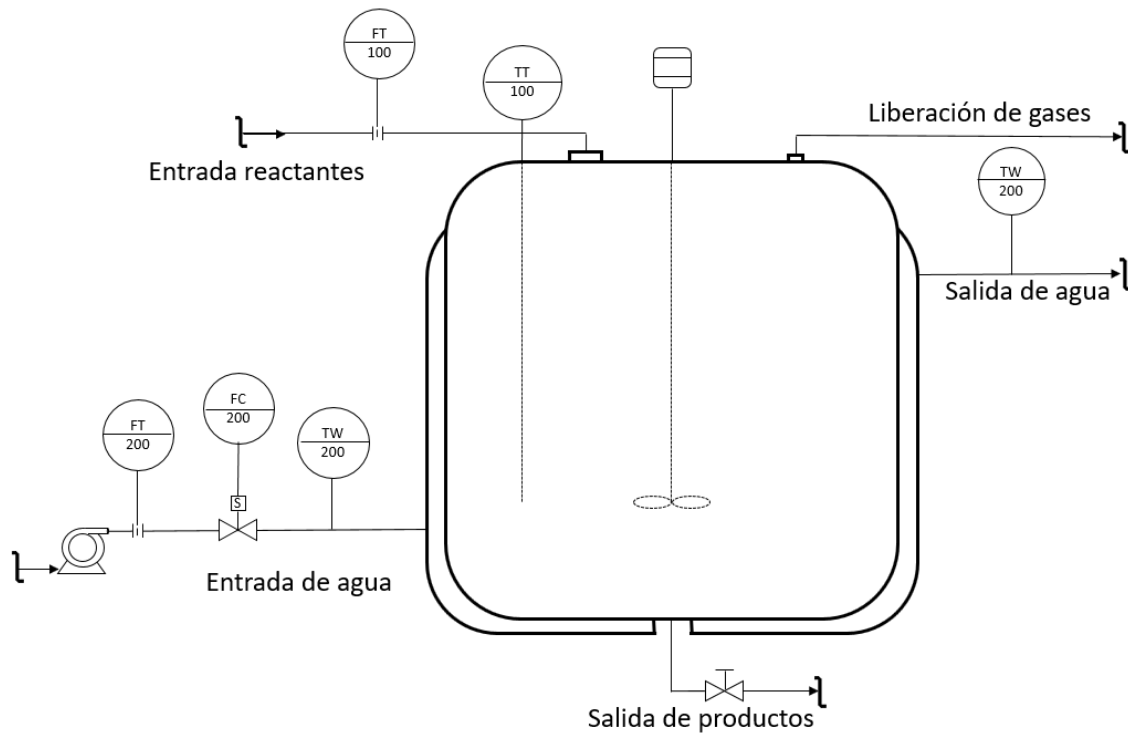


Figura 1-5.: Diagrama de instrumentación de un reactor de tanque agitado con alimentación continua.

Tabla 1-4.: Simbología de instrumentación de un reactor de tanque agitado con alimentación continua bajo la norma ISA

Simbología bajo la norma ISA		
Simbología	Nombre funcional	Descripción
FT100	Transmisor de flujo	Sensor de flujo
TT100	Transmisor de temperatura	Temperatura del reactor
FT200	Transmisor de flujo	Sensor de flujo
FC200	Controlador de flujo	Controlador de la válvula solenoide
S	Válvula solenoide	Válvula solenoide NC
TW200	Transmisor de Temperatura en termopozo	T_{cin}
TW200	Transmisor de Temperatura en termopozo	T_c

1.3.4. Conclusiones del estado del arte

En la literatura existen diferentes métodos reportados para realizar las tareas de detección y localización de fallas, como se muestra en los tablas sinápticos 1-6 y 1-7, los cuales fueron

1. Introducción

desarrollados originalmente en Isermann (2006), pero en forma de mapa conceptual. En particular, este tema doctoral aborda el diseño del sistema neurolocalizador de fallas mediante los temas resaltados en color rojo de los tablas sinápticos mencionados.

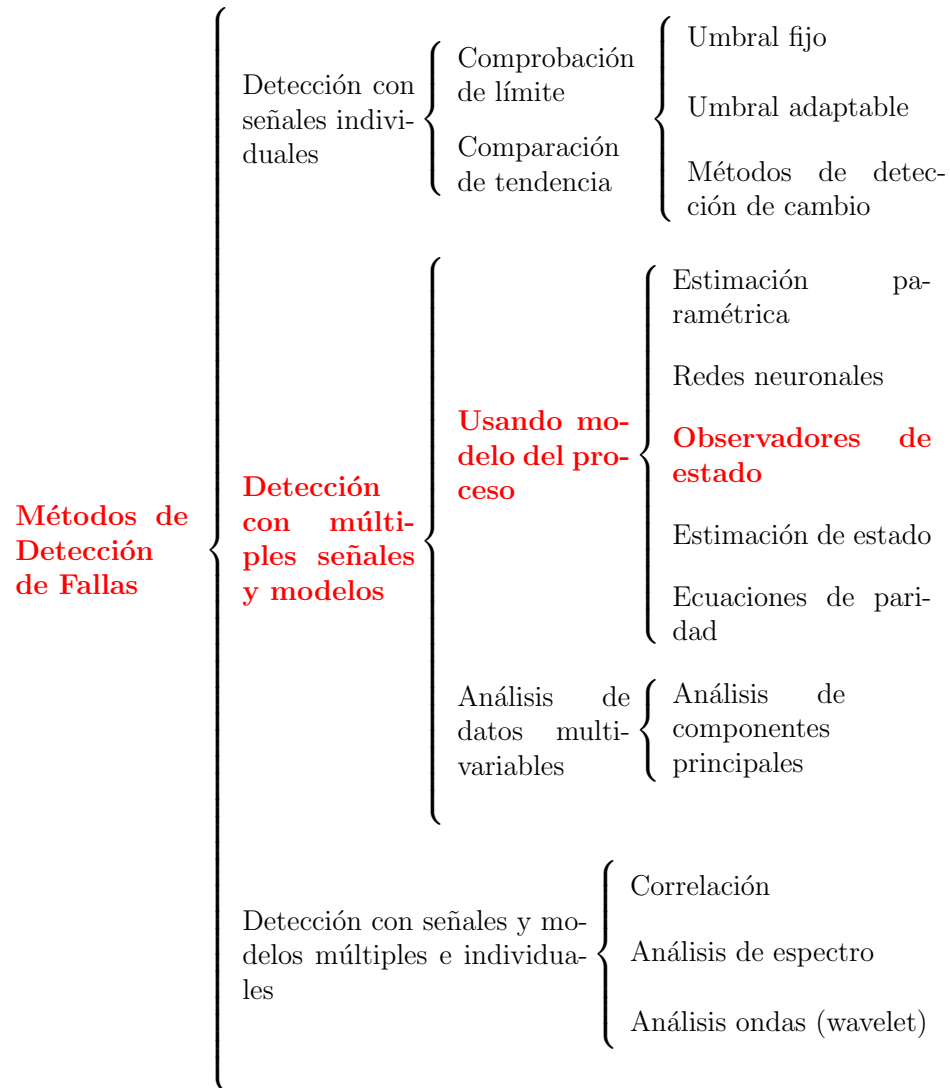


Figura 1-6.: Métodos de detección de fallas

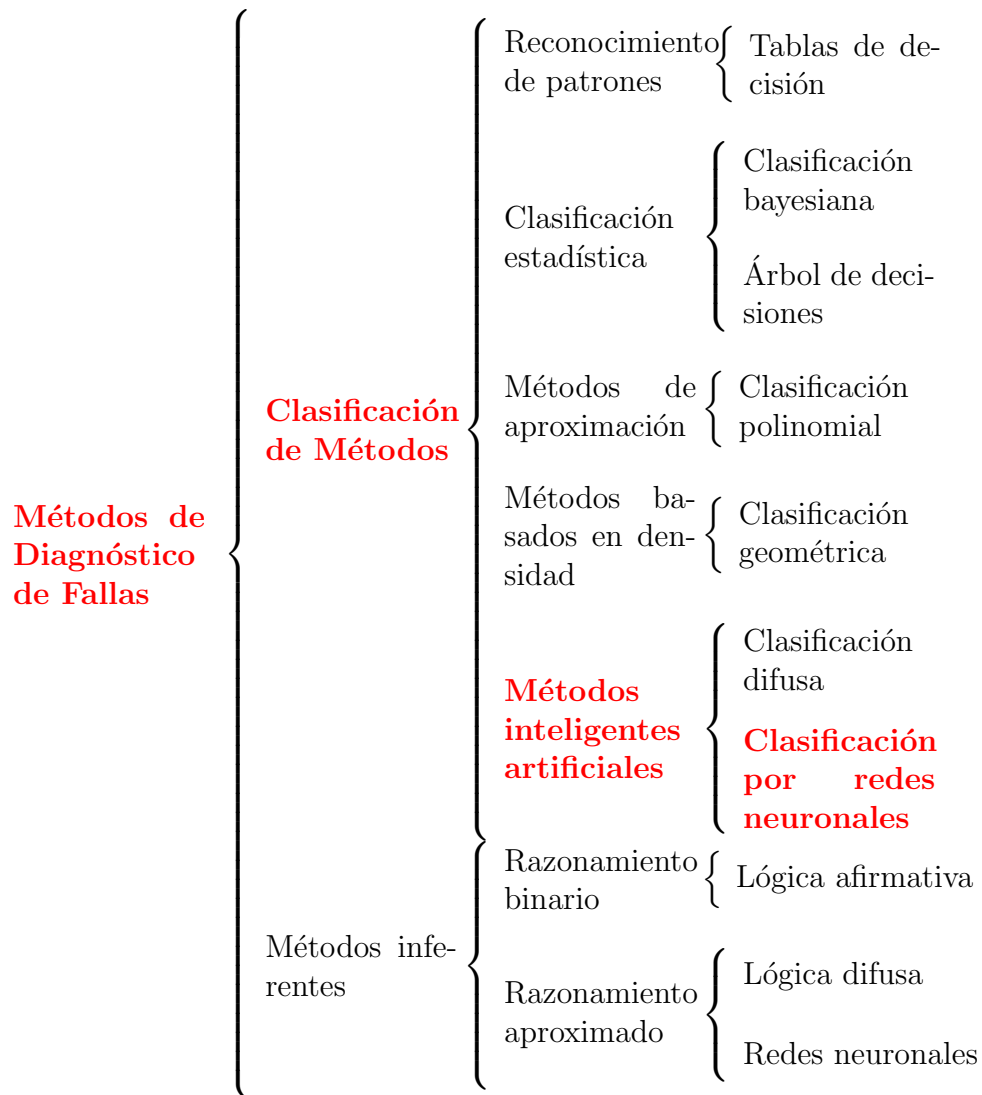


Figura 1-7.: Métodos de diagnóstico de fallas

1.4. Objetivos

1.4.1. Objetivo general

Diseñar un sistema neurolocalizador de fallas basado en redes neuronales artificiales y el modelado T-S de sistemas no lineales, para emplearlo en un proceso de fermentación para la detección y localización de fallas en sensores y actuadores.

1.4.2. Objetivos específicos

1. Proponer un modelo T-S del proceso de fermentación para fines de control automático a partir del modelo no lineal del proceso.
2. Diseñar el controlador para el seguimiento de una trayectoria de temperatura de una fermentación alcohólica.
3. Diseñar e implementar un sistema de detección de fallas basado en observadores a partir de las variables medibles y no medibles del proceso.
4. Diseñar e implementar un sistema neurolocalizador de fallas.
 - Analizar los residuos y síntomas correspondientes para cada falla en particular.
 - Proponer la arquitectura y la función de aprendizaje de la RNA.
 - Definir el algoritmo de aprendizaje de la RNA.

1.5. Hipótesis

Es posible realizar la localización de fallas formulando el problema de la evaluación de residuos y estados del proceso utilizando funciones estáticas y dinámicas en el algoritmo de aprendizaje de una red neuronal artificial.

1.6. Estructura de la tesis

La estructura de esta tesis consta de cuatro capítulos, de los cuales el capítulo uno está dedicado a introducir al lector en el tema de tesis mediante una introducción, planteamiento del problema, justificación, el estado del arte y los objetivos planteados. En el estado del arte se hace una recapitulación referente a la detección de fallas mediante sistemas T-S y cuáles se han utilizado en procesos de fermentación alcohólica. Así como también, el uso de redes neuronales para la localización de fallas y cuáles se han utilizado en procesos de fermentación alcohólica.

El capítulo dos consta de un marco teórico donde se detallan las herramientas teóricas utilizadas de los sistemas T-S y las RNA para la elaboración y diseño del sistema neurolocalizador. También, se muestra el modelo no lineal del proceso de fermentación alcohólica y los fuertes acoplamientos que existe entre el balance de energía y el balance de masas que lo conforman. Asimismo, se muestra la obtención de un modelo difuso T-S que representa la dinámica del proceso de forma exacta. Las dinámicas de ambos modelos se muestran tanto en lazo abierto como en lazo cerrado.

Los pormenores en el diseño del sistema neurolocalizador son abordados en el capítulo tres, donde se muestra el acoplamiento entre la teoría de los sistemas T-S y las RNA, mediante el diseño de un banco de observadores que generan una serie de señales, cada una relacionada a una falla en particular. Estas señales y el acceso a los estados del sistema permiten que la RNA, mediante su algoritmo de aprendizaje, localice cada falla y fallas simultáneas que se pudieran suscitar dentro de los sensores y actuadores del proceso de fermentación alcohólica.

Finalmente, en el capítulo cuatro se abordan las conclusiones generales sobre la investigación desarrollada, así como la mención de los posibles trabajos que se pueden deslindar a partir de ella.

En este capítulo se muestran las herramientas teóricas utilizadas para el diseño del sistema neurolocalizador de fallas. En primera instancia, se presenta el modelado T-S para procesos no lineales. Las dos clases de observadores T-S se muestran en la subsección 2.2 y los diferentes esquemas de banco de observadores. En la subsección 2.3 se muestra la teoría sobre las redes neuronales artificiales y cómo han sido empleadas para la detección y localización de fallas, así como la red neuronal que se propone en esta tesis. Los conceptos fundamentales en la detección, localización y diagnóstico de fallas son enunciados en la subsección 2.4. El caso de estudio es abordado en la subsección 2.5, donde se detalla el modelo no lineal del proceso de fermentación alcohólica llevado a cabo en un reactor tipo tanque de alimentación continua.

2.1. Modelado Takagi-Sugeno

En esta sección, se mencionan conceptos básicos sobre el modelado de procesos no lineales a partir de los sistemas T-S, los cuales fueron propuestos en [Takagi and Sugeno \(1985\)](#) y consisten en un subconjunto de modelos lineales interpolados entre sí mediante una base de reglas de tipo *si-entonces*. Este tipo de sistemas son muy parecidos al modelado mediante la teoría de los sistemas lineales de parámetros variables en el tiempo. Aunque se asemejan considerablemente no quiere decir que sean iguales tal como se menciona en [Rotondo \(2017\)](#), donde las principales semejanzas y diferencias entre ambos sistemas son esclarecidas.

Cada regla de los sistemas T-S es una expresión simple del modelo en conjuntos difusos denotada

2. Marco teórico

como sigue:

$$\text{si } z_1 \text{ es } Z_1^i \text{ y...y } z_p \text{ es } Z_p^i \text{ entonces } y = F_i(z) \quad (2-1)$$

Los sistemas T-S pueden representar la dinámica de procesos no lineales de la forma:

$$\begin{aligned} \dot{x} &= f(x, u, \vartheta) \\ y &= h(x, u, \zeta) \end{aligned} \quad (2-2)$$

donde f y h son funciones no lineales suaves, f es un campo vectorial en función de los estados del sistema y h es la función que describe la salida del sistema, $x \in \mathbb{R}^{n_x}$ es el vector de estado, $u \in \mathbb{R}^{n_u}$ es el vector de entrada, $y \in \mathbb{R}^{n_y}$ es el vector medido, ϑ y ζ representan los vectores de parámetros constantes u otras variables exógenas que actúan en el sistema.

Un sistema T-S que aproxima o representa al proceso no-lineal dado en la Ec.(2-2) y se expresa mediante un conjunto de m reglas difusas como sigue:

$$\begin{aligned} &\text{si } z_1(\tau) \text{ es } Z_1^i \text{ y...y } z_p(\tau) \text{ es } Z_p^i \\ \text{entonces} &\begin{cases} \dot{x} = f_i(x(\tau), u(\tau), \vartheta) \\ y = h_i(x(\tau), u(\tau), \zeta) \end{cases} \end{aligned} \quad (2-3)$$

donde $z_1(\tau), \dots, z_p(\tau)$ son las variables programadas, las cuales pueden ser estados del proceso, entradas de control o perturbaciones externas variantes en el tiempo; f_i y h_i son las funciones consecuentes de la i -ésima regla. Cada consecuencia lineal puede ser representado como: $A_i x(\tau) + B_i u(\tau) + a_i$, por lo tanto la Ec.(2-3) puede reescribirse de la siguiente forma:

$$\begin{aligned} &\text{si } z_1(\tau) \text{ es } Z_1^i \text{ y...y } z_p(\tau) \text{ es } Z_p^i \\ \text{entonces} &\begin{cases} \dot{x} = A_i x(\tau) + B_i u(\tau) + a_i \\ y = C_i x(\tau) + D_i u(\tau) + c_i \end{cases} \end{aligned} \quad (2-4)$$

formando un subsistema por cada regla difusa existente desde $i = 1, 2, \dots, m$. Cada estado y salida $(x(\tau), u(\tau))$ del sistema T-S puede ser inferido como sigue:

$$\dot{x} = \frac{\sum_{i=1}^m \varpi_i(z(\tau))(A_i x(\tau) + B_i u(\tau) + a_i)}{\sum_{i=1}^m \varpi_i(z(\tau))} = \sum_{i=1}^m \phi_i(z(\tau))(A_i x(\tau) + B_i u(\tau) + c_i) \quad (2-5)$$

$$y = \frac{\sum_{i=1}^m \varpi_i(z(\tau))(C_i x(\tau) + D_i u(\tau) + c_i)}{\sum_{i=1}^m \varpi_i(z(\tau))} = \sum_{i=1}^m \phi_i(z(\tau))(C_i x(\tau) + D_i u(\tau) + c_i) \quad (2-6)$$

donde $z(\tau) = (z_1(\tau), \dots, z_p(\tau))^T$ es el vector que contiene las variables programadas, mientras que $\varpi_i(z(\tau))$ y $\phi_i(z(\tau))$ se definen como:

$$\varpi_i(z(\tau)) = \prod_{j=1}^p \psi_{ij}(z(\tau)) \quad (2-7)$$

$$\phi_i(z(\tau)) = \frac{\varpi_i(z(\tau))}{\sum_{j=1}^m \varpi_j(z(\tau))} \quad (2-8)$$

donde $\psi_{ij}(z(\tau))$ se refiere a la normalización de las funciones de membresía de $z(\tau)$ en ψ_{ij} y $\phi_i(z(\tau))$ es tal que:

$$\phi_i(z(\tau)) = \sum_{i=1}^p \varpi_i(z(\tau)) = 1, \phi_i(z(\tau)) \geq 0, \forall_i = 1, \dots, m \quad (2-9)$$

El modelado mediante sistemas T-S tiene dos enfoques principalmente [Lendek et al. \(2011\)](#). El primero consiste en el enfoque del sector no lineal, el cual puede representar de manera exacta la dinámica de un sistema no lineal en un conjunto compacto de espacio de estados; y mientras que el segundo lo representa mediante la linealización del sistema no lineal, de la cual se obtiene una aproximación del sistema no lineal.

2.1.1. Enfoque del sector no lineal

El enfoque del sector no lineal de los sistemas T-S tiene como principal característica la capacidad de representar de forma exacta la dinámica del modelo no-lineal bajo estudio. En este trabajo, se utiliza la siguiente metodología para la obtención de un modelo T-S mediante el enfoque del sector no lineal a partir del modelo no lineal del proceso. Por ejemplo, considere el siguiente modelo no lineal:

$$\begin{aligned} \dot{x} &= \begin{bmatrix} \cos x_2 & 2 \\ 4 & x_1 \end{bmatrix} x + \begin{bmatrix} 1 \\ x_2 \end{bmatrix} u \\ y &= \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} x \end{aligned} \quad (2-10)$$

donde x es el vector de estados $x = [x_1 \ x_2]^T$ y u es la señal de control.

Paso 1. A partir del modelo no lineal bajo estudio, se prosigue a representar en variables de estado. Por ejemplo, el modelo dado en la Ec.(2-10) se puede representar de la siguiente forma:

$$\begin{aligned} \dot{x} &= A(x)x + B(x)u \\ y &= Cx \end{aligned} \quad (2-11)$$

es decir:

$$\begin{aligned} \dot{x} &= \begin{bmatrix} \cos x_2 & 2 \\ 4 & -x_1 \end{bmatrix} x + \begin{bmatrix} 1 \\ x_2 \end{bmatrix} u \\ y &= \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} x \end{aligned} \quad (2-12)$$

2. Marco teórico

Paso 2. Los términos variantes en el tiempo se identifican dentro de las matrices $A(x)$ y $B(x)$ del modelo Ec.(2-12), los cuales se encierran en cajas. Con ello es posible identificar qué términos dependientes se encuentran en función de las variables de estado. Note que el ejemplo en desarrollo tiene tres términos dependientes de los estados dentro de las matrices, el primero y segundo término $\cos x_2$ y x_1 , respectivamente, ubicados en la matriz $A(x)$ y el tercer término x_2 ubicado en la matriz $B(x)$.

Paso 3. Para obtener los valores límites (\underline{nl}_j \overline{nl}_j) de cada no linealidad, se debe determinar el rango de operación de las variables de estado, considerando las condiciones iniciales del modelo no lineal y la variación de la entrada del proceso. En este ejemplo académico, las condiciones iniciales del proceso son iguales a cero para ambos estados y la variación de la entrada u va de uno a tres. A partir, de la variación de u el estado $x_1 \in [0,01, 35,23]$ y para el estado $x_2 \in [0,01, 4,7]$. Por lo tanto, los valores de los límites obtenidos para las no linealidades son:

$$z_1 : \begin{cases} \underline{nl}_1 = \min_{x_2} \{\cos x_2\} = -1 \\ \overline{nl}_1 = \max_{x_2} \{\cos x_2\} = 1 \end{cases} \quad (2-13)$$

$$z_2 : \begin{cases} \underline{nl}_2 = \min_{x_1} \{x_1\} = 0,01 \\ \overline{nl}_2 = \max_{x_1} \{x_1\} = 35,23 \end{cases} \quad (2-14)$$

$$z_3 : \begin{cases} \underline{nl}_3 = \min_{x_2} \{x_2\} = 0,01 \\ \overline{nl}_3 = \max_{x_2} \{x_2\} = 4,7 \end{cases} \quad (2-15)$$

Paso 4. Partiendo de las variables programadas $z_j, j = 1, 2, 3$, se obtienen las funciones de ponderación. Entonces, como tenemos dos variables programadas, se obtienen cuatro funciones de ponderación como sigue:

$$\begin{aligned} \eta_0^1(z_1) &= \frac{\overline{nl}_1 - z_1}{\overline{nl}_1 - \underline{nl}_1}; & \eta_1^1(z_1) &= 1 - \eta_0^1, \\ \eta_0^2(z_2) &= \frac{\overline{nl}_2 - z_2}{\overline{nl}_2 - \underline{nl}_2}, & \eta_1^2(z_2) &= 1 - \eta_0^2, \\ \eta_0^3(z_3) &= \frac{\overline{nl}_3 - z_3}{\overline{nl}_3 - \underline{nl}_3}, & \eta_1^3(z_3) &= 1 - \eta_0^3 \end{aligned} \quad (2-16)$$

Cada variable programada z_j se puede representar como una suma ponderada, mediante la siguiente expresión:

$$z_j = \underline{nl}_j \eta_0^j(z_j) + \overline{nl}_j \eta_1^j(z_j) \quad (2-17)$$

es decir, para z_1 tenemos:

$$z_1 = -1 \frac{-1 - \cos x_2}{1 - (-1)} + 1 \left(1 - \frac{-1 - \cos x_2}{1 - (-1)} \right) \quad (2-18)$$

para z_2 :

$$z_2 = 0,01 \frac{0,01 - x_1}{1 - (0,01)} + 66,52 \left(1 - \frac{0,01 - x_1}{1 - (0,01)} \right) \quad (2-19)$$

y para z_3 :

$$z_3 = 0,01 \frac{0,01 - x_2}{1 - (0,01)} + 11,46 \left(1 - \frac{0,01 - x_2}{1 - (0,01)} \right) \quad (2-20)$$

Paso 5. Las funciones de pertenencia $\phi_i(z)$ son establecidas mediante la combinación de las funciones de ponderación, donde el número de funciones de pertenencia se establece mediante la expresión $m = 2^p$, siendo p el número de variables programadas. Por ejemplo, en el desarrollo del modelo T-S del sistema no lineal de la Ec.(2-10) el número de variables programadas es $p = 3$. Por lo tanto, las funciones de pertenencia son $m = 2^3 = 8$ y se expresan como:

$$\begin{aligned} \phi_1(z) &= \eta_0^1 \eta_0^2 \eta_0^3; \\ \phi_2(z) &= \eta_0^1 \eta_0^2 \eta_1^3; \\ \phi_3(z) &= \eta_0^1 \eta_1^2 \eta_0^3; \\ \phi_4(z) &= \eta_0^1 \eta_1^2 \eta_1^3; \\ \phi_5(z) &= \eta_1^1 \eta_0^2 \eta_0^3; \\ \phi_6(z) &= \eta_1^1 \eta_0^2 \eta_1^3; \\ \phi_7(z) &= \eta_1^1 \eta_1^2 \eta_0^3; \\ \phi_8(z) &= \eta_1^1 \eta_1^2 \eta_1^3; \end{aligned} \quad (2-21)$$

Paso 6. A partir de las funciones de pertenencia se infiere que el conjunto difuso del modelo T-S tiene 8 reglas, debido a que el número de reglas es igual al número de funciones de pertenencia. Esto es porque cada conjunto difuso Z_γ^j corresponde a una función de pertenencia η_γ^j). Entonces, por cada regla (del tipo *si – entonces*), existe un modelo matemático lineal. Por ejemplo, la regla del primer modelo difuso es:

$$\begin{aligned} &\text{si } z_1 \text{ es } Z_0^1 \text{ y } z_2 \text{ es } Z_0^2 \text{ y } z_3 \text{ es } Z_0^3 \\ &\text{entonces } \begin{cases} \dot{x} = A_1 x + B_1 x \\ y = C x \end{cases} \end{aligned} \quad (2-22)$$

Dado que $z_1 = \underline{nl}_1$, $z_2 = \underline{nl}_2$ y $z_3 = \underline{nl}_3$, entonces los límites \underline{nl}_j , $\forall j = [1, 2, 3]$ son directamente remplazados por los términos no lineales en las matrices $A(x)$, $B(x)$ de la Ecs.(2-12), resultando las matrices para el modelo de la Ec.(2-22) como sigue:

$$A_1 = \begin{bmatrix} \underline{nl}_1 & 1 \\ 4 & -\underline{nl}_2 \end{bmatrix}; \quad B_1 = \begin{bmatrix} 1 \\ \underline{nl}_3 \end{bmatrix}; \quad (2-23)$$

es decir,

$$A_1 = A(\underline{nl}_1, \underline{nl}_2); \quad B_1 = B(\underline{nl}_3) \quad (2-24)$$

Por lo tanto, la función de pertenencia correspondiente a la regla uno es $\phi_1(z) = \eta_0^1 \eta_0^2 \eta_0^3$.

Paso 7. Finalmente, el modelo T-S que reproduce adecuadamente la dinámica del modelo no lineal dado por las Ecs.(2-10) es:

$$\begin{aligned} \dot{x} = & (\phi_1 A_1 + \phi_2 A_2 + \phi_3 A_3 + \phi_4 A_4 + \phi_5 A_5 + \phi_6 A_6 + \phi_7 A_7 + \phi_8 A_8)x + \\ & (\phi_1 B_1 + \phi_2 B_2 + \phi_3 B_3 + \phi_4 B_4 + \phi_5 B_5 + \phi_6 B_6 + \phi_7 B_7 + \phi_8 B_8)u \end{aligned} \quad (2-25)$$

$$y = Cx$$

donde

$$\begin{aligned} A_1 &= A(\underline{nl}_1, \underline{nl}_2) & B_1 &= B(\underline{nl}_3) \\ A_2 &= A(\underline{nl}_1, \overline{nl}_2) & B_2 &= B(\overline{nl}_3) \\ A_3 &= A(\overline{nl}_1, \underline{nl}_2) & B_3 &= B(\underline{nl}_3) \\ A_4 &= A(\overline{nl}_1, \overline{nl}_2) & B_4 &= B(\overline{nl}_3) \\ A_5 &= A(\overline{nl}_1, \underline{nl}_2) & B_5 &= B(\underline{nl}_3) \\ A_6 &= A(\underline{nl}_1, \underline{nl}_2) & B_6 &= B(\underline{nl}_3) \\ A_7 &= A(\underline{nl}_1, \overline{nl}_2) & B_7 &= B(\overline{nl}_3) \\ A_8 &= A(\overline{nl}_1, \overline{nl}_2) & B_8 &= B(\overline{nl}_3) \end{aligned} \quad (2-26)$$

Por último, el modelo T-S puede escribirse como en la Ec.2-27, aunque al desarrollarlo se factorizan las variables de estado y entrada para no ponderarlas.

$$\begin{aligned} \dot{x} &= \sum_{i=1}^8 \phi_i(z)(A_i x + B_i u) \\ y &= Cx \end{aligned} \quad (2-27)$$

2.1.2. Linealización

A diferencia del enfoque del sector no lineal, el método de linealización de los sistemas T-S consiste en aproximar términos no lineales eligiendo juiciosamente términos lineales, reduciendo así el número de reglas [Rotondo \(2017\)](#). Sin embargo, al aproximar los términos no lineales, el modelo T-S obtenido no representa exactamente la dinámica del modelo no lineal original.

Al igual que el enfoque del sector no lineal, mediante el método de linealización se pueden representar procesos no lineales como el dado en la Ec.(2-2) y llegar a la forma de un modelo T-S de la forma:

$$\begin{aligned} \dot{x} &= \sum_{i=1}^m \phi_i(z)(A_i x + B_i u + a_i) \\ y &= \sum_{i=1}^m \phi_i(z)(C_i x + c_i) \end{aligned} \quad (2-28)$$

La diferencia radica en cómo se obtienen las funciones de pertenencia y las matrices A_i , B_i , C_i , a_i y c_i . Por ejemplo, considere el modelo no lineal dado en la Ec.2-29.

$$\dot{x} = \begin{bmatrix} x_1^2 x_2 - 4x_2^2 + x_1 u \\ -4x_1 + x_1 x_2^2 + u \end{bmatrix} \quad (2-29)$$

$$y = [x_1^2 + x_2]$$

Este modelo se puede representar en la forma dada en la Ec.(2-2). Por lo tanto, se puede obtener un modelo T-S mediante el método de linealización. Para ello, las matrices A_i , B_i , C_i , E_i y D_i se obtienen como sigue:

$$A_i = \left. \frac{\partial f}{\partial x} \right|_{z_{0,i},0} ; B_i = \left. \frac{\partial f}{\partial u} \right|_{z_{0,i},0} ; C_i = \left. \frac{\partial h}{\partial x} \right|_{z_{0,i},0}$$

$$a_i = f(x, u)|_{z_{0,i},0} - A_i x|_{z_{0,i},0} - B_i u|_{z_{0,i},0} \quad (2-30)$$

$$c_i = h(x)|_{z_{0,i},0} - C_i x|_{z_{0,i},0}$$

donde z es el vector de programación que determina cuáles de las reglas se activan en cierto momento, y $\phi_i(z)$, $i = 1, 2, \dots, m$ son las funciones de pertenencia normalizadas. El punto crítico del método de linealización es elegir el número suficiente m de puntos de linealización $z_{0,i}$, $i = 1, 2, \dots, m$, junto con una partición del espacio donde se definen las variables programadas, y las funciones de pertenencia correspondientes $\phi_{ij}(z)$, $i = 1, 2, \dots, m$. Por lo tanto, al aumentar el número de puntos de linealización, aumenta la precisión de la aproximación del modelo T-S. Veamos el ejemplo dado en la Ec.(2-29), donde f y h son:

$$f(x, u) = \begin{bmatrix} x_1^2 x_2 - 4x_2^2 + x_1 u \\ -4x_1 + x_1 x_2^2 + u \end{bmatrix} \quad (2-31)$$

$$h(x) = x_1^2 + x_2$$

de donde se puede observar que las variables de programación están relacionadas con el vector de estados \dot{x} , es decir $z = [x_1, x_2]^T$.

Para este ejemplo, los puntos de linealización se eligen como sigue:

$$\{(x_1, x_2) | x_1, x_2 \in \{-1, 0, 1\}\} \quad (2-32)$$

Por lo tanto, se pueden elegir funciones de pertenencia triangulares o normalizadas que tienen su máximo en los puntos de linealización, para cada variable programada. Por ejemplo, las

2. Marco teórico

funciones de pertenencia correspondientes a la variable programada $z_1 = x_1$ son:

$$\begin{aligned}\phi_{11}(z_1) &= \begin{cases} -z_1, & \text{si } z_1 \leq 0 \\ 0, & \text{otro caso} \end{cases} \\ \phi_{21}(z_1) &= 1 - |z_1| \\ \phi_{31}(z_1) &= \begin{cases} z_1, & \text{si } z_1 \geq 0 \\ 0, & \text{otro caso} \end{cases}\end{aligned}\tag{2-33}$$

mientras que para $z_2 = x_2$ son:

$$\begin{aligned}\phi_{12}(z_2) &= \begin{cases} -z_2, & \text{si } z_2 \leq 0 \\ 0, & \text{otro caso} \end{cases} \\ \phi_{22}(z_2) &= 1 - |z_2| \\ \phi_{32}(z_2) &= \begin{cases} z_2, & \text{si } z_2 \geq 0 \\ 0, & \text{otro caso} \end{cases}\end{aligned}\tag{2-34}$$

Los valores de las derivadas de las ecuaciones de estado con respecto al vector de programación son:

$$\begin{aligned}\frac{\partial f}{\partial x} &= \begin{bmatrix} 2x_1x_2 + u & x_1^2 - 8x_2 \\ -4 + x_2^2 & 2x_1x_2 \end{bmatrix}; \quad \frac{\partial f}{\partial u} = \begin{bmatrix} x_1 \\ 1 \end{bmatrix}; \quad \frac{\partial h}{\partial x} = [x_1 \ 0] \\ a_i &= \begin{bmatrix} 4x_2^2 - 2x_1^2x_2 - x_1u \\ 2x_1x_2^2 \end{bmatrix}\end{aligned}\tag{2-35}$$

$$c_i = -x_1^2$$

Estas matrices se evalúan mediante los puntos de linealización seleccionados, mostrados en la Ec.(2-32). Entonces, por cada regla (del tipo *si – entonces*), existe un modelo matemático lineal. Por ejemplo, la regla del primer modelo difuso es:

$$\begin{aligned}\text{si } z_1 \text{ es } -1 \text{ y } z_2 \text{ es } -1 \\ \text{entonces } \begin{cases} \dot{x} = A_1x + B_1u \\ y = C_1x \end{cases}\end{aligned}\tag{2-36}$$

donde

$$\begin{aligned}A_1 = \left. \frac{\partial f}{\partial x} \right|_{z_{0,1,0}} = \begin{bmatrix} 2 & 9 \\ -3 & 2 \end{bmatrix}; \quad B_1 = \left. \frac{\partial f}{\partial u} \right|_{z_{0,1,0}} = \begin{bmatrix} -1 \\ 1 \end{bmatrix}; \quad C_1 = \left. \frac{\partial h}{\partial x} \right|_{z_{0,1,0}} = [-2 \ 1] \\ a_1 = f(x, u)|_{z_{0,1,0}} - A_1x|_{z_{0,1,0}} - B_1u|_{z_{0,1,0}} = \begin{bmatrix} 6 \\ -2 \end{bmatrix}\end{aligned}\tag{2-37}$$

$$c_1 = h(x)|_{z_{0,1,0}} - C_1x|_{z_{0,1,0}} = 1$$

donde $z_{0,1} = (-1, -1)$, y la función de ponderación $\phi_1(z)$ se compone de las funciones de pertenencia η_1^0 y η_2^0 mediante la siguiente regla se compone como $\phi_1(z) = \eta_1^0 \eta_2^0$. Las funciones de pertenencia restantes que conforman al modelo T-S son:

$$\begin{aligned} \phi_1(z) &= \eta_1^0 \eta_2^0; & \phi_4(z) &= \eta_1^1 \eta_2^0; & \phi_7(z) &= \eta_1^2 \eta_2^0; \\ \phi_2(z) &= \eta_1^0 \eta_2^1; & \phi_5(z) &= \eta_1^1 \eta_2^1; & \phi_8(z) &= \eta_1^2 \eta_2^1; \\ \phi_3(z) &= \eta_1^0 \eta_2^2; & \phi_6(z) &= \eta_1^1 \eta_2^2; & \phi_9(z) &= \eta_1^2 \eta_2^2; \end{aligned} \quad (2-38)$$

Por último, el modelo T-S mediante el método de linealización se escribe de la forma:

$$\begin{aligned} \dot{x} &= \sum_{i=1}^9 \phi_i(z)(A_i x + B_i u + a_i) \\ y &= \sum_{i=1}^9 \phi_i(z)(C_i x + c_i) \end{aligned} \quad (2-39)$$

Se han mencionado los principales métodos de los sistemas T-S para representar procesos no lineales, logrando ambos una representación lineal a partir del modelo no lineal del proceso. El primero, el enfoque del sector no lineal tiene como principal característica la representación de forma exacta al modelo no lineal, mientras que el segundo método de linealización logra una representación casi exacta.

2.2. Observadores Takagi-Sugeno

La tarea principal de un observador es la reconstrucción y estimación del valor de una variable, parámetro o estado a partir de que éstos sean medibles o no. Por ello, se les conoce como sensores virtuales. En esta sección, se menciona la teoría para el diseño de observadores de estado mediante los sistemas Takagi-Sugeno del tipo:

$$\begin{aligned} \dot{x} &= \sum_{i=1}^m \phi_i(z)(A_i x + B_i u + a_i) \\ y &= \sum_{i=1}^m \phi_i(z)(C_i x + c_i) \end{aligned} \quad (2-40)$$

En el diseño de observadores de estado T-S, se considera el uso del modelo matemático del proceso y las mediciones de entrada y salida disponibles en él. Estos observadores pueden representar procesos no lineales como el dado en la Ec.(2-2), donde se nota que el observador T-S tiene una estructura similar al observador de Luenberger. Para los observadores T-S se busca una ganancia para cada submodelo lineal que se genera, es decir, una ganancia L_i donde $i = 1, 2, \dots, m$, como se expresa en la Ec.(2-2). La particularidad de los observadores T-S de estado radica en verificar que si el vector de variables programadas z_j depende o no de los estados medibles del proceso [Lendek et al. \(2011\)](#). A partir de ello, se pueden generar dos casos:

1. Cuando el vector de variables programadas depende de los estados conocidos, es decir, en el observador las variables de programación son conocidas y pueden ser usadas. Por lo

tanto, la estructura del observador para el sistema 2-40 tiene la siguiente forma:

$$\begin{aligned}\dot{\hat{x}} &= \sum_{i=1}^m \phi_i(z)(A_i \hat{x} + B_i u + a_i + L_i(y - \hat{y})) \\ \hat{y} &= \sum_{i=1}^m \phi_i(z)(C_i \hat{x} + c_i)\end{aligned}\tag{2-41}$$

donde \hat{x} es el vector de estado estimado, u es el vector de entrada, \hat{y} es el vector de estimación de la salida, L_i las ganancias del observador y las matrices A_i , B_i , C_i , a_i y c_i son matrices de dimensiones apropiadas. Note que el vector de ganancias programadas z al tener acceso a todos los estados no es necesario estimarlo.

2. Cuando el vector de variables programadas depende de los estados desconocidos, las variables de programación no son conocidas. Por lo tanto, no pueden ser usadas y deben de estimarse. Por consiguiente, la estructura del observador tiene la siguiente forma:

$$\begin{aligned}\dot{\hat{x}} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i \hat{x} + B_i u + a_i + L_i(y - \hat{y})) \\ \hat{y} &= \sum_{i=1}^m \phi_i(\hat{z})(C_i \hat{x} + c_i)\end{aligned}\tag{2-42}$$

Al igual que en el observador de la Ec.(2-41), \hat{x} es el vector de estado estimado, u es el vector de entrada, \hat{y} es el vector de estimación de la salida, L_i las ganancias del observador y las matrices A_i , B_i , C_i , a_i y c_i son matrices de dimensiones apropiadas. La diferencia se observa en el vector de ganancias programadas z . Como no se tiene acceso a todos los estados, se necesita estimar el vector de las ganancias programadas y se denota como \hat{z} .

En los procesos no lineales, es difícil tener acceso a todas las mediciones de las variables de estado. Por lo que, en lo subsecuente este trabajo utiliza el caso dos para el diseño de un observador u observadores de estado. En principio, el uso de un solo observador puede permitir el aislamiento de fallas si su efecto tiene consecuencias independientes sobre el espacio residual Zhang et al. (2016). Sin embargo, si el sistema tiene no linealidades severas, es difícil asegurar esta independencia. Por lo tanto, una alternativa es el uso de un banco de observadores para aislar las fallas que ocurran en diferentes componentes del proceso en el mismo instante de tiempo. Los diferentes esquemas de bancos de observadores, se muestran a continuación:

1. **Esquema de observadores dedicados.** En el esquema de observadores dedicados los n observadores están diseñados para generar n residuos y se espera que el residuo i sea solo sensible a la falla i , pero que sea insensible a los demás. Por ejemplo, en la Fig.2-1a se muestra un esquema de observadores dedicados para detectar y aislar fallas en actuadores. En la Fig.2-1b es un esquema de observadores dedicados para fallas en sensores. En ambas Figs.(2-1a y 2-1b), las líneas gruesas representan un vector mientras que las delgadas una sola variable de ese vector.

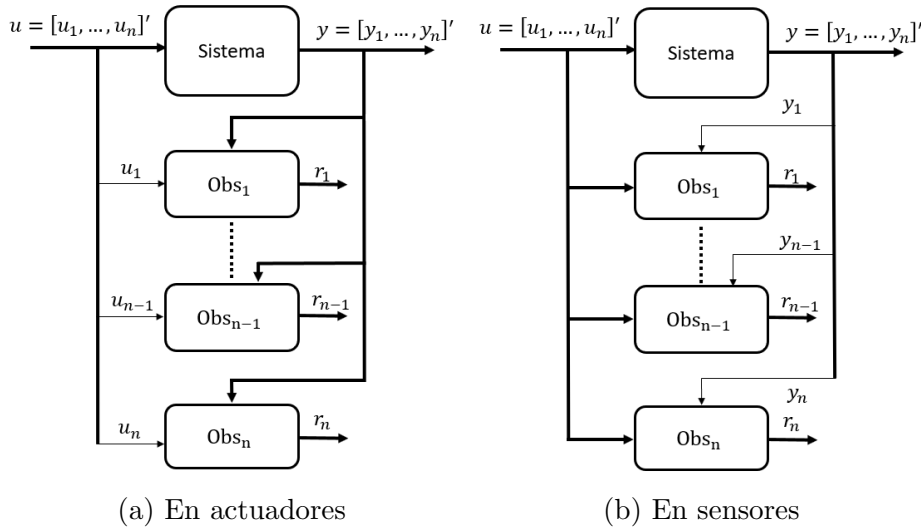


Figura 2-1.: Esquemas de observadores dedicados para fallas en actuadores y sensores.

2. **Esquema de observadores generalizado.** En el esquema de observadores generalizados, los n observadores también están diseñados para que produzcan n residuos. Sin embargo, la diferencia es que el i -ésimo observador es sensible a todas las fallas posibles, excepto la i -ésima falla. Por ejemplo, en la Fig. 2-2a se muestra un esquema de observadores generalizados para detectar y aislar fallas en actuadores, del cual el observador uno es sensible a todas las fallas excepto a la primera. En la Fig. 2-2b se tiene un esquema de observadores generalizados para detectar y localizar fallas en sensores, del cual el observador n es sensible a todas las fallas excepto a la falla n . En ambas Figs.(2-2a y 2-2b), las líneas gruesas representan un vector mientras que las delgadas una sola variable de ese vector.

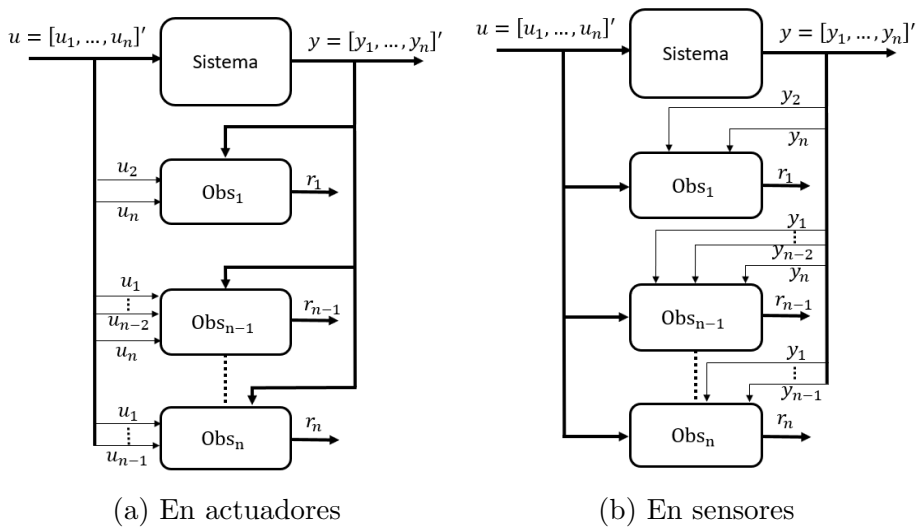



Figura 2-2.: Esquema de observadores generalizados para fallas en actuadores y sensores.

Una representación difusa T-S de un proceso no lineal, permite que en el diseño de esquemas de observadores dedicados o generalizados se pueda utilizar toda la teoría existente para sistemas lineales.

2.3. Redes neuronales artificiales

Las Redes Neuronales Artificiales (RNA) surgieron del estudio de las Redes Neuronales Biológicas (RNB). En la Fig. 2-3a se muestra una RNB simplificada, la cual básicamente está conformada por:

- **Soma**, es la parte central de la neurona en la que se realizan casi todas las funciones lógicas. En ella se encuentra el mecanismo genético y metabólico que mantiene viva a la neurona, así como la síntesis de proteínas.
- **Axón**, es un nervio conectado al soma, que está altamente ramificado. En el segmento inicial del axón, la señal se transforma en impulsos nerviosos los cuales se propagan sin atenuación a células receptoras, musculares, o bien, otras neuronas.
- **Dendritas**, son ramificaciones densas de fibras nerviosas largas y de forma irregular que están conectadas al soma. Las dendritas reciben señales de otras neuronas por medio de un contacto especializado conocido como sinapsis.
- **Sinapsis**, son puntos terminales de los axones de otras neuronas. Las cuales tienen la habilidad de incrementar o atenuar la excitación de la neurona.



(a) Red neuronal biológica [Reyes Reyes \(2001\)](#) (b) Estructura de una red neuronal McCulloch y Pitts

Figura 2-3.: RNA y RNB

Por otra parte, una RNA es el modelo matemático simplificado de una RNB. Basados en esta idea, en 1948 W. McCulloch y W. Pitts presentaron la estructura de una RNA. En la Fig.

2-3b, se muestra una RNA donde u_{RN1} , u_{RN2} y u_{RNn} representan las entradas de la RNA, ω_1 , ω_2 y ω_n , son los pesos sinápticos de cada entrada de la neurona, θ , es el umbral, $\varphi(\cdot)$ es la función de activación, y_{RN} es la salida de la neurona. Algunas funciones de activación son la sigmoide, la tangente, tangente hiperbólica y otras funciones de base radial, las cuales son parte fundamental del algoritmo de aprendizaje de las RNA. Las RNA se pueden clasificar en:

- **Redes neuronales estáticas** son aquellas que no forman lazos de retroalimentación.
- **Redes neuronales recurrentes** son aquellas que forman lazos de retroalimentación.

La arquitectura de una RNA determina la distribución de neuronas dentro de ella, formando niveles o capas de neuronas Verde et al. (2013). Por lo tanto, existen diferentes modelos de RNA como el McCullochPitt, perceptrón y el modelo de retropropagación.

La versatilidad en el diseño de una RNA las ha hecho una herramienta poderosa en la resolución de múltiples problemas.

2.3.1. Estimación de fallas mediante redes neuronales

En la detección y localización de fallas, el diseño de una RNA se enfoca en la detección de las desviaciones no permitidas en los parámetros del proceso. Por ejemplo, considere el siguiente sistema:

$$\Sigma_{f_{ABC}} : \begin{cases} \dot{x} = (A_0 + \Delta_A)x + (B_0 + \Delta_B)u \\ y = (C_0 + \Delta_C)x \end{cases} \quad (2-43)$$

donde A_0 , B_0 y C_0 corresponde a la parte sin falla del sistema, Δ_A , Δ_B y Δ_C a la parte con falla del sistema es desconocido. Por consiguiente, se tienen las siguientes suposiciones:

1. **Suposición 1.-** Se considera que en el sistema (2-43) se tiene acceso completo al estado, es decir, C_0 es una matriz identidad, por lo que $y = x$. Entonces, el sistema se considera libre de fallas en sensores, es decir, $\Delta_C = 0$.
2. **Suposición 2** La parte desconocida donde se puedan presentar las fallas en el proceso o sistema son acotadas y solo se conoce la norma euclidiana de ésta. Por ejemplo, para el término $\Delta_A(t)$ es acotada, y solo se conoce que la norma euclidiana de la incertidumbre es menor o igual que un valor dado denominado $\delta_A(x)$, es decir, $\|\Delta_A(x)\|$ tiene como cota superior el valor $\delta_A(t)$. Esto se representa por la Ec.(2-44) y el valor de $\delta_A(x)$ es conocido o seleccionado por diseño.

$$\|\Delta_A(x)\| \leq \delta_A(x) \quad (2-44)$$

A partir de la suposición 1 se tiene que el sistema (2-43) se reescribe de la siguiente forma:

$$\Sigma_{f_{AB}} : \begin{cases} \dot{x} = (A_0 + \Delta_A)x + (B_0 + \Delta_B)u \\ y = x \end{cases} \quad (2-45)$$

Por lo anterior, se desprenden dos casos:

Fallas en actuadores

Partiendo de la expresión (2-45), la posibilidad de que se presente una falla en actuadores se representa de la siguiente manera:

$$\Delta_B \neq 0 \text{ y } \Delta_A = 0$$

de tal forma que el modelo de la Ec.(2-45) se reescribe de la siguiente forma:

$$\Sigma_{f_B} : \begin{cases} \dot{x} = (A_0)x + (B_0 + \Delta_B)u \\ y = x \end{cases} \quad (2-46)$$

donde la parte sin falla de la matriz B se representa por B_0 , mientras que la parte con una o varias fallas se representa por $\Delta_B(t)$.

Fallas en proceso

La posibilidad de que se presente una falla en actuadores se representa de la siguiente manera:

$$\Delta_A \neq 0 \text{ y } \Delta_B = 0.$$

Por lo tanto, el modelo de la Ec.(2-45) se reescribe de la siguiente forma:

$$\Sigma_{f_A} : \begin{cases} \dot{x} = (A_0 + \Delta_A)x + B_0u \\ y = x \end{cases} \quad (2-47)$$

donde la parte sin falla de la matriz A se representa por A_0 y la parte con una o varias fallas se representa por $\Delta_A(t)$.

Dadas las suposiciones 1 y 2, el siguiente paso es el análisis de estabilidad de la RNA. Para ello, se elige el caso donde se presenta fallas en el proceso.

2.3.2. Red neuronal dinámica propuesta

El modelo matemático propuesto para la RND que aprende el comportamiento del modelo mostrado en la Ec.(2-47) es:

$$\widehat{\Sigma}_A : \begin{cases} {}^A\dot{\hat{x}} = A_0x + Q_A W_A \varphi_A({}^A\hat{x}) + \psi_A + B_0u + L_A(y - \hat{y}_A) \\ \hat{y}_A = {}^A\hat{x} \end{cases} \quad (2-48)$$

El término $Q_A W_A \varphi_A({}^A\hat{x}) + \psi_A$ del modelo matemático de la RNA permite la identificación del término Δ_A correspondiente a la Ec. (2-47), siendo φ_A una tangente hiperbólica. Mientras que el término $L_A(y - \hat{y}_A)$ de la RNA permite garantizar que el error de identificación sea

estable mediante un valor adecuado para L_A .

El análisis estilo Lyapunov es una herramienta popular para demostrar la estabilidad de un sistema, y para el caso de una RN también. En este análisis se propone una función V que sea definida positiva y que su derivada \dot{V} sea definida negativa, con el fin de garantizar la estabilidad del sistema.

La función candidata de Lyapunov propuesta para el análisis de estabilidad de la RNA dada en la Ec.(2-48) se muestra a continuación:

$$V(e_A, W) := \frac{1}{2}e_A^T e_A + \frac{1}{2}tr\langle W\xi^{-1} \cdot W^T \rangle \quad (2-49)$$

donde

$$\xi^{-1} = (\xi^{-1})^T > 0 \quad (2-50)$$

y la derivada de Ec.(2-49) es

$$\dot{V}(e_A, W) := e_A^T \dot{e}_A + tr\langle W\xi^{-1} \cdot \dot{W}^T \rangle \quad (2-51)$$

Ahora partiendo de que el error está dado por la siguiente expresión:

$$e_A = x - {}^A\hat{x} \quad (2-52)$$

y su derivada

$$\dot{e}_A = \dot{x} - {}^A\dot{\hat{x}} \quad (2-53)$$

Sustituyendo a \dot{x} y ${}^A\dot{\hat{x}}$ en la Ec.(2-53) tenemos que:

$$\begin{aligned} \dot{e}_A &= A_0x + \Delta_A(t){}^A\hat{x} + B_0u - [A_0x + Q_A W_A \varphi_A({}^A\hat{x}) + \psi_A + B_0u + L_A(y - \hat{y}_A)] \\ \dot{e}_A &= A_0x + \Delta_A(t){}^A\hat{x} + B_0u - A_0x - Q_A W_A \varphi_A({}^A\hat{x}) - \psi_A - B_0u - L_A(y - \hat{y}_A) \\ \dot{e}_A &= \Delta_A(t){}^A\hat{x} - Q_A W_A \varphi_A({}^A\hat{x}) - \psi_A - L_A(y - \hat{y}_A) \end{aligned} \quad (2-54)$$

Ahora sustituyendo \dot{e}_A en la Ec.(2-49)

$$\dot{V}(e_A, W) := e_A^T \dot{e}_A + tr\langle W\xi^{-1} \cdot \dot{W}^T \rangle$$

se tiene que

$$\dot{V}(e_A, W) := e_A^T [\Delta_A(t){}^A\hat{x} - Q_A W_A \varphi_A({}^A\hat{x}) - \psi_A - L_A(y - \hat{y}_A)] + tr\langle W\xi^{-1} \cdot \dot{W}^T \rangle$$

$$\dot{V}(e_A, W) := e_A^T \Delta_A(t){}^A\hat{x} - e_A^T Q_A W_A \varphi_A({}^A\hat{x}) - e_A^T \psi_A - e_A^T L_A(y - \hat{y}_A) + tr\langle W\xi^{-1} \cdot \dot{W}^T \rangle \quad (2-55)$$

2. Marco teórico

de la Ec.(2-55) se toman los términos $-e^T Q_A W_A \varphi_A({}^A \hat{x})$ y $tr\langle W \xi^{-1} \cdot \dot{W}^T \rangle$ y aplicando las propiedades de la traza de una matriz, se tiene que:

$$\begin{aligned} & -e_A^T Q_A W_A \varphi_A({}^A \hat{x}) + tr\langle W \xi^{-1} \cdot \dot{W}^T \rangle \\ & -tr\langle Q_A W_A \varphi_A({}^A \hat{x}) e_A^T \rangle + tr\langle W \xi^{-1} \cdot \dot{W}^T \rangle \\ & tr\langle W [-\varphi_A({}^A \hat{x}) e_A^T Q_A + \xi^{-1} \dot{W}^T] \rangle \end{aligned} \quad (2-56)$$

Dadas las manipulaciones anteriores, se reescribe la Ec.(2-55) quedando de la siguiente forma:

$$\dot{V}(e_A, W) := e_A^T \Delta_A(t) {}^A \hat{x} - e_A^T \psi_A - e_A^T L_A (y - \hat{y}_A) + tr\langle W [-\varphi_A({}^A \hat{x}) e_A^T Q_A + \xi^{-1} \dot{W}^T] \rangle \quad (2-57)$$

A continuación, si se escoge el algoritmo de aprendizaje como

$$\dot{W}^T = \xi^{-1} \varphi_A({}^A \hat{x}) e_A^T Q_A \quad (2-58)$$

y se sustituye en el término (2-57). Una parte de la ecuación se simplifica y se obtiene:

$$\dot{V}(e_A, W) = e_A^T \Delta_A(t) {}^A \hat{x} - e_A^T \psi_A - e_A^T L_A (y - \hat{y}_A) \quad (2-59)$$

Tomando el término $e_A^T \Delta_A(t) {}^A \hat{x}$ de la Ec.(2-59) y aplicándole la propiedad de la norma, $a^T b \leq \|a\| \cdot \|b\|$, se obtiene

$$e_A^T \delta_A(t) {}^A \hat{x} \leq \|e_A\|_1 \|\Delta_A(t) {}^A \hat{x}\| \quad (2-60)$$

y mediante la propiedad de la norma, $\|a\|_1 = a^T \cdot \text{sign}(a)$, se tiene que $\|e_A\|_1 = e_A^T \text{sign}(e_A)$, por lo tanto

$$e_A^T \delta_A(t) {}^A \hat{x} \leq e_A^T \text{sign}(e) \|\Delta_A(t) {}^A \hat{x}\| \quad (2-61)$$

Sustituyendo la cota superior del término (2-61) en (2-59) se obtiene

$$\dot{V}(e_A, W) \leq e_A^T \text{sign}(e_A) \|\Delta_A(t) {}^A \hat{x}\| \cdot \|x\| - e_A^T \psi - e_A^T L e_A$$

$$\dot{V}(e_A, W) \leq e_A^T [\text{sign}(e_A) \delta_A \cdot \|x\| - \psi] - e_A^T L e_A \quad (2-62)$$

entonces se elige el valor de

$$\psi = \text{sign}(e_A) \delta_A \cdot \|x\| \quad (2-63)$$

y se reescribe como:

$$\dot{V}(e_A, W) \leq -e_A^T L e_A \quad (2-64)$$

Por último, en el análisis de estabilidad se debe de asegurar que:

$$L_A = L_A^T > \mathbf{0} \quad (2-65)$$

Con ello se garantiza que la derivada de la función candidata de Lyapunov propuesta sea definida negativa, es decir

$$\dot{V}(e_A, W) \leq 0 \quad (2-66)$$

por lo tanto, se concluye que el error de identificación $e_A = x - {}^A \hat{x}$ es estable.

2.4. Detección y localización de fallas

Se parte de la definición de **falla** [Isermann and Ballé \(1997\)](#) proporcionada por la IFAC como una desviación no permitida de una propiedad característica o parámetro del proceso que generó su mal funcionamiento. Existen diferentes clasificaciones de fallas, por ejemplo, de acuerdo al lugar donde se presentan se pueden clasificar como fallas en sensores, actuadores y componentes del proceso [Blanke and Schröder \(2006\)](#). Otra clasificación ampliamente utilizada es la realizada en [Isermann and Ballé \(1997\)](#), la cual menciona las tres principales clases:

1. **Fallas de medición aditivas**, las cuales son discrepancias entre los valores reales y medidos de las entradas y salidas de la planta. Estas fallas principalmente describen las desviaciones de las mediciones proporcionadas por los sensores, también pueden usarse para describir un mal funcionamiento en los actuadores.
2. **Fallas de proceso aditivas**, son perturbaciones (entradas no medidas) que actuando sobre la planta causan una desviación en las salidas independientes de las entradas medidas.
3. **Fallas de proceso multiplicativas**, son cambios (abruptos o graduales) de los parámetros de la planta. Estas fallas describen adecuadamente el deterioro del equipo de la planta.

En la Fig.2-4, se muestra un sistema en el cual se pudieran presentar las fallas mencionadas con anterioridad.

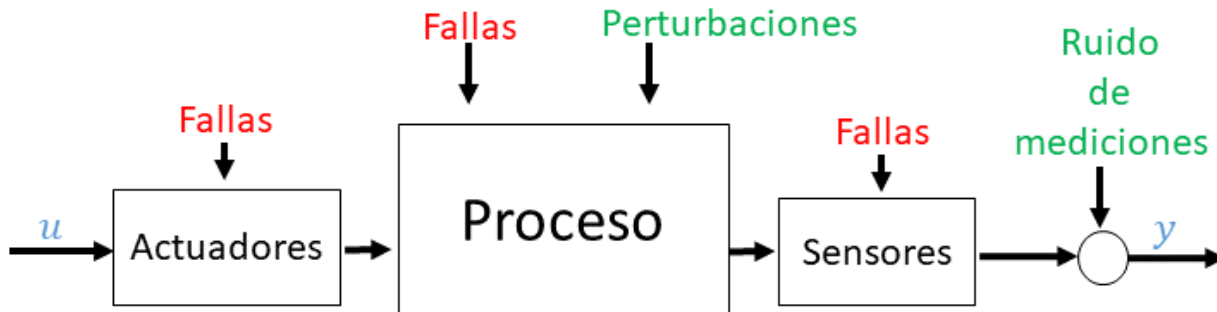


Figura 2-4.: Esquema descriptivo de un sistema con posibles fallas.

En la práctica, las fallas en el proceso o sensores y actuadores causan cambios en los parámetros del modelo [Ding \(2008\)](#). Éstos pueden ser modelados como se muestra en la Ec.(2-67).

$$\begin{aligned} \dot{x} &= (A_0 + \Delta_A)x + (B_0 + \Delta_B)u \\ y &= (C_0 + \Delta_C)x + Du \end{aligned} \quad (2-67)$$

2. Marco teórico

donde Δ_A , Δ_B y Δ_C corresponden a la desviación de los parámetros con respecto a sus valores nominales; y A_0 , B_0 y C_0 corresponden a los valores nominales del sistema. Para tomar decisiones ante la presencia de estas fallas que se pudieran presentar en los sistemas, la IFAC en [Isermann and Ballé \(1997\)](#) estableció una serie de tareas que se describen a continuación:

Detección de fallas Consiste en determinar la presencia de fallas en el proceso y el tiempo de su detección.

Aislamiento de fallas Determinación del tipo, localización y tiempo de la detección de la falla.

Identificación de fallas Es la determinación del tamaño y comportamiento variable en el tiempo de la falla.

Diagnóstico de fallas Determinación del tipo, tamaño, localización y tiempo de detección de la falla.

En conjunto, estas tareas forman un sistema de detección y diagnóstico de fallas FDD (por las siglas en inglés de Fault Detection and Diagnosis) [Blanke and Schröder \(2006\)](#). Pero solo cuando se conjuntan las tres primeras tareas se tiene un sistema de detección e identificación/localización de fallas FDI (por las siglas en inglés Fault Detection and Isolation) [Isermann \(2005\)](#); siendo este último tema la inspiración para la elaboración del sistema neurolocalizador de fallas.

Ahora bien, el diseño de un sistema FDD, depende de las características del proceso y las necesidades que se desean cubrir. Para ello, un sistema FDD puede realizarse empleando mediante redundancia material o redundancia analítica, las cuales se describen a continuación:

- **Redundancia material**, se basa en métodos de redundancia física o de hardware, los cuales emplean múltiples sensores, actuadores, componentes de medición y control de una variable en particular. El mayor problema de este método es el costo de mantenimiento y del equipo adicional, así como el espacio requerido para dichos instrumentos [Höfling and Isermann \(1996\)](#).
- **Redundancia analítica**, se basa en la diferencia generada por la comparación de valores medidos; esta diferencia se llama señal residual o síntoma. La mayor ventaja de un enfoque basado en modelos es que no requiere hardware adicional para realizar la detección de fallas y puede implementarse vía software en un proceso controlado por computadora. La redundancia analítica que hace uso de un modelo matemático del sistema bajo investigación se refiere frecuentemente como un enfoque basado en modelos.

Para el diseño del sistema neurolocalizador de fallas, se utiliza la redundancia analítica del proceso. En el proceso de fermentación, la medición de múltiples variables implica el uso de múltiples sensores y esto resultaría costoso. Por ello, se utilizan sensores virtuales para la estimación de los estados del proceso y se genera un banco de observadores difusos T-S desarrollados para la generación de residuos.

2.5. Caso de estudio

En esta sección, se presenta el modelo no lineal de un proceso de fermentación alcohólica. El modelo se basa en el balance de energía y balance de masas del proceso. Las dinámicas del proceso se muestran primeramente en lazo abierto con la finalidad de observar el equilibrio que proporciona dichos balances. Posteriormente, el modelo no lineal se representa de forma difusa mediante el enfoque del sector no lineal de los sistemas Takagi-Sugeno. Finalmente, se diseña un controlador de temperatura para el seguimiento de trayectoria del proceso con el objetivo de analizar el comportamiento del proceso.

2.5.1. Modelo no lineal de un proceso de fermentación alcohólica

En una fermentación alcohólica, el balance de masa enuncia la transformación de la materia prima durante el desarrollo del proceso. Esto se lleva a cabo mediante el acoplamiento del sustrato, el catalizador y el producto generado, así como las variables que se derivan durante el proceso como puede ser la concentración de oxígeno en la reacción, etc. Por otra parte, el balance de energía en una fermentación alcohólica permite relacionar la parte térmica del proceso con la del medio donde se desarrolla, es decir, expresar la relación entre la liberación o absorción de calor que se genera en la reacción. Para ello, existen diferentes expresiones. La más usada es la ecuación de Arrhenius y la ecuación de Monod, las cuales se describen a continuación:

- La ecuación de Arrhenius enuncia la dependencia de la reacción con respecto a la temperatura mediante la siguiente expresión:

$$k = ae^{-\frac{E_a}{RT}} \quad (2-68)$$

donde k es la tasa de la reacción química, a es el factor pre-exponencial, E_a es la energía de activación, R la constante de gases y T la temperatura en Kelvin.

- La ecuación de Monod, a diferencia de la ecuación de Arrhenius, se vincula con la transformación de la materia prima en el producto deseado mediante la siguiente expresión:

$$\mu = \frac{\mu_{max}S}{K_S + S} \quad (2-69)$$

donde μ es la tasa específica de crecimiento en la reacción, μ_{max} es la tasa específica máxima de crecimiento en la reacción, S es la concentración de sustrato, y K_S es el término constante del sustrato para el crecimiento de la levadura.

Existen diferentes modelos matemáticos que representan la dinámica de un proceso de fermentación alcohólica, pero que solo optan por utilizar ya sea la ecuación de Arrhenius o la de Monod. Pocos modelos son reportados conjugando de ambas ecuaciones. Tal es el caso del

2. Marco teórico

modelo presentado en Zoltan-Kalman (2007), donde consideran ambas ecuaciones para los balances de masa y energía de un proceso de fermentación alcohólica que se lleva a cabo en un reactor de tanque agitado continuo con una alimentación de sustrato constante. El modelo matemático se representa en las Ecs.((2-70) – (2-75)), que representan la concentración de biomasa (levaduras) c_X , la concentración del producto (etanol) c_P , la concentración del sustrato (glucosa) c_S , la concentración de oxígeno en la fase líquida c_{O_2} , la temperatura dentro del reactor T_r , y la temperatura en la chaqueta térmica T_c , respectivamente.

$$\frac{dc_X}{dt} = \mu_X c_X \frac{c_S}{K_S + c_S} e^{-K_p c_P} - \frac{F_{out}}{V} c_X \quad (2-70)$$

$$\frac{dc_P}{dt} = \mu_p c_X \frac{c_S}{K_{S1} + c_S} e^{-K_{p1} c_P} - \frac{F_{out}}{V} c_P \quad (2-71)$$

$$\frac{dc_S}{dt} = -\frac{1}{R_{SX}} \mu_X c_X \frac{c_S}{K_S + c_S} e^{-K_p c_P} - \frac{1}{R_{SP}} \mu_p c_X \frac{c_S}{K_{S1} + c_S} e^{-K_{p1} c_P} + \frac{F_{in}}{V} c_{S,in} - \frac{F_{out}}{V} c_S \quad (2-72)$$

$$\frac{dc_{O_2}}{dt} = k_{la}(c_{O_2EL} - c_{O_2}) - r_{O_2} \quad (2-73)$$

$$\frac{dT_r}{dt} = \frac{F_{in}}{V} (T_{r,in} + 273) - \frac{F_{out}}{V} (T_r + 273) + \frac{r_{O_2} \Delta H_r}{32 \rho_r C_{heat,r}} + \frac{K_T A_T (T_r - T_c)}{V \rho_r C_{heat,r}} \quad (2-74)$$

$$\frac{dT_c}{dt} = \frac{F_c}{V_c} (T_{c,in} - T_c) + \frac{K_T A_T (T_r - T_c)}{V_c \rho_c C_{heat,c}} \quad (2-75)$$

donde la tasa específica máxima de crecimiento μ_X y la tasa de oxígeno r_{O_2} se componen por las siguientes expresiones:

$$\mu_X(T_r) = a_1 e^{-\left(\frac{E_{a1}}{R(T_r + 273)}\right)} - a_2 e^{-\left(\frac{E_{a2}}{R(T_r + 273)}\right)} \quad (2-76)$$

$$r_{O_2}(c_{O_2}, c_X) = \mu_{O_2} \frac{1}{Y_{O_2}} c_X \frac{c_{O_2}}{k_{O_2} + c_{O_2}} \quad (2-77)$$

La representación de un modelo matemático en espacio de estados es la más adecuada para aplicaciones de control. Por lo tanto, las variables de estado del modelo presentado son la concentración de biomasa (levaduras) c_X , la concentración del producto (etanol) c_P , la concentración del sustrato (glucosa) c_S , la concentración de oxígeno en la fase líquida c_{O_2} , la temperatura dentro del reactor T_r y la temperatura en la chaqueta térmica T_j .




Figura 2-5.: Esquema de un reactor de fermentaciones alcohólicas.

En la Fig.2-5 se muestra un esquema de la interacción entre el balance de energía y el balance de masas del proceso, que describen al modelo no lineal del proceso de fermentación alcohólica. De dicha interacción se derivan las siguientes observaciones:

Observación 1

El balance de masas se expresa mediante las Ecs.((2-70) – (2-73)) que representan a c_X , c_P , c_S y c_{O_2} , respectivamente. En estas ecuaciones se modela el consumo del sustrato por el catalizador y cuanto éste se transforma en el producto deseado, así como el oxígeno que se encuentra en la fase líquida de la reacción.

Observación 2

El balance de energía se genera mediante el acoplamiento que existe entre T_r y T_c , representado en las Ecs. (2-74) y (2-75), respectivamente. Este acoplamiento representa la estrecha relación que mantienen las temperaturas del reactor y de la chaqueta térmica. Un cambio en cualquiera de las dos temperaturas se ve reflejado en la opuesta, es decir, un incremento en T_r causa un incremento en T_c acorde al incremento presentado en T_r ; y viceversa.

Observación 3

La relación entre el balance de masas y el balance de energía se lleva a cabo mediante el término $\mu_X(T_r)$ expresado en la Ec.3-35. El cual indica la dependencia del catalizador de una temperatura adecuada, para la transformación del sustrato en el producto deseado.

2. Marco teórico

Dadas las Ecs.((2 – 70) – (2 – 75)) que representan el desarrollo de un proceso de fermentación alcohólica desarrollado en un reactor de tanque continuamente agitado y las observaciones anteriores, en la siguiente sección aborda la obtención de un modelo T-S que describa al modelo no lineal dado.

Neurolocalización de fallas

En este capítulo se muestran los detalles de la elaboración del sistema neurolocalizador de fallas en sensores y actuadores. Primeramente, en la sección 3.1 se obtiene el un modelo Takagi-Sugeno del proceso de fermentación alcohólica. La siguiente sección 3.2 toma como base dicho modelo Takagi-Sugeno para el diseño de un banco de observadores, el cual tiene como objetivo extraer información relevante de las fallas en sensores. En cambio, en la sección 3.3 se tiene como principal objetivo extraer información relevante de las fallas en actuadores, esto mediante una red neuronal dinámica. La información recabada en las secciones 3.2 y 3.3 se utiliza para establecer una firma a cada falla en particular como se muestra en la matriz de firmas elaborada en la sección 3.4. Por último, en la sección 3.5 se muestra la estructura general del sistema neurolocalizador de fallas en sensores y actuadores, así como los pormenores de la red neuronal que toma las decisiones para la neurolocalización de fallas.

3.1. Modelo Takagi-Sugeno del proceso de fermentación alcohólica mediante el enfoque del sector no lineal

En esta sección, se obtiene el modelo T-S mediante el enfoque del sector no lineal a partir del modelo no lineal dado en las Ecs.((2-70)–(2-75)). Para ello, considere los pasos mencionados en la sección 2.1.

Paso 1. Considerando el proceso de fermentación alcohólica descrito en las Ecs.((2-70)-(2-75)) y considerando las siguientes suposiciones:

3. Neurolocalización de fallas

- *Suposición 1.* La temperatura del reactor T_r se controla manipulando el flujo del agente de enfriamiento F_c .
- *Suposición 2.* El flujo de alimentación de sustrato en el reactor F_{in} es constante.
- *Suposición 3.* La temperatura de entrada del agente de enfriamiento en la chaqueta térmica T_{cin} y la temperatura en el flujo de alimentación del sustrato en el reactor T_{rin} se asumen como constantes.

El modelo no lineal (2-70-2-75) se representa de la siguiente forma:

$$\begin{aligned}\dot{x} &= A(x)x + B(x)\bar{u} + E \\ y &= Cx\end{aligned}\tag{3-1}$$

donde x es el vector de estados $x = [c_x \ c_P \ c_s \ c_{O_2} \ T_r \ T_c]^T$, $\bar{u} = [F_{in} \ F_c]^T$ es el vector de entradas, $A(x)$, $B(x)$, C son matrices de dimensiones apropiadas y E representa el vector de parámetros constantes u otras variables exógenas que actúan en el sistema. E es equivalente conceptualmente al término a_i dado en el modelo T-S (2-5). Las matrices $A(x)$ y $B(x)$ contienen los términos no lineales dependientes de las variables de estado. La matriz $B(x)$ se puede decomponer en una sección variante en el tiempo y una constante, es decir, $B(x) = [B_{nv} \ B_v(x)]$, donde el sub-índice nv se usa para distinguir la parte no variable y el sub-índice v la parte variable. Por lo tanto, el flujo de entrada del sustrato en el reactor F_{in} se considera como una señal de entrada constante. Mientras que F_c es la variable manipulada y el sistema (3-1) puede ser reescrito como:

$$\begin{aligned}\dot{x} &= A(x)x + [B_{nv} \ B_v(x)]\bar{u} + E \\ y &= Cx\end{aligned}\tag{3-2}$$

Paso 2. Los términos variables en las matrices $A(x)$ y $B_v(x)$ del modelo no lineal (3-1) se encierran en recuadros en las Ecs.((A-1)-(A-2)) del Anexo A. Con ello, es posible identificar los cuatro términos dependientes de las variables de estado.

Paso 3. Para obtener los valores límites de cada no linealidad, se necesita determinar el rango de operación de las variable de estado considerando las condiciones iniciales del reactor. El procedimiento que se utilizó es el siguiente:

- (i) Determinación del rango de la variable de control, en este caso, el rango de la temperatura dentro del reactor: $T_{r_{min}} \leq T_r \leq T_{r_{max}}$. Este rango se basa en el conocimiento del proceso;
- (ii) Determinación del rango de la variable manipulada $F_{c_{min}} \leq F_c \leq F_{c_{max}}$. $F_{c_{min}}$ es el flujo necesario del agente de enfriamiento para obtener $T_{r_{min}}$, mientras que $F_{c_{max}}$ es el flujo necesario del agente de enfriamiento para obtener $T_{r_{max}}$;

3.1. Modelo Takagi-Sugeno del proceso de fermentación alcohólica mediante el enfoque del sector no lineal

- (iii) El estado estable del proceso con $F_{c_{min}}$ determina el primer valor de las variables del proceso;
- (iv) El estado estable del proceso con $F_{c_{max}}$ determina el segundo valor de las variables del proceso.

Los siguientes intervalos $25 \leq T_r \leq 41^\circ C$, $0 \leq F_c \leq 55 \text{ l/h}$, $7,0 \leq c_{O_2} \leq 9,0 \text{ mg/l}$, $24,0 \leq c_P \leq 25,0 \text{ g/l}$, $1,0 \leq c_S \leq 3,5 \text{ mg/l}$, $25 \leq T_c \leq 31^\circ C$, son los establecidos para obtener los límites de las no linealidades:

$$z_1 : \begin{cases} \underline{nl}_1 = \min_{T_r, c_S, c_P} \left\{ \mu_X(T_r) \frac{c_S}{K_S + c_S} e^{-K_P c_P} \right\} = 0,015 \\ \overline{nl}_1 = \max_{T_r, c_S, c_P} \left\{ \mu_X(T_r) \frac{c_S}{K_S + c_S} e^{-K_P c_P} \right\} = 0,143 \end{cases} \quad (3-3)$$

$$z_2 : \begin{cases} \underline{nl}_2 = \min_{c_S, c_P} \left\{ \mu_p \frac{c_S}{K_{S1} + c_S} e^{-K_{P1} c_P} \right\} = 0,532 \\ \overline{nl}_2 = \max_{c_S, c_P} \left\{ \mu_p \frac{c_S}{K_{S1} + c_S} e^{-K_{P1} c_P} \right\} = 1,738 \end{cases} \quad (3-4)$$

$$z_3 : \begin{cases} \underline{nl}_3 = \min_{c_{O_2}} \left\{ \mu_{O_2} \frac{1}{Y_{O_2}} \frac{c_{O_2}}{k_{O_2} + c_{O_2}} \right\} = 0,228 \\ \overline{nl}_3 = \max_{c_{O_2}} \left\{ \mu_{O_2} \frac{1}{Y_{O_2}} \frac{c_{O_2}}{k_{O_2} + c_{O_2}} \right\} = 0,260 \end{cases} \quad (3-5)$$

$$z_4 : \begin{cases} \underline{nl}_4 = \min_{T_c} \{T_c\} = 25 \\ \overline{nl}_4 = \max_{T_c} \{T_c\} = 31 \end{cases} \quad (3-6)$$

Paso 4. Partiendo de las cuatro variables programadas $z_j, j = 1, 2, 3, 4$, se obtienen ocho funciones de ponderación como sigue:

$$\begin{aligned} \eta_0^1(z_1) &= \frac{\overline{nl}_1 - z_1}{\underline{nl}_1 - \overline{nl}_1}, & \eta_1^1(z_1) &= 1 - \eta_0^1, & \eta_0^2(z_2) &= \frac{\overline{nl}_2 - z_2}{\underline{nl}_2 - \overline{nl}_2}, & \eta_1^2(z_2) &= 1 - \eta_0^2, \\ \eta_0^3(z_3) &= \frac{\overline{nl}_3 - z_3}{\underline{nl}_3 - \overline{nl}_3}, & \eta_1^3(z_3) &= 1 - \eta_0^3, & \eta_0^4(z_4) &= \frac{\overline{nl}_4 - z_4}{\underline{nl}_4 - \overline{nl}_4}, & \eta_1^4(z_4) &= 1 - \eta_0^4 \end{aligned} \quad (3-7)$$

Por lo tanto, cada variable programada z_j se representa como una suma ponderada:

$$z_j = \underline{nl}_j \eta_0^j(z_j) + \overline{nl}_j \eta_1^j(z_j)$$

Por ejemplo:

$$z_1 = 0,0152 \frac{0,1436 - \mu_X \frac{c_S}{K_S + c_S} e^{-K_P c_P}}{0,1436 - 0,0152} + 0,1436 \left(1 - \frac{0,1436 - \mu_X \frac{c_S}{K_S + c_S} e^{-K_P c_P}}{0,1436 - 0,0152} \right)$$

3. Neurolocalización de fallas

Paso 5. El número de funciones de pertenencia se calcula como $m = 2^p$, en este caso $p = 4$, de tal forma que $m = 2^4 = 16$. Las funciones de pertenencia resultantes se escriben de la siguiente manera:

$$\begin{aligned}
 \phi_1(z) &= \eta_0^1 \eta_0^2 \eta_0^3 \eta_0^4; & \phi_5(z) &= \eta_0^1 \eta_1^2 \eta_0^3 \eta_0^4; & \phi_9(z) &= \eta_1^1 \eta_0^2 \eta_0^3 \eta_0^4; & \phi_{13}(z) &= \eta_1^1 \eta_1^2 \eta_0^3 \eta_0^4; \\
 \phi_2(z) &= \eta_0^1 \eta_0^2 \eta_0^3 \eta_1^4; & \phi_6(z) &= \eta_0^1 \eta_1^2 \eta_0^3 \eta_1^4; & \phi_{10}(z) &= \eta_1^1 \eta_0^2 \eta_0^3 \eta_1^4; & \phi_{14}(z) &= \eta_1^1 \eta_1^2 \eta_0^3 \eta_1^4; \\
 \phi_3(z) &= \eta_0^1 \eta_0^2 \eta_1^3 \eta_0^4; & \phi_7(z) &= \eta_0^1 \eta_1^2 \eta_1^3 \eta_0^4; & \phi_{11}(z) &= \eta_1^1 \eta_0^2 \eta_1^3 \eta_0^4; & \phi_{15}(z) &= \eta_1^1 \eta_1^2 \eta_1^3 \eta_0^4; \\
 \phi_4(z) &= \eta_0^1 \eta_0^2 \eta_1^3 \eta_1^4; & \phi_8(z) &= \eta_1^1 \eta_1^2 \eta_1^3 \eta_1^4; & \phi_{12}(z) &= \eta_1^1 \eta_0^2 \eta_1^3 \eta_1^4; & \phi_{16}(z) &= \eta_1^1 \eta_1^2 \eta_1^3 \eta_1^4;
 \end{aligned} \tag{3-8}$$

Paso 6. A partir de las funciones de pertenencia, el modelo T-S tiene 16 reglas difusas y, para cada regla, existe un modelo matemático lineal de la forma:

$$\dot{x} = A_i x + B_{v_i} F_c + B_{nv} F_{in} + E, \quad \forall i = [1, \dots, m]$$

Por ejemplo, la regla del primer modelo difuso es:

Si z_1 es Z_0^1 y z_2 es Z_0^2 y z_3 es Z_0^3 y z_4 es Z_0^4 ,

en otras palabras,

Si $z_1 = \underline{nl}_1$, $z_2 = \underline{nl}_2$, $z_3 = \underline{nl}_3$ y $z_4 = \underline{nl}_4$

esto es porque cada conjunto difuso Z_γ^j corresponde a una función de pertenencia η_γ^j . Entonces los límites \underline{nl}_j , $\forall j = [1, \dots, 4]$ son directamente remplazados por los términos no lineales en la matriz $A(x)$ de la Ec.(A-1), resultando el siguiente modelo:

$$\dot{x} = A_1 x + B_{v_1} F_c + B_{nv} F_{in} + E$$

siendo

$$A_1 = \begin{bmatrix}
 \underline{nl}_1 - \frac{F_{out}}{V} & 0 & 0 & 0 & 0 & 0 \\
 \underline{nl}_2 & -\frac{F_{out}}{V} & 0 & 0 & 0 & 0 \\
 -\frac{1}{R_{SX}} \underline{nl}_1 - \frac{1}{R_{SP}} \underline{nl}_2 & 0 & -\frac{F_{out}}{V} & 0 & 0 & 0 \\
 -\underline{nl}_3 & 0 & 0 & -k_{la} & 0 & 0 \\
 \underline{nl}_3 & 0 & 0 & 0 & -\frac{F_e}{V} + \frac{K_T A_T}{V \rho_r C_{heat,r}} & -\frac{K_T A_T}{V \rho_r C_{heat,r}} \\
 0 & 0 & 0 & 0 & \frac{K_T A_T}{V_c \rho_c C_{heat,c}} & -\frac{K_T A_T}{V_c \rho_c C_{heat,c}}
 \end{bmatrix} \tag{3-9}$$

$$B_{v_1} = \begin{bmatrix}
 0 \\
 0 \\
 0 \\
 0 \\
 \frac{T_{c,in} - \underline{nl}_4}{V_c} \\
 0
 \end{bmatrix} \tag{3-10}$$

la matriz B_{nv} y E se definen como sigue:

$$B_{nv} = \begin{bmatrix} 0 \\ 0 \\ \frac{c_{S,in}}{V} \\ 0 \\ \frac{T_{r,in}}{V} \\ 0 \end{bmatrix}, E = \begin{bmatrix} 0 \\ 0 \\ 0 \\ k_{la}c_{O_2EL} \\ 0 \\ 0 \end{bmatrix} \quad (3-11)$$

La función de pertenencia de la regla es $\phi_1(z) = \eta_0^1 \eta_0^2 \eta_0^3 \eta_0^4$. La siguiente notación se usa para simplificar la escritura de las matrices A_1 y B_{v_1} :

$$A_1 = A(\underline{nl_1}, \underline{nl_2}, \underline{nl_3}) \quad (3-12)$$

$$B_{v_1} = B(\underline{nl_4}) \quad (3-13)$$

Paso 7. Finalmente, el modelo T-S que reproduce adecuadamente la dinámica del modelo no lineal Ecs.(3-1) original es:

$$\dot{x} = (\phi_1(z) \cdot A_1 + \phi_2(z) \cdot A_2 + \dots + \phi_{16}(z) \cdot A_{16})x + (\phi_1(z) \cdot B_{v_1} + \phi_2(z) \cdot B_{v_2} + \dots + \phi_{16}(z) \cdot B_{v_{16}})F_c + B_{nv} \cdot F_{in} + E \quad (3-14)$$

donde

$$\begin{aligned} A_1 = A_2 &= A(\underline{nl_1}, \underline{nl_2}, \underline{nl_3}) & A_3 = A_4 &= A(\underline{nl_1}, \underline{nl_2}, \overline{nl_3}) \\ A_5 = A_6 &= A(\underline{nl_1}, \overline{nl_2}, \underline{nl_3}) & A_7 = A_8 &= A(\underline{nl_1}, \overline{nl_2}, \underline{nl_3}) \\ A_9 = A_{10} &= A(\overline{nl_1}, \underline{nl_2}, \underline{nl_3}) & A_{11} = A_{12} &= A(\overline{nl_1}, \underline{nl_2}, \overline{nl_3}) \\ A_{13} = A_{14} &= A(\overline{nl_1}, \overline{nl_2}, \underline{nl_3}) & A_{15} = A_{16} &= A(\overline{nl_1}, \overline{nl_2}, \overline{nl_3}) \end{aligned} \quad (3-15)$$

$$\begin{aligned} B_{v_1} = B_{v_3} = B_{v_5} = B_{v_7} = B_{v_9} = B_{v_{11}} = B_{v_{13}} = B_{v_{15}} &= B(\underline{nl_4}) \\ B_{v_2} = B_{v_4} = B_{v_6} = B_{v_8} = B_{v_{10}} = B_{v_{12}} = B_{v_{14}} = B_{v_{16}} &= B(\overline{nl_4}) \end{aligned} \quad (3-16)$$

El modelo matemático del proceso de fermentación alcohólica (3-14) puede escribirse en su forma T-S como:

$$\begin{aligned} \dot{x} &= \sum_{i=1}^{16} \phi_i(z)(A_i x + B_{v_i} F_c) + B_{nv} F_{in} + E \\ y &= Cx \end{aligned} \quad (3-17)$$

La comparación entre el modelo no lineal y el modelo T-S obtenido se muestra en la Fig.3-1. Los parámetros del reactor usados en esta simulación se proporcionan en la sección [Nomenclatura](#) y las condiciones iniciales para ambos modelos son: $c_X(0) = 0.905 \text{ g/l}$, $c_P(0) = 12.515 \text{ g/l}$, $c_S(0) = 29.739 \text{ mg/l}$, $c_{O_2}(0) = 3.107 \text{ mg/l}$, $T_r(0) = 29.573 \text{ }^\circ\text{C}$ y $T_c(0) = 27.054 \text{ }^\circ\text{C}$.

El objetivo de la simulación es mostrar el comportamiento de las variables del proceso en lazo abierto de ambos modelos y demostrar que el modelo T-S reproduce fielmente la dinámica del

3. Neurolocalización de fallas

modelo no lineal. En las gráficas obtenidas, puede observarse que la concentración c_x decrece conforme el sustrato c_s se transforma en el producto deseado c_p . Esto sucede en el proceso al mantener la variable de control F_c y $T_{c,in}$ constantes en $F_c = 18l/h$ y $15^\circ C$, respectivamente.

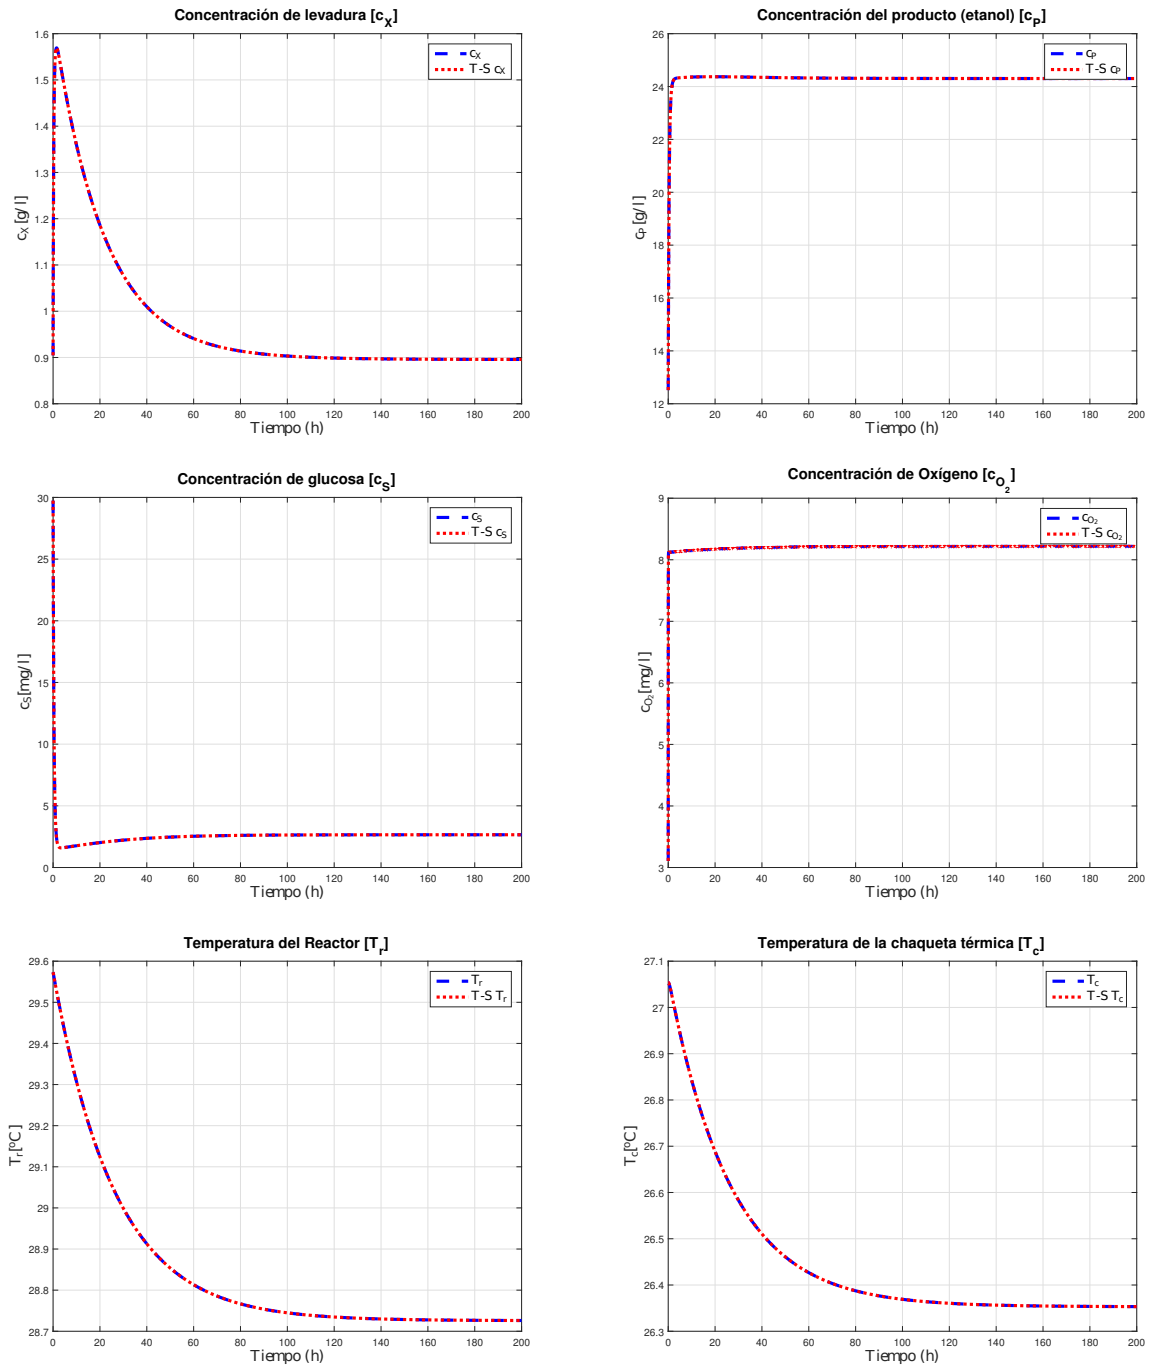


Figura 3-1.: Respuesta en lazo abierto del modelo no lineal dado en las Ecs.(2-70) a (2-75) versus el modelo T-S dado en la Ec.(3-17).

Proceso en lazo cerrado

El objetivo de mostrar el sistema en lazo cerrado es para analizar el comportamiento en el tiempo de las dinámicas del proceso ante cambios en la temperatura deseada al interior del reactor. En la Fig. 3-2 se muestra un esquema del control de temperatura del proceso de fermentación alcohólica en un reactor de alimentación continua.




Figura 3-2.: Esquema del control de temperatura de un reactor con alimentación continua.

En la industria, el principal controlador para los reactores es el controlador Proporcional Integral (PI). Estos tipos de controladores también se pueden diseñar a partir de un modelo T-S, donde la principal ventaja de los controladores PI para sistemas T-S sobre los controladores PI típicos es que los controladores PI están originalmente concebidos para procesos lineales o procesos no lineales que operan en un rango de operación restringido. Esto se debe a que las ganancias de los controladores PI típicos son constantes. Por otro lado, los controladores PI Takagi-Sugeno permiten un rango de operación más amplio del proceso, debido a que las ganancias del controlador se adaptan según la región de operación del proceso. Para resaltar esta característica, se propone un controlador PI Takagi-Sugeno para la regulación de la temperatura del reactor de fermentación alcohólica. Se realizan varios cambios en el punto de ajuste para evaluar las capacidades de adaptabilidad del controlador PI Takagi-Sugeno. El esquema propuesto se representa en la Fig. 3-3.

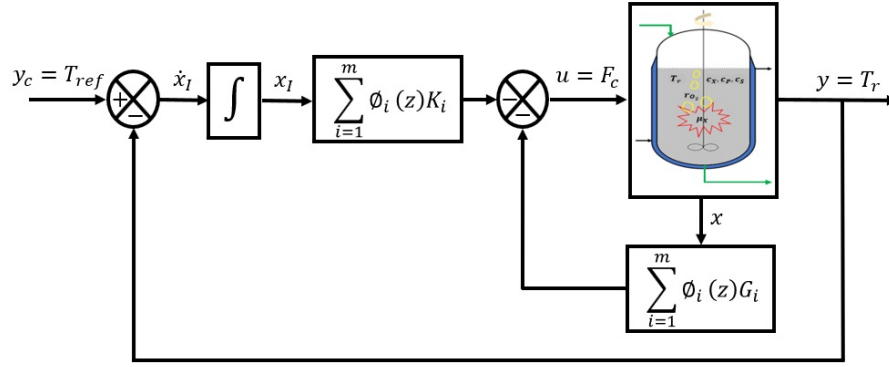


Figura 3-3.: Diagrama a bloques del control de temperatura del proceso de fermentación alcohólica.

La ley de control propuesta es:

$$u = - \sum_{i=1}^m \phi_i(z) (G_i \quad K_i) \begin{pmatrix} x \\ x_I \end{pmatrix} \quad (3-18)$$

donde el término integral es:

$$x_I = \int (y_c - y) dt$$

cuya derivada es:

$$\dot{x}_I = y_c - Cx$$

Esta nueva variable x_I se aumenta como un nuevo estado en el sistema (3-17), resultando en el siguiente sistema T-S aumentado:

$$\begin{aligned} \dot{\bar{x}} &= \sum_{i=1}^m \phi_i(z) (\bar{A}_i \bar{x} + \bar{B}_i u) + \bar{B}_{nv} F_{in} + \bar{E} + B_y y_c \\ y &= \bar{C} \bar{x} \end{aligned} \quad (3-19)$$

donde

$$\begin{aligned} \bar{x} &= \begin{bmatrix} x \\ x_I \end{bmatrix}, \quad \bar{A}_i = \begin{bmatrix} A_i & 0 \\ -C & 0 \end{bmatrix}, \quad \bar{B}_i = \begin{bmatrix} B_{vi} \\ 0 \end{bmatrix}, \quad \bar{B}_{nv} = \begin{bmatrix} B_{nv} \\ 0 \end{bmatrix} \\ B_y &= \begin{bmatrix} 0 \\ I \end{bmatrix}, \quad \bar{E} = \begin{bmatrix} E \\ 0 \end{bmatrix}, \quad \bar{C} = [C \quad 0] \end{aligned} \quad (3-20)$$

La ley de control es una suma ponderada de m ganancias proporcional G_i , $i = 1, \dots, m$, y m ganancias integral K_i , $i = 1, \dots, m$ donde cada par G_i , K_i corresponde a un punto de operación del proceso.

3.1. Modelo Takagi-Sugeno del proceso de fermentación alcohólica mediante el enfoque del sector no lineal

Al sustituir (3-18) en el modelo T-S dado en la Ec.(3-19), se obtiene el siguiente sistema en lazo cerrado:

$$\dot{\bar{x}} = \sum_{i=1}^m \phi_i(z) \left(\bar{A}_i - \bar{B}_i \sum_{j=1}^m \phi_j(z) \bar{L}_j \right) \bar{x} + B_y y_c + \bar{B}_{nv} F_{in} + \bar{E} \quad (3-21)$$

o

$$\dot{\bar{x}} = \sum_{i=1}^m \sum_{j=1}^m \phi_i(z) \phi_j(z) (\bar{A}_i - \bar{B}_i \bar{L}_j) \bar{x} + B_y y_c + \bar{B}_{nv} F_{in} + \bar{E} \quad (3-22)$$

donde $\bar{L}_j = [G_j \quad K_j]$ es una matriz que contiene m ganancias proporcional e integral del controlador.

El nuevo problema es calcular las matrices \bar{L}_j tal que el sistema en lazo cerrado dado en la Ec.(3-22) sea estable. Esto se puede lograr por medio del análisis de estabilidad de Lyapunov [Lendek et al. \(2011\)](#) considerando la siguiente función cuadrática:

$$V(\bar{x}) = \bar{x}^T P \bar{x}, \quad P = P^T > 0 \quad (3-23)$$

La derivada de (3-23) a lo largo de la trayectoria del sistema (3-22) es:

$$\dot{V}(\bar{x}) = \sum_{i=1}^m \sum_{j=1}^m \phi_i(z) \phi_j(z) \bar{x}^T \left((\bar{A}_i - \bar{B}_i \bar{L}_j)^T P + P (\bar{A}_i - \bar{B}_i \bar{L}_j) \right) \bar{x} \quad (3-24)$$

Para asegurar que $\dot{V}(\bar{x}) < 0$ (la condición de estabilidad necesaria del sistema en lazo cerrado en el sentido de Lyapunov), se necesita que:

$$\sum_{i=1}^m \sum_{j=1}^m \phi_i(z) \phi_j(z) (\bar{A}_i^T P + P \bar{A}_i - P \bar{B}_i \bar{L}_j - \bar{L}_j^T \bar{B}_j^T P) < 0 \quad (3-25)$$

Ya que las matrices P y \bar{L}_j son desconocidas, la expresión $P \bar{B}_i \bar{L}_j$ es un término bilineal. Entonces, el siguiente cambio de variable puede ser hecho con la finalidad de expresar (3-25) como una LMI:

$$X = P^{-1}, \quad M_i = \bar{L}_i X, \quad \forall i = [1, \dots, m] \quad (3-26)$$

Considerando la propiedad de congruencia con el rango completo de la matriz $X = P^{-1}$, la desigualdad (3-25) es equivalente a:

$$\sum_{i=1}^m \sum_{j=1}^m \phi_i(z) \phi_j(z) (X \bar{A}_i^T + \bar{A}_i X - \bar{B}_i M_j - M_j^T \bar{B}_j^T) < 0 \quad (3-27)$$

Así, resolviendo la desigualdad (3-27), se obtienen las matrices X y M_j y entonces, las ganancias del controlador \bar{L}_i son dadas por:

$$\bar{L}_i = M_i X^{-1}, \quad \forall i = [1, \dots, m] \quad (3-28)$$

3. Neurolocalización de fallas

Considerando las matrices del sistema T-S (3-14), las LMIs se resuelven usando el Toolbox de Yalmip para MatLab Lofberg (2004). Las ganancias obtenidas son:

$$\begin{aligned}
 \bar{L}_1 &= [58,5724 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_2 &= [37,7406 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353] \\
 \bar{L}_3 &= [58,5707 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_4 &= [37,7397 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353] \\
 \bar{L}_5 &= [58,5970 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_6 &= [37,8146 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353] \\
 \bar{L}_7 &= [58,5954 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_8 &= [37,8138 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353] \\
 \bar{L}_9 &= [58,5802 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_{10} &= [37,7064 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353] \\
 \bar{L}_{11} &= [58,5784 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_{12} &= [37,7061 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6786 \quad -46,1743 \quad -6,8355] \\
 \bar{L}_{13} &= [58,5909 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,8740 \quad -71,8892 \quad -10,6058] \\
 \bar{L}_{14} &= [37,7746 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353] \\
 \bar{L}_{15} &= [58,5938 \quad 0,0018 \quad -0,0046 \quad 0,0020 \quad 326,9100 \quad -71,8976 \quad -10,6068] \\
 \bar{L}_{16} &= [37,7737 \quad 0,0012 \quad -0,0029 \quad 0,0013 \quad 210,6739 \quad -46,1732 \quad -6,8353]
 \end{aligned} \tag{3-29}$$

La Fig.3-4 muestra el lazo de control de temperatura del proceso de fermentación alcohólica que se lleva a cabo en un reactor tipo tanque de agitación continua con volumen constante. Esta suposición implica que el flujo de alimentación del sustrato y la salida del flujo del sustrato son iguales, es decir $F_{in} = F_{out}$. En esta simulación, se asume que el flujo de entrada del bioreactor F_{in} es constante. La variable controlada es la temperatura dentro del reactor T_r y la variable manipulada es el flujo de alimentación de la chaqueta térmica F_c . Las temperaturas de entrada del sustrato y el agente de enfriamiento, T_{rin} y $T_{c,in}$ respectivamente, se asumen como constantes.

En la simulación, el proceso a controlar es el sistema no lineal dado en las Ecs.(2-70) a (2-75) (ver Fig.3-3). El objetivo del controlador PI Takagi-Sugeno dado en la Ec.(3-18) es mantener la temperatura T_r en el punto de referencia $y_c = T_{ref}$.




Figura 3-4.: Lazo de control de temperatura del proceso de fermentación.

Para evaluar el desarrollo del controlador, se presentan varios cambios en forma de escalón en el punto de ajuste en los instantes $t = 100\text{h}$, $t = 300\text{h}$, $t = 500\text{h}$ y $t = 700\text{h}$. El desarrollo de las variables del proceso se muestran en la Fig.(3-5). Se puede apreciar que T_r converge adecuadamente al punto de ajuste T_{ref} , y no se observa ningún sobrepaso. Esto se consigue por medio de adecuadas variaciones de la temperatura de la chaqueta térmica T_c a través de variaciones del flujo de alimentación de la chaqueta térmica F_c (la señal de control presentada en la Fig.3-6) por medio de la válvula de control. Un cambio en F_c es causado por un escalón de cambio en la señal T_{ref} . Por ejemplo, el primer escalón en T_{ref} es una variación positiva de 3°C , y teniendo en cuenta que la temperatura de entrada de la camisa térmica (T_{cin}) permanece constante, entonces F_c aumenta. De lo contrario, cuando el escalón es negativo en T_{ref} , F_c disminuye. Por otro lado, no se presenta ningún error de estado estable gracias al término integral del controlador. Es importante apreciar el comportamiento de la concentración de levadura c_X y la concentración de etanol c_P cuando la temperatura T_r varía: un incremento de temperatura provoca un incremento de las concentraciones de levadura y etanol y viceversa. Por otro lado, un incremento de la temperatura provoca una disminución de la concentración de glucosa c_S y viceversa. De hecho, la concentración de glucosa desciende porque se transforma en etanol (cuya concentración aumenta). Por último, el crecimiento en la concentración de oxígeno c_{O_2} está vinculado a la bioreacción que se genera por la transformación de la glucosa en etanol, es decir, cuando la levadura transforma la glucosa en etanol, la concentración de oxígeno disminuye.

3. Neurolocalización de fallas

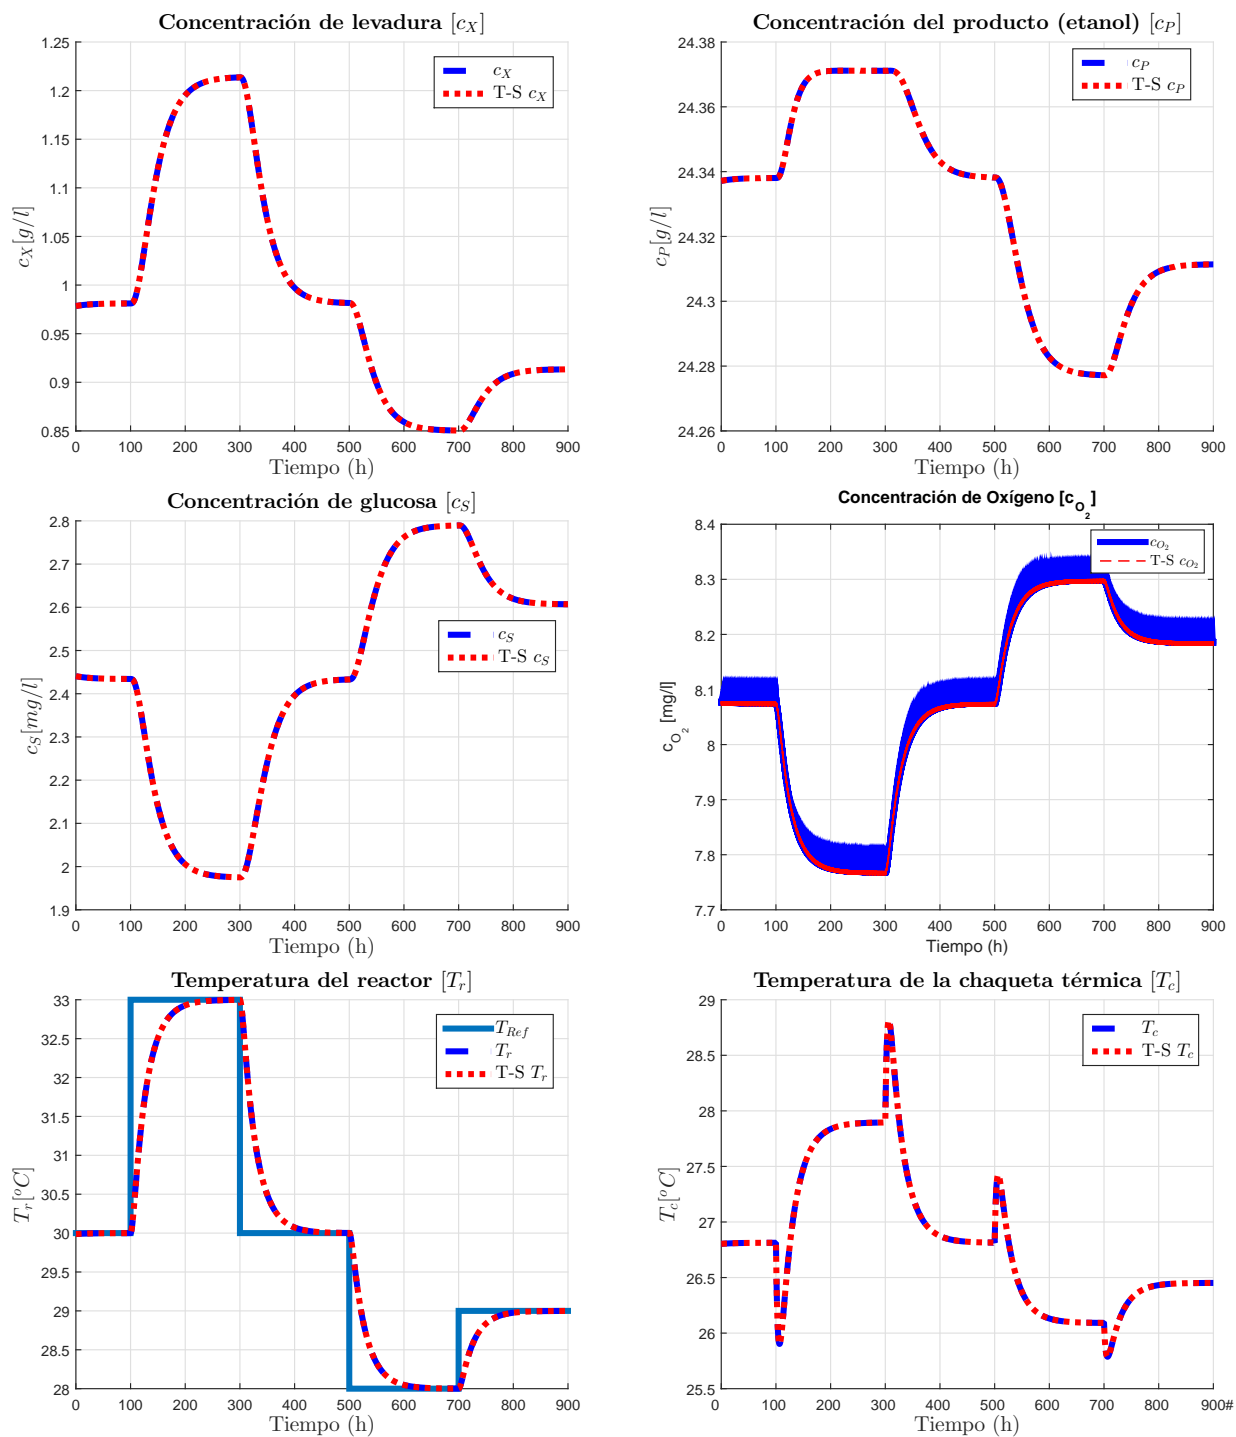


Figura 3-5.: Dinámica de las variables de estado.

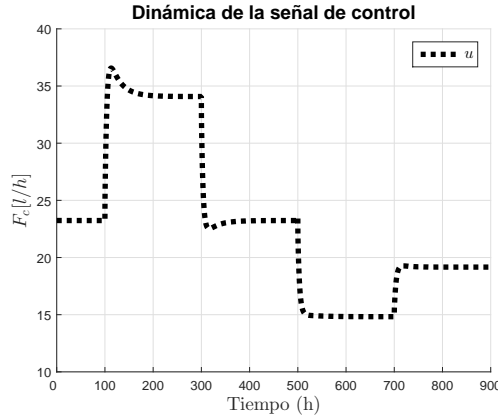


Figura 3-6.: Ley de control F_c .

La dinámica de señal de control F_c mostrada en la Fig.3-5 mantiene la temperatura T_r en el punto de referencia $y_c = T_{ref}$ de forma correcta. Por lo tanto, y ante las pruebas realizadas al controlador se concluye que el diseño de la ley de control 3-18 para el modelo no lineal del proceso de fermentación alcohólica descrito en las Ecs.(2-70) a (2-75) proporciona una solución al problema de mantener la temperatura del reactor en un punto de referencia.

3.2. Banco de observadores

El desarrollo de un proceso de fermentación alcohólica debe de cumplir con normas y estándares para obtener las especificaciones del producto deseado, es por ello que en esta sección se presenta el diseño de una clase de observadores Takagi-Sugeno. Mediante dichos observadores se puede crear un banco de observadores, el cual permita extraer información de las fallas en sensores para ser utilizada en el sistema neurolocalizador de fallas.

3.2.1. Diseño de los observadores Takagi-Sugeno

El diseño de los observadores difusos T-S que conforman al banco de observadores parten del modelo de una clase de observadores mostrado en Lendek et al. (2011), cuyo modelo matemático se describe en la siguiente ecuación:

$$\begin{aligned} \dot{\hat{x}} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i \hat{x} + B_i u + a_i + L_i(y - \hat{y})) \\ \hat{y} &= \sum_{i=1}^m \phi_i(\hat{z})(C_i \hat{x} + c_i) \end{aligned} \quad (3-30)$$

A partir de la forma del observador T-S anterior, el diseño se puede abordar mediante dos casos: i) el vector de programación z no depende de los estados no medibles, es decir, en el

3. Neurolocalización de fallas

observador se conocen las variables de programación para ser usadas; ii) el vector de programación z depende de los estados que no son medibles. La dinámica del error de estimación en el caso general cuando el observador (3-30) es utilizado para el sistema denotado en (2-5) y (2-6) puede ser derivada como

$$\dot{e} = \dot{x} - \dot{\hat{x}} \quad (3-31)$$

$$\begin{aligned} \dot{e} &= \sum_{i=1}^m \phi_i(z)(A_i x + B_i u + a_i) - \sum_{i=1}^m \phi_i(\hat{z})(A_i \hat{x} + B_i u + a_i + L_i(y - \hat{y})) \\ \dot{e} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i x + B_i u + a_i) - \sum_{i=1}^m \phi_i(\hat{z})(A_i x + B_i u + a_i) + \\ &\quad \sum_{i=1}^m \phi_i(z)(A_i x + B_i u + a_i) - \sum_{i=1}^m \phi_i(\hat{z})(A_i \hat{x} + B_i u + a_i + L_i(y - \hat{y})) \\ \dot{e} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i e - L_i(y - \hat{y})) + \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(A_i x + B_i u + a_i) \\ \dot{e} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i e - L_i(\sum_{j=1}^m \phi_j(z)(C_j x + c_j) - \sum_{j=1}^m \phi_j(\hat{z})(C_j \hat{x} + c_j))) + \\ &\quad \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(A_i x + B_i u + a_i) \\ \dot{e} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i e - L_i(\sum_{j=1}^m \phi_j(z)(C_j x + c_j) - \sum_{j=1}^m \phi_j(\hat{z})(C_j x + c_j) + \sum_{i=1}^m \phi_i(\hat{z})(C_j x + c_j) - \\ &\quad \sum_{i=1}^m \phi_i(\hat{z})(C_j \hat{x} + c_j))) + \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(A_i x + B_i u + a_i) \\ \dot{e} &= \sum_{i=1}^m \phi_i(\hat{z})(A_i e - L_i(\sum_{j=1}^m \phi_j(\hat{z})(C_j e) + \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(C_j x + c_j))) + \\ &\quad \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(A_i x + B_i u + a_i) \end{aligned}$$

Si $\sum_{j=1}^m \phi_j(\hat{z}) = 1$, y por ultimo, la formula es:

$$\begin{aligned} \dot{e} &= \sum_{i=1}^m \phi_i(\hat{z}) \sum_{j=1}^m \phi_j(\hat{z})(A_i - L_i C_j) e + \sum_{i=1}^m \phi_i(\hat{z}) L_i \sum_{j=1}^m (\phi_j(z) - \phi_j(\hat{z}))(C_j x + c_j) + \\ &\quad \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(A_i x + B_i u + a_i) \end{aligned} \quad (3-32)$$

La expresión anterior del error de estimación del caso general, se desprenden para el caso uno y dos. Por lo tanto, la expresión del error de estimación para cuando las variables de programación dependen de las variables y estado medibles es:

$$\dot{e} = \sum_{i=1}^m \phi_i(z)(A_i - L_i C)e \quad (3-33)$$

Para el caso dos, la expresión del error de estimación cuando las variables de programación dependen de las variables y estado no medibles es:

$$\dot{e} = \sum_{i=1}^m \phi_i(\hat{z})(A_i - L_i C)e + \sum_{i=1}^m (\phi_i(z) - \phi_i(\hat{z}))(A_i x + B_i u) \quad (3-34)$$

Se han mencionado que a partir del observador (3-30) se pueden generar dos casos de diseño y se han mostrado sus respectivos errores de estimación.

Por ejemplo, para el diseño del observador del caso dos, en el cual no se tiene acceso a todos los estados y las variables programadas dependen de dichos estados. Existe una diferencia que varía con el tiempo entre los estados reales y los estimados. Para que esta diferencia tienda a cero y los estados estimados converjan a los reales, el observador debe ser lo suficientemente robusto como para lidiar con esta diferencia. Para ello, el siguiente teorema es utilizado:

Teorema 3.2.1 (Bergsten (2001)) *Considere el error del sistema dado en la Ec.(3-34), y asumiendo que*

$$\left\| \sum_{i=1}^m (w_i(z) - w_i(\hat{z}))(A_i x + B_i u) \right\| \leq \mu \|e\| \quad (3-35)$$

cuando $\mu > 0$ es una constante conocida. Entonces, el error del sistema dado en la Ec.(3-34) es exponencialmente estable, si existe una matriz $P = P^T > 0$, $Q = Q^T > 0$, y L_i , $i = 1, 2, \dots, m$, tal que

$$\begin{aligned} \mathcal{H}(P(A_i - L_i C)) &\leq -Q \\ \begin{pmatrix} Q - \mu^2 I & P \\ P & I \end{pmatrix} &\geq 0 \end{aligned} \quad (3-36)$$

para $i = 1, 2, \dots, m$.

Recordemos que la observabilidad de un sistema es la propiedad de reconstruir los estados, mediante un observador a partir de las entradas y salidas medibles del sistema. En el diseño de observadores difusos T-S, parece sencillo utilizar los criterios de observabilidad para sistemas no lineales. Sin embargo, dado que los observadores están diseñados de modo que cada regla tenga una ganancia local L_i , se requiere que los modelos locales sean observables en lugar del sistema no lineal completo. En general, este requisito no es suficiente ni necesario para que el sistema no lineal sea observable. Sin embargo, debido a la forma del observador mostrado en [Lendek et al. \(2011\)](#) y que es denotado en la Ec.(3-30), se requiere para el diseño y se supone implícitamente que los modelos locales (A_i, C_i) , $i = 1, 2, \dots, m$, son observables. Por lo tanto, el análisis de observabilidad se realiza al modelo T-S obtenido a partir del modelo no lineal

3. Neurolocalización de fallas

del proceso de fermentación alcohólica. El modelo esta constituido por 16 submodelos como se denotó en la (3-14) y que se reescribe a continuación:

$$\dot{x} = (\phi_1(z) \cdot A_1 + \phi_2(z) \cdot A_2 + \dots + \phi_{16}(z) \cdot A_{16})x + (\phi_1(z) \cdot B_{v_1} + \phi_2(z) \cdot B_{v_2} + \dots + \phi_{16}(z) \cdot B_{v_{16}})F_c + B_{nv} \cdot F_{in} + E$$

y en su forma difusa como:

$$\begin{aligned} \dot{x} &= \sum_{i=1}^{16} \phi_i(z)(A_i x + B_{vi} F_c) + B_{nv} F_{in} + E \\ y &= Cx \end{aligned}$$

Se ha mencionado en el diseño del controlador de temperatura para el reactor donde se realiza el proceso de fermentación alcohólica que se pueden medir todos los estados del proceso. Sin embargo, para el diseño del banco de observadores y mediante el siguiente análisis de observabilidad se establecen las matrices C que cumplen con la condición de observabilidad. La observabilidad de cada modelo local $(A_i, C_i), i = 1, 2, \dots, 16$, se puede realizar mediante la condición de observabilidad de un sistema lineal, la cual se escribe a continuación:

$$O = \begin{bmatrix} C \\ CA \\ CA^2 \\ \vdots \\ CA^{n-1} \end{bmatrix} = n \quad (3-37)$$

Siendo C la matriz de estados disponibles, A la matriz dependiente de los estados. Para utilizar dicha condición para cada modelo local, la condición se reescribe de la siguiente forma:

$$O = \begin{bmatrix} C_i \\ C_i A_i \\ C_i (A_i)^2 \\ \vdots \\ C_i (A_i)^{n-1} \end{bmatrix} = n \quad (3-38)$$

Aplicando el análisis de observabilidad al modelo T-S obtenido del proceso de fermentación alcohólica denotado en de la Ec.(3-17) y con las matrices A_i denotadas en la Ec.(3-15), las cuales son reescritas a continuación:

$$\begin{aligned} A_1 = A_2 &= A(\underline{nl_1}, \underline{nl_2}, \underline{nl_3}) & A_3 = A_4 &= A(\underline{nl_1}, \underline{nl_2}, \overline{nl_3}) \\ A_5 = A_6 &= A(\underline{nl_1}, \underline{nl_2}, \underline{nl_3}) & A_7 = A_8 &= A(\underline{nl_1}, \underline{nl_2}, \underline{nl_3}) \\ A_9 = A_{10} &= A(\overline{nl_1}, \underline{nl_2}, \underline{nl_3}) & A_{11} = A_{12} &= A(\overline{nl_1}, \underline{nl_2}, \overline{nl_3}) \\ A_{13} = A_{14} &= A(\underline{nl_1}, \overline{nl_2}, \underline{nl_3}) & A_{15} = A_{16} &= A(\underline{nl_1}, \underline{nl_2}, \underline{nl_3}) \end{aligned} \quad (3-39)$$

Las matrices C_i que satisfacen la condición de observabilidad (3-37) son:

$$\begin{aligned}
C_i^1 &= \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}; C_i^2 = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \\
C_i^3 &= \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}; C_i^4 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \\
C_i^5 &= \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}
\end{aligned} \tag{3-40}$$

Dado el análisis de observabilidad, cinco matrices cumplen la condición de observabilidad. Note que, las cinco matrices tienen acceso a los estados x_2 , x_3 y x_4 , mientras que los estados x_1 , x_5 y x_6 no todas las matrices tienen acceso a ellos. Por lo tanto, haciendo uso de la redundancia analítica se define que los sensores donde se pueden neurolocalizar fallas es en los estados x_1 , x_5 y x_6 , que corresponden a la concentración de la levadura, la temperatura del reactor, y la temperatura de la chaqueta térmica, respectivamente.

El diseño de cada observador parte de cada una de las matrices de notadas en la Ec.(3-40). Por ejemplo, a partir de la matriz C_i^1 , del modelo T-S denotado en la Ec.(3-17) y del observador T-S denotado en la Ec.3-30, este se puede escribir de la siguiente forma:

$$\begin{aligned}
\hat{x}^1 &= \sum_{i=1}^{16} \phi_i(\hat{z})(A_i \hat{x}^1 + B_{vi} F_c + L_i^1 (y - \hat{y}^1)) + B_{nv} F_{in} + E \\
\hat{y}^1 &= C_i^1 \hat{x}^1
\end{aligned}$$

Note que aunque la matriz C_i^1 tiene cuatro estados medibles, se pueden reconstruir todos los estados del modelo no lineal del proceso de fermentación alcohólica. A través, del caso dos para el diseño de observadores T-S, el cual indica que el vector de las variables programadas depende de los estados no medibles del proceso. De forma similar ocurre con la matriz C_i^2 . Para las matrices C_i^3 , C_i^4 y C_i^5 ocurre algo similar, solo que para el diseño de sus respectivos observadores se pueden medir cinco salidas del proceso y con ellas se reconstruye la dinámica del proceso no lineal. Es importante mencionar que sólo estas matrices cumplen con la condición de observabilidad dada en la Ec.3-38. Por lo tanto, haciendo uso de la redundancia analítica del proceso y mediante el análisis de observabilidad al modelo T-S que representa al proceso

3. Neurolocalización de fallas

de fermentación alcohólica se puede realizar la detección de fallas en los sensores que miden los estados x_1 , x_5 y x_6 , que representan la concentración de la biomasa c_X , la temperatura del reactor T_r , la temperatura de la chaqueta térmica T_c , respectivamente.

La estructura del banco de observadores debe ser la apropiada para extraer información sobre las fallas que se presentan en los sensores del proceso de fermentación alcohólica, antes mencionados. Para ello, la estructura pertinente es la de un banco de observadores generalizados como se mostró en la Fig.2-2b. El banco de observadores generalizada en esta tesis se forma a partir de las matrices C_i^1 , C_i^2 , C_i^3 , C_i^4 y C_i^5 , donde la matriz C_i^1 correspondería al observador 1; la matriz C_i^2 al observador 2; la matriz C_i^3 al observador 3; la matriz C_i^4 al observador 4; y finalmente la matriz C_i^5 al observador 5. Dado que el diseño de cada observador parte del modelo T-S obtenido en la sección 2.5, obtendremos un banco de observadores generalizado difuso, cuya estructura se muestra en la Fig.3-7.

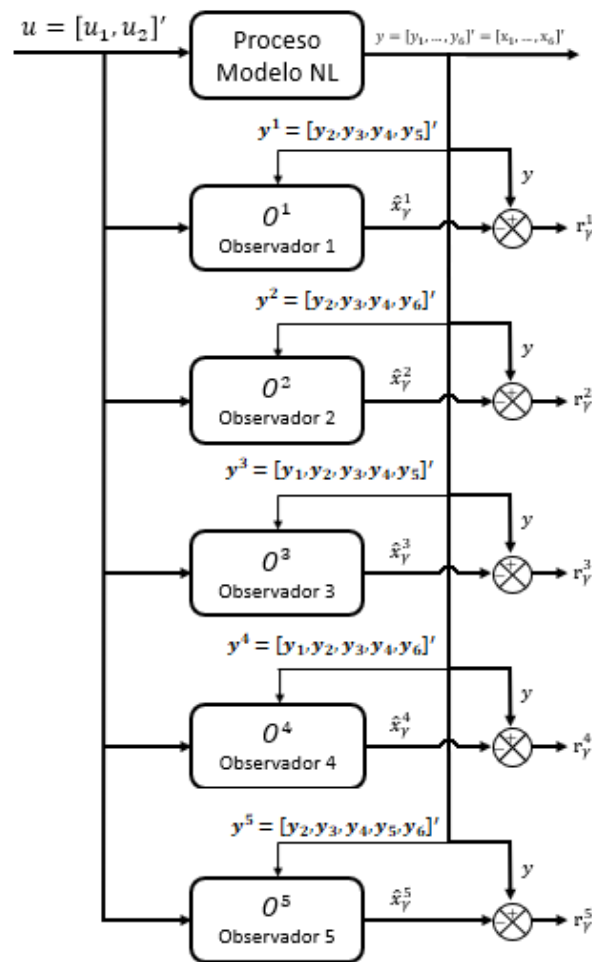


Figura 3-7.: Banco de observadores generalizados para fallas en sensores.

El diseño de los cinco observadores que en conjunto forman al banco de observadores generali-

zado de la Fig.3-7 es mostrado a continuación, empezando por el observador uno O^1 y dos O^2 correspondientes a las matrices C_i^1 y C_i^2 denotadas en Ec.(3-40), respectivamente. El diseño de los observadores tres O^3 , cuatro O^4 y cinco O^5 se muestran en el Anexo B, correspondientes a las matrices C_i^3 , C_i^4 y C_i^5 denotadas en Ec.(3-40), respectivamente.

Diseño del observador O^1 correspondiente a la matriz C_i^1

El diseño del observador O^1 se basa en la primera matriz C obtenida del análisis de observabilidad del modelo no lineal del proceso de fermentación alcohólica, la cual se reescribe en la Ec.(3-42) y que llamaremos C_i^1 . Por lo tanto, a partir de ello y del observador presentado en la Ec.(3-30), el modelo matemático que representa al observador O^1 es:

$$\begin{aligned}\dot{\hat{x}}^1 &= \sum_{i=1}^{16} \phi_i(\hat{z})(A_i \hat{x}^1 + B_{vi} F_c + L_i^1 (y - \hat{y}^1)) + B_{nv} F_{in} + E \\ \hat{y}^1 &= C_i^1 \hat{x}^1\end{aligned}\quad (3-41)$$

donde A_i , B_{vi} , B_{nv} , y E son matrices de dimensiones adecuadas que conforman al modelo T-S denotado en la Ec.(3-17), \hat{x}^1 es el vector de estados estimados y \hat{y}^1 las salidas del observador O^1 , que corresponde a la matriz C_i^1 denotada en la Ec.(3-40).

$$C_i^1 = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}\quad (3-42)$$

A partir de la matriz C_i^1 , note que los estados medibles del proceso para el diseño del O^1 son x_2 , x_3 , x_4 , x_5 y los no medibles son x_1 y x_6 . Por lo tanto, en el diseño del observador, las variables programadas z_1, z_2 , z_3 y z_4 descritas en la Ecs.(3-3), (3-4), (3-5) y (3-6), respectivamente, únicamente la variable programada z_4 debe de ser reconstruida dado que depende del estado no medible x_6 . Entonces, la estimación de la variable programada \hat{z}_4 tiene que ser utilizada en el observador, y la Ec.(3-35) puede ser satisfecha con $\mu = 1$. De modo que, para el cálculo de las ganancias del O^1 las condiciones dadas en la Ec.(3-36) pueden ser transformadas en LMI, mediante el siguiente cambio de variable $M_i^1 = P^1 L_i^1$, $i = 1, 2, \dots, m$, de tal manera que las nuevas condiciones son:

$$\begin{aligned}\mathcal{H}(P^1 A_i - M_i^1 L_i^1) &< -Q^1 \\ \begin{pmatrix} Q^1 - \mu^2 I & P^1 \\ P^1 & I \end{pmatrix} &\geq 0\end{aligned}\quad (3-43)$$

para $i = 1, 2, \dots, m$. Recordemos que $m = 16$, de acuerdo al modelo T-S obtenido en la sección 3.1 y denotado en la Ec.(3-17). Por lo tanto, las ganancias del observador se encuentran resolviendo las LMI dadas en la Ec.(3-43) mediante el Toolbox de Yalmip para MatLab 2014b Lofberg (2004). Las ganancias obtenidas son:

3. Neurolocalización de fallas

$$L_1^1 = \begin{bmatrix} 37,19 & -113,78 & -0,24 & 0,34 \\ 98,20 & -19,65 & -0,86 & -0,84 \\ -18,63 & 176,34 & -0,22 & -1,10 \\ -0,85 & -0,18 & 54,45 & 1,11 \\ -0,88 & -0,87 & 1,11 & 86,03 \\ 0,01 & 0,01 & -0,02 & 0,92 \end{bmatrix} \quad L_2^1 = \begin{bmatrix} 35,48 & -94,63 & -0,24 & 0,34 \\ 89,95 & -16,72 & -0,86 & -0,84 \\ -17,88 & 134,04 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,39 & 1,11 \\ -0,88 & -0,87 & 1,11 & 85,99 \\ 0,01 & 0,01 & -0,02 & 10,02 \end{bmatrix}$$

$$L_3^1 = \begin{bmatrix} 35,56 & -113,82 & -0,24 & 0,34 \\ 90,37 & -19,72 & -0,86 & -0,84 \\ -17,89 & 176,35 & -0,22 & -1,10 \\ -0,85 & -0,18 & 54,37 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,33 \\ 0,01 & 0,01 & -0,02 & 3,25 \end{bmatrix} \quad L_4^1 = \begin{bmatrix} 35,56 & -113,89 & -0,24 & 0,34 \\ 90,37 & -19,66 & -0,86 & -0,84 \\ -17,90 & 176,39 & -0,22 & -1,10 \\ -0,85 & -0,18 & 54,38 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & 1,99 \end{bmatrix}$$

$$L_5^1 = \begin{bmatrix} 38,00 & -94,72 & -0,24 & 0,34 \\ 101,90 & -16,80 & -0,86 & -0,84 \\ -19,04 & 134,09 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,10 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -0,76 \end{bmatrix} \quad L_6^1 = \begin{bmatrix} 37,96 & -94,61 & -0,24 & 0,34 \\ 101,89 & -16,71 & -0,86 & -0,84 \\ -18,94 & 133,91 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,41 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & 2,06 \end{bmatrix}$$

$$L_7^1 = \begin{bmatrix} 37,99 & -94,62 & -0,24 & 0,34 \\ 101,90 & -16,79 & -0,86 & -0,84 \\ -19,04 & 133,92 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,41 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -0,86 \end{bmatrix} \quad L_8^1 = \begin{bmatrix} 37,95 & -94,52 & -0,24 & 0,34 \\ 101,89 & -16,70 & -0,86 & -0,84 \\ -18,94 & 133,88 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,41 & 1,11 \\ -0,88 & -0,87 & 1,11 & 95,52 \\ 0,01 & 0,01 & -0,02 & -0,70 \end{bmatrix}$$

$$L_9^1 = \begin{bmatrix} 37,94 & -94,58 & -0,24 & 0,34 \\ 101,89 & -16,78 & -0,86 & -0,84 \\ -18,93 & 133,90 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,57 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -0,76 \end{bmatrix} \quad L_{10}^1 = \begin{bmatrix} 37,95 & -94,59 & -0,24 & 0,34 \\ 101,89 & -16,71 & -0,86 & -0,84 \\ -18,95 & 133,91 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,59 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -0,76 \end{bmatrix}$$

$$L_{11}^1 = \begin{bmatrix} 38,99 & -94,56 & -0,24 & 0,34 \\ 102,05 & -16,71 & -0,86 & -0,84 \\ -19,40 & 133,89 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,10 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,35 \\ 0,01 & 0,01 & -0,02 & -6,87 \end{bmatrix} \quad L_{12}^1 = \begin{bmatrix} 39,03 & -94,62 & -0,24 & 0,34 \\ 102,06 & -16,72 & -0,86 & -0,84 \\ -19,42 & 133,92 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,57 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,35 \\ 0,01 & 0,01 & -0,02 & -7,37 \end{bmatrix}$$

$$L_{13}^1 = \begin{bmatrix} 39,01 & -94,53 & -0,24 & 0,34 \\ 102,05 & -16,70 & -0,86 & -0,84 \\ -19,41 & 133,88 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,46 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -1,87 \end{bmatrix} \quad L_{14}^1 = \begin{bmatrix} 38,98 & -94,51 & -0,24 & 0,34 \\ 102,05 & -16,69 & -0,86 & -0,84 \\ -19,39 & 133,86 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,59 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -1,87 \end{bmatrix}$$

$$L_{15}^1 = \begin{bmatrix} 39,01 & -94,56 & -0,24 & 0,34 \\ 102,05 & -16,78 & -0,86 & -0,84 \\ -19,49 & 133,89 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,47 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -1,83 \end{bmatrix} \quad L_{16}^1 = \begin{bmatrix} 39,02 & -94,57 & -0,24 & 0,34 \\ 102,05 & -16,78 & -0,86 & -0,84 \\ -19,49 & 133,90 & -0,22 & -1,10 \\ -0,85 & -0,20 & 54,58 & 1,11 \\ -0,88 & -0,87 & 1,11 & 98,34 \\ 0,01 & 0,01 & -0,02 & -1,83 \end{bmatrix}$$

El desempeño del observador O^1 es evaluado en la siguiente simulación:

Simulación 3.1 Desempeño del observador O^1 ante variaciones en la señal de control

El objetivo de la simulación es evaluar el desempeño del observador O^1 al estimar los estados del proceso no lineal. Para ello, tanto el modelo no lineal como el modelo del O^1 son sometidos a cambios en la señal de control F_c , que se muestra en la Fig.3-8. Se puede observar que su valor inicial es 18 l/h hasta que se presenta el primer cambio en el instante 200 h, siendo éste un incremento en forma de escalón que lleva a la señal F_c al valor de 23 l/h manteniéndose así hasta el instante 400 h; que es cuando se presenta el segundo cambio en forma de un escalón que decrece y lleva a la señal F_c al valor de 13 l/h. Finalmente, en el instante 600 h la señal de control F_c regresa a su valor inicial.

3. Neurolocalización de fallas

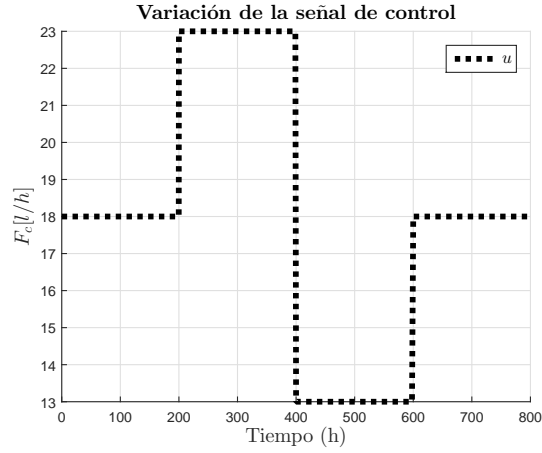


Figura 3-8.: Variación de la señal de control $u = F_c$.

El esquema que ejemplifica esta simulación se muestra en la Fig.3-9, donde se resalta que el O^1 está diseñado de acuerdo al modelo dado en la Ec.(3-41), es decir, el O^1 solo tiene acceso a los estados medibles x_2, x_3, x_4 y x_5 , con los cuales estima los estados del modelo no lineal del proceso de fermentación y los expresa mediante y^1 denotada en Ec.(3-41).

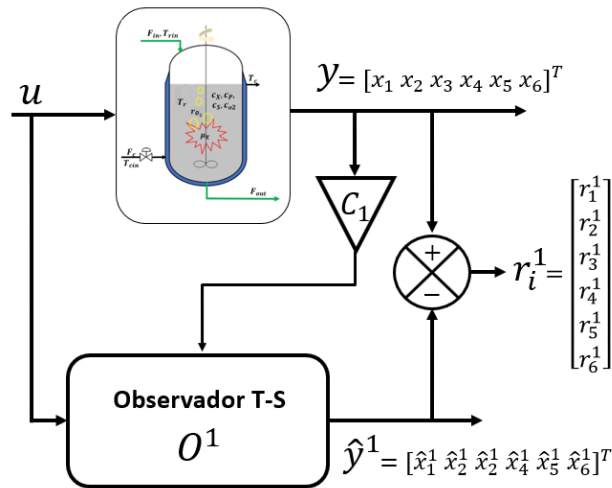


Figura 3-9.: Esquema representativo de la simulación 5.1.

Las condiciones iniciales para los estados del proceso no lineal son:

$$\dot{x}(0) = [x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6]^T = [0.905 \ 12.515 \ 29.739 \ 3.107 \ 29.573 \ 27.054]^T \quad (3-44)$$

y para el O^1 son:

$$\hat{x}^1(0) = [\hat{x}_1^1 \ \hat{x}_2^1 \ \hat{x}_3^1 \ \hat{x}_4^1 \ \hat{x}_5^1 \ \hat{x}_6^1]^T = [0.7 \ 10 \ 27 \ 2.8 \ 27 \ 25]^T \quad (3-45)$$

La comparación entre los estados del proceso no lineal y los estados estimados por el observador O^1 se visualiza en la Fig.3-10, donde la línea en color azul muestra los estados del proceso no lineal, mientras que la línea punteada en color rojo muestra los estados estimados.

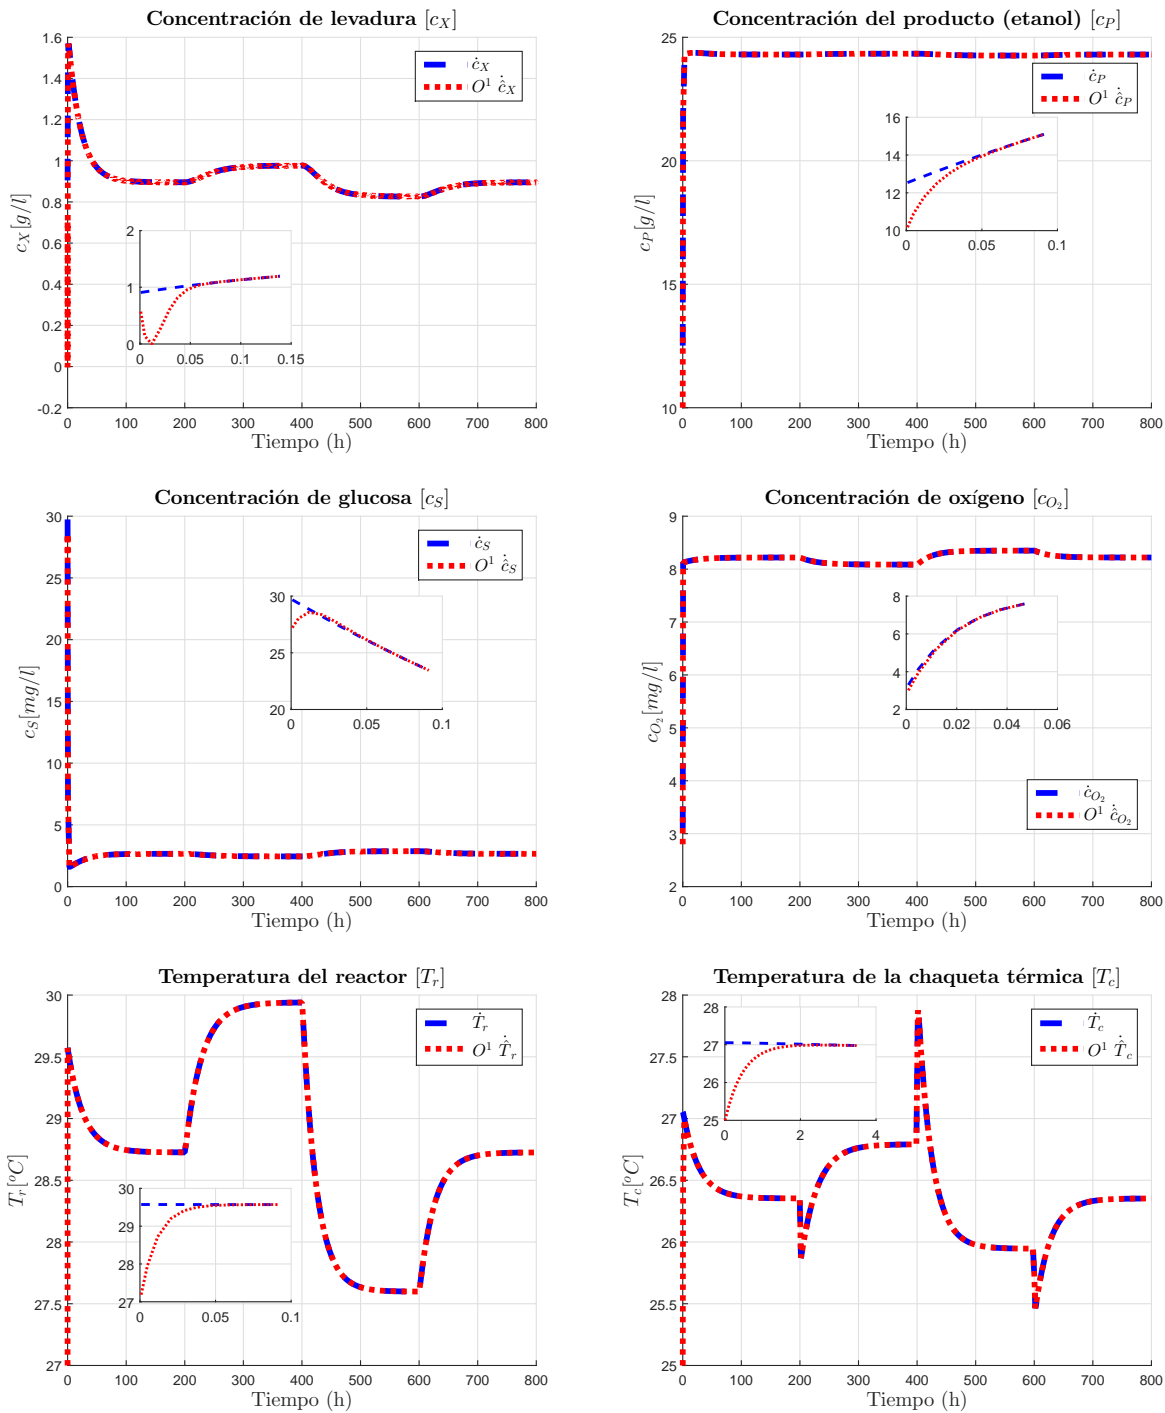


Figura 3-10.: Respuesta del O^1 ante cambios en la señal de control F_c .

Note que, el tiempo de convergencia de los estados estimados es relativamente pequeño, y el observador mantiene la estimación de una forma adecuada ante los cambios realizados en la señal de control F_c . Por ejemplo, ante el primer cambio en el valor de F_c que es un incremento de 5°C generado en la hora 200, provoca un incremento en el estado x_5 y que repercute en todos los demás estados como se

3. Neurolocalización de fallas

muestra en la Fig.3-10, a lo cual el observador estima de forma adecuada todos los estados.

La interpolación entre los 16 modelos que forman al observador O^1 se muestra en la Fig.3-11, mediante las dinámicas de las 16 funciones de pertenencia que corresponden a cada modelo del observador O^1 . Es decir la función de pertenencia ϕ_1 corresponde al modelo uno del observador O^1 . La suma de todas las funciones de pertenencia se denota como $\sum_{i=1}^{16}$ la cual es igual a uno en todo momento.

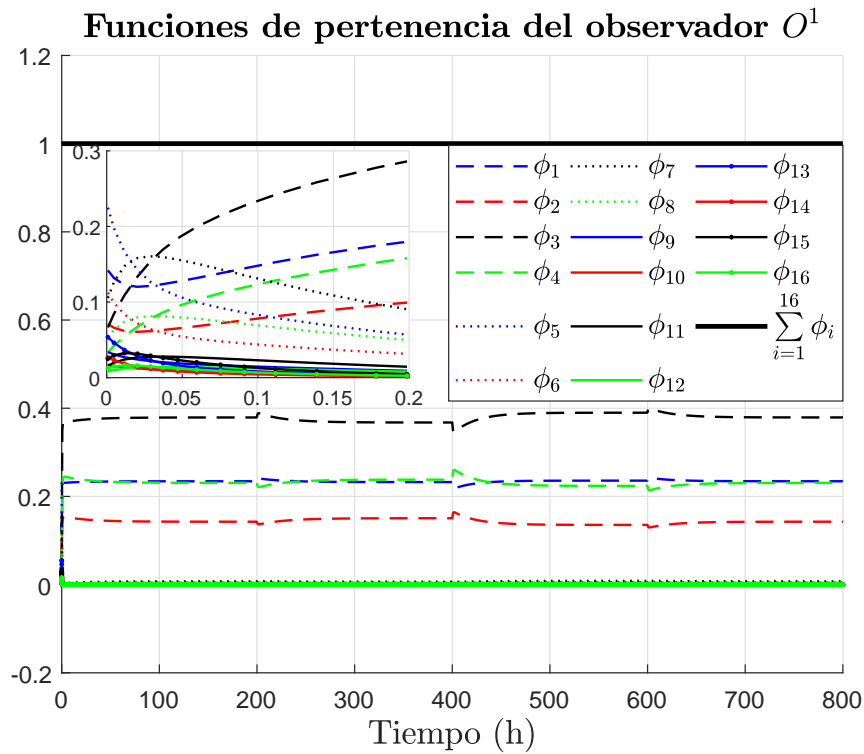


Figura 3-11.: Funciones de pertenencia del observador O^1 .

El error de estimación se muestra en la Fig.3-12, en ella se puede apreciar que el error de estimación es prácticamente cero incluso en las variaciones realizadas a F_c . En los títulos de cada gráfica se expresa la obtención de cada error obtenido por el observador O^1 . Por ejemplo, mediante la expresión $e_1^1 = x_1 - \hat{x}_1^1$ se obtiene el error correspondiente al estado no lineal uno que representa la concentración de la levadura c_x , así para el error $e_2^1 = x_2 - \hat{x}_2^1$ corresponderá al estado no lineal x_2 que representa la concentración del producto. El error del estado no lineal x_3 que corresponde a la concentración de la glucosa se obtiene como $e_3^1 = x_3 - \hat{x}_3^1$, así mismo el error del estado no lineal x_4 que corresponde a la concentración de oxígeno se obtiene como $e_4^1 = x_4 - \hat{x}_4^1$. Para los errores de los estados no lineales x_5 y x_6 que corresponde a la temperatura del reactor y la temperatura de la chaqueta térmica se obtiene como $e_5^1 = x_5 - \hat{x}_5^1$ y $e_6^1 = x_6 - \hat{x}_6^1$, respectivamente. Caso similar ocurre para la obtención de los errores con los observadores O^2 , O^3 , O^4 y O^5 .

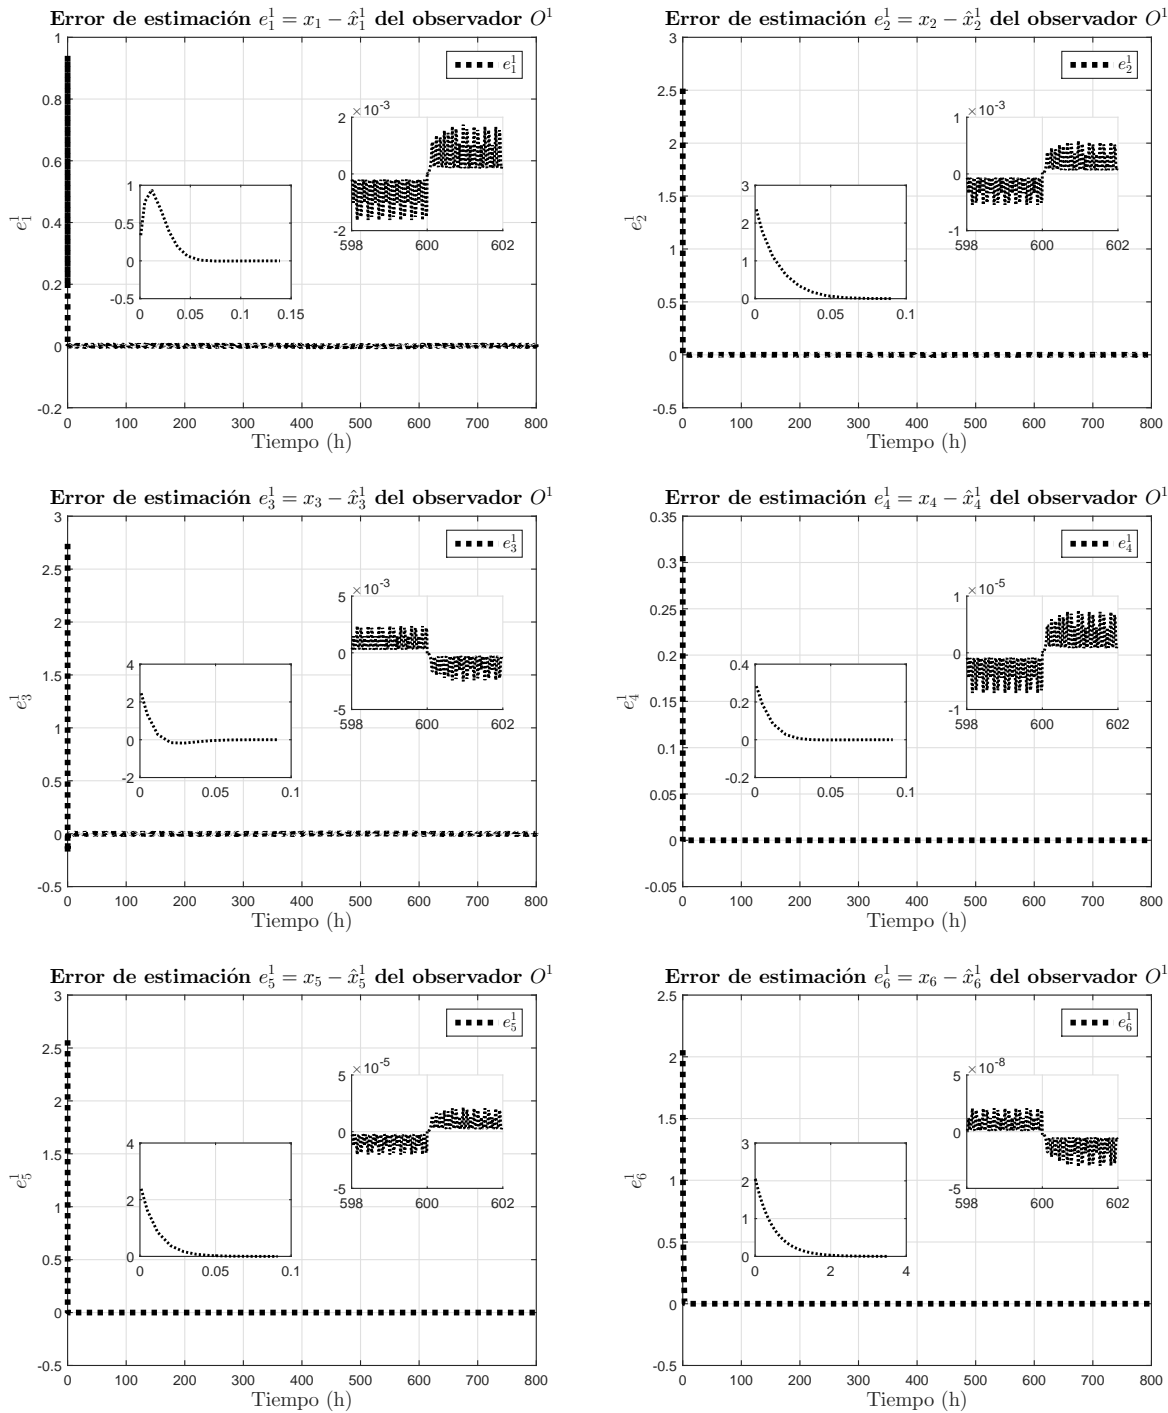


Figura 3-12.: Dinámica de los errores de estimación del O^1 ante cambios en F_c .

La simulación 3.2.1 permite apreciar que el observador estima adecuadamente al proceso no lineal. Por otra parte, en la siguiente simulación se analiza el desempeño del O^1 ante la adición de fallas en el proceso no lineal y con una señal de control $F_c = 18l/h$.

3. Neurolocalización de fallas

Simulación 3.2 Desempeño del observador O^1 ante la presencia de las fallas f_1 , f_2 y f_3 .

Los objetivos de esta simulación son:

1. El análisis del desempeño del O^1 ante la presencia de fallas.
2. La evaluación de los errores de estimación mediante umbrales.
3. Una estructuración de síntomas afines a fallas en particular.

Las fallas que se abordan son del tipo aditivas y su dinámica se muestra en la Fig.3-13. La falla f_1 se presenta en el sensor de la concentración de la levadura x_1 ; la falla f_2 corresponde al sensor x_5 que mide la temperatura del reactor; y la falla f_3 se presenta en el sensor x_6 que mide la temperatura de la chaqueta térmica.

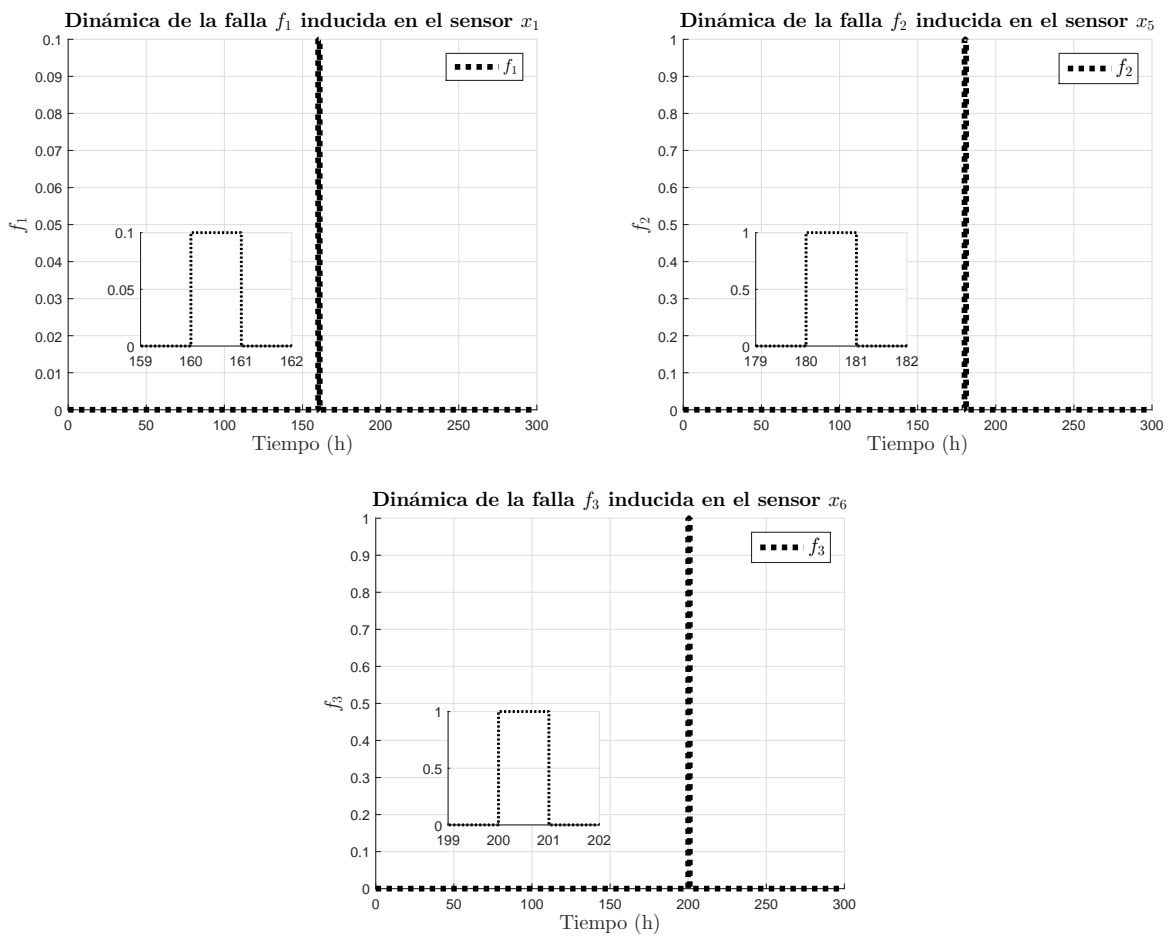


Figura 3-13.: Fallas en los sensores del proceso de fermentación alcohólica.

En la Tabla 3-1 se muestran los tiempos en que se presentan las fallas f_1 , f_2 y f_3 . La dinámica de la falla f_1 permanece en cero hasta la hora 160, instante en el cual cambia de su valor a 0.1 g/l y así se mantiene hasta la hora 161, regresando en este tiempo a un valor de cero. Es decir, durante el

intervalo de tiempo 160 a 161 el sensor sufre una desviación de 0.1 g/l y se genera un cambio en la lectura del sensor. La falla f_2 se presenta en la hora 180, donde de 0°C incrementa su valor a 1°C en este instante de tiempo, manteniendo este valor hasta la hora 181, posteriormente regresa a 0°C . Es decir, durante el intervalo de tiempo 180 a 181 el sensor sufre una desviación de 1°C , en referencia a la temperatura real en el reactor. Finalmente la falla f_3 se presenta en la hora 200, pasando de 0°C a 1°C manteniendo este valor hasta la hora 201, posteriormente regresa a 0°C . Es decir, durante el intervalo de tiempo 200 a 201 el sensor sufre una desviación de 1°C , en referencia a la temperatura real en la chaqueta térmica.

Tabla 3-1.: Descripción de las fallas en sensores.

Falla	Tiempo inicial	Tiempo final	Valor
f_1	160 hrs	161 hrs	$+0.1\text{g/l}$
f_2	180 hrs	181 hrs	-2°C
f_3	200 hrs	201 hrs	-1°C

Con el fin de mostrar el desempeño del O^1 ante la adición de las fallas mostradas en la Fig. 3-13, éstas son añadidas al modelo no lineal del proceso de fermentación alcohólica. Las condiciones iniciales para el modelo no lineal y el observador son las mismas que se dieron en la simulación 3.2.1. En la Fig. 3-14 se muestra la respuesta tanto del proceso como del O^1 ante la presencia de fallas. La línea continua en color azul representa las dinámicas de los estados del proceso no lineal, mientras que la línea punteada en color rojo representa los estados estimados por el O^1 . Aunado a las fallas en las señales de los sensores se presenta ruido, el cual se incide instantes antes de que aparezcan las fallas y terminan instantes después a ellas, de acuerdo a los tiempos de la Tabla 3-2. El ruido es una señal aleatoria de $\pm 0,01$ para los sensores correspondientes a los estados x_1, x_2, x_3 y x_4 , mientras que para los sensores correspondientes a los estados x_5 y x_6 es una señal aleatoria de $\pm 0,1$.

Tabla 3-2.: Ruido en las señales de los sensores.

	Tiempo inicial	Tiempo final	Valor
x_1, x_2, x_3, x_4	158 hrs	163 hrs	$\pm 0,001\text{g/l}$
	178 hrs	183 hrs	$\pm 0,001\text{g/l}$
	198 hrs	203 hrs	$\pm 0,001\text{g/l}$
x_5, x_6	158 hrs	163 hrs	$\pm 0,01^\circ\text{C}$
	178 hrs	183 hrs	$\pm 0,01^\circ\text{C}$
	198 hrs	203 hrs	$\pm 0,01^\circ\text{C}$

La sensibilidad del O^1 a las fallas se aprecia en el instante que se presenta la falla f_1 , ya que no es capaz de reconstruir la dinámica del estado no lineal x_1 mediante el estado reconstruido \hat{x}_1^1 . Con la falla f_3 sucede algo semejante, cuando se presenta f_3 en el estado no lineal x_6 el observador O^1 no estima la falla y con ello se genera una diferencia. Al contrario de lo sucedido con f_1 y f_3 , cuando incide f_2 en el estado x_5 el observador estima correctamente a la falla mediante el estado x_5^1 . Pero esta

3. Neurolocalización de fallas

estimación genera un cambio en la dinámica del estado observado x_6^1 . Esto es derivado del balance de energía del modelo no lineal del proceso de fermentación alcohólica, del cual los pormenores se dieron en la observación 2.5.1. Es por ello que la obtención del error de estimación es trascendental, para evitar falsas alarmas en la detección de fallas. Por lo tanto, el error de estimación se calcula mediante la siguiente expresión:

$$e_\gamma^\tau = x_\gamma - \hat{x}_\gamma^\tau \quad (3-46)$$

donde x_γ representa los estados no lineales, \hat{x}_γ^τ los estados estimados por O^1 . El sub-índice γ representa a un estado en particular y el super-índice τ al observador que los estima. Al obtener el error de estimación mediante la Ec.(3-46) se obtendrían valores positivos y negativos. Los positivos cuando el valor del estado no lineal sea mayor al del estimado, y los negativos cuando el estado estimado sea mayor al no lineal. Esto implica que cuando se presente un cambio en el \hat{x}_6^1 el cual es generado por una falla que incide en el estado x_5 y que repercute en la dinámica de \hat{x}_5^1 , no se genere una falsa alarma derivada del estrecho acoplamiento del balance de energía. Por ejemplo, el error de estimación que se genera entre x_1 y \hat{x}_1^1 es representado mediante la siguiente expresión:

$$e_1^1 = x_1 - \hat{x}_1^1 \quad (3-47)$$

de manera similar los errores e_2^1 , e_3^1 , e_4^1 , e_5^1 y e_6^1 son obtenidos, en correspondencia a su estado y su estado estimado.

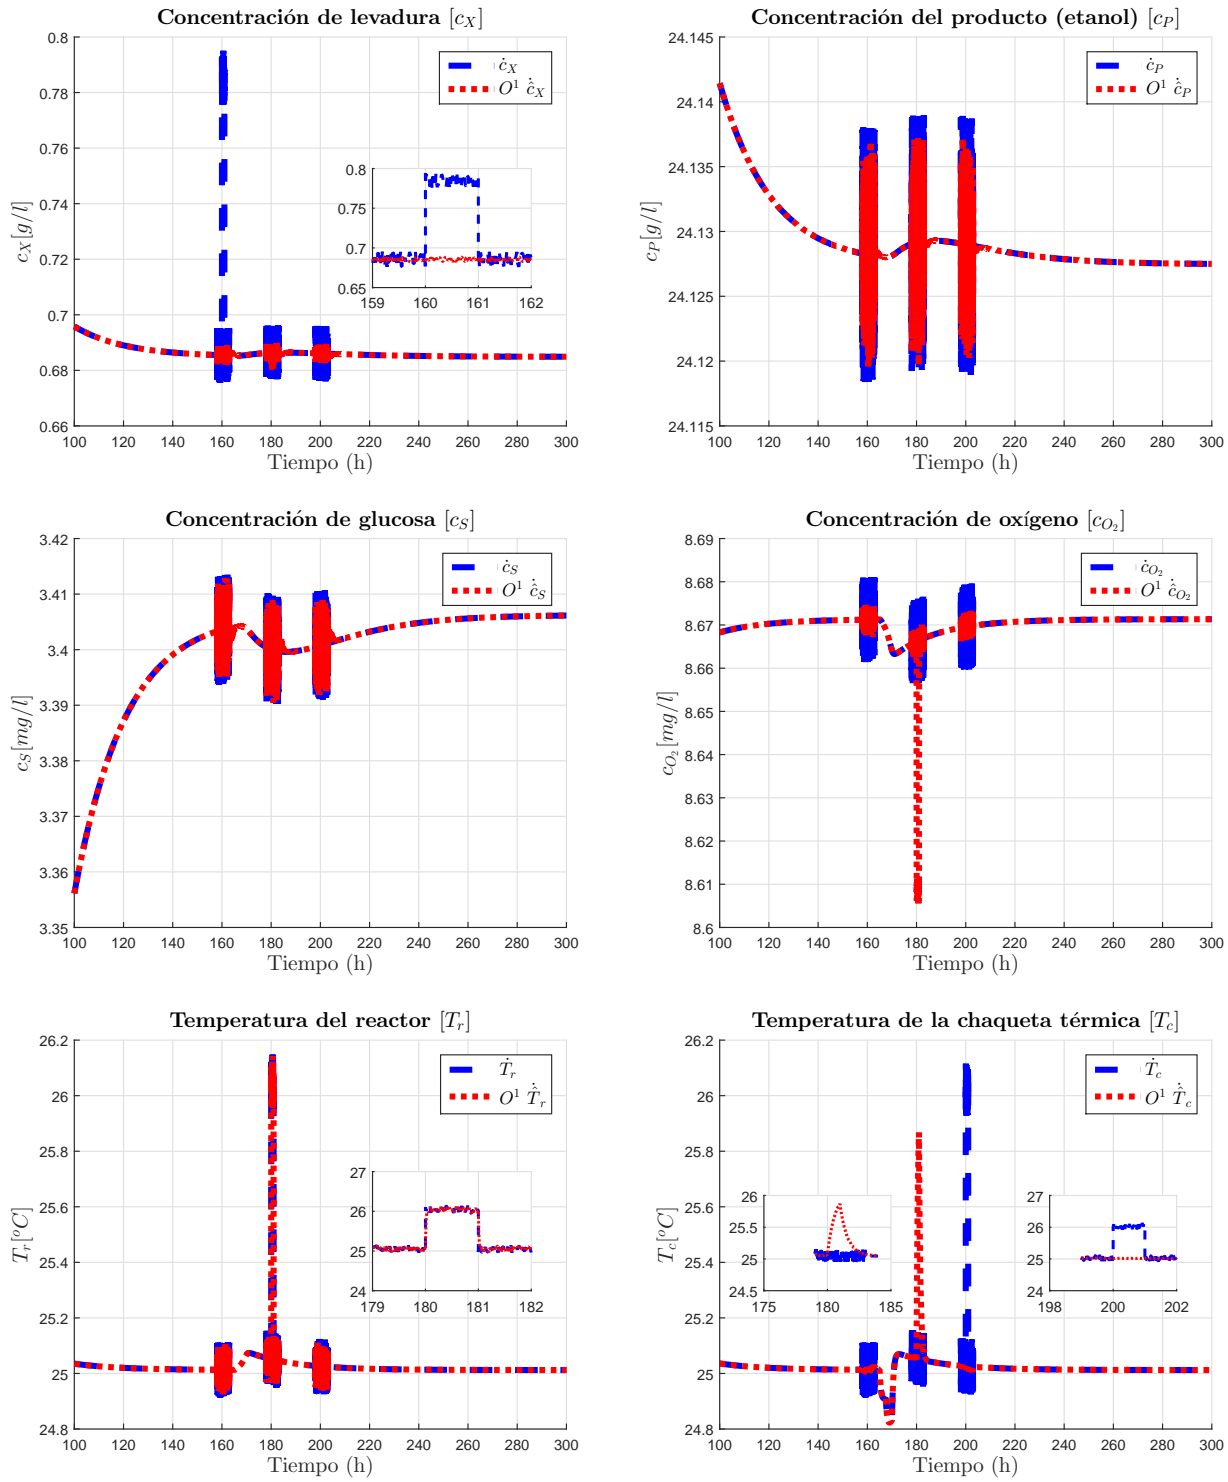


Figura 3-14.: Dinámicas del modelo no lineal y del observador O^1 ante la presencia de fallas.

Note, que la dinámica de e_6^1 muestra valores positivos y negativos. Esto derivado por el estrecho acoplamiento en el balance de energía.

3. Neurolocalización de fallas

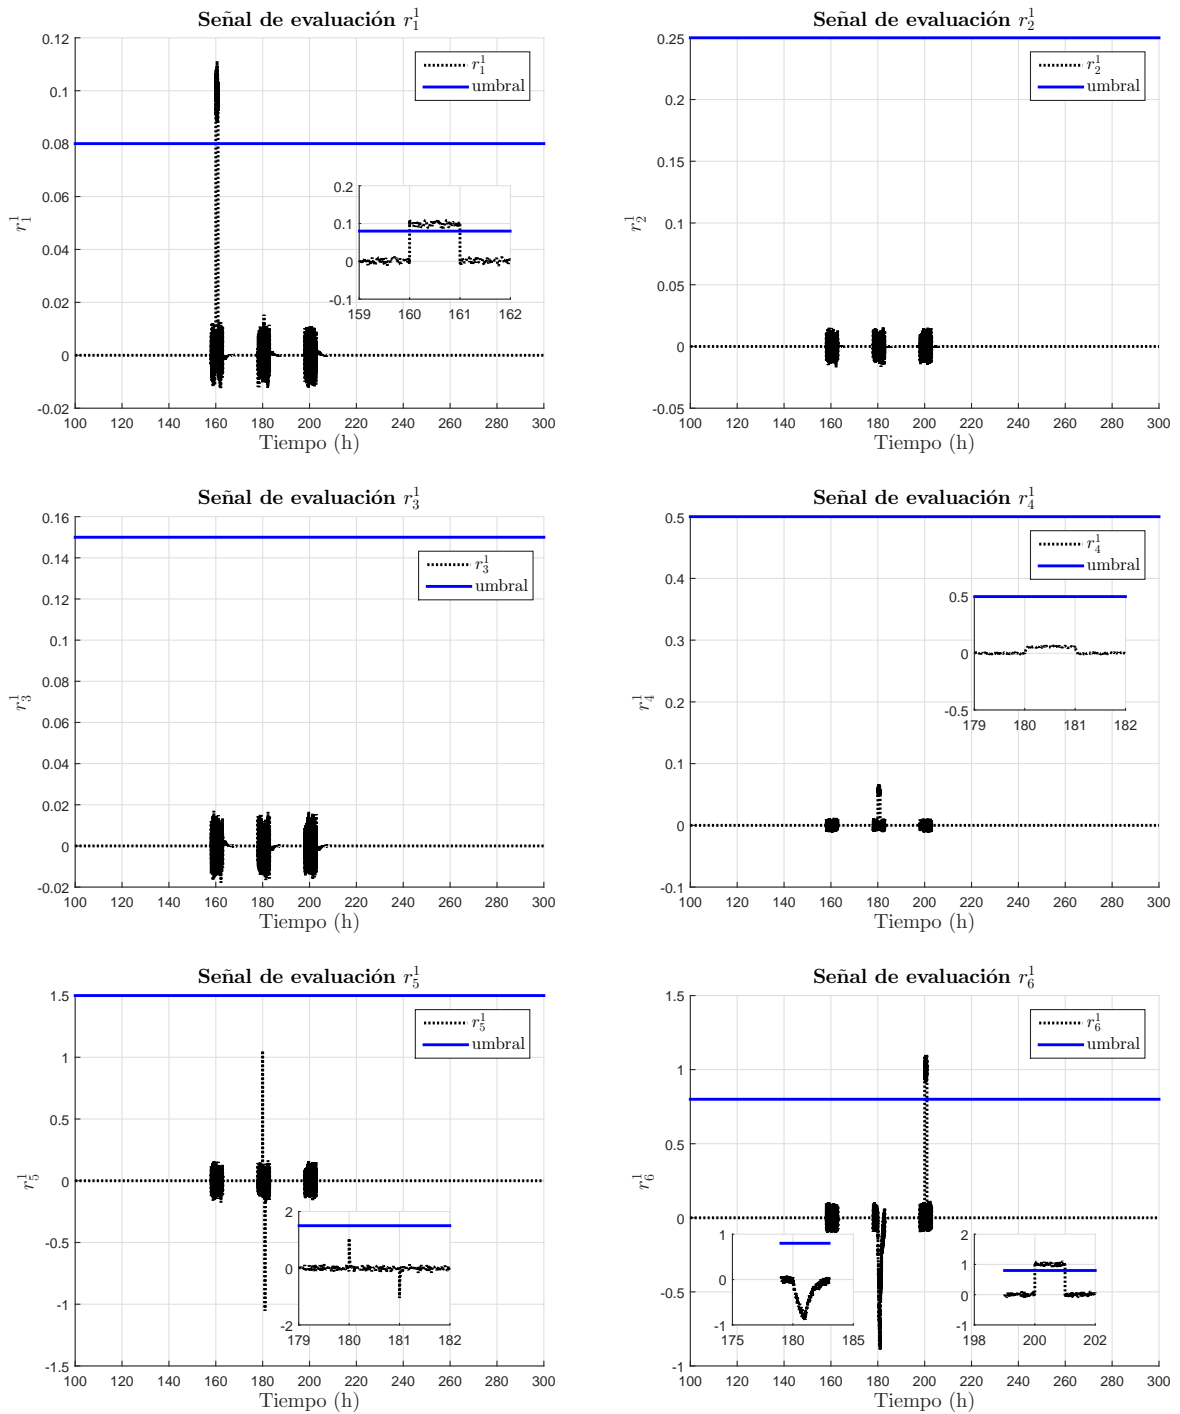


Figura 3-15.: Dinámica de las señales de evaluación r_γ^1 del O^1 .

La evaluación de los errores e_γ^1 se realiza mediante umbrales como se muestra en la Fig 3-15. La señal de evaluación r_γ^1 , mostrada en dicha figura es el residuo de cada error e_γ^1 , es decir para el error

$e_1^1 = x_1 - \hat{x}_1^1 = r_1^1$ se tiene la señal r_1^1 . De manera similar las señales de evaluación $r_2^1, r_3^1, r_4^1, r_5^1$ y r_6^1 son obtenidas.

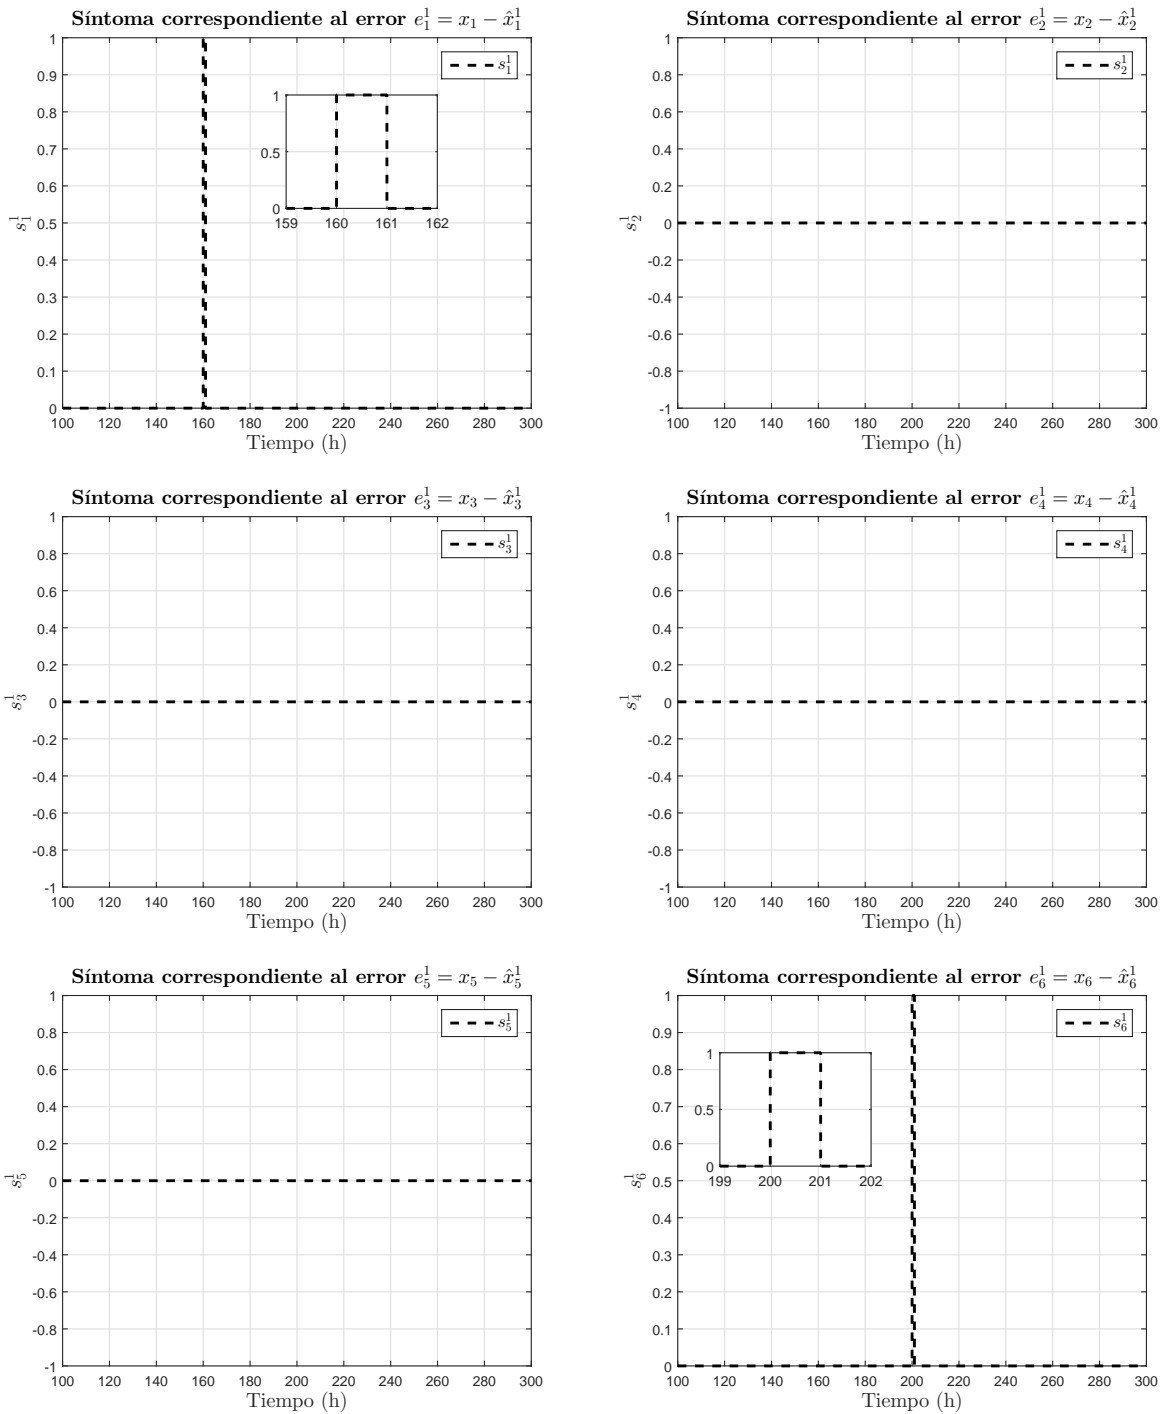


Figura 3-16.: Síntomas s_γ^1 generados a partir de la evaluación de los errores de estimación e_γ^1 .

El valor del umbral de evaluación es establecido de manera a priori, por el diseñador. Es decir, el diseñador cuenta con los conocimientos necesarios y suficientes obtenidos ya sea de manera analítica o

3. Neurolocalización de fallas

empírica para establecer el valor de un umbral para cada señal de evaluación. Así, cuando un umbral es superado por una señal de evaluación se genera un síntoma en particular. Por ejemplo, cuando se presentan las fallas f_1 y f_3 los umbrales de cada falla son superados por su respectiva señal de evaluación y se generan los síntomas s_1^1 y s_6^1 , respectivamente, como se muestra en la Fig.3-16.

En la Fig.3-16 se muestra la dinámica de los síntomas s_γ^1 obtenidos mediante el análisis de la señal de evaluación o residuo r_γ^1 . La diferencia de un residuo y un síntoma, es que el síntoma mantiene un valor constante durante el tiempo en que el residuo supera el umbral establecido para él, aunque el valor del residuo varíe durante este tiempo. Es por ello que las dinámicas de los s_γ^1 mostrados en la Fig.3-16 mantiene dos valores 0 o 1. Cuando el valor es 1 indica la presencia de una falla y en caso contrario 0 indica que no existe falla. Por ejemplo, cuando s_1^1 y s_6^1 valen 1 indican la presencia de las fallas f_1 y f_3 , respectivamente.

Diseño del observador O^2 correspondiente a la matriz C_i^2

A diferencia del diseño del observador O^1 , el diseño del observador O^2 parte de la matriz C_i^2 , la cual se reescribe en la Ec.3-49. Esto con el fin de formar el banco de observadores como se muestra en la Fig.3-7. Por lo tanto, a partir de la matriz C_i^2 y del observador presentado en la Ec.(3-30), el modelo matemático que representa al observador O^2 es:

$$\begin{aligned}\dot{\hat{x}}^2 &= \sum_{i=1}^{16} \phi_i(\hat{z})(A_i \hat{x}^2 + B_{vi} F_c + L_i^2 (y - \hat{y}^2)) + B_{nv} F_{in} + E \\ \hat{y}^2 &= C_i^2 \hat{x}^2\end{aligned}\quad (3-48)$$

donde A_i , B_{vi} , B_{nv} , y E son matrices de dimensiones adecuadas que conforman al modelo T-S denotado en la Ec.(3-17), \hat{x}^2 es el vector de estados estimados y \hat{y}^2 las salidas del observador O^2 , que corresponde a la matriz C_2 denotada en la Ec.(3-40) y que se reescribe a continuación:

$$C_i^2 = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}\quad (3-49)$$

A partir de la matriz C_i^2 , note que los estados medibles del proceso en el diseño del O^2 son x_2 , x_3 , x_4 , x_6 y los no medibles son x_1 y x_5 . Por lo tanto, en el diseño del observador, las variables programadas z_1, z_2 , z_3 y z_4 descritas en la Ecs.(3-3), (3-4), (3-5) y (3-6), respectivamente, únicamente la variable programada z_1 debe de ser reconstruida dado que depende del estado no medible x_5 . Entonces, la estimación de la variable programada \hat{z}_1 tiene que ser utilizada en el observador, y la Ec.(3-35) puede ser satisfecha con $\mu = 1$. De modo que, para el cálculo de las ganancias del O^2 las condiciones dadas en la Ec.(3-36) pueden ser transformadas en LMI, mediante el siguiente cambio de variable $M_i^2 = P^2 L_i^2$, $i = 1, 2, \dots, m$, de tal manera que las nuevas condiciones son:

$$\begin{aligned}\mathcal{H}(P^2 A_i^2 - M_i^2 L_i^2) &< -Q^2 \\ \begin{pmatrix} Q^2 - \mu^2 I & P^2 \\ P^2 & I \end{pmatrix} &\geq 0\end{aligned}\quad (3-50)$$

para $i = 1, 2, \dots, m$, siendo $m = 16$. Por lo tanto, las ganancias para el O^2 son encontradas resolviendo las LMI formuladas en la Ec.(3-43) mediante el Toolbox de Yalmip para MatLab 2014b Lofberg (2004). Las ganancias obtenidas son:

$$L_1^2 = \begin{bmatrix} 37,61 & -98,01 & -1,61 & -0,34 \\ 102,35 & -15,60 & -1,36 & 0,14 \\ -17,26 & 142,24 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,71 & -0,76 \\ 0,19 & 0,64 & -0,77 & 302,80 \\ 0,19 & 0,65 & -0,78 & 103,34 \end{bmatrix} \quad L_2^2 = \begin{bmatrix} 40,52 & -97,60 & -1,61 & -0,34 \\ 117,07 & -15,54 & -1,36 & 0,14 \\ -18,30 & 141,35 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,74 & -0,76 \\ 0,19 & 0,64 & -0,77 & 20,61 \\ 0,19 & 0,65 & -0,78 & 94,79 \end{bmatrix}$$

$$L_3^2 = \begin{bmatrix} 37,52 & -97,59 & -1,61 & -0,34 \\ 102,51 & -15,54 & -1,36 & 0,14 \\ -16,99 & 141,34 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,75 & -0,76 \\ 0,19 & 0,64 & -0,77 & 303,94 \\ 0,19 & 0,65 & -0,78 & 102,42 \end{bmatrix} \quad L_4^2 = \begin{bmatrix} 39,91 & -97,58 & -1,61 & -0,34 \\ 114,02 & -15,53 & -1,36 & 0,14 \\ -18,03 & 141,34 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,72 & -0,76 \\ 0,19 & 0,64 & -0,77 & 39,46 \\ 0,19 & 0,65 & -0,78 & 94,97 \end{bmatrix}$$

$$L_5^2 = \begin{bmatrix} 39,91 & -97,60 & -1,61 & -0,34 \\ 114,02 & -15,53 & -1,36 & 0,14 \\ -18,03 & 141,34 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,73 & -0,76 \\ 0,19 & 0,64 & -0,77 & 38,15 \\ 0,19 & 0,65 & -0,78 & 94,74 \end{bmatrix} \quad L_6^2 = \begin{bmatrix} 37,48 & -97,59 & -1,61 & -0,34 \\ 102,50 & -15,53 & -1,36 & 0,14 \\ -16,97 & 141,34 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,74 & -0,76 \\ 0,19 & 0,64 & -0,77 & 19,59 \\ 0,19 & 0,65 & -0,78 & 94,20 \end{bmatrix}$$

$$L_7^2 = \begin{bmatrix} 37,48 & -105,32 & -1,61 & -0,34 \\ 102,50 & -16,71 & -1,36 & 0,14 \\ -16,97 & 158,38 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,71 & -0,76 \\ 0,19 & 0,64 & -0,77 & 37,80 \\ 0,19 & 0,65 & -0,78 & 94,32 \end{bmatrix} \quad L_8^2 = \begin{bmatrix} 37,49 & -105,33 & -1,61 & -0,34 \\ 102,58 & -16,71 & -1,36 & 0,14 \\ -16,98 & 158,41 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,71 & -0,76 \\ 0,19 & 0,64 & -0,77 & 565,26 \\ 0,19 & 0,65 & -0,78 & 108,73 \end{bmatrix}$$

$$L_9^2 = \begin{bmatrix} 37,47 & -105,35 & -1,61 & -0,34 \\ 102,50 & -16,71 & -1,36 & 0,14 \\ -16,97 & 158,41 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,74 & -0,76 \\ 0,19 & 0,64 & -0,77 & 13,14 \\ 0,19 & 0,65 & -0,78 & 93,93 \end{bmatrix} \quad L_{10}^2 = \begin{bmatrix} 37,49 & -105,42 & -1,61 & -0,34 \\ 102,59 & -16,72 & -1,36 & 0,14 \\ -16,97 & 158,45 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,88 & -0,76 \\ 0,19 & 0,64 & -0,77 & 12,70 \\ 0,19 & 0,65 & -0,78 & 93,90 \end{bmatrix}$$

3. Neurolocalización de fallas

$$L_{11}^2 = \begin{bmatrix} 37,46 & -105,38 & -1,61 & -0,34 \\ 102,50 & -16,72 & -1,36 & 0,14 \\ -16,96 & 158,44 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,90 & -0,76 \\ 0,19 & 0,64 & -0,77 & 12,55 \\ 0,19 & 0,65 & -0,78 & 93,90 \end{bmatrix} \quad L_{12}^2 = \begin{bmatrix} 37,49 & -97,64 & -1,61 & -0,34 \\ 102,55 & -15,54 & -1,36 & 0,14 \\ -16,98 & 141,37 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,88 & -0,76 \\ 0,19 & 0,64 & -0,77 & 16,54 \\ 0,19 & 0,65 & -0,78 & 94,00 \end{bmatrix}$$

$$L_{13}^2 = \begin{bmatrix} 37,50 & -97,90 & -1,61 & -0,34 \\ 102,55 & -15,58 & -1,36 & 0,14 \\ -16,98 & 141,49 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,74 & -0,76 \\ 0,19 & 0,64 & -0,77 & 37,94 \\ 0,19 & 0,65 & -0,78 & 94,57 \end{bmatrix} \quad L_{14}^2 = \begin{bmatrix} 37,50 & -97,92 & -1,61 & -0,34 \\ 102,54 & -15,58 & -1,36 & 0,14 \\ -16,98 & 141,49 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,76 & -0,76 \\ 0,19 & 0,64 & -0,77 & 37,94 \\ 0,19 & 0,65 & -0,78 & 94,57 \end{bmatrix}$$

$$L_{15}^2 = \begin{bmatrix} 37,50 & -97,90 & -1,61 & -0,34 \\ 102,54 & -15,58 & -1,36 & 0,14 \\ -16,98 & 141,48 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,76 & -0,76 \\ 0,19 & 0,64 & -0,77 & 48,97 \\ 0,19 & 0,65 & -0,78 & 94,87 \end{bmatrix} \quad L_{16}^2 = \begin{bmatrix} 37,49 & -97,92 & -1,61 & -0,34 \\ 102,54 & -15,58 & -1,36 & 0,14 \\ -16,98 & 141,49 & 2,68 & 0,84 \\ -1,14 & 1,91 & 57,69 & -0,76 \\ 0,19 & 0,64 & -0,77 & 46,15 \\ 0,19 & 0,65 & -0,78 & 94,79 \end{bmatrix}$$

A partir de las ganancias obtenidas para O^2 . La siguiente simulación muestra el desempeño del observador O^2 ante una señal de control $F_c = 18l/h$ y la presencia de las fallas f_1 , f_2 , y f_3 , cuya dinámica se muestra en la Fig. 3-13. Dichas fallas son las mismas que se utilizaron en la Simulación 5.2, donde la falla f_1 se presenta en el sensor de la concentración de la levadura x_1 ; la falla f_2 corresponde al sensor x_5 que mide la temperatura del reactor; y la falla f_3 se presenta en el sensor x_6 que mide la temperatura de la chaqueta térmica.

Simulación 3.3 Desempeño del observador O^2 ante la presencia de fallas f_1 , f_2 y f_3 .

Los objetivos de esta simulación son:

1. El análisis del desempeño del O^2 ante la presencia de fallas.
2. La evaluación de los errores de estimación mediante umbrales.
3. Una estructuración de síntomas afines a fallas en particular.

Con el fin de mostrar el desempeño del O^2 ante la adición de las fallas mostradas en la Fig. 3-13, éstas son añadidas al modelo no lineal del proceso de fermentación alcohólica. Las condiciones iniciales para el modelo no lineal y el observador son las mismas que se dieron para la simulación 3.2.1.

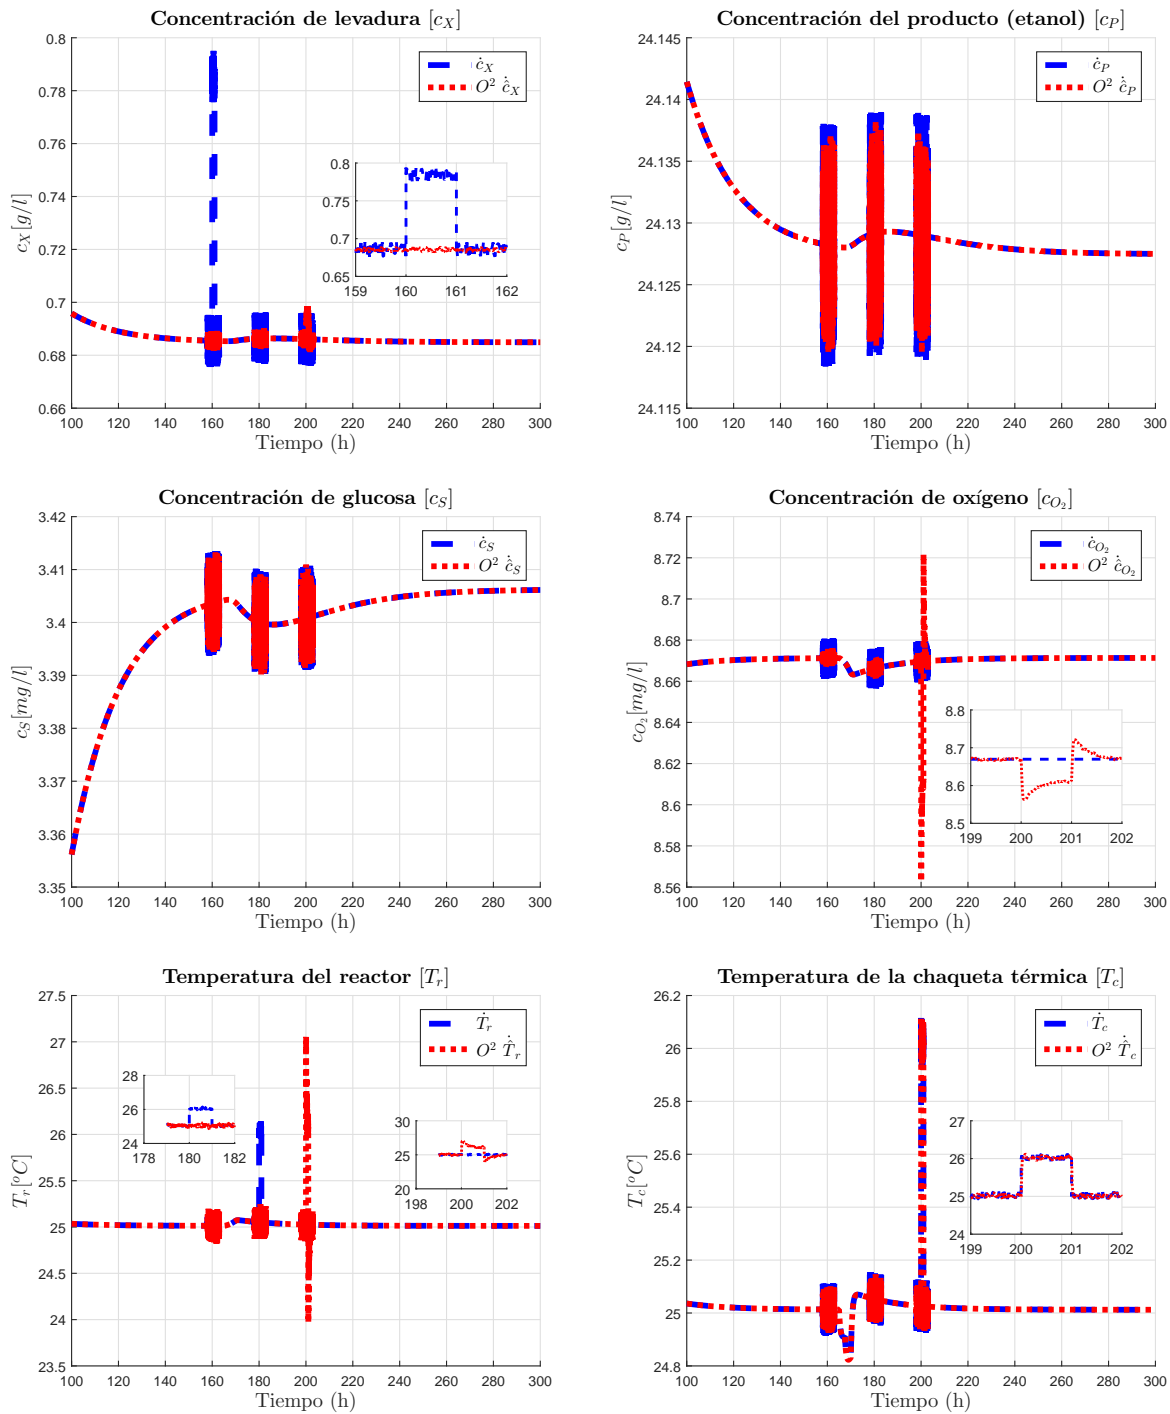


Figura 3-17.: Dinámicas del modelo no lineal y del observador O^2 ante la presencia de fallas.

3. Neurolocalización de fallas

En la Fig. 3-17 se muestra la respuesta tanto del proceso como del O^2 ante la presencia de fallas y ruido, descritos en las Tablas 3-1 y 3-2, respectivamente. Las líneas continuas en color azul representan la dinámica de los estados del modelo no lineal y las líneas punteadas de color rojo la dinámica de los estados estimados del observador O^2 .

La falla f_1 se presenta en el sensor de la concentración de la levadura x_1 ; la falla f_2 corresponde al sensor x_5 que mide la temperatura del reactor; y la falla f_3 se presenta en el sensor x_6 que mide la temperatura de la chaqueta térmica.

La sensibilidad del O^2 a las fallas mostradas en la Fig. 3-13 se aprecia en el instante que se presenta la falla f_1 sobre el estado del modelo no lineal x_1 correspondiente a la concentración de la levadura, la cual representa una desviación positiva en la medición del sensor. Entonces, el observador O^2 no estima la falla y con ello se genera una diferencia. La falla f_2 se presenta sobre el estado del modelo no lineal x_5 correspondiente a la temperatura del reactor, la cual representa una desviación positiva en la medición del sensor. Cuando se manifiesta f_2 sucede algo semejante a cuando se presenta f_1 , es decir, el observador O^2 es sensible a la falla. Es decir, el observador O^2 no estima la falla y con ello se genera una diferencia.

Cuando se manifiesta la falla f_3 sobre el estado x_6 el observador estima de manera correcta la falla, mediante el estado observado \hat{x}_6^2 . Pero dicha estimación, repercute en el estado estimado \hat{x}_5^2 creando un cambio en su dinámica con respecto al estado x_5 del modelo no lineal. Este cambio es derivado del estrecho acoplamiento del balance de energía que presenta el modelo no lineal del proceso de fermentación alcohólica como se mencionó en la Observación 2.5.1.

Por otra parte, como se mencionó en la simulación 3.2.1, que el error de estimación se calcula mediante la Ec.3-46. Por lo tanto, se obtendrán valores positivos y negativos. Por ejemplo, en el error e_5^2 , que corresponde a la diferencia entre el estado no lineal x_5 y el estado estimado \hat{x}_5^2 se genera una primera diferencia positiva en el instante que se presenta la falla f_2 y con ello se puede generar un síntoma; sin embargo, cuando se presenta la falla f_3 la diferencia es negativa y se evita una falsa alarma. Es importante evitar las falsas alarmas, puesto que pueden generar falsos síntomas y con ello falsas localizaciones de fallas. Otro punto es que si la falsa alarma pertenece a una falla que al ocurrir se dé el orden del paro en el desarrollo del proceso de fermentación alcohólica causará la pérdida del producto.

La evaluación de los errores e_γ^2 se realiza mediante umbrales como se muestra en la Fig.3-18. La señal de evaluación r_γ^2 , mostrada en dicha figura es el residuo de cada error e_γ^2 , es decir para el error $e_1^2 = x_1 - \hat{x}_1^2 = r_1^2$ se tiene la señal r_1^2 . De manera similar las señales de evaluación $r_2^2, r_3^2, r_4^2, r_5^2$ y r_6^2 son obtenidas.

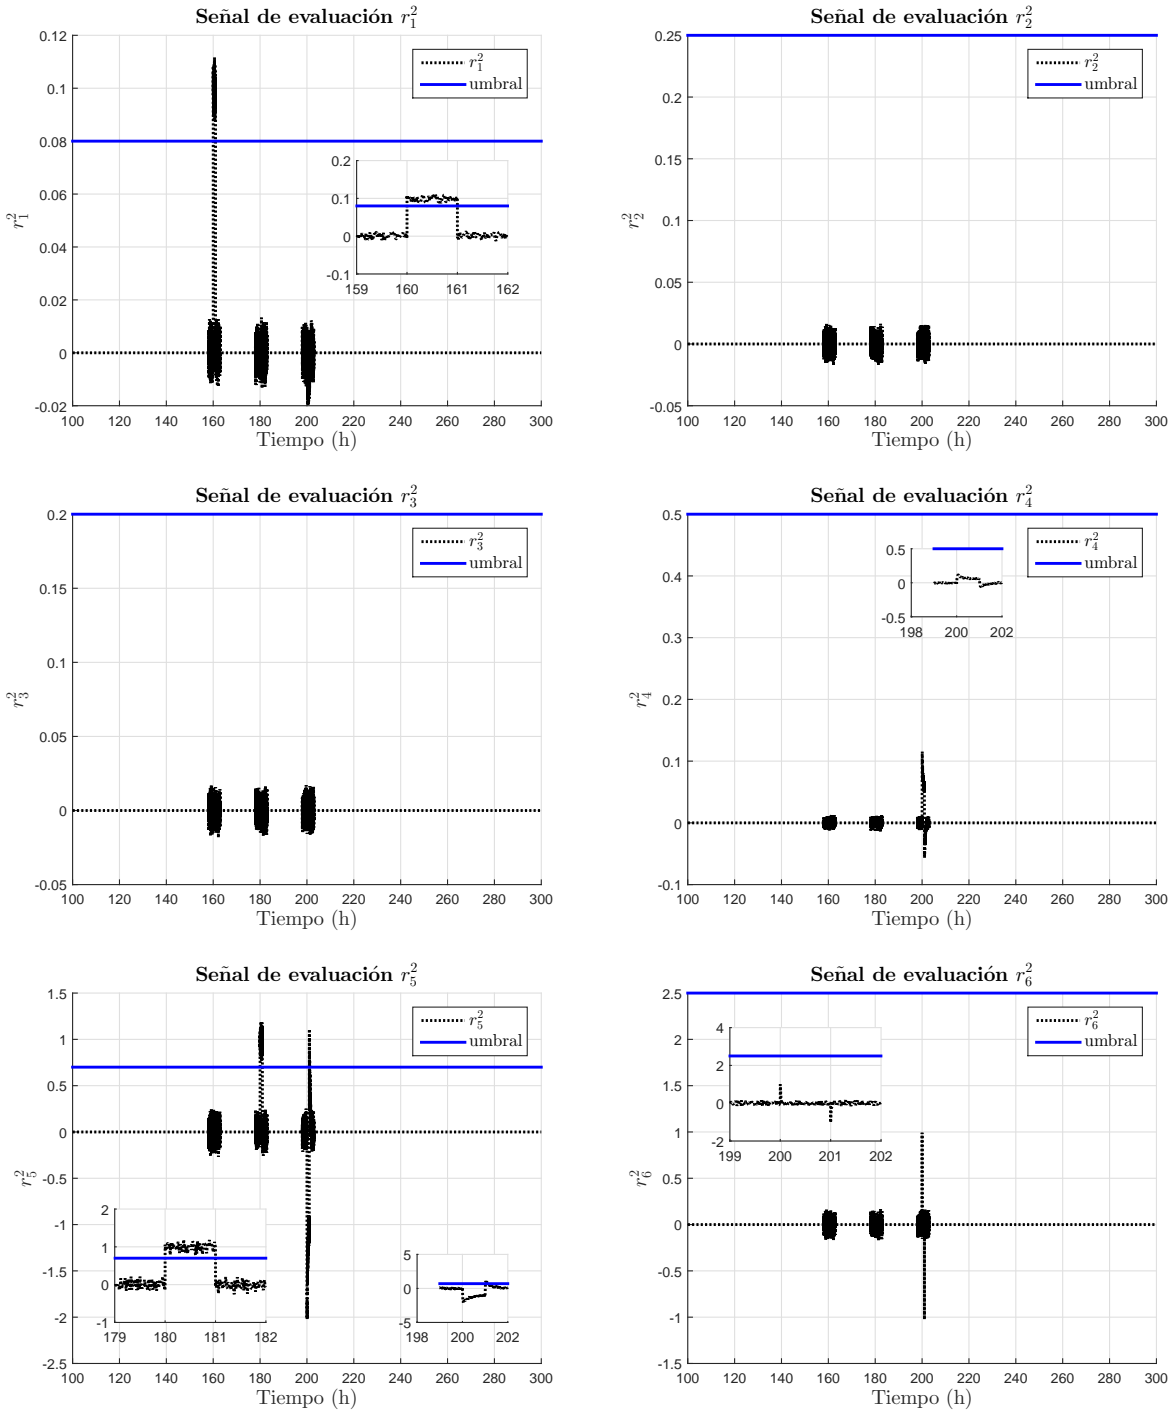


Figura 3-18.: Dinámica de las señales de evaluación r_γ^2 del O^2 .

El valor del umbral de evaluación es establecido de manera a priori, por el diseñador. Recordemos que si el diseñador cuenta con los conocimientos necesarios y suficientes puede establecer el valor de un umbral para cada señal de evaluación. Así, cuando un umbral es superado por una señal de evaluación se genera un síntoma en particular. Por ejemplo, cuando se presentan las fallas f_1 y f_2 los umbrales

3. Neurolocalización de fallas

de cada falla son superados por su respectiva señal de evaluación y se generan los síntomas s_1^2 y s_5^2 , como se muestra en la Fig.3-19.

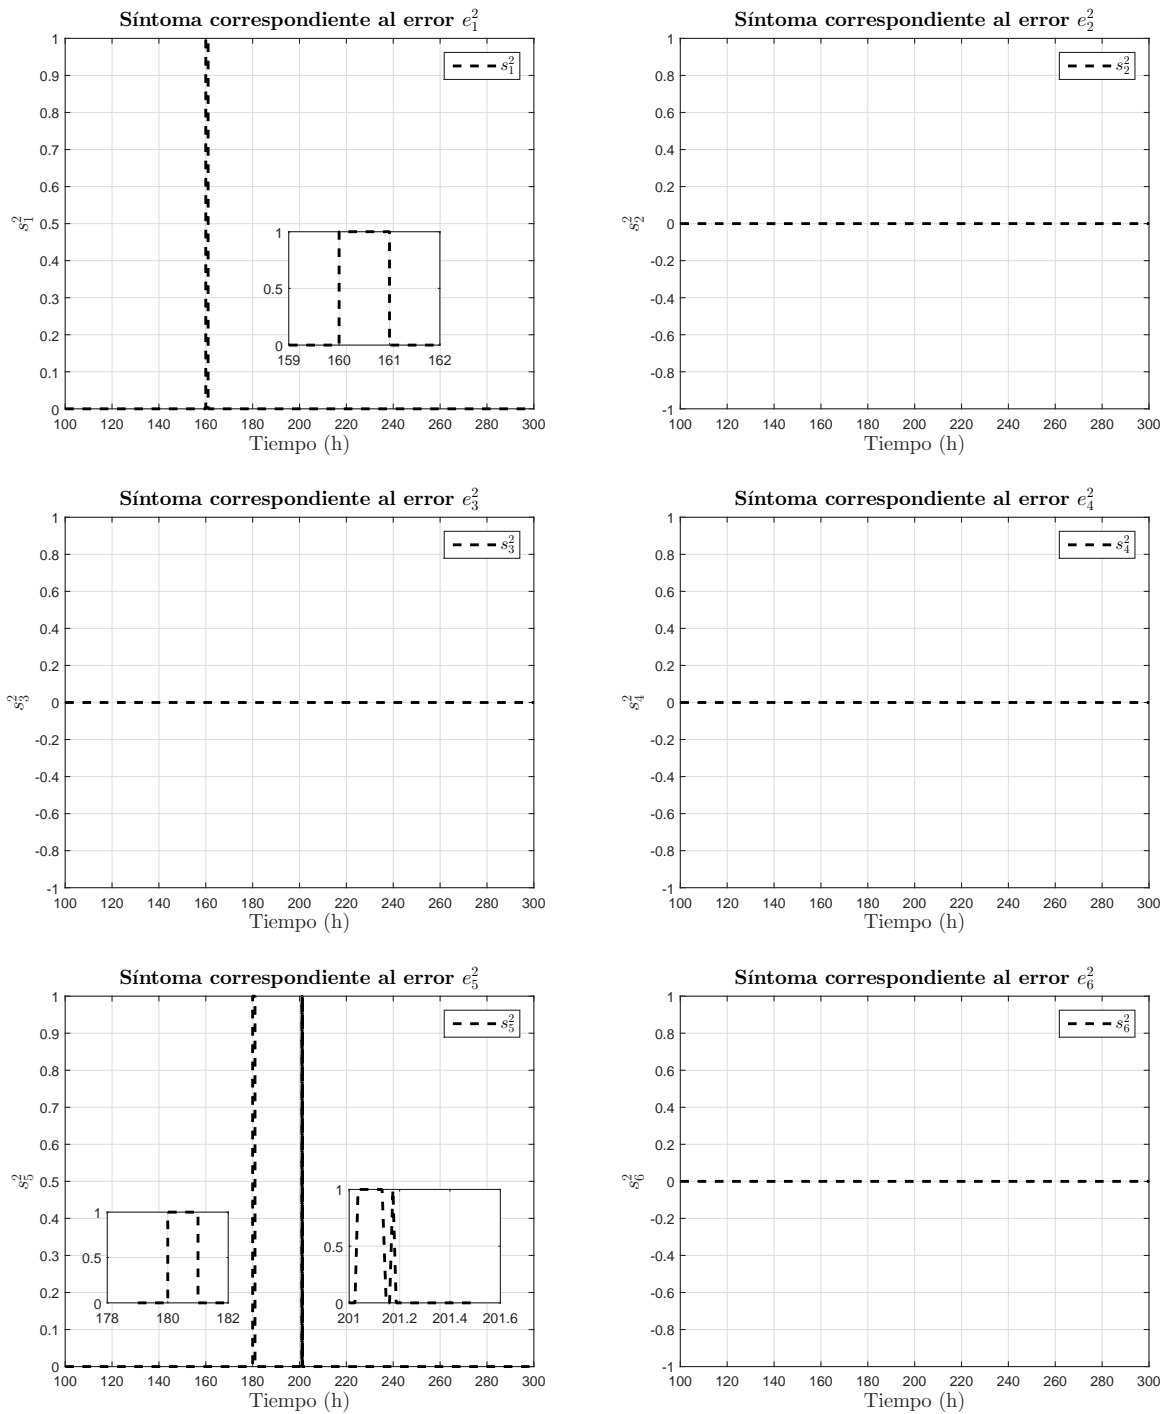


Figura 3-19.: Síntomas S_γ^2 generados a partir de la evaluación de los errores de estimación e_γ^2 .

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

En la Fig. 3-19 se muestra la dinámica de los síntomas s_γ^2 obtenidos mediante el análisis de la señal de evaluación o residuo r_γ^2 . Las dinámicas de los s_γ^2 muestran que solo se mantienen dos valores 0 o 1, y cuando el valor es 1 indica la presencia de una falla, en caso contrario el valor 0 indica que no existe falla. Por ejemplo, cuando s_1^2 y s_5^2 valen 1 indican la presencia de las fallas f_1 y f_2 , respectivamente.

Recuerde que los pormenores en el diseño del observador O^3 , el observador O^4 y del observador O^5 son realizados en los Anexos B.1, B.2 y B.3, respectivamente.

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

En el capítulo 2 sección 2.3 se enunció el modelo matemático de un proceso no lineal en la Ec.2-45, el cual se escribe a continuación y que permite visualizar la presencia de fallas en el proceso y actuadores.

$$\Sigma_{f_{AB}} : \begin{cases} \dot{x} = (A_0 + \Delta_A)x + (B_0 + \Delta_B)u \\ y = x \end{cases} \quad (3-51)$$

El caso en que se presente una falla en proceso fue analizado en la sección 2.3. En esta sección, la posibilidad de que se presenta una falla en actuadores es vista talque:

$$\Delta_B \neq 0 \text{ y } \Delta_A = 0$$

de tal forma que el modelo no lineal se reescribe de la siguiente forma:

$$\Sigma_{f_B} : \begin{cases} \dot{x} = (A_0)x + (B_0 + \Delta_B)u \\ y = x \end{cases} \quad (3-52)$$

donde la parte sin falla de la matriz B se representa por B_0 , la parte con una o varias fallas se representa por $\Delta_B(t)$. Este diseño permite extraer información sobre las fallas presentes en los actuadores del proceso. Por lo tanto, para desarrollar el modelo dado de la RNA descrito en la Ec.3-52 se toman las siguientes consideraciones:

Suposición 3.1 En el diseño de la red neuronal al estar enfocada para la extracción de residuos y síntomas cuando se presentan fallas en actuadores se asume que se tiene acceso a los estados del proceso.

Suposición 3.2 La parte desconocida correspondiente al término $\Delta_B(t)$ es acotada, y solo se conoce que la norma euclidiana de la incertidumbre es menor o igual que un valor dado denominado $\delta_b(x)$, es decir, $\|\Delta_B(x)\|$ tiene como cota superior el valor $\delta_B(t)$, esto es representado por en la Ec.(3-53). El valor de $\delta_B(x)$ es conocido o seleccionado por diseño.

$$\|\Delta_B(x)\| \leq \delta_B(x) \quad (3-53)$$

El modelo matemático propuesto para una red neuronal dinámica que aprende el comportamiento del modelo no lineal con fallas en actuadores es:

3. Neurolocalización de fallas

$$\widehat{\Sigma}_B : \begin{cases} {}^B\dot{\hat{x}} = A_0x + B_0u + (W_B + \psi_B)u + L_B(y - \hat{y}_B) \\ \hat{y}_B = {}^B\hat{x} \end{cases} \quad (3-54)$$

El término $W_B + \psi_B$ del modelo matemático de la RNA permite la identificación del término δ_B correspondiente a la Ec.(3-54). Mientras que el término $L_B(y - \hat{y}_B)$ de la RNA permite garantizar que el error de identificación sea estable, mediante un valor adecuado para L_B .

El análisis estilo Lyapunov se utiliza para verificar la estabilidad del modelo de la RNA propuesta en la Ec.(3-54). La función candidata de Lyapunov propuesta para el análisis de estabilidad de la RNA dada en la Ec.(3-54) se muestra a continuación:

$$V(e_B, W) := \frac{1}{2}e_B^T e + \frac{1}{2}tr\langle W * W^T \rangle \quad (3-55)$$

y su derivada es

$$\dot{V}(e_B, W) := e_B^T \dot{e}_B + tr\langle W * \dot{W}^T \rangle \quad (3-56)$$

Ahora partiendo de que el error está dado por la siguiente expresión:

$$e_B = x - {}^B\hat{x} \quad (3-57)$$

y su derivada

$$\dot{e}_B = \dot{x} - {}^B\dot{\hat{x}} \quad (3-58)$$

Sustituyendo a \dot{x} y ${}^B\dot{\hat{x}}$ en la Ec.(3-58) tenemos que:

$$\dot{e}_B = A_0x + B_0u + \delta_B(t)u - [A_0x + B_0u + (W_B + \psi_B)u + L_B(y - \hat{y}_B)]$$

$$\dot{e}_B = A_0x + B_0u + \delta_B(t)u - A_0x - B_0u - W_Bu - \psi_Bu - L_B(y - \hat{y}_B)$$

$$\dot{e}_B = \delta_B(t)u - W_Bu - \psi_Bu - L_B(y - \hat{y}_B) \quad (3-59)$$

Ahora sustituyendo \dot{e}_B en la Ec.(3-55)

$$\dot{V}(e_B, W) := e_B^T \dot{e}_B + tr\langle W * \dot{W}^T \rangle$$

tenemos que

$$\dot{V}(e_B, W) := e_B^T [\delta_B(t)u - W_Bu - \psi_Bu - L_B(y - \hat{y}_B)] + tr\langle W * \dot{W}^T \rangle$$

$$\dot{V}(e_B, W) := e_B^T \delta_B(t)u - e_B^T W_Bu - e_B^T \psi_Bu - e_B^T L_B(y - \hat{y}_B) + tr\langle W * \dot{W}^T \rangle \quad (3-60)$$

de la Ec.(3-60) se toman los términos $-e_B^T W_Bu$ y $tr\langle W * \dot{W}^T \rangle$ y aplicando la propiedad mostrada en la Ec.(C-2) del anexo (C), se tiene que:

$$-e_B^T W_Bu + tr\langle W * \dot{W}^T \rangle$$

$$-tr\langle W_B u e_B^T \rangle + tr\langle W * \dot{W}^T \rangle$$

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

$$\text{tr}\langle W_B[ue_B^T + \dot{W}^T] \rangle \quad (3-61)$$

Dadas las manipulaciones anteriores, ahora se reescribe la Ec.(3-60) quedando de la siguiente forma:

$$\dot{V}(e_B, W) := e_B^T \delta_B(t)u - e_B^T \psi_B - e_B^T L_B(y - \hat{y}_B) + \text{tr}\langle W_B[-ue_B^T + \dot{W}^T] \rangle \quad (3-62)$$

Ahora se selecciona el aprendizaje como:

$$\dot{W}^T = ue_B^T \quad (3-63)$$

y se sustituye en el término (3-62). Una parte de la Ec.(3-62) se cancela y se obtiene:

$$\dot{V}(e_B, W) = e_B^T \delta_B(t)u - e_B^T \psi_B u - e_B^T L_B(y - \hat{y}_B) \quad (3-64)$$

Tomando el término $e_B^T \Delta_B(t)u$ de la Ec.(3-64) y aplicándole la propiedad de la norma dada en la Ec.(C-7) del Anexo (C), se obtiene

$$e_B^T \Delta_B(t)u - e_B^T \psi_B u \leq \|e_B\|_1 \|\Delta_B(t)\| \cdot \|u\|_1 \quad (3-65)$$

De la propiedad de la norma representada en la Ec.(C-11) se tiene que $\|e_B\|_1 = e_B^T \text{sign}(e_B)$ y $\|u\|_1 = e_B^T \text{sign}(u)$, por lo tanto

$$e_B^T \text{sign}(e_B) \cdot \Delta_B(t) \text{sign}(u^T) u \quad (3-66)$$

Sustituyendo la cota superior del término (3-66) en (3-64) se obtiene

$$e_B^T \Delta_B(t)u - e_B^T \psi_B u \leq e_B^T \text{sign}(e_B) \cdot \delta_B(t) \cdot \text{sign}(u^T) u - e_B^T \psi_B u$$

$$e_B^T \Delta_B(t)u - e_B^T \psi_B u \leq e_B^T (\text{sign}(e_B) \delta_B(t) \text{sign}(u^T) - \psi_B) u \quad (3-67)$$

entonces se elige el valor de

$$\psi_B = \text{sign}(e_B) \delta_B(t) \text{sign}(u^T) \quad (3-68)$$

Por último se tendrá que asegurar que:

$$L_B = L_B^T > \mathbf{0} \quad (3-69)$$

con lo que se garantiza que la derivada de la función candidata de Lyapunov propuesta es definida negativa, es decir

$$\dot{V}(e_B, W_B) \leq 0 \quad (3-70)$$

por lo tanto, se concluye que el error de identificación $e_B = x - {}^B \hat{x}$ es estable y acotado, es decir

$$\lim_{t \rightarrow \infty} \|e_B(t)\| < \infty \quad (3-71)$$

El modelo no lineal del proceso de fermentación alcohólica se reescribe a continuación, con el fin de establecer las posibles fallas en los actuadores del sistema.

3. Neurolocalización de fallas

$$\begin{aligned}\dot{x} &= A(x)x + B_{nv}F_{in} + B_v(x)F_c + E \\ y &= Cx\end{aligned}$$

A partir del modelo no lineal se observa que el proceso cuenta con dos actuadores principales. El primero actúa sobre el flujo de enfriamiento de la chaqueta térmica, representado como F_c , y el segundo actúa sobre el flujo de alimentación del sustrato, representado como F_{in} . Por lo tanto, se definen dos fallas una en cada actuador, siendo la falla f_4 la que incide en el actuador de F_c y la f_5 la que incide en el actuador de F_{in} .

La extracción de los síntomas para la neurolocalización de las fallas f_4 y f_5 , se realiza mediante una red neuronal como la descrita en esta sección, cuyo modelo matemático se muestra en la Ec.(3-54) y que se reescribe a continuación:

$$\widehat{\Sigma}_B : \begin{cases} {}^B\hat{x} = A_0x + B_0u + (W_B + \psi_B)u + L_B(y - \hat{y}_B) \\ \hat{y}_B = {}^B\hat{x} \end{cases}$$

En el modelo matemático de la red neuronal se establece una parte conocida y otra desconocida del modelo no lineal que describe al proceso. Esto aunado al modelo no lineal del proceso de fermentación alcohólica, donde la matriz B se ha separado en dos matrices B_{nv} y B_v , se diseña una red neuronal para la falla f_4 que incide sobre el actuador del F_c . Por lo tanto, la matriz B_{nv} corresponde a la parte conocida de la matriz B y B_v la desconocida.

El modelo que describe a cada red neuronal uno se muestra a continuación:

$$\begin{aligned}\dot{\hat{x}}^{RNA1} &= A_0x + B_{nv}F_{in} + (Q_B^{RNA1}W_B^{RNA1} + \psi_B^{RNA1})F_c + L_B^{RNA1}(y - \hat{y}_B^{RNA1}) \\ \hat{y}_B^{RNA1} &= \hat{x}^{RNA1}\end{aligned}\tag{3-72}$$

En las simulaciones 3.4 y 3.5 se muestra el desempeño de la red neuronal uno en lazo abierto y ante la presencia de la falla f_4 , respectivamente.

Simulación 3.4 Desempeño de la red neuronal uno en la estimación del modelo no lineal

El objetivo de esta simulación es mostrar el desempeño de la red neuronal uno al estimar el modelo no lineal del proceso de fermentación. El modelo de la red neuronal uno se denotó en Ec.(3-72), el cual se reescribe a continuación:

$$\begin{aligned}\dot{\hat{x}}^{RNA1} &= A_0x + B_{nv}F_{in} + (Q_B^{RNA1}W_B^{RNA1} + \psi_B^{RNA1})F_c + L_B^{RNA1}(y - \hat{y}_B^{RNA1}) \\ \hat{y}_B^{RNA1} &= \hat{x}^{RNA1}\end{aligned}$$

La matriz A_0 representa la parte dinámica del proceso y no contiene fallas, la cual es denotada en la Ec.(A-1). La matriz B_{nv} es la parte conocida de la matriz B , la cual está denotada en la Ec.(A-2). El término $Q_B^{RNA1}W_B^{RNA1} + \psi_B^{RNA1}$ correspondiente a la red neuronal uno permite la identificación del término B_v que corresponde a la parte desconocida del proceso y es denotado en la Ec.(3-72), siendo ψ_B^{RNA1} una tangente hiperbólica. Mientras que el término $L_B^{RNA1}(y - \hat{y}_B^{RNA1})$ de la red neuronal uno permite garantizar que el error de identificación sea estable mediante un valor adecuado para L_B^{RNA1} , el cual se denota en la Ec.(3-73).

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

$$L_B^{RNA1} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0,001 \end{bmatrix} \quad (3-73)$$

Las condiciones iniciales del modelo no lineal son:

$$\dot{x}(0) = [x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6]^T = [0.905 \ 12.515 \ 29.739 \ 3.107 \ 29.573 \ 27.054]^T \quad (3-74)$$

y de la RNA uno:

$$\dot{\hat{x}}^{RNA1}(0) = [x_1^{RNA1} \ x_2^{RNA1} \ x_3^{RNA1} \ x_4^{RNA1} \ x_5^{RNA1} \ x_6^{RNA1}]^T = [0.7 \ 10 \ 27 \ 2.8 \ 27 \ 25]^T \quad (3-75)$$

En la simulación se mantiene el flujo de enfriamiento de la chaqueta térmica constante a un valor de $F_c = 18l/h$. La estimación del modelo no lineal que representa al proceso de fermentación alcohólica mediante la red neuronal uno se muestra en la Fig. 3-20. Note que los estados x_1^{RNA1} , x_2^{RNA1} , x_3^{RNA1} , x_4^{RNA1} , x_5^{RNA1} y x_6^{RNA1} estiman de manera correcta a los estados no lineales x_1 , x_2 , x_3 , x_4 , x_5 y x_6 , respectivamente. El tiempo en que la red neuronal uno estima al modelo no lineal es menor a una hora.

3. Neurolocalización de fallas

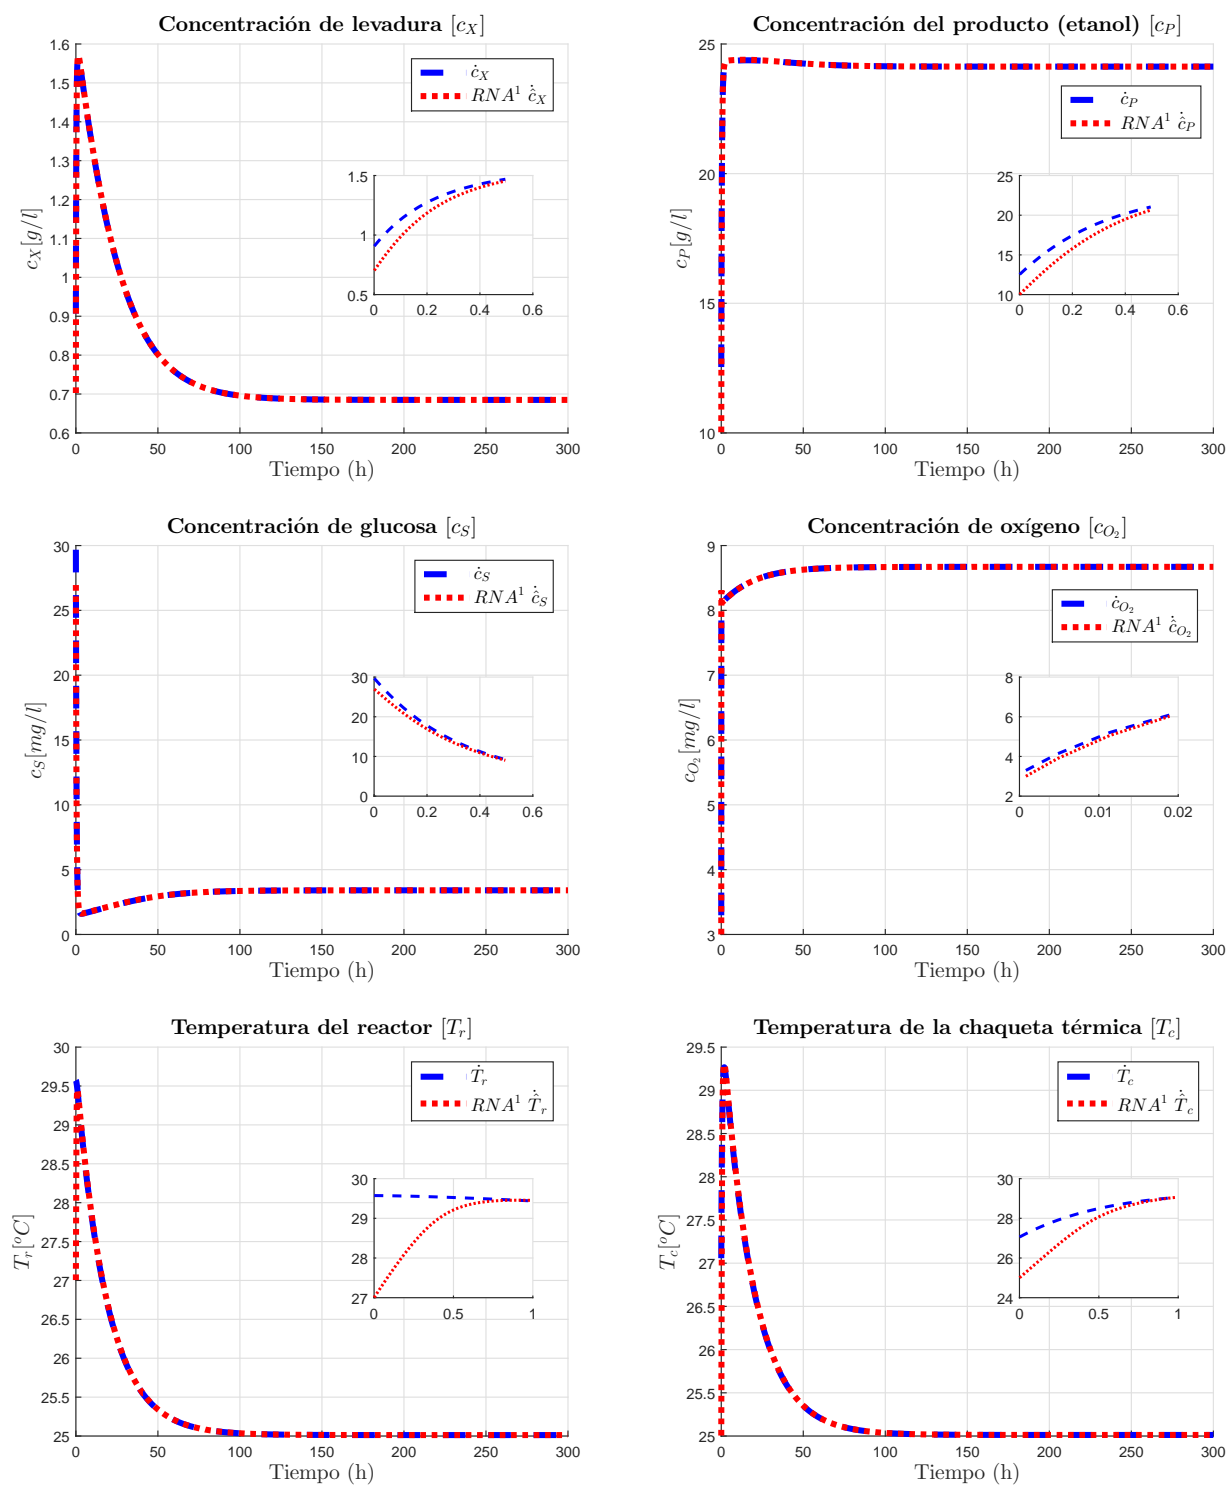


Figura 3-20.: Comparación de las dinámicas del proceso no lineal y la red neuronal uno.

El error de estimación de la red neuronal con respecto al modelo no lineal del proceso de fermentación alcohólica se muestra en la Fig. 3-21. Note que la dinámica de los errores es cero después de la primera

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

hora de haber iniciado el proceso.

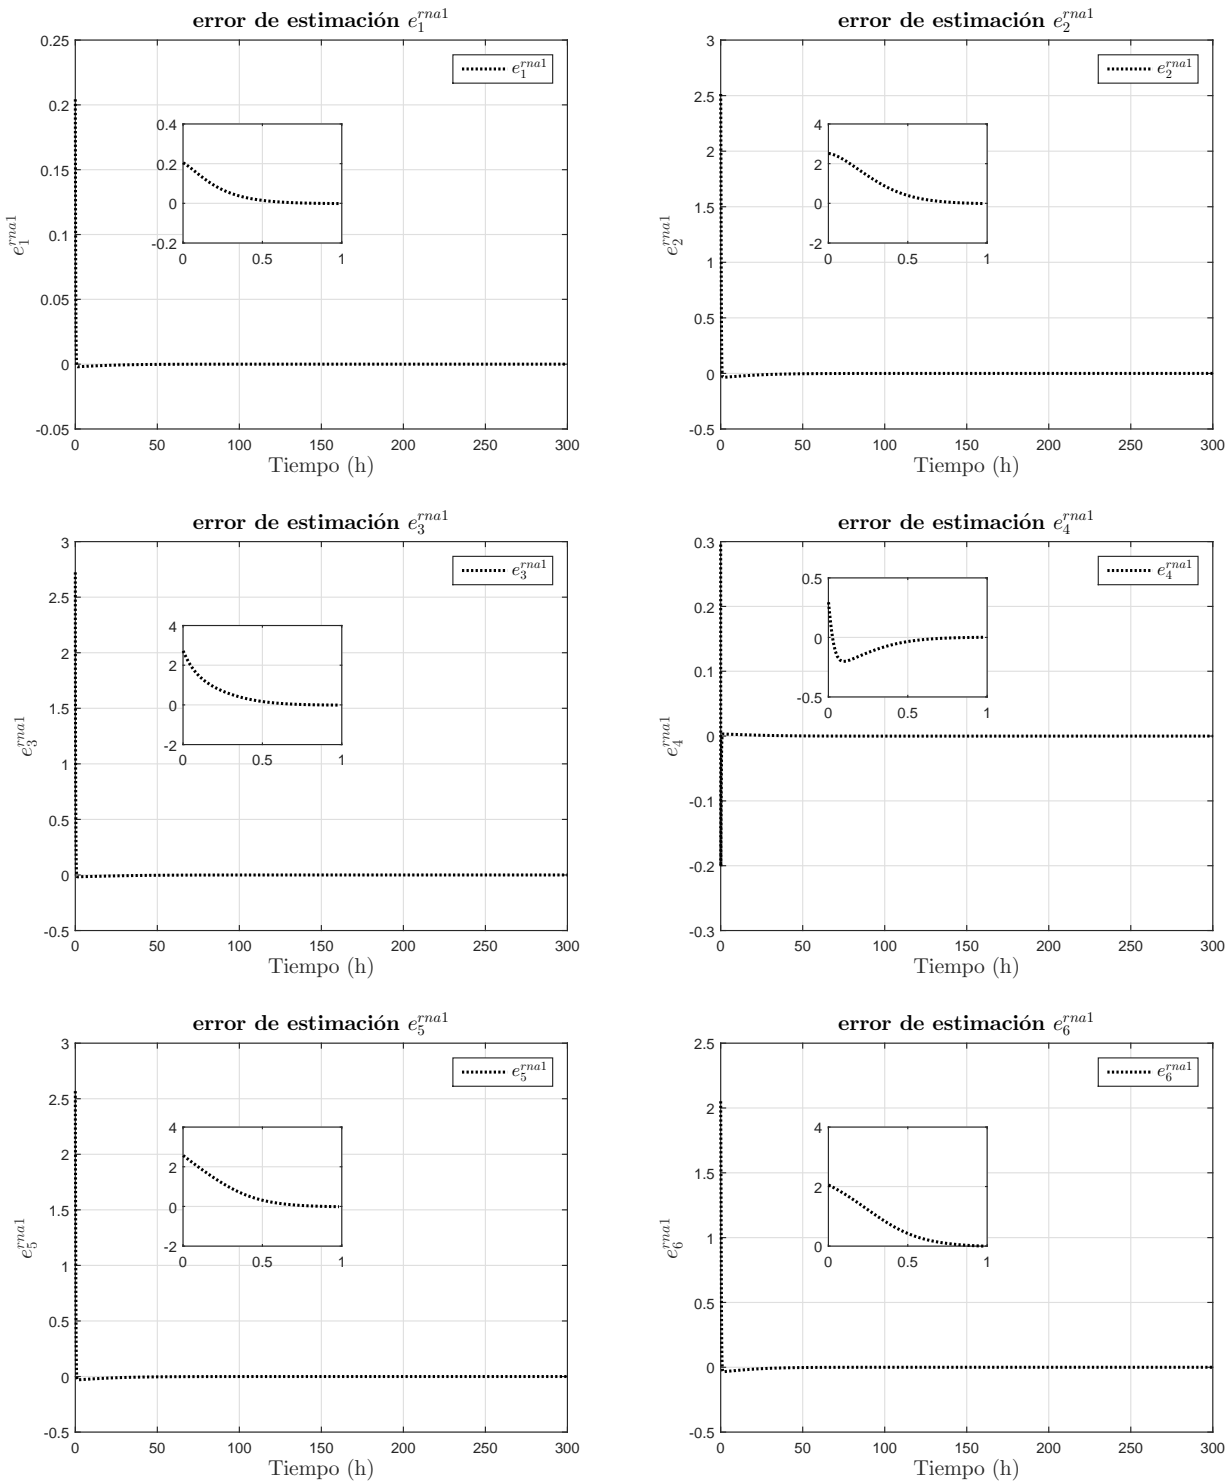


Figura 3-21.: Error de las dinámicas del proceso no lineal y la red neuronal uno.

Simulación 3.5 Desempeño de la red neuronal uno ante la falla f_4

El objetivo de esta simulación es mostrar el desempeño de la red neuronal uno cuando ocurre la falla f_4 en el actuador F_c . La dinámica de la falla f_4 se muestra en la Fig.3-22. Dicha dinámica se mantiene en cero hasta la hora 220 en la cual tiene un cambio en forma de escalón de uno con una duración de una hora, es decir en la hora 221 regresa a cero.




Figura 3-22.: Dinámica de la falla f_4 .

Las condiciones iniciales de la simulación 3.4 son las mismas que para la simulación 3.5. La incidencia de la falla f_4 sobre el proceso no lineal y la estimación de la red neuronal uno se muestra en la Fig. 3-23, la dinámica se muestra partir de la hora 100. Cuando se presenta la falla los estados no lineales que sufren una cambio drástico en su dinámica son x_4 , x_5 y x_6 , siendo en este último donde influye en mayor presencia. De igual manera, el estado x_6^{RNA1} la red neuronal uno sufre las consecuencias de la falla f_4 y no logra estimar al estado no lineal x_6 cuando se presenta dicha falla. Esto se propicia debido a que la falla f_4 influye en la señal de control del flujo de la chaqueta térmica F_c y ésta a su vez incide en la parte B_{nv} que es la parte desconocida de la red neuronal uno. A partir de ello, se establece un residuo o error de estimación, el cual es calculado mediante la siguiente expresión:

$$r_{\gamma}^{RNA1} = e_{\gamma}^{RNA1} = |x_{\gamma} - \hat{x}_{\gamma}^{RNA1}| \quad (3-76)$$

donde x_{γ} representa los estados no lineales, \hat{x}_{γ}^{RNA1} son los estados estimados por la red neuronal uno. El sub-índice γ representa a un estado en particular. Al obtener el error de estimación mediante la Ec.(3-76) se obtendrán solamente valores positivos dado que la diferencia se encuentra dentro del valor absoluto. El residuo r_1^{RNA1} , por ejemplo, se genera entre el estado no lineal x_1 y el estado estimado \hat{x}_1^{RNA1} por la red neuronal uno mediante la siguiente expresión:

$$r_1^{RNA1} = |x_1 - \hat{x}_1^{RNA1}| \quad (3-77)$$

de manera similar los residuos r_2^{RNA1} , r_3^{RNA1} , r_4^{RNA1} , r_5^{RNA1} y r_6^{RNA1} son obtenidos, en correspondencia a su estado y su estado estimado.

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

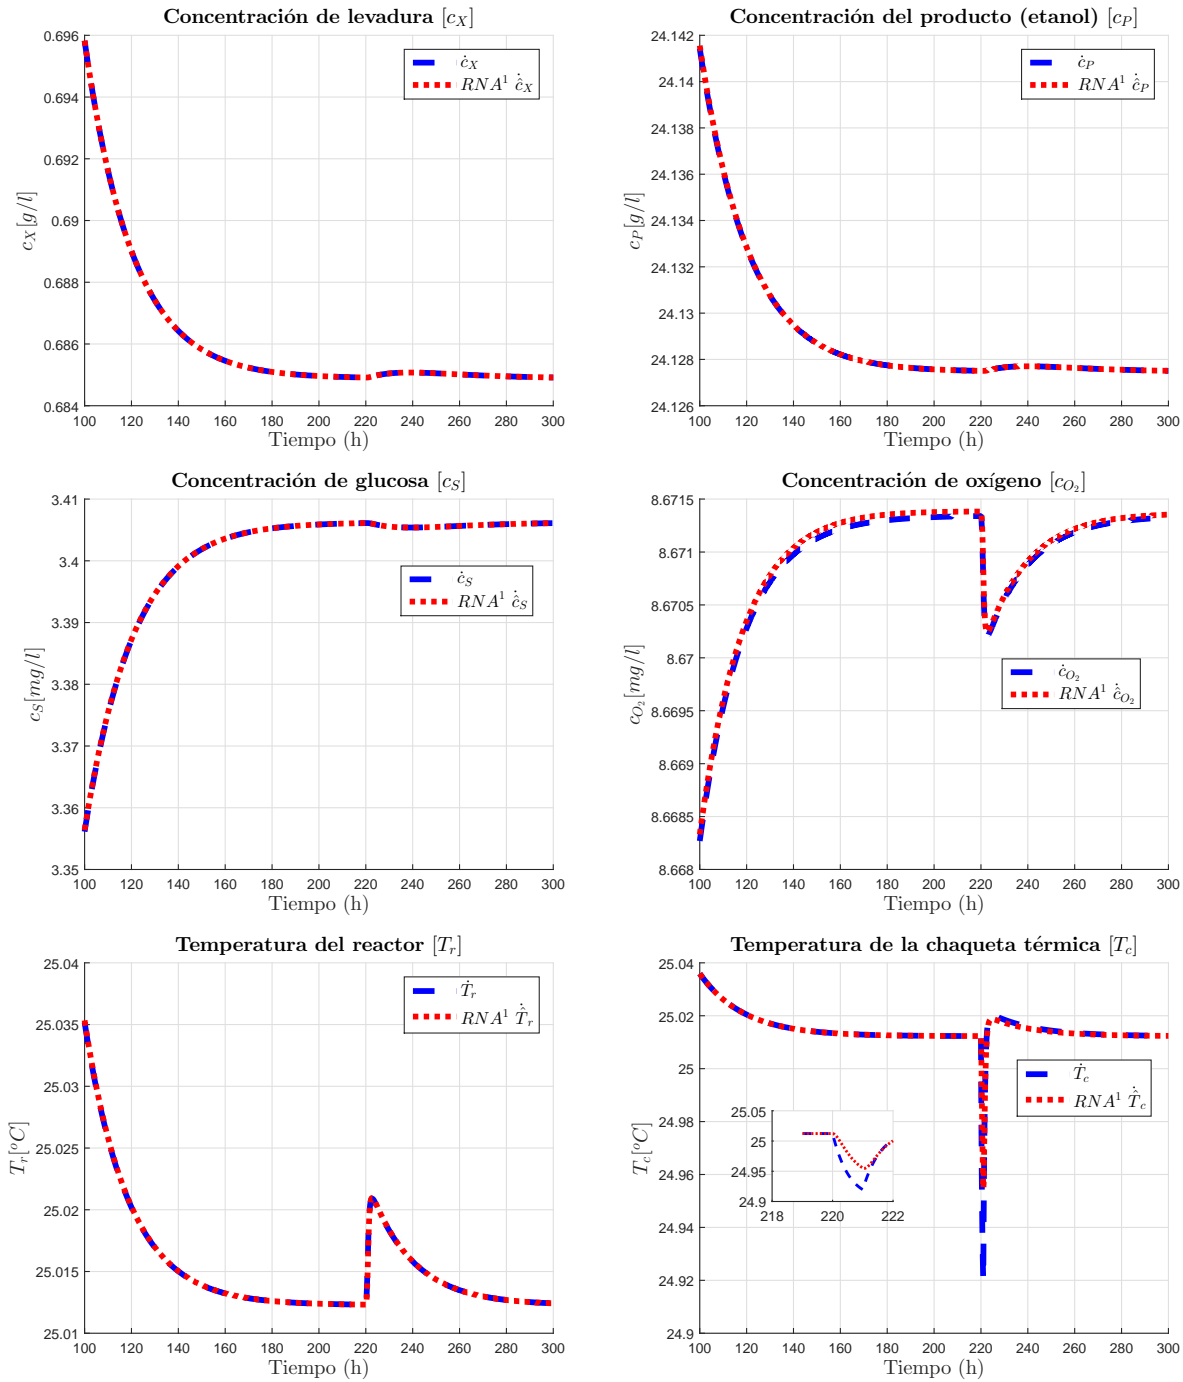


Figura 3-23.: Comparación de las dinámicas del proceso no lineal y la red neuronal uno ante la presencia de la falla f_4 .

Cada residuo es evaluado mediante un umbral para generar un síntoma en particular para la falla f_4 . La evaluación se muestra en la Fig.3-24, donde los umbrales son establecidos a priori por el diseñador. Estos son representados mediante una línea continua en color azul, mientras que los errores mediante una línea punteada en color negro.

3. Neurolocalización de fallas

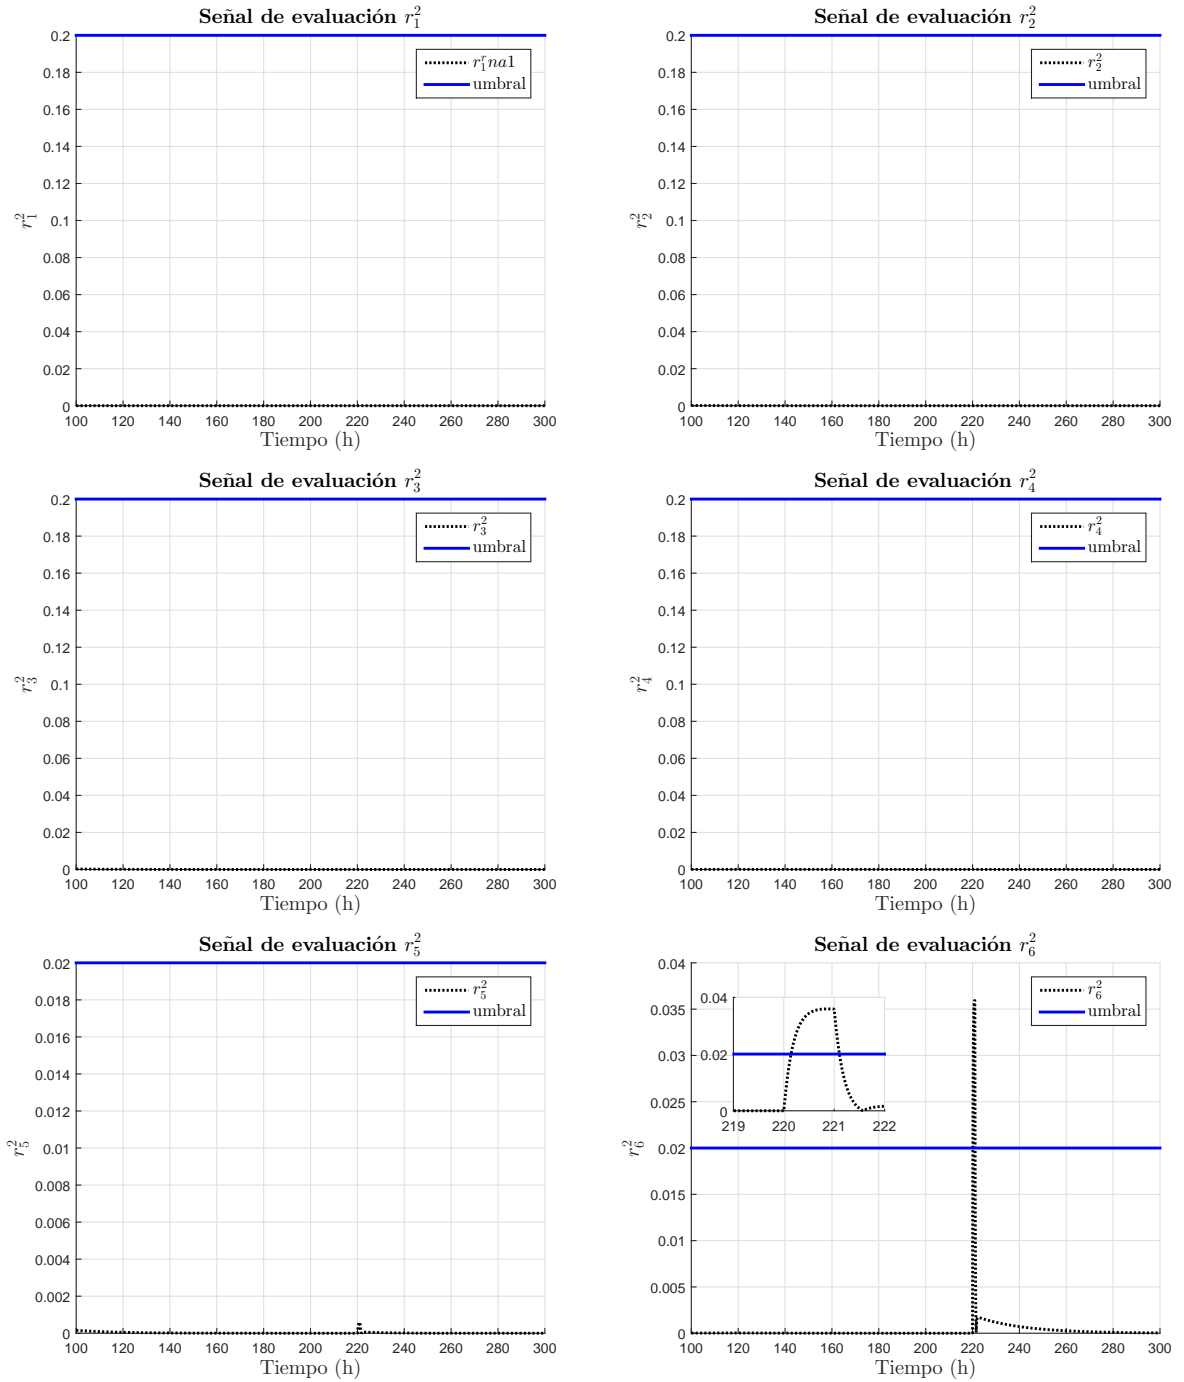


Figura 3-24.: Dinámica de las señales de evaluación r_{γ}^{RNA1} de la red neuronal uno.

El residuo que sobrepasa su respectivo umbral es el residuo r_6^{RNA1} que corresponde al valor absoluto de la diferencia entre el estado no lineal x_6 y el estado estimado x_6^{RNA1} , es decir $r_6^{RNA1} = |x_6 - x_6^{RNA1}|$. Por lo tanto, se genera un síntoma para la falla f_4 como se muestra en la Fig. 3-25, el cual se denota como s_6^{RNA1} .

3.3. Arquitectura y entrenamiento de una red neuronal para extraer síntomas de fallas en actuadores

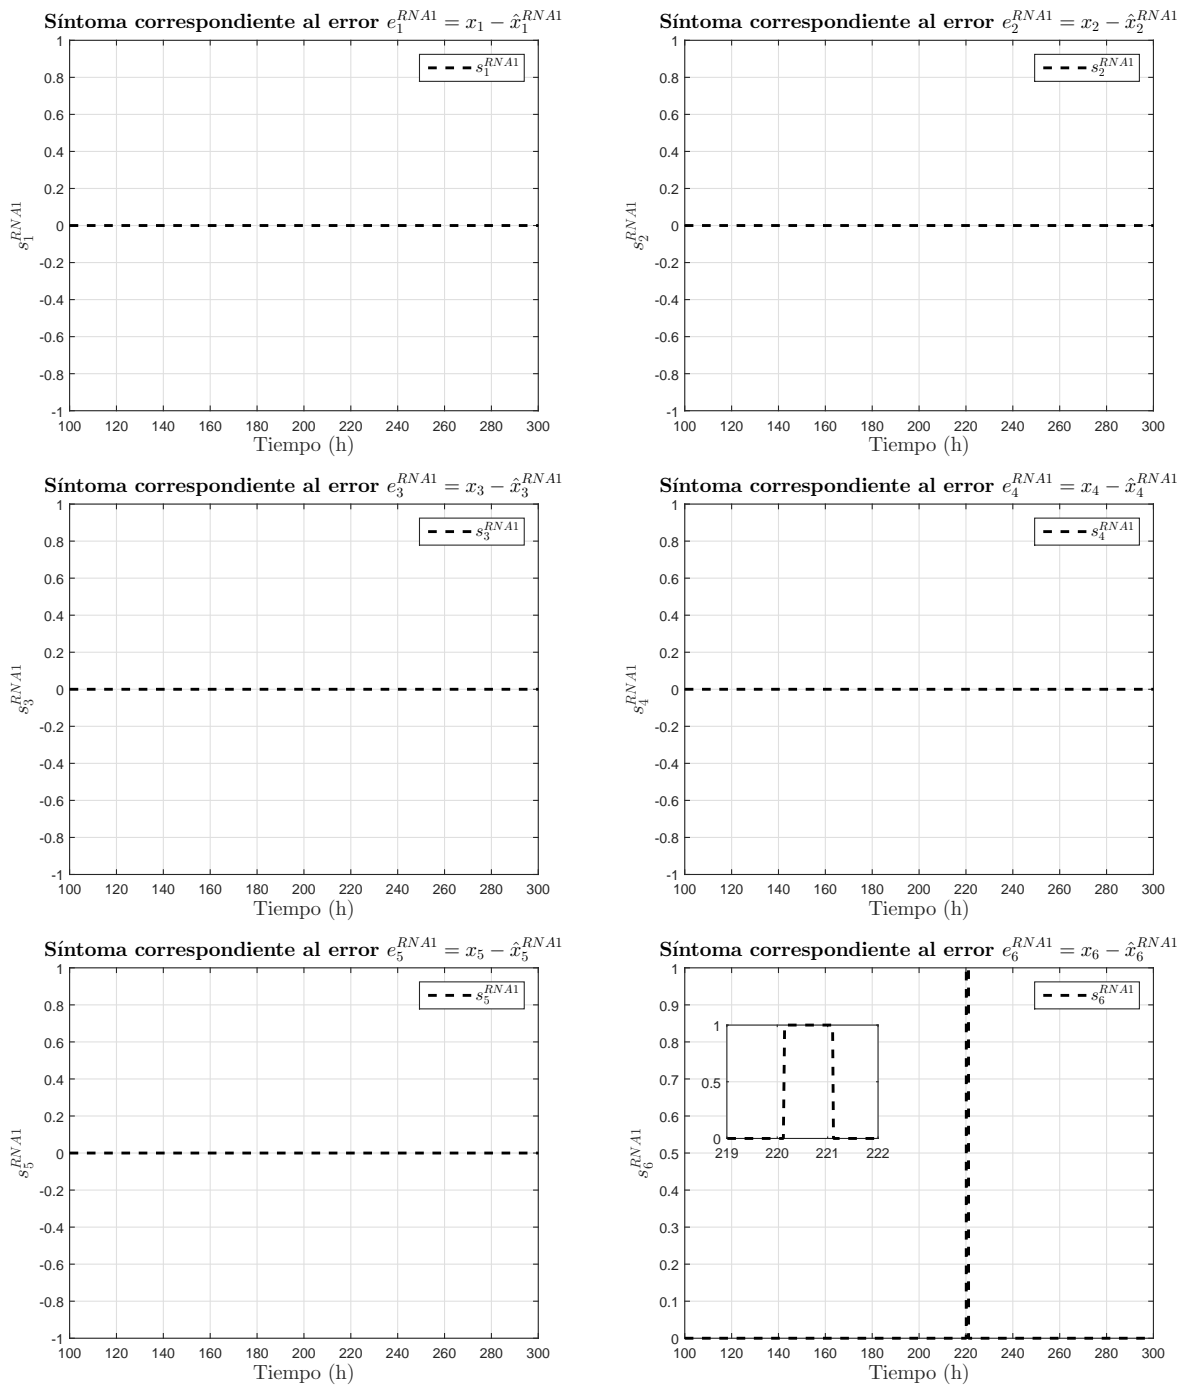


Figura 3-25.: Síntomas S_γ^{RNA1} generados a partir de los errores de estimación e_γ^{RNA1} .

3.4. Construcción de la matriz de firmas

Del análisis independiente de los observadores O^1 , O^2 , O^3 , O^4 y O^5 , realizado en las simulaciones 3.2.1, 3.2.1, B.1, B.2 y B.3, respectivamente, y mediante el diagrama del banco de observadores generalizado representado en la Fig.3-7 se destaca lo siguiente:

- A través del O^1 podemos obtener los síntomas s_1^1 y s_1^6 , que corresponden a la fallas f_1 y f_3 , respectivamente.
- A través del O^2 podemos obtener los síntomas s_1^2 y s_5^2 , que corresponden a la fallas f_1 y f_2 , respectivamente.
- A través del O^3 podemos obtener el síntoma s_6^3 , que corresponde a la falla f_3 .
- A través del O^4 podemos obtener el síntoma s_5^4 , que corresponde a la falla f_2 .
- A través del O^5 podemos obtener el síntoma s_1^5 , que corresponde a la falla f_1 .

Aunado al análisis de observadores también tenemos el análisis de obtenido de las simulaciones 3.4 y 3.5 que corresponden a la $RNA1$, del cual se concluye lo siguiente:

- A través de la $RNA1$ podemos obtener el síntoma s_6^{RNA1} que corresponde a la falla f_4 .

Por lo tanto, se puede realizar una comparativa entre los residuos y síntomas que abordan fallas iguales y determinar la existencia de ella o no. Es decir, una falla genera una firma característica mediante un residuo y síntoma en particular. La matriz de firmas resultante de nuestro caso de estudio se muestra en el Cuadro 3-3, donde cada renglón representa una falla en particular, así por ejemplo, para identificar la falla f_1 su firma pertenece al renglón 1, y así respectivamente. En la matriz de firmas se expresan cinco fallas, de las cuales f_1 , f_2 y f_3 son fallas que afectan a los sensores que censan los estados x_1 , x_5 y x_6 del modelo no lineal del proceso de fermentación alcohólica, respectivamente. La falla f_4 representa la falla en el actuador F_{ag} del proceso de fermentación alcohólica.

Tabla 3-3.: Matriz de firmas. Fallas en sensores y actuadores

falla \ síntoma	s_1^1	s_6^1	s_1^2	s_5^2	s_6^3	s_5^4	s_1^5	s_6^{RNA1}
f_1	1	0	1	0	0	0	1	0
f_2	0	0	0	1	0	1	0	0
f_3	0	1	0	0	1	0	0	0
f_4	0	0	0	0	0	0	0	1

Mediante establecimiento de cada firma a cada falla en particular realizado en la matriz de firmas, la neurolocalización de las fallas se lleva a cabo mediante una red neuronal. Siendo, la matriz de firmas denotada en el Cuadro 3-3 la entrada de la red neuronal, quien toma las decisiones sobre la neurolocalización de las fallas, lo cual se detalla en la siguiente sección.

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

El sistema neurolocalizador de fallas en sensores y actuadores se muestra en la Fig.3-26, en ella se clarifica como se obtienen los síntomas para fallas en particular tanto en actuadores como en sensores. Dichos síntomas son mostrados en la matriz de firmas de fallas denotada en el cuadro 3-3 la cual en la Fig.3-26 como U y que representa la entrada a la red neuronal donde se toman las decisiones sobre la neurolocalización de fallas. Los pormenores de dicha red neuronal se abordan en la siguiente subsección.

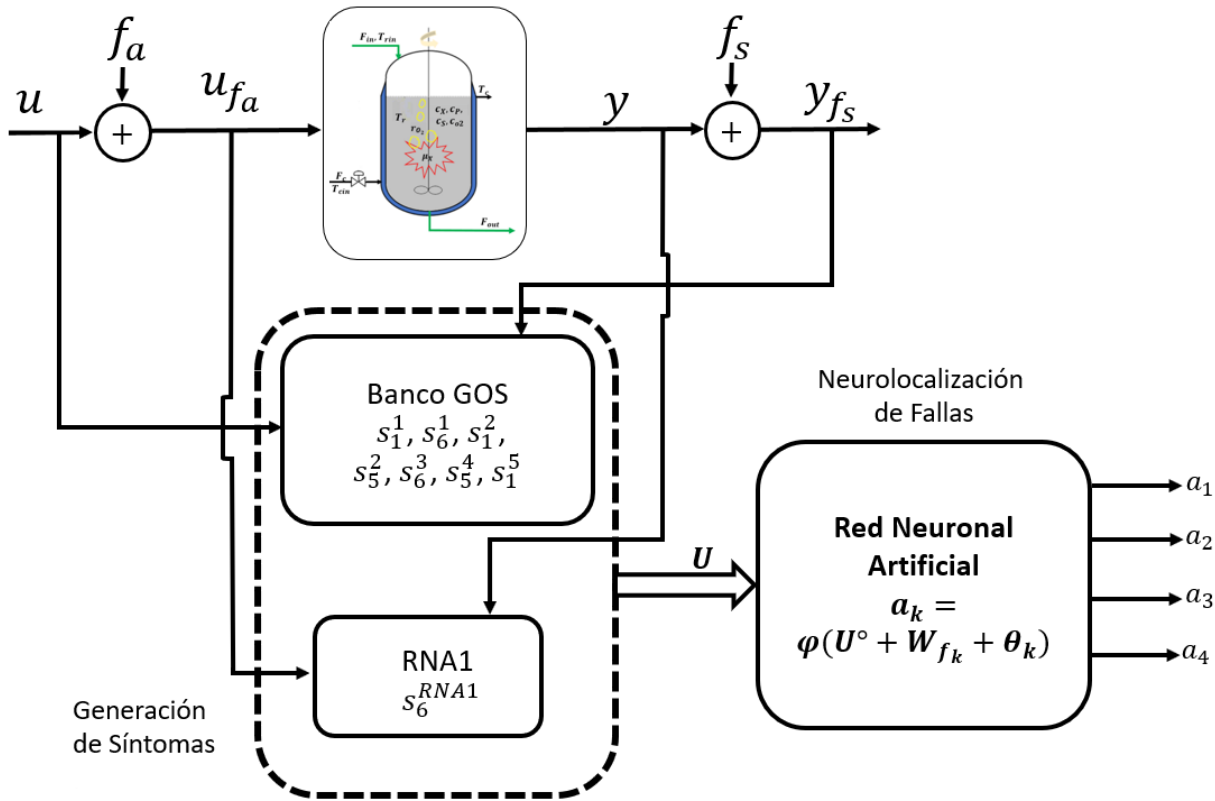


Figura 3-26.: Esquema del sistema neurolocalizador de fallas.

3.5.1. Arquitectura y entrenamiento de la red neuronal para la toma de decisiones en la neurolocalización de fallas

En la sub-sección 3.4 se definieron las firmas correspondientes a las fallas f_1, f_2, f_3, f_4 y f_5 mediante la matriz de firmas de las fallas descrita en el Cuadro 3-3.

Mediante la matriz de firmas de las fallas descrita en el Cuadro 3-3 se definieron las firmas correspondientes a las fallas f_1, f_2, f_3, f_4 .

La neurolocalización de las fallas se realizó mediante una red neuronal, la cual se ilustra en la Fig.3-27.




Figura 3-27.: Red neuronal para la neurolocalización de fallas.

Note que la entrada de la red es la matriz de firma de fallas denotada como U ; W_{f_1} , W_{f_2} , W_{f_3} y W_{f_4} son las matrices de los pesos sinápticos establecidos para la localización de las fallas f_1 , f_2 , f_3 y f_4 , respectivamente; θ_1 , θ_2 , θ_3 y θ_4 es el umbral correspondiente a las fallas f_1 , f_2 , f_3 y f_4 , respectivamente; φ_1 , φ_2 , φ_3 y φ_4 es la función de activación correspondiente a las fallas f_1 , f_2 , f_3 y f_4 , respectivamente; las salidas de la red neuronal a_1 , a_2 , a_3 y a_4 indican la alarma uno, alarma dos, la alarma tres, la alarma cuatro y la alarma cinco, respectivamente, para la localización de las fallas f_1 , f_2 , f_3 y f_4 , respectivamente, las cuales se describen en la Ec.(3-78).

$$\begin{aligned}
 a_1 &= \varphi(U \circ_+ W_{f_1} + \theta_1) \\
 a_2 &= \varphi(U \circ_+ W_{f_2} + \theta_2) \\
 a_3 &= \varphi(U \circ_+ W_{f_3} + \theta_3) \\
 a_4 &= \varphi(U \circ_+ W_{f_4} + \theta_4)
 \end{aligned}
 \tag{3-78}$$

Tanto en la Fig.3-27 y en la Ec.(3-78) se expresa el operador \circ_+ que representa la suma de los productos de las entradas de las matrices operadas. Las matrices U y W_{f_k} son rectangulares de dimensiones $U, W_{f_k} \in \mathfrak{R}^{p \times q}$. Por lo tanto, el operador \circ_+ dado en la Fig.3-27 y en la Ec.(3-78) representa la suma de los productos de cada elemento de las matrices U y W_{f_k} , es decir:

$$\begin{aligned}
 U \circ_+ W_{f_k} := & \\
 & U_{11} \cdot W_{f_{k,11}} + U_{12} \cdot W_{f_{k,12}} + U_{13} \cdot W_{f_{k,13}} + U_{14} \cdot W_{f_{k,14}} + U_{15} \cdot W_{f_{k,15}} + \\
 & \quad U_{16} \cdot W_{f_{k,16}} + U_{17} \cdot W_{f_{k,17}} + U_{18} \cdot W_{f_{k,18}} + \\
 & U_{21} \cdot W_{f_{k,21}} + U_{22} \cdot W_{f_{k,22}} + U_{23} \cdot W_{f_{k,23}} + U_{24} \cdot W_{f_{k,24}} + U_{25} \cdot W_{f_{k,25}} + \\
 & \quad U_{26} \cdot W_{f_{k,26}} + U_{27} \cdot W_{f_{k,27}} + U_{28} \cdot W_{f_{k,28}} + \\
 & U_{31} \cdot W_{f_{k,31}} + U_{32} \cdot W_{f_{k,32}} + U_{33} \cdot W_{f_{k,33}} + U_{34} \cdot W_{f_{k,34}} + U_{35} \cdot W_{f_{k,35}} + \\
 & \quad U_{36} \cdot W_{f_{k,36}} + U_{37} \cdot W_{f_{k,37}} + U_{38} \cdot W_{f_{k,38}} + \\
 & U_{41} \cdot W_{f_{k,41}} + U_{42} \cdot W_{f_{k,42}} + U_{43} \cdot W_{f_{k,43}} + U_{44} \cdot W_{f_{k,44}} + U_{45} \cdot W_{f_{k,45}} + \\
 & \quad U_{46} \cdot W_{f_{k,46}} + U_{47} \cdot W_{f_{k,47}} + U_{48} \cdot W_{f_{k,48}} + \\
 & U_{51} \cdot W_{f_{k,51}} + U_{52} \cdot W_{f_{k,52}} + U_{53} \cdot W_{f_{k,53}} + U_{54} \cdot W_{f_{k,54}} + U_{55} \cdot W_{f_{k,55}} + \\
 & \quad U_{56} \cdot W_{f_{k,56}} + U_{57} \cdot W_{f_{k,57}} + U_{58} \cdot W_{f_{k,58}}
 \end{aligned}$$

Por lo tanto, U_{11} es el primer término de la matriz de firmas y $W_{f_{k,11}}$ es el primer término de la matriz de pesos sinápticos para la falla k . Es decir, el término $U_{11} \cdot W_{f_{k,11}}$ indica la multiplicación del primer elemento de la matriz de firma de fallas por el primer elemento de la matriz de los pesos sinápticos para cada falla en particular. Entonces, para denotar la suma del producto de cada elemento de la matriz de firma de fallas por cada elemento de la matriz de los pesos sinápticos de la falla f_1 es mediante la siguiente expresión $U \circ_+ W_{f_1}$. De igual manera para las expresiones $U \circ_+ W_{f_2}$, $U \circ_+ W_{f_3}$ y $U \circ_+ W_{f_4}$, las cuales indican la suma del producto de cada elemento de la matriz de firma de fallas por cada elemento de la matriz de los pesos sinápticos para las falla f_2 , f_3 y f_4 , respectivamente. El del desempeño de la red neuronal propuesta en la Ec.3-78 para la neurolocalización de las fallas se realiza en la simulación 3.6, la Simulación 3.7, la Simulación 3.8 y la Simulación 3.9.

3.5.2. Sistema neurolocalizador ante la presencia de fallas en los sensores correspondientes a los estados no lineales x_1 , x_5 y x_6

En esta sub-sección se presenta el análisis del sistema neurolocalizador ante la presencia de fallas en los sensores correspondientes a los estados del modelo no lineal del proceso de fermentación alcohólica x_1 , x_5 y x_6 . Mediante la simulación 3.6.1 y la simulación 3.6.2 se muestra el desempeño del sistema neurolocalizador.

El sistema neurolocalizador de fallas no está diseñado para neurolocalizar fallas en los sensores de los estados no lineales x_2 , x_3 y x_4 del modelo no lineal del proceso de fermentación alcohólica. Lo anterior, se debe a que en el diseño del banco de observadores, los observadores que lo conforman tienen acceso a dichos estados como se mencionó en la sección 3.2. La simulación donde se le aplican fallas a los estados no lineales x_2 , x_3 y x_4 del modelo no lineal del proceso de fermentación alcohólica se muestra en el anexo D.

Simulación 3.6.1 Localización de las fallas en sensores

El objetivo de esta simulación es determinar la localización de las tres fallas que inciden directamente en los sensores del proceso de fermentación alcohólica. Por lo tanto, las fallas en actuadores se mantienen en magnitud cero en todo el tiempo. Las fallas en sensores son: f_1 esta falla se presenta en

3. Neurolocalización de fallas

el sensor que mide la concentración de las levaduras c_X y que incide sobre el estado x_1 del modelo no lineal del proceso de fermentación alcohólica; la falla f_2 la cual se presenta en el sensor que mide la temperatura del reactor T_r y que incide sobre el estado x_5 del modelo no lineal del proceso de fermentación alcohólica; por último la falla f_3 se presenta en el sensor que censa la temperatura de la chaqueta térmica y que incide sobre el estado x_6 del proceso de fermentación alcohólica. La descripción de las fallas se muestra en el Cuadro 3-4. En la primera columna se indica la falla correspondiente, la segunda columna el tiempo de inicio de la falla y la magnitud, la tercera columna muestra el tiempo y magnitud de un cambio en la dinámica de la falla en forma de escalón, y la cuarta columna muestra el tiempo final y magnitud de la falla; siendo la falla f_1 la que se presenta más veces, con un total de tres veces, mientras que las fallas f_2 y f_3 solamente se presentan dos veces.

Tabla 3-4.: Descripción de las fallas en sensores.

Falla	Tiempo inicial	Valor	Cambio en escalón	Valor	Tiempo final	Valor
f_1	156 hrs	+0.1g/l	160 hrs	+0.1g/l	164 hrs	+0.1g/l
	216 hrs	+0.1g/l	200 hrs	+0.1g/l	224 hrs	+0.1g/l
	236 hrs	+0.1g/l	240 hrs	+0.1g/l	244 hrs	+0.1g/l
f_2	176 hrs	+1°C	180 hrs	+1°C	184 hrs	-2°C
	219 hrs	+1°C	220 hrs	+1°C	224 hrs	-2°C
f_3	196 hrs	+2°C	200 hrs	-1°C	204 hrs	-1°C
	236 hrs	+2°C	240 hrs	-1°C	243 hrs	-1°C

La dinámica de las fallas se muestra en la Fig 3-28. Recuerde que la falla f_1 afecta al sensor correspondiente a x_1 , la falla f_2 afecta al sensor correspondiente a x_5 y la falla f_3 afecta al sensor correspondiente a x_6 . Dichas fallas son inducidas en los sensores del proceso de fermentación alcohólica, siendo la falla f_1 la que se presenta primero en la hora 156 mediante un cambio en escalón de 0.1 g/l, posteriormente en la hora 160 sufre otro cambio en forma de escalón de 0.1 g/l llegando a un valor de 0.2 g/l, manteniendo este valor hasta la hora 164, después tiene una decaída de 0.2 g/l con lo cual regresa a de 0 g/l. La segunda falla en presentarse es f_2 en la hora 176 mediante un cambio en escalón de 1°C, posteriormente en la hora 180 sufre otro cambio en forma de escalón de 1°C llegando a un valor de 2°C, manteniendo este valor hasta la hora 184, después tiene una decaída de 2°C con lo cual regresa a de 0°C. La tercera falla que se presenta es f_3 en la hora 196 mediante un cambio en escalón de 2°C, posteriormente en la hora 200 sufre una decaída en forma de escalón de 1°C llegando a un valor de 1°C, manteniendo este valor hasta la hora 204, después tiene una decaída de 1°C con lo cual regresa a de 0°C.

Una señal de ruido incide en los sensores del proceso de fermentación alcohólica. Los tiempos de inicio y fin de los ruidos insidentes se muestran en el Cuadro 3-5. Por ejemplo, en la hora 155 incide un ruido de magnitud $\pm 0,1$ g/l en los sensores correspondientes a los estados x_1 , x_2 , x_3 y x_4 , el cual termina en la hora 165. En los mismos tiempos de inicio y término de este ruido, incide otro ruido de magnitud $\pm 1^\circ C$ sobres los sensores correspondientes a los estados x_5 y x_6 no lineales del proceso de fermentación alcohólica.

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

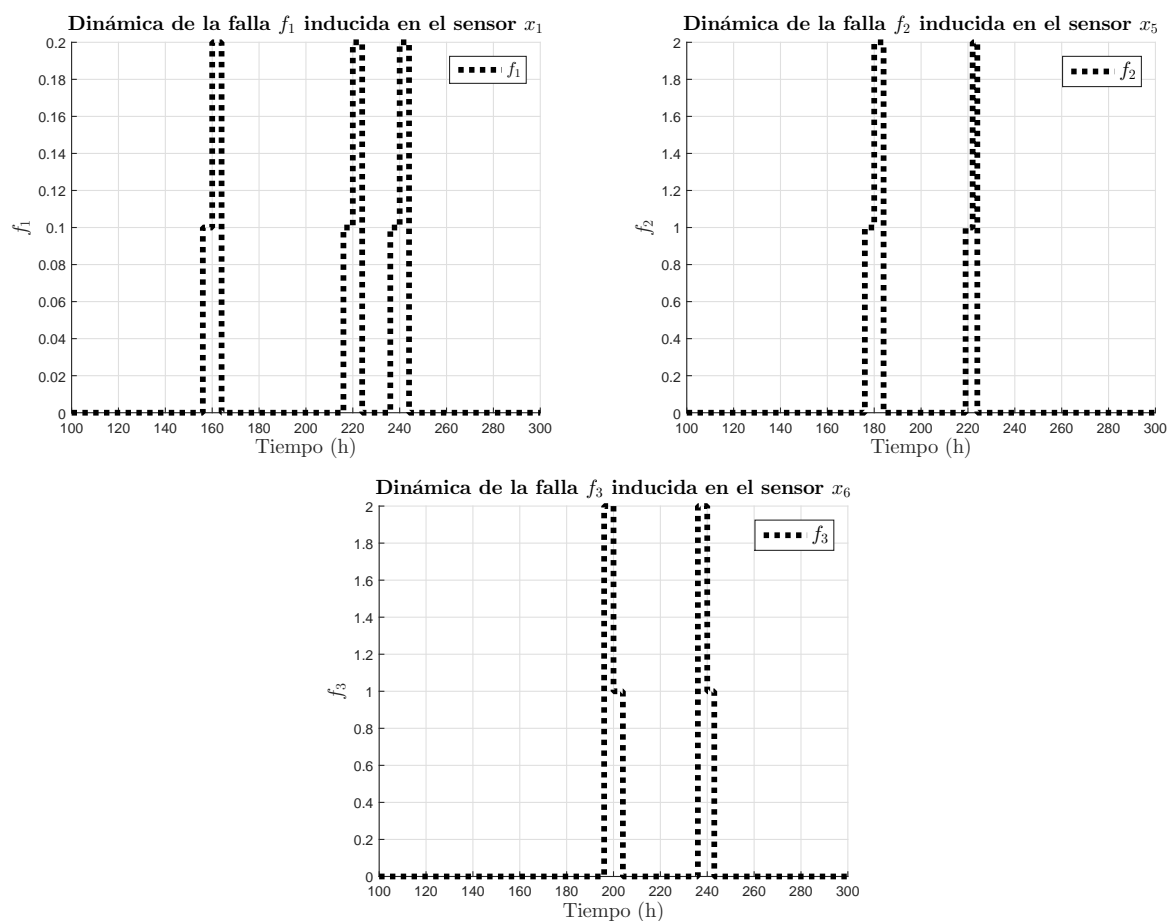


Figura 3-28.: Dinámica de las fallas en los sensores del proceso de fermentación alcohólica.

Tabla 3-5.: Descripción de los ruidos en los sensores del proceso de fermentación alcohólica.

Sensor del estado	Tiempo inicial	Tiempo final	Valor
x_1, x_2, x_3, x_4	155 hrs	165 hrs	$\pm 0,1 \text{ g/l}$
	176 hrs	184 hrs	$\pm 0,1 \text{ g/l}$
	196 hrs	204 hrs	$\pm 0,1 \text{ g/l}$
	255 hrs	265 hrs	$\pm 0,1 \text{ g/l}$
	275 hrs	285 hrs	$\pm 0,1 \text{ g/l}$
x_5, x_6	155 hrs	165 hrs	$\pm 1^\circ\text{C}$
	176 hrs	184 hrs	$\pm 1^\circ\text{C}$
	196 hrs	204 hrs	$\pm 1^\circ\text{C}$
	255 hrs	265 hrs	$\pm 1^\circ\text{C}$
	275 hrs	285 hrs	$\pm 1^\circ\text{C}$

La dinámica del sistema no lineal bajo la influencia de las fallas f_1 , f_2 y f_3 se muestra en la Fig. 3-29. En dicha figura sólo se muestra la dinámica de los estados no lineales del proceso de fermentación alcohólica con el fin de mostrar la influencia de las fallas y sobretodo el ruido que incide en ellos.

3. Neurolocalización de fallas

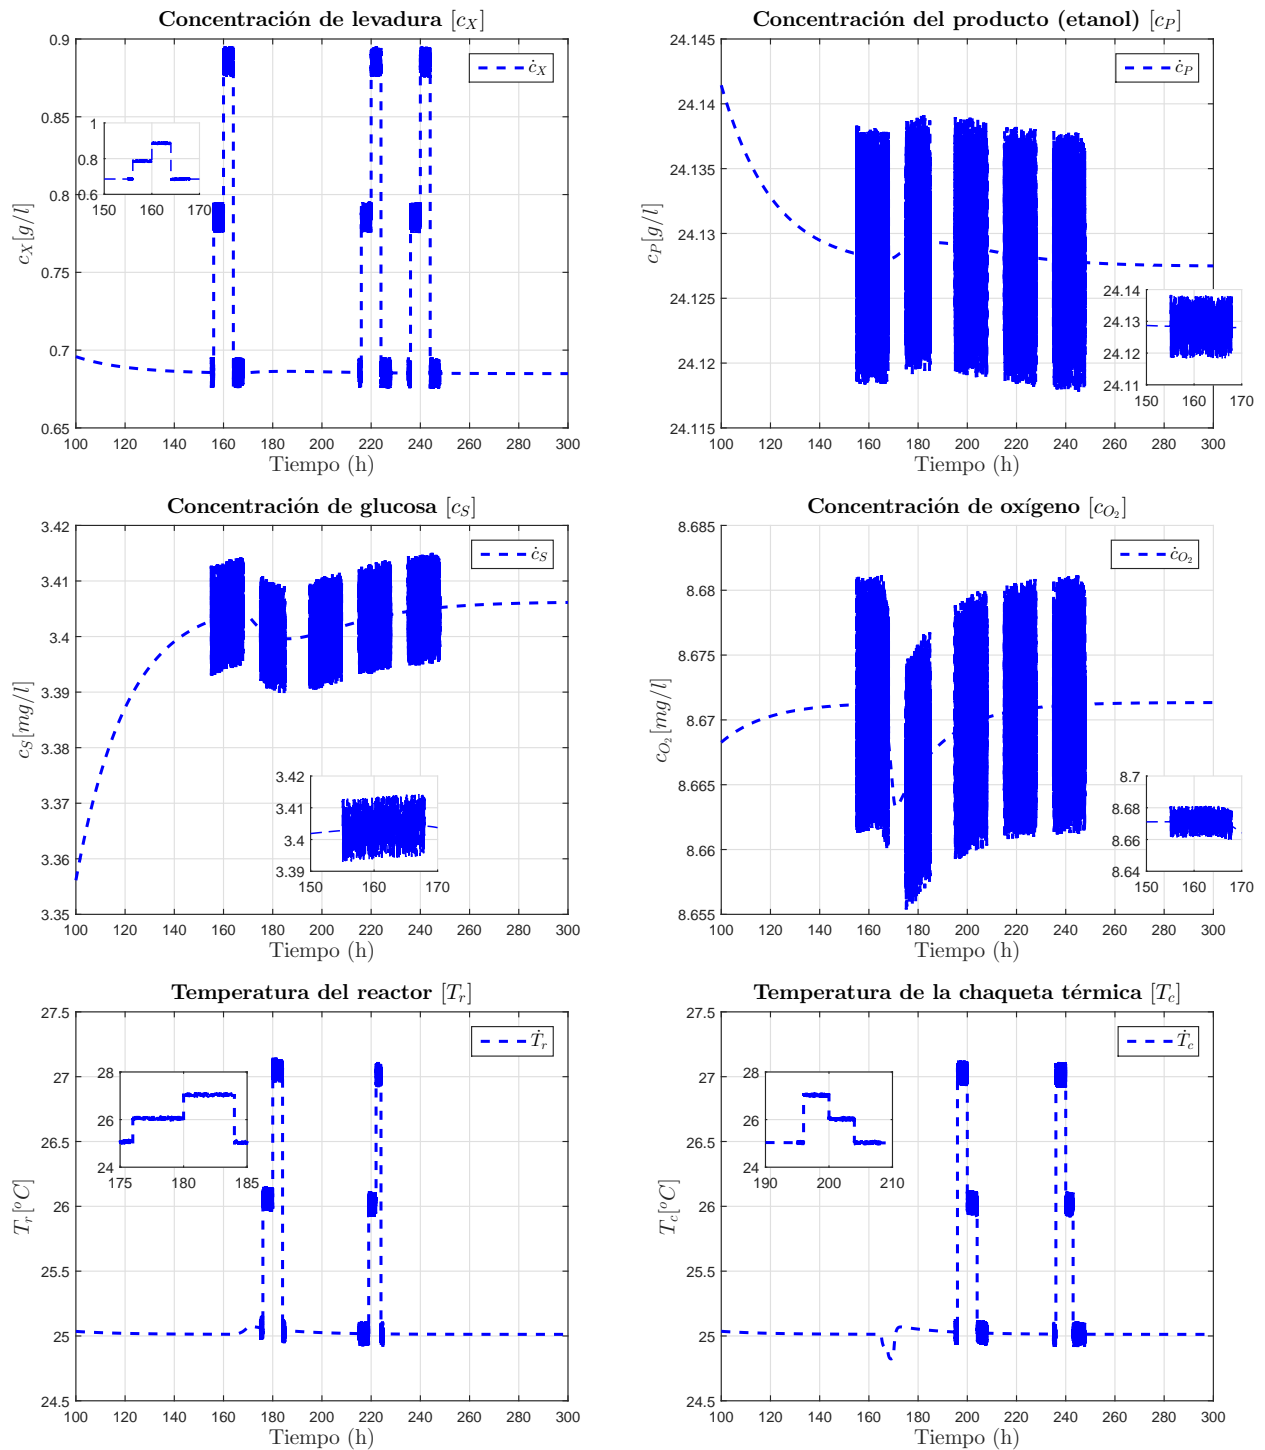


Figura 3-29.: Respuesta en lazo abierto del modelo no lineal dado en las Ecs.(2-70) a (2-75) ante la presencia de las fallas f_1, f_2 y f_3 .

En la Fig.3-30 se muestra la comparación entre las dinámicas de los estados no lineales del proceso de fermentación alcohólica y los estados estimados por el observador O^3 , con el propósito de mostrar

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

como los observadores antes diseñados se desempeñan ante la presencia de las fallas y el ruido que se presentan en el proceso.

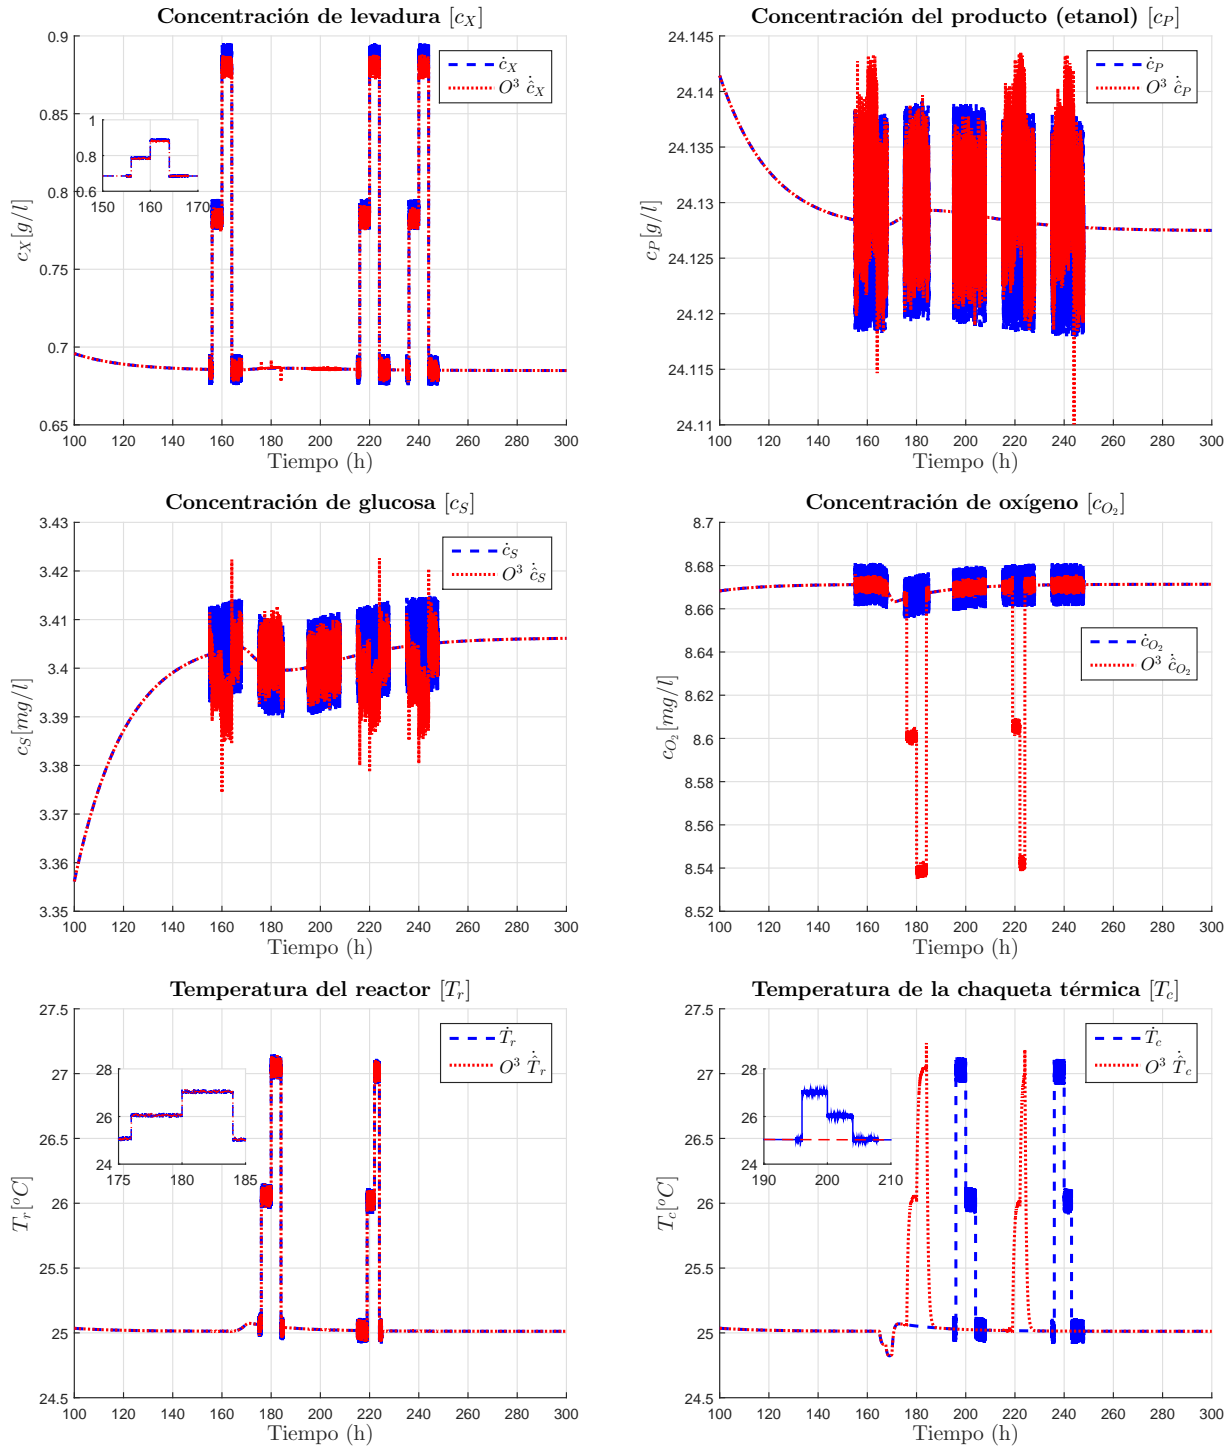


Figura 3-30.: Dinámicas del modelo no lineal y el observador O^3 ante la presencia de las fallas f_1, f_2 y f_3 .

3. Neurolocalización de fallas

Los residuos generados por el observador O^3 se muestran en la Fig.3-31. en la dinámica de los residuos se puede apreciar como el ruido inducido en los sensores del proceso no lineal provoca que los residuos oscilen durante el tiempo que se presentan dichos ruidos.

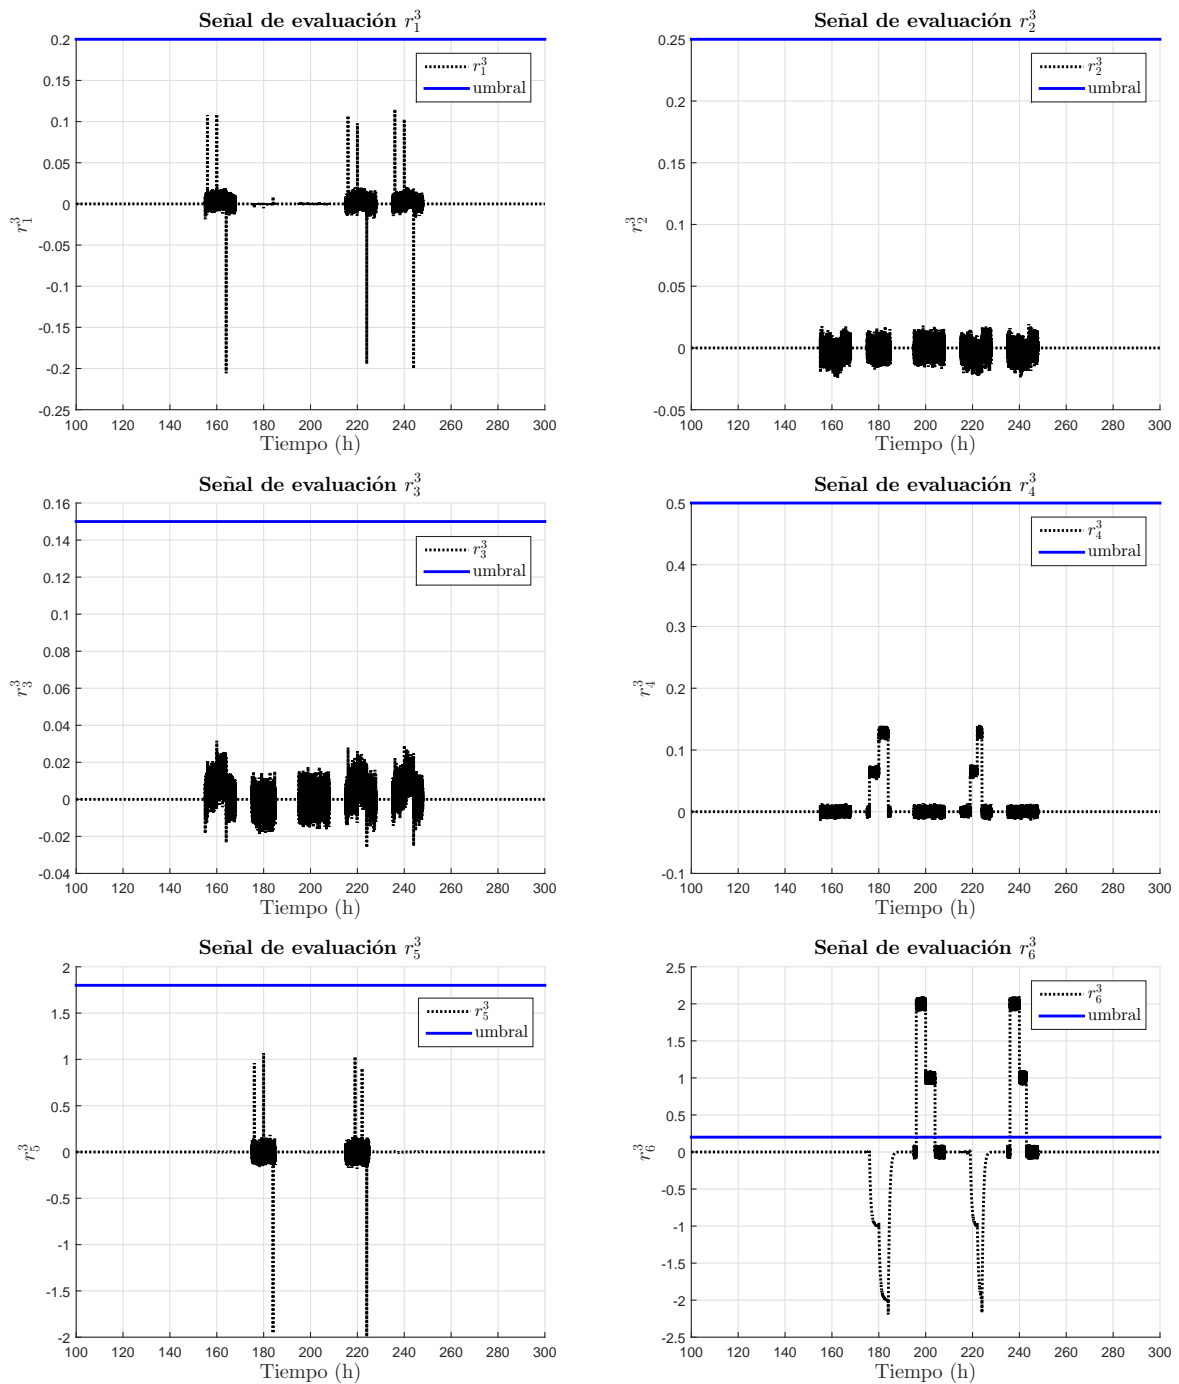


Figura 3-31.: Residuos generados por la estimación del observador O^3 ante la presencia de las fallas f_1, f_2 y f_3 .

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

Los síntomas son generados y se muestran en la Fig.3-32. Dado que el observador O^3 sólo es sensible a la falla f_3 que incide en el estado no lineal x_6 , únicamente se genera el síntoma s_6^3 .

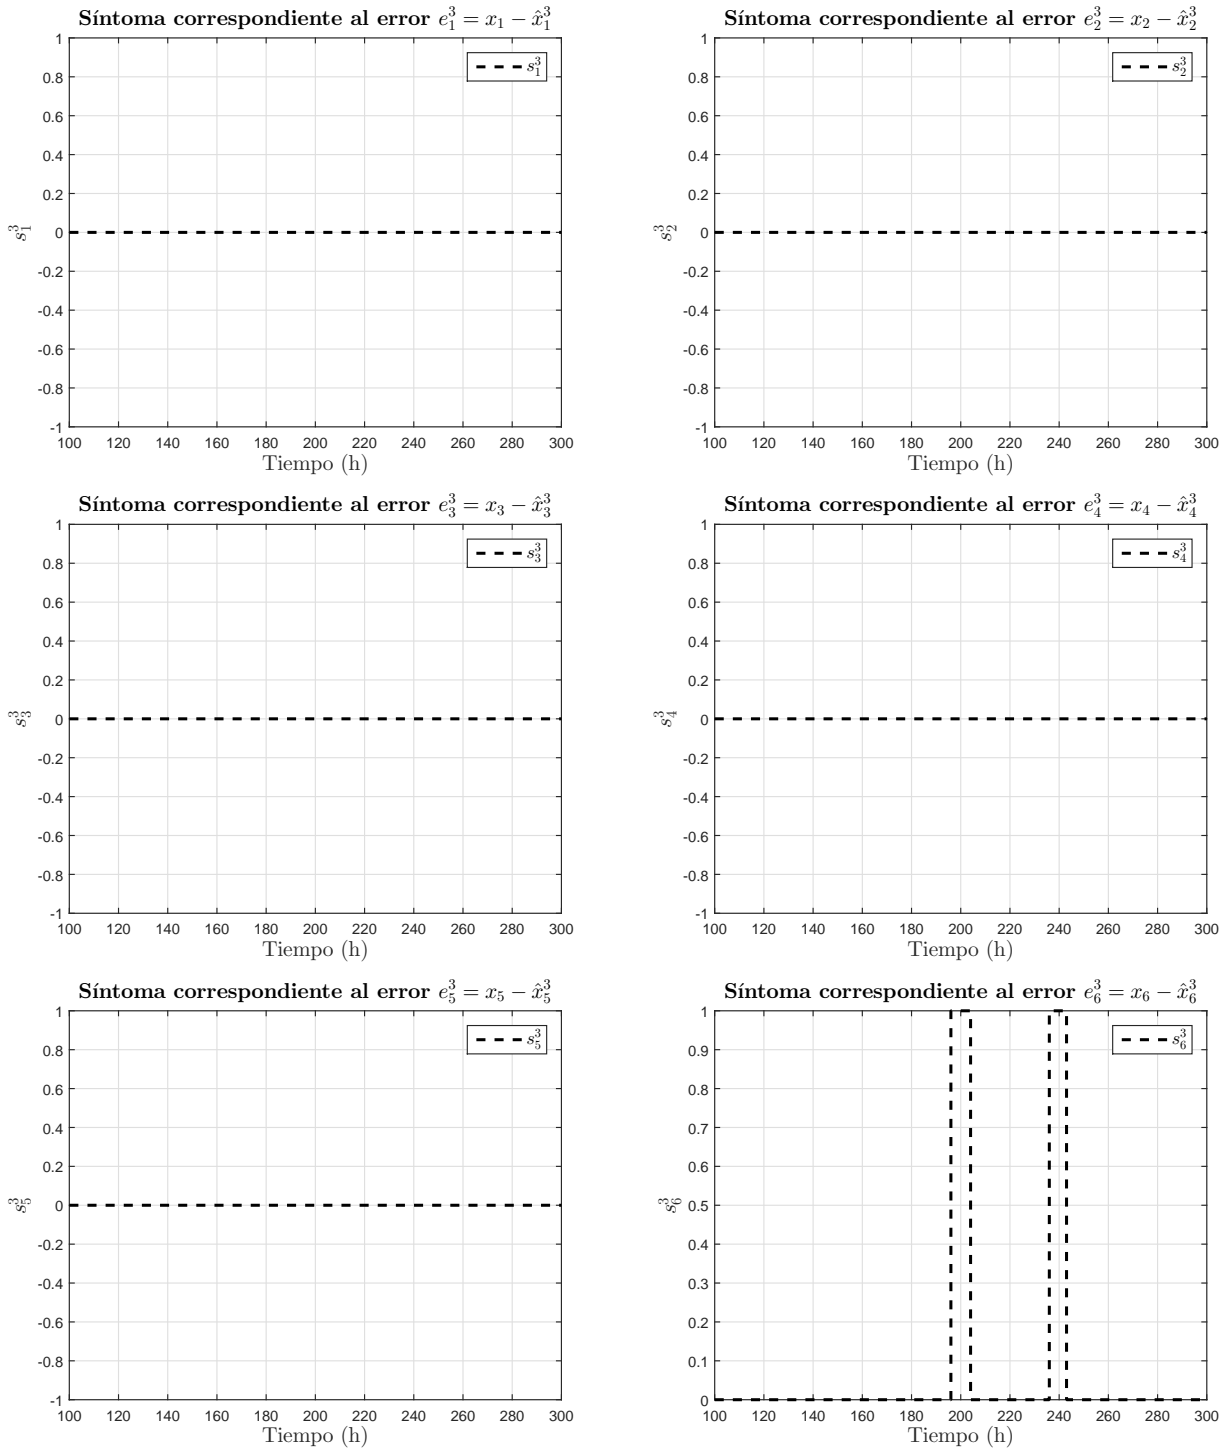


Figura 3-32.: Síntomas generados por la estimación del observador O^3 ante la presencia de las fallas f_1, f_2 y f_3 .

3. Neurolocalización de fallas

El desempeño del observador O^3 permite esclarecer que se ha generado de manera correcta el síntoma correspondiente a una falla en particular mediante él. Este síntoma es almacenado en la matriz de firmas al igual que todos los demás síntomas generados. En la Fig. 3-28 se mostraron las fallas que se han inducido en los sensores del proceso. Note que, primeramente se presentan independientemente cada una, empezando por la falla f_1 , posteriormente f_2 y en seguida f_3 . Después de que se presentan de forma individual cada falla, ahora se manifiestan de forma simultánea, siendo las fallas f_1 y f_2 el primer par en presentarse y en el segundo par las fallas f_1 y f_3 .

Una vez que se han establecido los síntomas en la matriz de fallas, la matriz de fallas es la entrada en la red neuronal para realizar la neurolocalización. Una neurolocalización se indica cuando el valor de a_1 , a_2 y a_3 es un uno lógico, mientras que si su valor es cero no existe falla tal como se muestra en la Fig.3-33. Por lo tanto, cuando se presentan las fallas f_1 , f_2 y f_3 por separado y cuando se presentan en conjunto f_1 y f_2 , así como f_1 y f_3 , el sistema neurolocalizador detecta y localiza de manera correcta dichas fallas. Así, las señal lógicas a_1 , a_2 y a_3 proporcionadas por la red neuronal pueden ser usadas para emitir una alarma para cada falla en particular, con lo cual el operador puede tomar las decisiones adecuadas para mantener la seguridad y confiabilidad del proceso.

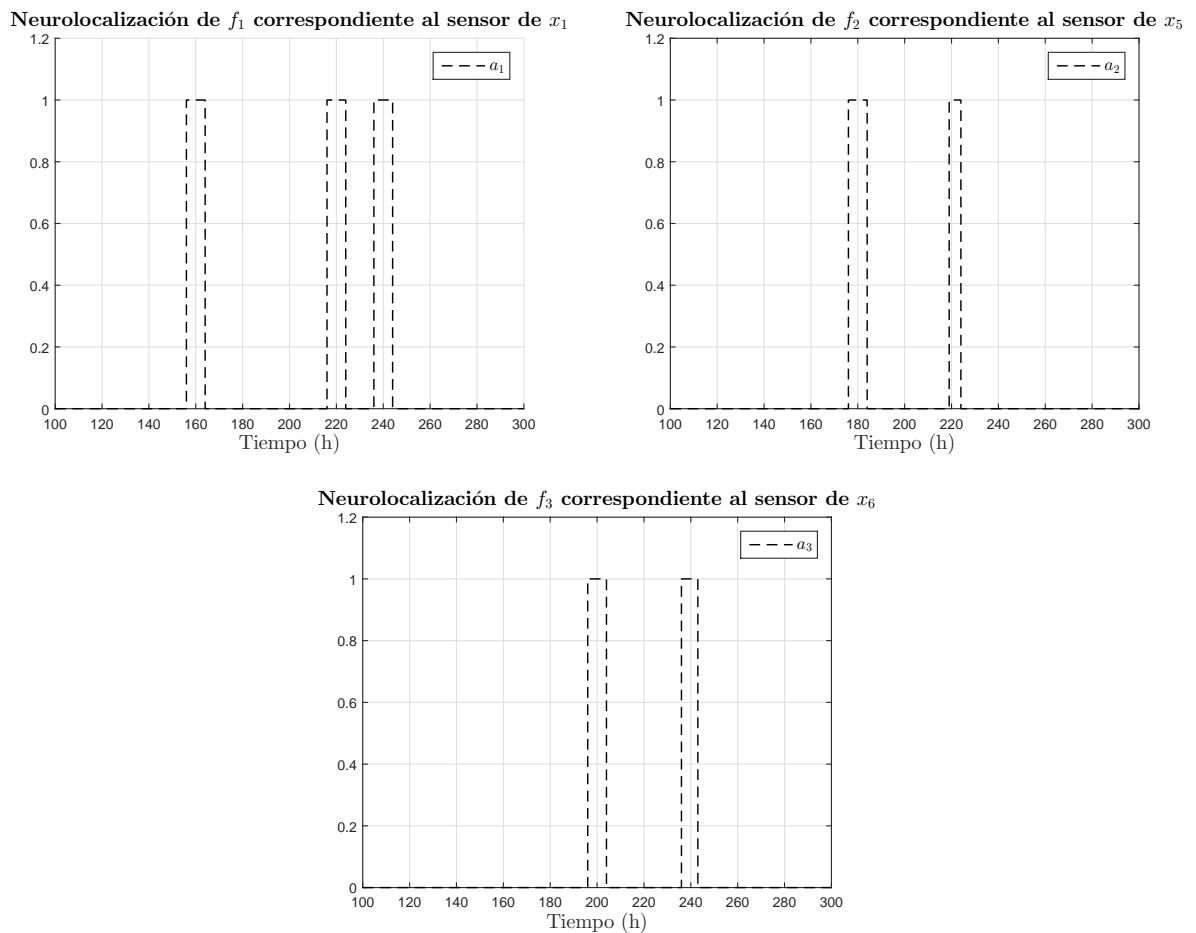


Figura 3-33.: Neurolocalización de fallas en sensores del proceso de fermentación alcohólica.

Simulación 3.6.2 Fallas f_2 y f_3 simultáneas

El objetivo de esta simulación es analizar el sistema neurolocalizador de fallas cuando se presentan simultáneamente f_2 y f_3 . Para ello, la dinámica de ambas fallas y la dinámica de f_1 se muestra en la Fig.3-34.

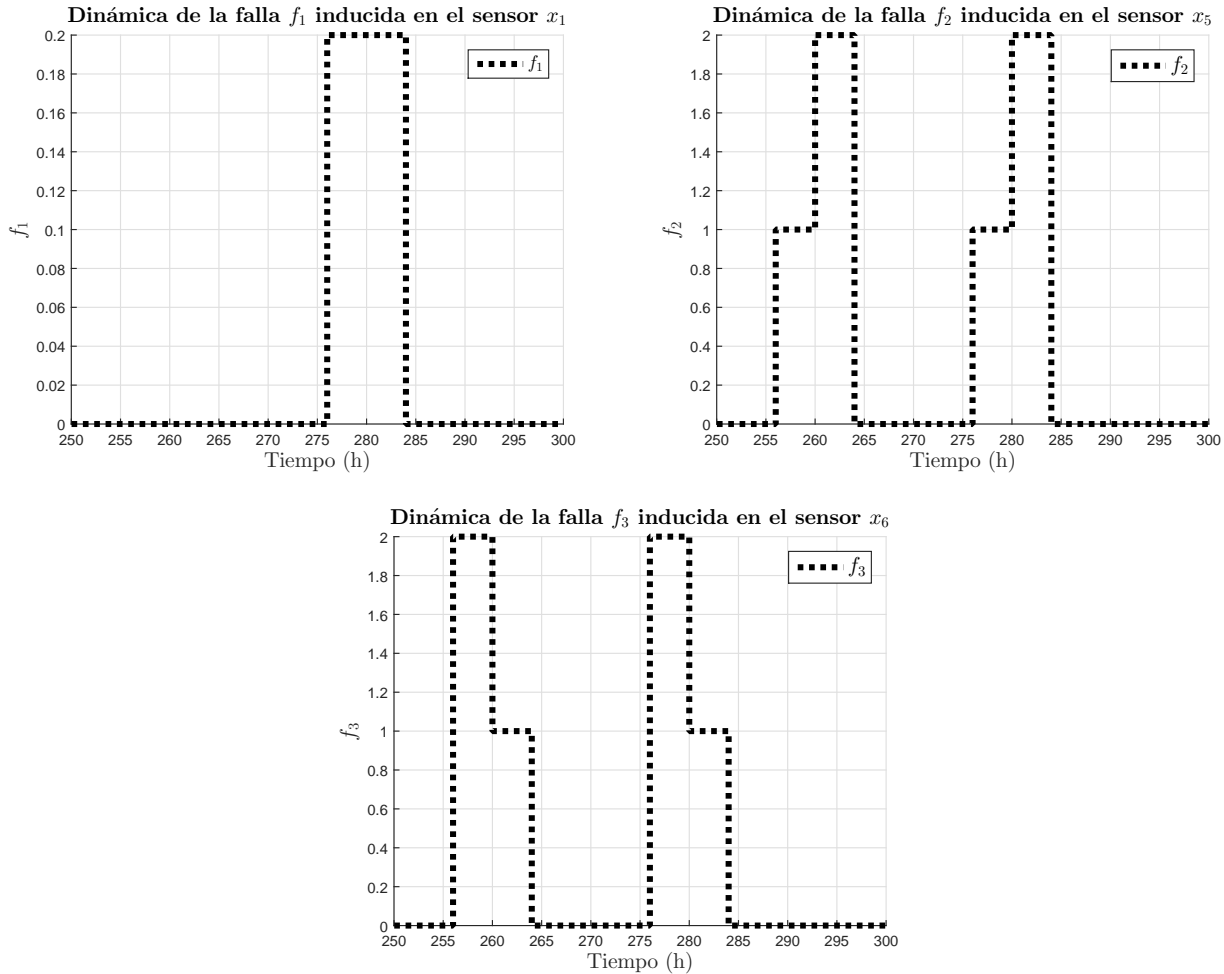


Figura 3-34.: Fallas en sensores del proceso de fermentación alcohólica.

La falla f_2 se presenta en el hora 256 en forma de escalón con un valor de uno y en la hora 260 se presenta un nuevo cambio en escalón positivo de un valor de uno, llevando a un valor de dos a la falla, el cual permanece hasta la hora 264 instante en que regresa a cero. En la hora 276 se presenta nuevamente la falla f_2 en forma de escalón con un valor de uno y en la hora 280 se presenta un nuevo cambio en escalón positivo de un valor de uno, llevando a un valor de dos a la falla, el cual permanece hasta la hora 284 instante en que regresa a cero. Por otra parte, la falla f_3 se presenta en el hora 256 en forma de escalón con un valor de dos y en la hora 260 se presenta un nuevo cambio en escalón pero ahora negativo de un valor de uno, llevando a un valor de uno a la falla, el cual permanece hasta la hora 264 instante en que regresa a cero. En la hora 276 se presenta nuevamente la falla f_3 en forma de escalón con un valor de dos y en la hora 280 se presenta un nuevo cambio en escalón negativo de un

3. Neurolocalización de fallas

valor de uno, llevando a un valor de uno a la falla, el cual permanece hasta la hora 284 instante en que regresa a cero. En cambio la falla f_1 se presenta una vez, iniciando en la hora 276 en forma de escalón con un valor de 0,2 y que permanece con ese valor hasta la hora 284. Derivado de lo anterior, las fallas f_2 y f_3 se presentan simultáneamente en la hora 256 con una dinámica diferente, pero terminan ambas en la hora 264. Por último, las tres fallas coinciden de la hora 276 a la hora 284, con las dinámicas mencionadas anteriormente.

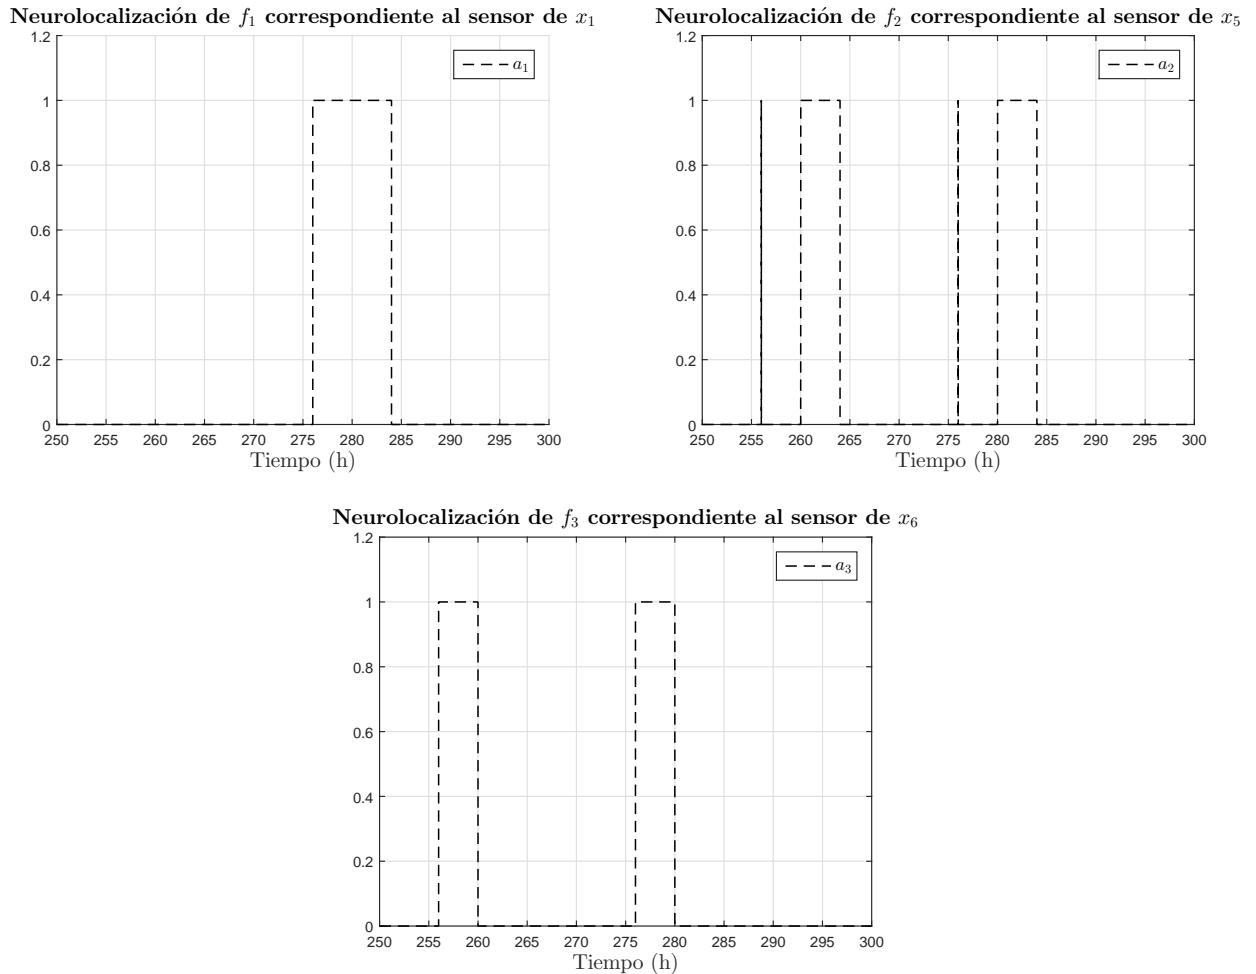


Figura 3-35.: Neurolocalización de fallas en sensores del proceso de fermentación alcohólica.

La neurolocalización de las fallas f_2 y f_3 cuando se presentan de forma simultánea y cuando se presentan las tres fallas de forma simultánea, se muestra en la Fig. 3-35. En dicha figura se muestran tres gráficas, en la primera se representa la alarma a_1 que corresponde a la falla f_1 . En la segunda gráfica se presenta la alarma a_2 , la cual corresponde a la falla f_2 ; y en la tercera gráfica se presenta la alarma a_3 que corresponde a la alarma f_3 . Note que cuando se presenta las falla f_2 y f_3 de forma simultánea, la alarma a_2 se manifiesta en el instante que se presentan dichas fallas, pero solo por un instante de tiempo; mientras que la alarma a_3 si se manifiesta y mantiene cuando se presentan ambas fallas. Las alarmas a_2 y a_3 se mantienen apagada y encendida, respectivamente, durante el periodo

comprendido al primer escalón de las fallas f_2 y f_3 . En cambio cuando se presenta el segundo escalón en ambas fallas en la hora 260, la alarma a_2 cambia de apagada a encendida y la alarma a_3 cambia de encendida a apagada. Estas acciones (encendido y apagado) de las alarmas a_2 y a_3 se repiten cuando se presentan de forma simultánea las tres fallas f_1 , f_2 y f_3 , mientras que la alarma a_1 se mantiene encendida durante el tiempo que ocurren dichas fallas.

Cuando se presentan las fallas f_2 y f_3 de forma simultánea, el sistema neurolocalizador de fallas no mantiene la acción de encendido de las alarmas a_2 y a_3 de forma correcta. Esto coincide con los valores de las fallas, es decir, cuando la magnitud de una de la fallas es mayor a la otra falla, la alarma correspondiente a la falla de mayor magnitud se mantiene encendida. Esto es debido al estrecho acoplamiento que existe entre el estado x_5 y x_6 del modelo no lineal por su balance de energía como se especifica en la 2.5.1.




Figura 3-36.: Dinámicas sobre puestas de las alarmas a_1 , a_2 y a_3 .

En la Fig.3-36 se muestran las dinámicas sobre puestas de las alarmas a_1 , a_2 y a_3 , esto con el fin de clarificar la explicación de como actúan el sistema neurolocalizador de fallas cuando se presentan en conjunto las fallas f_2 y f_3 . En color negro y con el símbolo de suma se muestra la acción de la alarma a_1 , en color azul y con una línea seccionada se muestra la acción de la alarma a_2 , por último la acción de la alarma a_3 se muestra con una línea punteada en color rojo. En la gráfica de la Fig.3-36 solo se muestran las acciones de las alarmas a_2 y a_3 , en ellas se puede apreciar que en el primer instante en que se presentan las fallas f_2 y f_3 el sistema neurolocalizador emite la acción de encendido de ambas alarmas, pero la alarma a_2 solo dura un pequeño instante de tiempo mientras que la alarma a_3 mantiene la acción correcta, hasta la hora 260 que se presenta el cambio en escalón de las fallas f_2 y f_3 . En ese momento la falla f_2 tiene un cambio positivo y la falla f_3 tiene un cambio negativo, ocasionando que la magnitud de la f_2 sea mayor a f_3 . Con ello, las acciones de las alarmas a_2 y a_3 cambian de acción, es decir, de estar encendida la alarma a_3 pasa a estar apagada y la alarma a_2 de estar apagada pasa a encendida.

3.5.3. Sistema neurolocalizador ante la presencia de la falla f_4 en el actuador F_c

En la siguiente simulación se analiza el desempeño del sistema neurolocalizador ante la presencia de la falla f_4 , la cual incide en el actuador que ejerce sobre el flujo de enfriamiento a la chaqueta térmica F_c .

Simulación 3.7 Neurolocalización de la falla f_4

El objetivo de esta simulación es la neurolocalización de la falla f_4 mediante el sistema neurolocalizador. Para ello, la falla es inducida en la señal de control F_c del proceso de fermentación alcohólica. La dinámica de la falla f_4 y la repercusión que tiene en F_c se muestra en la Fig.3-37. En la hora 165 se presenta por primera vez f_4 , en forma de escalón con una magnitud de uno, valor que mantiene hasta la hora 167,5 instante en que se presenta un segundo escalón de igual magnitud llevando a la falla a un valor de dos, el cual se mantiene hasta la hora 170 instante donde se presenta un escalón negativo de una magnitud de -2 , el cual lleva a cero el valor de la falla. La falla se vuelve a presentar una segunda vez con una dinámica semejante en la hora 210 y terminando en la hora 215. Acompañada a la falla f_4 una señal de ruido también se introduce en el actuador F_c , la cual inicia una hora antes de la falla y termina una hora después, con una magnitud que oscila entre $\pm 0,1$. Las condiciones iniciales para esta simulación son las mismas que en la simulación 3.4

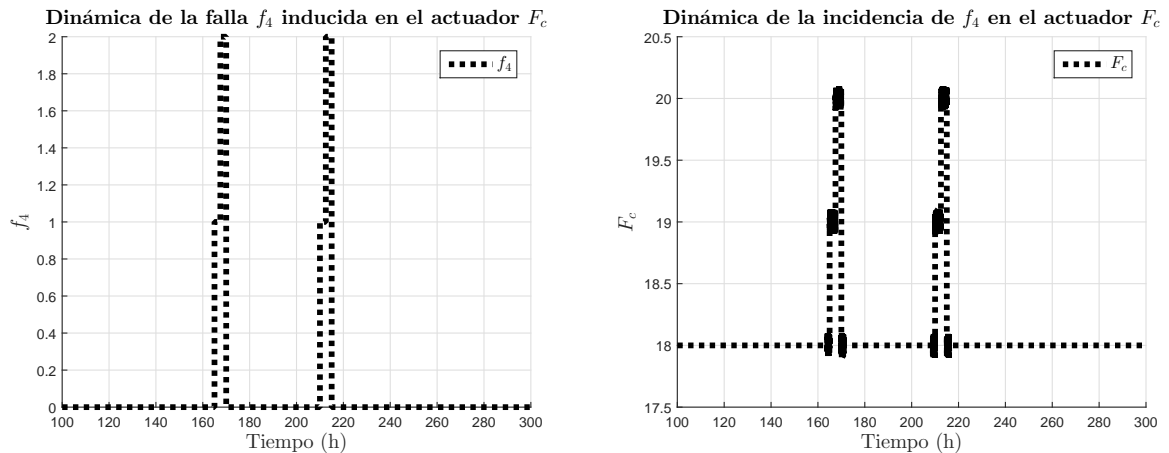


Figura 3-37.: Dinámica de la falla f_4 y su repercusión en F_c .

En la Fig.3-38 se muestra la estimación del modelo no lineal del proceso de fermentación alcohólica a través de la red neuronal uno. Los estados no lineales x_1, x_2, x_3, x_4 y x_5 son estimados de manera correcta mediante los estados $\hat{x}_1^{RNA1}, \hat{x}_2^{RNA1}, \hat{x}_3^{RNA1}, \hat{x}_4^{RNA1}$ y \hat{x}_5^{RNA1} aún cuando se presenta la falla f_4 . Por ejemplo, en la hora 165 la falla f_4 se presenta por primera vez derivado de ello el estado no lineal x_6 tiene un cambio en su dinámica, mientras que la red neuronal uno trata de estimar a dicho estado como se muestra en el estado neuronal \hat{x}_6^{RNA1} . Esta estimación genera un error dado que no se logra estimar de forma correcta. Por lo tanto, mediante la red neuronal uno solamente se genera un error de estimación e_6^{RNA1} , el cual se utiliza para la neurolocalización de la falla f_4 .

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

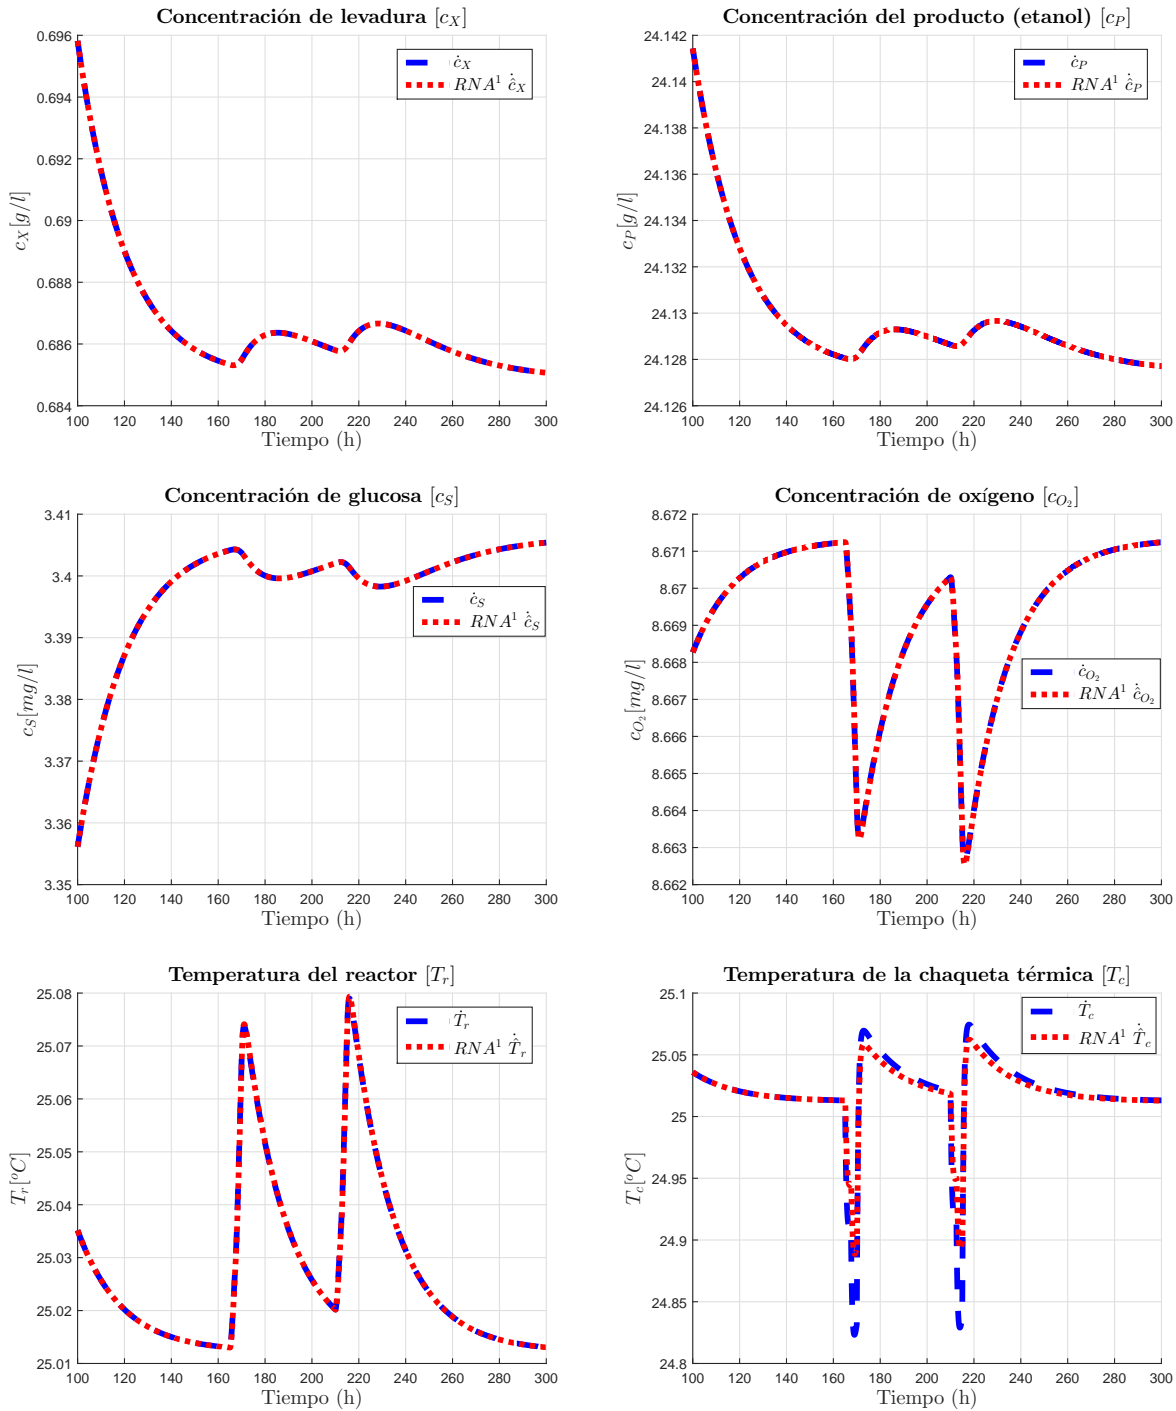


Figura 3-38.: Estimación del proceso no lineal con falla en el actuador F_c mediante la red neuronal uno.

Los residuos generados a partir de la estimación del proceso no lineal mediante la red neuronal uno son presentados en la Fig. 3-39. Dichos residuos se obtuvieron mediante la siguiente expresión:

$$r_i = |x_{i_{NL}} - x_{i_{RNA}}| \quad (3-79)$$

3. Neurolocalización de fallas

Observe que los residuos r_1^{RNA1} , r_2^{RNA1} , r_3^{RNA1} y r_4^{RNA1} son iguales a 0. El residuo r_5^{RNA1} obtenido de la diferencia de $|x_5 - \hat{x}_5^{RNA1}|$ presenta mínimas variaciones cuando incide la falla f_4 . El residuo en el que se refleja la falla es en r_6^{RNA1} obtenido mediante la diferencia de $|x_6 - \hat{x}_6^{RNA1}|$, el cual es evaluado mediante un umbral establecido a priori. Así cuando el residuo rebasa el umbral se genera un síntoma el cual es utilizado para neurolocalización de la falla f_4 .

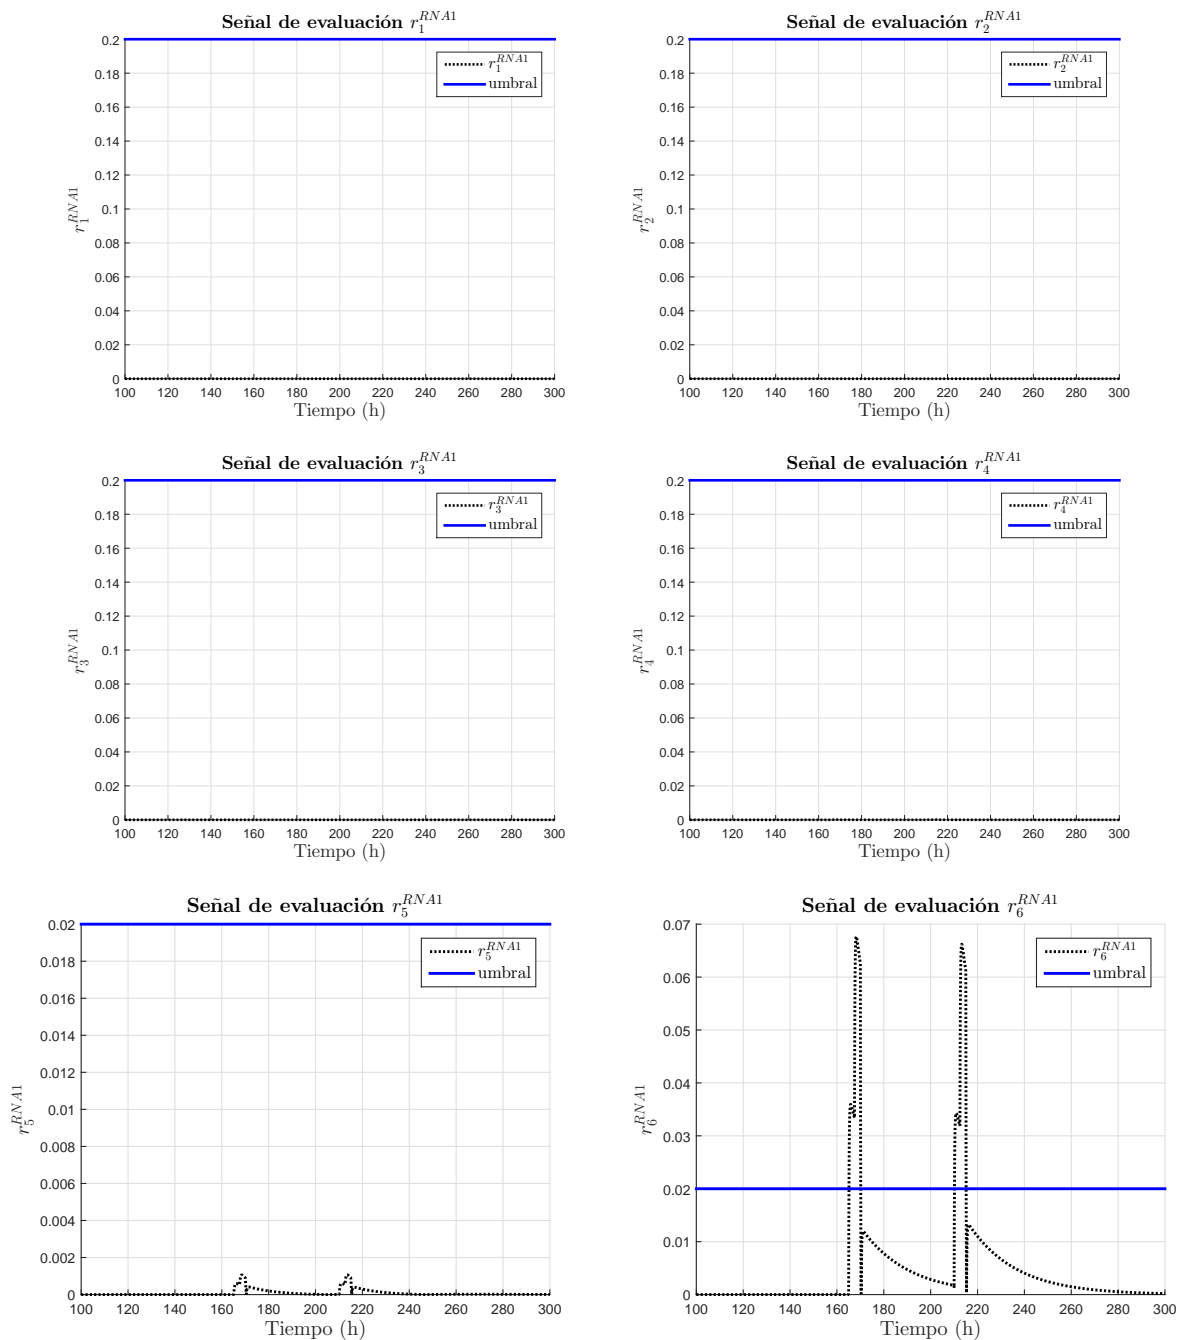


Figura 3-39.: Residuos generados por la estimación mediante la red neuronal uno.

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

Note que cuando se presenta el primer escalón de la falla f_4 el neurolocalizador emite la señal de alarma a_4 de inmediato y la mantiene activa de forma correcta hasta que termina la primera aparición de la falla. De manera similar ocurre cuando se presenta por segunda vez dicha falla.

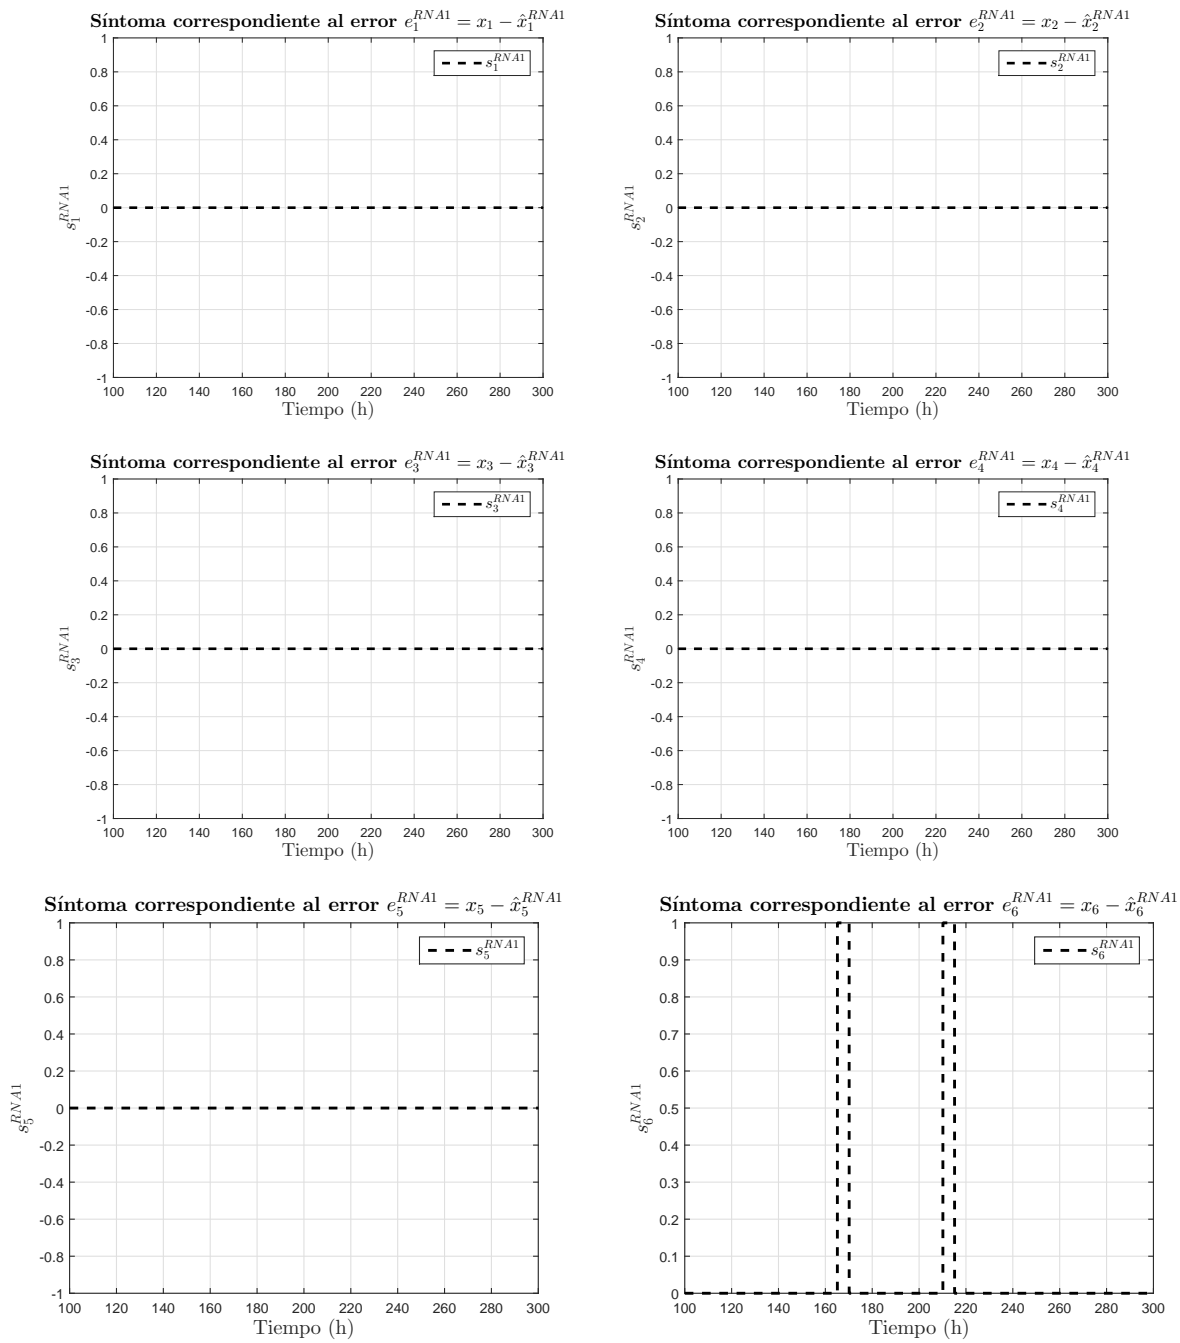


Figura 3-40.: Síntomas generados por la estimación mediante la red neuronal uno.

Independientemente si la señal tiene cambios positivos o negativos, la neurolocalización de la falla f_4 se lleva a cabo en el mismo instante de tiempo que se presenta dicha falla y una alarma se emite para

3. Neurolocalización de fallas

información del operario como se muestra en la Fig.3-41.




Figura 3-41.: Neurolocalización de fallas en actuadores del proceso de fermentación alcohólica.

Por último, la red neuronal dinámica propuesta en la Ec.(3-54) al tener acceso a los estados del proceso puede reconstruir los estados no lineales del proceso de fermentación alcohólica como se muestra en la Fig.3-38. Posteriormente, se generan los residuos mediante la comparación de los estados del proceso no lineal y los estados aproximados mediante la red neuronal dinámica como se muestra en la Fig.3-39, los cuales son evaluados mediante un umbral establecido por el diseñador. Finalmente, la neurolocalización se muestra en la Fig.3-41, donde la falla f_4 afecta únicamente al actuador correspondiente al estado no lineal x_6 .

3.5.4. Sistema neurolocalizador ante la presencia de fallas en sensores y actuadores

En esta sección el desempeño del sistema neurolocalizador cuando se presentan de forma simultánea las fallas en los sensores x_1 , x_5 y x_6 y en el actuador F_c es llevado a cabo, tal caso se muestra en la siguiente simulación.

Simulación 3.8 fallas en sensores (x_1 , x_5 y x_6) y actuadores (F_c)

El objetivo de esta simulación es el analizar la respuesta del sistema neurolocalizador de fallas cuando se presentan las fallas f_1 , f_2 , f_3 y f_4 de forma simultánea. Para ello, las fallas son inducidas al proceso de fermentación alcohólica y cuya dinámica se muestra en la Fig.3-42.

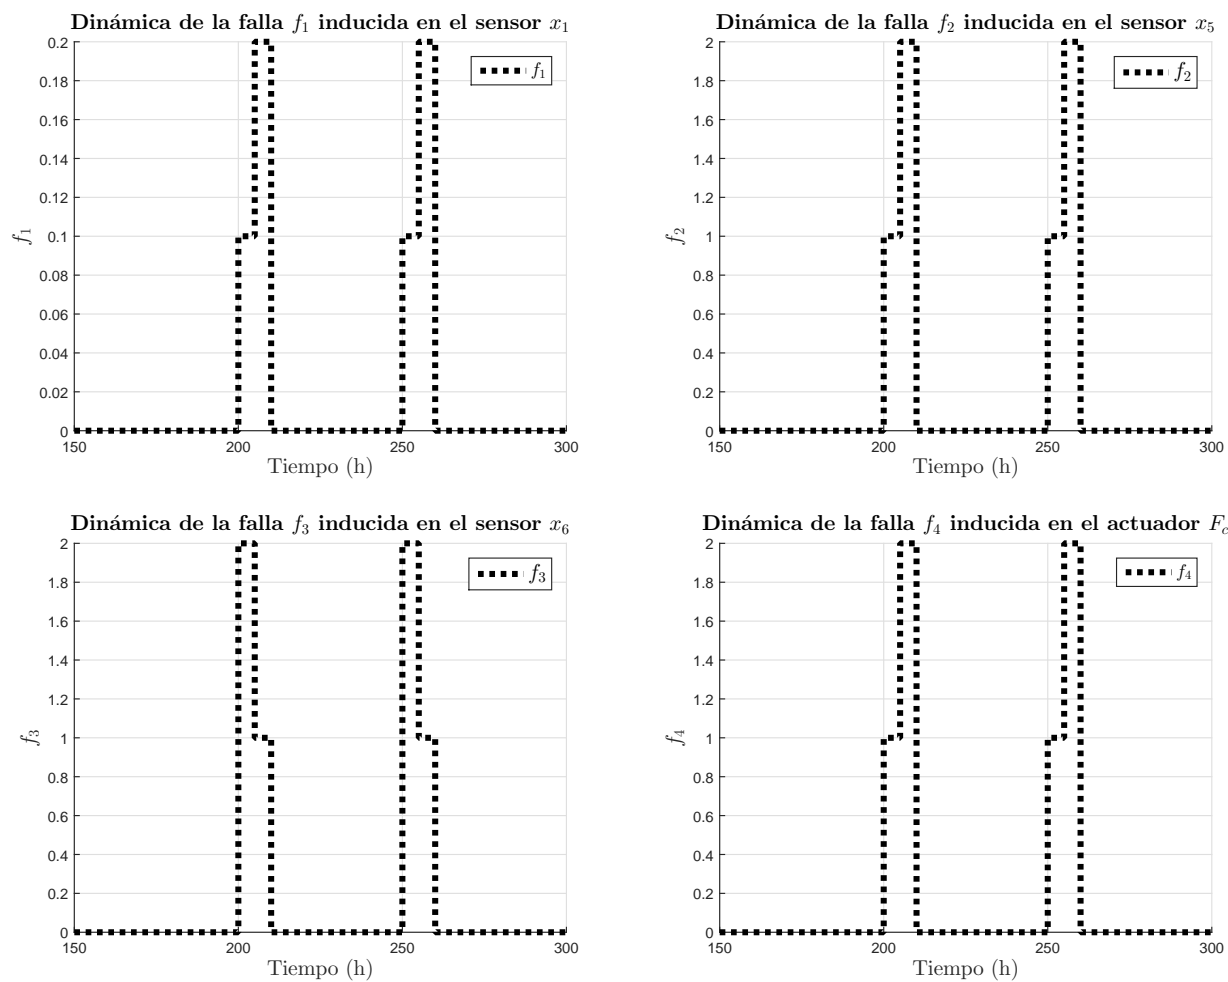


Figura 3-42.: Dinámicas de las fallas f_1 , f_2 , f_3 y f_4 .

Todas las fallas tienen su primera aparición en la hora 200. Por ejemplo, la falla f_1 comienza en forma de escalón con una magnitud positiva de 0,1; mientras que las fallas f_2 y f_4 comienzan con un escalón

3. Neurolocalización de fallas

positivo de magnitud 1; por otra parte la falla f_3 comienza con un escalón positivo de magnitud 2, todas mantienen esta dinámica hasta la hora 205. Hora en la cual, tienen un nuevo cambio en su dinámica, en la falla f_1 se presenta un escalón de una magnitud positiva de 0,1 llevando el valor de la falla a 0,2; mientras que las fallas f_2 y f_4 tienen un nuevo cambio en forma de escalón positivo de una magnitud de 1 llevando el valor de la falla a 2; por otra parte la falla f_3 tiene un cambio de escalón negativo de magnitud -1 , todas mantienen esta dinámica hasta la hora 210. En dicha hora todas las fallas regresan a un valor de cero. Todas las fallas se vuelven a presentar una segunda vez con dinámicas semejante, esta vez en la hora 250 y terminando en la hora 260. Acompañada a cada falla una señal de ruido es inducida, la cual empieza cinco horas antes de cada falla y termina cinco horas después de cada falla.

Esta simulación es semejante a la simulación 3.6.2, donde se analizó el desempeño del sistema neurolocalizador cuando se presentaron simultáneamente las fallas f_1 , f_2 y f_3 , la variante consiste en que aunado a las tres fallas mencionadas también se presenta la falla f_4 . Por lo tanto, el sistema neurolocalizador está utilizando las dos partes del sistema neurolocalizador fallas, es decir, trabaja para la parte enfocada a la detección de fallas en actuadores y sensores, así como la red neuronal mostrada en la Fig.3-27 que es la encargada de la localización de fallas para posterior emitir una alarma en caso de ser necesario.

En la Fig.3-43 se muestran las dinámicas de las alarmas a_1 , a_2 , a_3 y a_4 emitidas por el sistema neurolocalizador al presentarse las cuatro fallas de forma f_1 , f_2 , f_3 y f_4 de forma simultánea. La respuesta del sistema neurolocalizador mediante la alarma a_1 al presentarse la falla f_1 se muestra en la gráfica superior izquierda de la Fig.3-43, en ella se puede apreciar que el neurolocalizador emite de forma correcta la alarma cuando se presenta por primera vez dicha falla, en la segunda vez que se presenta la falla f_1 la alarma a_1 solo se apaga por un pequeño instante.

Las alarmas a_2 y a_3 al presentarse las fallas f_2 y f_3 , no mantiene la acción de encendido de las alarmas a_2 y a_3 de forma correcta. Esto coincide con los valores de las fallas, es decir, cuando la magnitud de una de las fallas es mayor a la otra falla, la alarma correspondiente a la falla de mayor magnitud se mantiene encendida. Esto es debido al estrecho acoplamiento que existe entre el estado x_5 y x_6 del modelo no lineal por su balance de energía como se especifica en la 2.5.1. Es decir, se mantienen apagada y encendida, respectivamente, durante el periodo comprendido al primer escalón de las fallas f_2 y f_3 , y en el segundo escalón la alarma a_2 cambia de apagada a encendida y la alarma a_3 cambia de encendida a apagada. Estas acciones (encendido y apagado) de las alarmas a_2 y a_3 se repiten cuando se presentan nuevamente las fallas.

El sistema neurolocalizador para la falla f_4 realiza la acción correcta mediante la alarma a_4 , solo se genera un pequeño cambio cuando de encendido a apagado derivado del efecto de la falla f_2 en el estado no lineal x_5 mismo estado en que repercute de forma indirecta la falla f_4 .

3.5. Sistema neurolocalizador de fallas en sensores y actuadores

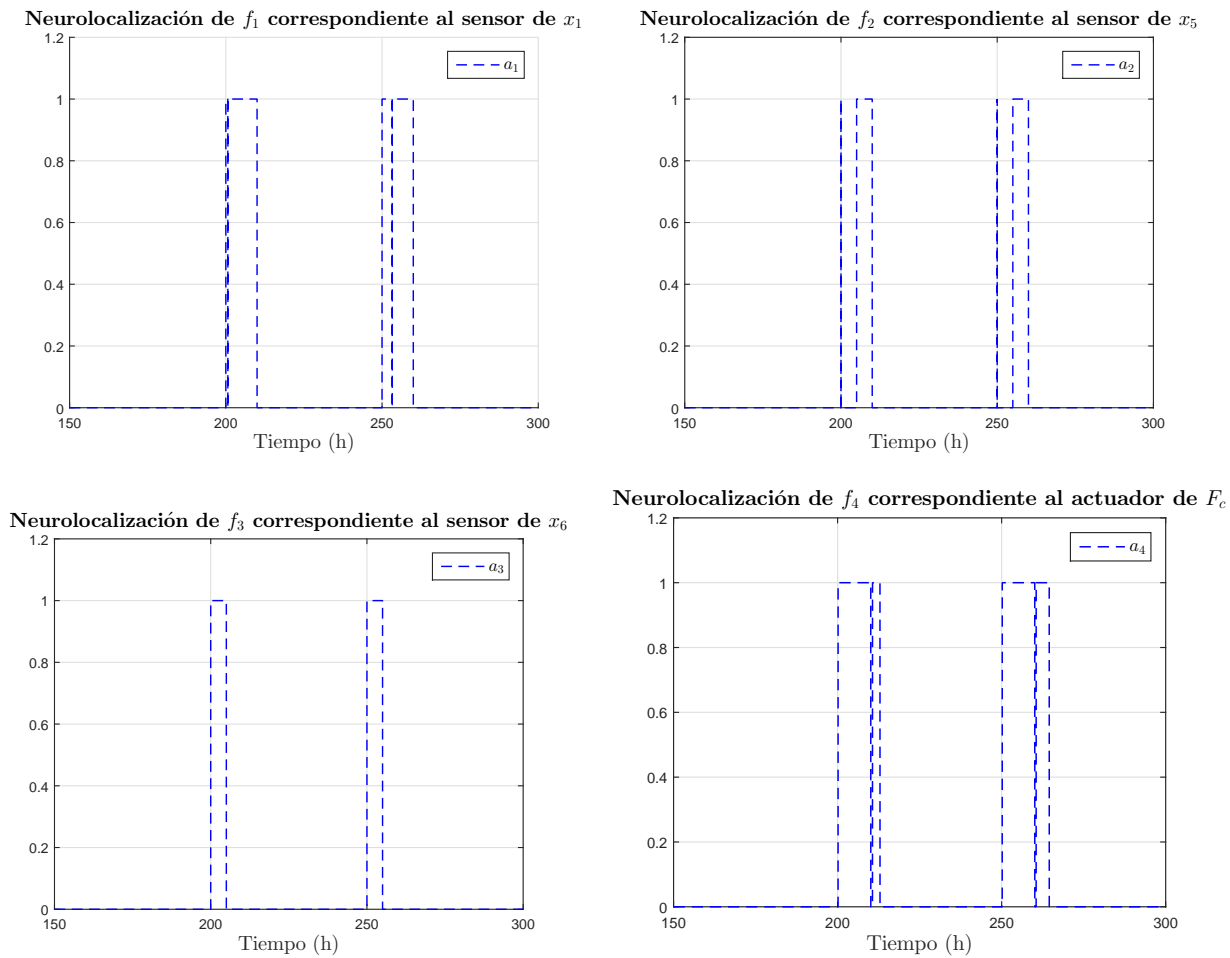


Figura 3-43.: Dinámicas de las alarmas correspondientes a la neurolocalización de las fallas f_1 , f_2 , f_3 y f_4 .

El sistema neurolocalizador de fallas tiene un desempeño adecuado al presentarse de forma simultánea puesto que logra emitir las alarmas correspondientes que indican al operador donde están ocurriendo las fallas y así se tomen las medidas necesarias y pertinentes.

4.1. Conclusiones

En esta tesis se desarrolló un sistema neurolocalizador de fallas para sensores y actuador de un proceso de fermentación alcohólica. Las conclusiones del diseño y pruebas realizadas al sistema neurolocalizador de fallas se escriben a continuación en el orden que se presentaron los capítulos de esta tesis.

- En el capítulo 1 sección 1.3 se presentó el estado del arte referente a los trabajos de que abordaron los temas de detección y localización de fallas mediante la teoría de los sistemas Takagi-Sugeno, los observadores de estado y mediante redes neuronales. Dichos trabajos permitieron establecer la oportunidad de conjuntar la teoría de los sistemas T-S y las redes neuronales. Puesto que la tendencia es crear sistemas híbridos para resolver los retos de seguridad y producción en los procesos industriales actuales.
- El capítulo 2 se dividió en cinco partes abarcando la teoría necesaria para la elaboración del sistema neurolocalizador. La primera parte aborda los dos principales métodos para la elaboración de una representación Takagi-Sugeno a partir del modelo no lineal del proceso o sistema. Para ello, se desarrollaron ejemplos académicos con los cuales se mostró la metodología para la obtención de una representación T-S de un modelo no lineal mediante el enfoque del sector no lineal y el de linealización.

En la segunda parte se analizó el diseño de observadores difusos T-S, con el fin de establecer un banco de observadores que fuese capaz de proporcionar información útil para fallas en particular. A partir del análisis de observabilidad del modelo no lineal del proceso de fermentación alcohólica, se propuso un banco de observadores generalizados difusos con el propósito de generar residuos para la detección y localización de fallas en sensores.

4. Conclusiones generales

El estudio de las redes neuronales se abordó en la parte número tres, del cual se desprende una estructura de una red que puede abordar por ella misma la detección y localización de fallas en sensores, proceso y actuadores, si se cumplen con las condiciones necesarias de diseño como la estabilidad y el acceso a los estados del proceso.

En la cuarta parte se mencionaron los tipos de fallas y conceptos utilizados en las tareas de detección, localización, identificación, diagnóstico así como del control tolerante a fallas.

Por último, en la sección 2.5 se estableció el modelo no lineal del proceso de fermentación alcohólica. Inmediatamente después se llevó a cabo la versión difusa del mismo mediante el enfoque del sector no lineal de los sistemas T-S. El modelo T-S resultante reproduce adecuadamente la dinámica del proceso no lineal original. Esto se debe a que, técnicamente, el modelo no lineal original se transforma en una nueva representación que consiste en modelos locales interpolados por funciones de ponderación en función de los estados originales. Este modelo fue sometido a una serie de pruebas en lazo abierto y la principal prueba fue cuando se diseñó un control de temperatura del proceso de fermentación alcohólica. La particularidad del diseño en el controlador es que se basa en la representación T-S obtenida. La principal ventaja de este enfoque es que no es necesario linealizar o identificar el modelo para el diseño del controlador, con el consiguiente beneficio de preservar el rendimiento del controlador en un amplio rango de operación del proceso. El rendimiento del controlador se evaluó mediante simulaciones que demuestran que el resultado del diseño del controlador fue una ley de control robusta ante los cambios en la trayectoria y suave a la hora de ejercer sobre la variable manipulada. Se puede concluir que los controladores diseñados en el marco de los sistemas T-S representan una alternativa viable y confiable a los enfoques no lineales y que el enfoque T-S permite utilizar herramientas teóricas para procesos complejos no lineales que originalmente fueron concebidos para sistemas lineales.

- El diseño del sistema neurolocalizador se abordó en el capítulo 3, el cual consta de dos partes. La primera se enfoca en extraer los síntomas de fallas en particular para la construcción de la matriz y la segunda parte consiste de una red neuronal que utiliza como entrada dicha matriz para evaluarla y emitir una alarma de acuerdo a la presencia de las fallas.

El sistema neurolocalizador fue sometido a pruebas en diferentes simulaciones de las cuales se establece que el rendimiento del sistema neurolocalizador es correcto cuando se presentan las fallas f_1 , f_2 , f_3 y f_4 por separado y cuando se presentan en conjunto f_1 y f_2 , así como f_1 y f_3 . Mediante las alarmas a_1 , a_2 , a_3 y a_4 el sistema neurolocalizador indica el sensor o actuador que está fallando, con lo cual el operador puede tomar las decisiones adecuadas para mantener la seguridad y confiabilidad del proceso. Sin embargo, cuando se presentan en conjunto las fallas f_2 y f_3 de forma simultánea el sistema neurolocalizador no es capaz de distinguir entre una falla y otra. Esto es debido al fuerte acoplamiento que existe entre los estados donde inciden dichas fallas. De igual forma sucede cuando todas las fallas se presentan simultáneamente.

La red neuronal que forma parte del sistema neurolocalizador para la toma de decisiones y emitir las alarmas de cada falla en particular, permite neurolocalizar fallas tanto en los sensores del proceso como en el actuador indicado.

4.2. Ventajas y limitaciones de esta tesis doctoral

Las ventajas de este tema de tesis son mostradas a continuación:

- La representación del modelo no lineal de fermentación alcohólica para fines de control automático mediante los sistemas Takagi-Sugeno. Puesto que a partir de ella se puede diseñar mediante la teoría de sistemas lineales diferentes estrategias de control, sistemas de detección, localización, diagnóstico y control tolerante a fallas.
- El lazo de control de temperatura del reactor que se diseñó en base al modelo T-S obtenido.
- La compaginación de los sistemas T-S y las redes neuronales artificiales para el diseño del sistema neurolocalizador de fallas.
- El diseño de un banco de observadores generalizados. Lo cual, permite visualizar el desarrollo de un sistema de control basado en un observador de los que conforman a dicho banco de observadores.
- El diseño de la red neuronal dinámica, la cual puede servir como base para el diseño de controladores o estimadores neuronales de procesos no lineales como el de la fermentación alcohólica.
- El sistema neurolocalizador, a pesar de sus limitaciones proporciona de manera correcta y rápida la señal de detección y localización de las fallas. Con lo cual, el operario puede tomar la decisión que él considere adecuada para mantener el buen funcionamiento en el proceso de fermentación alcohólica.

Las limitaciones que presenta este tema doctoral son:

- El no poder neurolocalizar de forma correcta la presencia de las fallas f_2 y f_3 cuando se presentan simultáneamente.
- El establecer un valor fijo de los umbrales y no uno adaptable.

4.3. Trabajos futuros

A partir de este tema de tesis, pueden generarse nuevas investigaciones y trabajos futuros como los siguientes:

- La inclusión de un umbral adaptable en el banco de observadores.
- El diseño de observadores que permitan la estimación de ciertos parámetros que se asumen como medibles.

4. Conclusiones generales

- El control mediante la estimación de variables no medibles.
- El control del sustrato con fines de mantener una producción constante.
- El diseño de un control tolerante a fallas tanto en sensores como en actuadores.
- El diseño de una RNA que permita la estimación de los estados no medibles.
- El control Neuronal del proceso de fermentación alcohólica.

- Ahmadizadeh, S. , Zarei, J. , and Karimi, H. R. . A robust fault detection design for uncertain takagi-sugeno models with unknown inputs and time-varying delays. *Nonlinear Analysis: Hybrid Systems*, 11:98–117, 2014.
- Akhenak, A. , Chadli, M. , Ragot, J. , and Maquin, D. . Design of sliding mode unknown input observer for uncertain takagi-sugeno model. In *Control & Automation, 2007. MED'07. Mediterranean Conference on*, pages 1–6. IEEE, 2007.
- Ali, J. M. , Hussain, M. , Tade, M. O. , and Zhang, J. . Artificial intelligence techniques applied as estimator in chemical process systems—a literature survey. *Expert Systems with Applications*, 42(14):5915–5931, 2015.
- Bahmanpour, S. , Bashooki, M. , and Refan, M. . State estimation and fault diagnosis of industrial process by using of particle filters. In *Proceedings of the 6th WSEAS International Conference on Signal Processing, Robotics and Automation*, pages 208–213. World Scientific and Engineering Academy and Society (WSEAS), 2007.
- Bergsten, P. . *Observers and controllers for Takagi-Sugeno fuzzy systems*. PhD thesis, Örebro universitetsbibliotek, 2001.
- Bergsten, P. , Palm, R. , and Driankov, D. . Observers for takagi-sugeno fuzzy systems. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 32(1):114–121, 2002.
- Blanke, M. and Schröder, J. . *Diagnosis and fault-tolerant control*, volume 2. Springer, 2006.
- Ding, S. . *Model-based fault diagnosis techniques: design schemes, algorithms, and tools*, 2008.
- Duan, H. and Liu, D. . Application of improved elman neural network based on fuzzy input for fault diagnosis in oil-filled power transformers. In *Mechatronic Science, Electric Engineering and Computer (MEC), 2011 International Conference on*, pages 28–31. IEEE, 2011.

- El-koujok, M. , Benammar, M. , Meskin, N. , Al-Naemi, M. , and Langari, R. . Multiple sensor fault diagnosis for non-linear and dynamic system by evolving approach. In *Prognostics and System Health Management (PHM), 2012 IEEE Conference on*, pages 1–10. IEEE, 2012.
- Geetha, M. and Jerome, J. . Fuzzy expert system based sensor and actuator fault diagnosis for continuous stirred tank reactor. In *Fuzzy Theory and Its Applications (iFUZZY), 2013 International Conference on*, pages 251–257. IEEE, 2013.
- Gowthami, R. and Vijayachitra, S. . Fault detection and diagnosis in continuous stirred tank reactor (cstr). *International Journal of Technical Research and Applications*, pages 07–11, 2015.
- Hamdi, H. , Rodrigues, M. , MECHMECHE, C. , and Braiek, N. B. . Observer based fault tolerant control for takagi-sugeno nonlinear descriptor systems. *Proceedings Engineering & Technology-Vol, 1:52–57*, 2013.
- Höfling, T. and Isermann, R. . Fault detection based on adaptive parity equations and single-parameter tracking. *Control Engineering Practice*, 4(10):1361–1369, 1996.
- Ichalal, D. , Marx, B. , Ragot, J. , and Maquin, D. . Fault diagnosis in takagi-sugeno nonlinear systems. In *7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes, Safeprocess 2009*, page CDROM, 2009.
- Ichalal, D. , Marx, B. , Maquin, D. , and Ragot, J. . Observer design and fault tolerant control of takagi-sugeno nonlinear systems with unmeasurable premise variables. *Fault Diagnosis in Robotic and Industrial Systems*, pages 1–21, 2012.
- Isermann, R. . Model-based fault-detection and diagnosis—status and applications. *Annual Reviews in control*, 29(1):71–85, 2005.
- Isermann, R. . *Fault-diagnosis systems: an introduction from fault detection to fault tolerance*. Springer Science & Business Media, 2006.
- Isermann, R. and Ballé, P. . Trends in the application of model-based fault detection and diagnosis of technical processes. *Control engineering practice*, 5(5):709–719, 1997.
- Janarthanan, K. and Prakash, J. . Fuzzy kalman filter based simultaneous state and fault parameter estimation scheme with an application to a continuous stirred tank reactor. In *India Conference, 2006 Annual IEEE*, pages 1–3. IEEE, 2006.
- Lendek, Z. , Guerra, T.-M. , and Babuska, R. . On non-pdc local observers for ts fuzzy systems. In *Fuzzy Systems (FUZZ), 2010 IEEE International Conference on*, pages 1–7. IEEE, 2010.
- Lendek, Z. , Guerra, T. M. , Babuska, R. , and De Schutter, B. . *Stability analysis and nonlinear observer design using Takagi-Sugeno fuzzy models*. Springer, 2011. doi: 10.1007/978-3-642-16776-8.
- Liu, J. , Ohran, B. J. , Peña, D. M. , de la, Christofides, P. D. , and Davis, J. F. . Monitoring and handling of actuator faults in two-tier control systems for nonlinear processes. *Chemical Engineering Science*, 65(10):3179–3190, 2010.

- Lofberg, J. . Yalmip: A toolbox for modeling and optimization in matlab. In *Computer Aided Control Systems Design, 2004 IEEE International Symposium on*, pages 284–289. IEEE, 2004.
- Luzar, M. , Czajkowski, A. , Witczak, M. , and Korbicz, J. . Actuators and sensors fault diagnosis with dynamic, state-space neural networks. In *Methods and Models in Automation and Robotics (MMAR), 2012 17th International Conference on*, pages 196–201. IEEE, 2012.
- Martínez-Guerra, R. and Mata-Machuca, J. L. . *Fault Detection and Diagnosis in Nonlinear Systems: A Differential and Algebraic Viewpoint*, volume 1. springer, 2014.
- Mirea, L. and Patton, R. . Recurrent wavelet neural networks applied to fault diagnosis. In *Control and Automation, 2008 16th Mediterranean Conference on*, pages 1774–1779. IEEE, 2008.
- Nagy-Kiss, A. , Schutz, G. , and Ragot, J. . Parameter estimation for uncertain systems based on fault diagnosis using takagi-sugeno model. *ISA transactions*, 2015.
- Nagy-Kiss, A. M. , Schutz, G. , and Ragot, J. . State, unknown input and uncertainty estimation for nonlinear systems using a takagi-sugeno model. In *Control Conference (ECC), 2014 European*, pages 1274–1280. IEEE, 2014.
- Patan, K. . *Artificial neural networks for the modelling and fault diagnosis of technical processes*, volume 377. Springer Science & Business Media, 2008.
- Pierri, F. , Paviglianiti, G. , Caccavale, F. , and Mattei, M. . Observer-based sensor fault detection and isolation for chemical batch reactors. *Engineering Applications of Artificial Intelligence*, 21(8): 1204–1216, 2008.
- Reyes Reyes, J. . Pasividad robusta de sistemas no lineales via redes neuronales dinámicas. *CINVESTAV, INP, México, Tesis de Doctorado*, 2001.
- Rotondo, D. . *Advances in Gain-Scheduling and Fault Tolerant Control Techniques*. Springer Theses, 2017.
- Sawattanakit, N. and Jaovisidha, V. . Process fault detection and diagnosis in cstr system using on-line approximator. In *Circuits and Systems, 1998. IEEE APCCAS 1998. The 1998 IEEE Asia-Pacific Conference on*, pages 747–750. IEEE, 1998.
- Sayed-Mouchaweh, M. . *Fault Diagnosis of Hybrid Dynamic and Complex Systems*. Springer, 2018.
- Takagi, T. and Sugeno, M. . Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15(1):116–132, 1985. ISSN 0018-9472. doi: 10.1109/TSMC.1985.6313399.
- Tayarani-Bathaie, S. S. , Vanini, Z. S. , and Khorasani, K. . Dynamic neural network-based fault diagnosis of gas turbine engines. *Neurocomputing*, 125:153–165, 2014.

Bibliografía

- Thumati, B. T. , Feinstein, M. A. , and Jagannathan, S. . A model-based fault detection and prognostics scheme for takagi-sugeno fuzzy systems. *Fuzzy Systems, IEEE Transactions on*, 22(4):736–748, 2014.
- Verde, C. , Gentil, S. , and Menéndez, R. . *Monitoreo Y Diagnóstico Automático de Fallas en Sistemas Dinámicos: Detección de fallas, Métodos de supervisión, Revisión de procesos*. Trillas, 2013.
- Zhang, J. , Swain, A. K. , and Nguang, S. K. . *Robust Observer-Based Fault Diagnosis for Nonlinear Systems Using MATLAB®*. Springer, 2016.
- Zhang, X. and Hoo, K. A. . Effective fault detection and isolation using bond graph-based domain decomposition. *Computers & chemical engineering*, 35(1):132–148, 2011.
- Zoltan-Kalman, N. . Model based control of a yeast fermentation bioreactor using optimally designed artificial neural networks. *Chemical Engineering Journal*, 127(1):95 – 109, 2007. ISSN 1385-8947. doi: <https://doi.org/10.1016/j.cej.2006.10.015>. URL <http://www.sciencedirect.com/science/article/pii/S1385894706004141>.

APÉNDICE A

Anexo A: Términos variables de las matrices $A(x)$ y $B_v(x)$

$$A(x) = \begin{bmatrix} \boxed{\mu_X \frac{c_S}{K_S + c_S} e^{-K_p c_P}} - \frac{F_{out}}{V} & 0 & 0 & 0 & 0 & 0 \\ \boxed{\mu_p \frac{c_S}{K_{S1} + c_S} e^{-K_{p1} c_P}} & -\frac{F_{out}}{V} & 0 & 0 & 0 & 0 \\ -\frac{1}{R_{SX}} \boxed{\mu_X \frac{c_S}{K_S + c_S} e^{-K_p c_P}} - \frac{1}{R_{SP}} \boxed{\mu_p \frac{c_S}{K_{S1} + c_S} e^{-K_{p1} c_P}} & 0 & -\frac{F_{out}}{V} & 0 & 0 & 0 \\ -\boxed{\mu_{O_2} \frac{1}{Y_{O_2}} \frac{c_{O_2}}{k_{O_2} + c_{O_2}}} & 0 & 0 & -k_{la} & 0 & 0 \\ \boxed{\mu_{O_2} \frac{1}{Y_{O_2}} \frac{c_{O_2}}{k_{O_2} + c_{O_2}}} \frac{\Delta H_r}{32\rho_r C_{heat,r}} & 0 & 0 & 0 & -\frac{F_{out}}{V} + \frac{K_T A_T}{V\rho_r C_{heat,r}} & -\frac{K_T A_T}{V\rho_r C_{heat,r}} \\ 0 & 0 & 0 & 0 & \frac{K_T A_T}{V_c \rho_c C_{heat,c}} & -\frac{K_T A_T}{V_c \rho_c C_{heat,c}} \end{bmatrix} \quad (A-1)$$

$$B_{nv} = \begin{bmatrix} 0 \\ 0 \\ \frac{c_{S,in}}{V} \\ 0 \\ \frac{T_{r,in}}{V} \\ 0 \end{bmatrix}, B_v(x) = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ \frac{T_{c,in} - T_c}{V_c} \end{bmatrix}, E = \begin{bmatrix} 0 \\ 0 \\ 0 \\ k_{la} c_{O_2 EL} \\ 0 \\ 0 \end{bmatrix} \quad (A-2)$$

Anexo B: Diseño de los observadores O^3 , O^4 y O^5

B.1. Diseño del observador O^3 correspondiente a la matriz C_i^3

El diseño del observador O^3 se basa en la primera matriz C obtenida del análisis de observabilidad del modelo no lineal del proceso de fermentación alcohólica, la cual se reescribe en la Ec.(B-2) y que llamaremos C_i^3 . Por lo tanto, a partir de ello y del observador presentado en la Ec.(3-30), el modelo matemático que representa al observador O^3 es:

$$\begin{aligned}\dot{\hat{x}}^3 &= \sum_{i=1}^{16} \phi_i(\hat{z})(A_i \hat{x}^3 + B_{vi} F_c + L_i^3 (y - \hat{y}^3)) + B_{nv} F_{in} + E \\ \hat{y}^3 &= C_i^3 \hat{x}^3\end{aligned}\tag{B-1}$$

donde A_i , B_{vi} , B_{nv} , y E son matrices de dimensiones adecuadas que conforman al modelo T-S denotado en la Ec.(3-17), \hat{x}^3 es el vector de estados estimados y \hat{y}^3 las salidas del observador O^3 , que corresponde a la matriz C_3 denotada en la Ec.(3-40).

$$C_i^3 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}\tag{B-2}$$

A partir de la matriz C_i^3 , note que los estados medibles del proceso en el diseño del O^3 son x_1 , x_2 , x_3 , x_4 , x_5 y el no medible es x_6 . Por lo tanto, en el diseño del observador, las variables programadas z_1, z_2, z_3 y z_4 descritas en la Ecs.(3-3), (3-4), (3-5) y (3-6), respectivamente, únicamente la variable

programada z_4 debe de ser reconstruida dado que depende del estado no medible x_6 . Entonces, la estimación de la variable programada \dot{z}_4 tiene que ser utilizada en el observador, y la Ec.(3-35) puede ser satisfecha con $\mu = 1$. De modo que, para el cálculo de las ganancias del O^3 las condiciones dadas en la Ec.(3-36) pueden ser transformadas en LMI mediante el siguiente cambio de variable $M_i^3 = P^3 L_i^3$, $i = 1, 2, \dots, m$, de tal manera que las nuevas condiciones son:

$$\begin{aligned} \mathcal{H}(P^3 A_i - M_i^3 L_i^3) &< -Q^3 \\ \begin{pmatrix} Q^3 - \mu^2 I & P^3 \\ P^3 & I \end{pmatrix} &\geq 0 \end{aligned} \quad (\text{B-3})$$

para $i = 1, 2, \dots, m$. Recordemos que $m = 16$, de acuerdo al modelo T-S obtenido en la Ec.(3-17). Por lo tanto, las ganancias del observador son encontradas resolviendo las LMI mencionadas en la Ec.(3-43) mediante el Toolbox de Yalmip para MatLab 2014b [Lofberg \(2004\)](#). Las ganancias obtenidas son:

$$L_1^3 = \begin{bmatrix} 95,53 & 14,81 & -37,39 & -0,64 & 1,08 \\ 14,83 & 89,13 & 1,84 & 0,86 & -0,20 \\ -37,41 & 1,86 & 70,92 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,36 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 99,95 \\ -0,02 & 0,004 & -0,01 & -0,03 & 43,83 \end{bmatrix} \quad L_2^3 = \begin{bmatrix} 95,53 & 14,85 & -37,43 & -0,65 & 1,08 \\ 14,82 & 91,27 & 1,86 & 0,86 & -0,20 \\ -37,43 & 1,85 & 118,48 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,22 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 100,04 \\ -0,02 & 0,004 & -0,01 & -0,03 & -79,55 \end{bmatrix}$$

$$L_3^3 = \begin{bmatrix} 95,53 & 14,85 & -37,67 & -0,65 & 1,08 \\ 14,85 & 66,04 & 1,85 & 0,86 & -0,20 \\ -37,67 & 1,85 & 70,93 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,27 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 85,14 \\ -0,02 & 0,004 & -0,01 & -0,03 & 47,28 \end{bmatrix} \quad L_4^3 = \begin{bmatrix} 95,55 & 14,85 & -37,66 & -0,65 & 1,08 \\ 14,85 & 105,02 & 1,84 & 0,86 & -0,20 \\ -37,66 & 1,84 & 93,34 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,30 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 100,11 \\ -0,02 & 0,004 & -0,01 & -0,03 & -104,62 \end{bmatrix}$$

$$L_5^3 = \begin{bmatrix} 95,54 & 14,82 & -37,93 & -0,65 & 1,08 \\ 14,82 & 105,63 & 1,84 & 0,86 & -0,20 \\ -37,69 & 1,84 & 93,32 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,35 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 85,33 \\ -0,02 & 0,004 & -0,01 & -0,03 & -104,67 \end{bmatrix} \quad L_6^3 = \begin{bmatrix} 95,53 & 14,82 & -37,94 & -0,65 & 1,08 \\ 14,82 & 105,61 & 1,84 & 0,86 & -0,20 \\ -37,94 & 1,84 & 93,32 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,33 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 85,35 \\ -0,02 & 0,004 & -0,01 & -0,03 & -104,67 \end{bmatrix}$$

B.1. Diseño del observador O^3 correspondiente a al matriz C_i^3

$$L_7^3 = \begin{bmatrix} 95,53 & 14,81 & -37,91 & -0,65 & 1,08 \\ 14,82 & 91,28 & 1,85 & 0,86 & -0,20 \\ -37,89 & 1,85 & 93,32 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,31 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 85,36 \\ -0,02 & 0,004 & -0,01 & -0,03 & -110,24 \end{bmatrix} \quad L_8^3 = \begin{bmatrix} 95,53 & 14,79 & -37,95 & -0,65 & 1,08 \\ 14,80 & 91,28 & 1,86 & 0,86 & -0,20 \\ -37,88 & 1,85 & 93,33 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,33 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 101,02 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,02 \end{bmatrix}$$

$$L_9^3 = \begin{bmatrix} 95,57 & 14,82 & -37,96 & -0,65 & 1,08 \\ 14,81 & 105,61 & 1,86 & 0,86 & -0,20 \\ -37,97 & 1,86 & 93,33 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,35 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 82,56 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,39 \end{bmatrix} \quad L_{10}^3 = \begin{bmatrix} 95,57 & 14,82 & -37,91 & -0,65 & 1,08 \\ 14,82 & 65,14 & 1,85 & 0,86 & -0,20 \\ -37,89 & 1,85 & 93,33 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,35 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,61 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,36 \end{bmatrix}$$

$$L_{11}^3 = \begin{bmatrix} 95,57 & 14,82 & -37,84 & -0,64 & 1,08 \\ 14,82 & 91,27 & 1,85 & 0,86 & -0,20 \\ -37,85 & 1,85 & 93,33 & 2,51 & 0,46 \\ -0,65 & 0,86 & 2,51 & 43,11 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,62 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,36 \end{bmatrix} \quad L_{12}^3 = \begin{bmatrix} 95,56 & 14,82 & -37,56 & -0,64 & 1,08 \\ 14,82 & 106,03 & 1,85 & 0,86 & -0,20 \\ -37,54 & 1,85 & 93,33 & 2,51 & 0,46 \\ -0,64 & 0,86 & 2,51 & 43,34 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,61 \\ -0,02 & 0,004 & -0,01 & -0,03 & 47,09 \end{bmatrix}$$

$$L_{13}^3 = \begin{bmatrix} 95,56 & 14,81 & -37,51 & -0,64 & 1,08 \\ 14,82 & 106,03 & 1,85 & 0,86 & -0,20 \\ -37,50 & 1,85 & 93,33 & 2,51 & 0,46 \\ -0,64 & 0,86 & 2,51 & 43,36 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,62 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,29 \end{bmatrix} \quad L_{14}^3 = \begin{bmatrix} 95,55 & 14,82 & -37,53 & -0,64 & 1,08 \\ 14,82 & 106,03 & 1,85 & 0,86 & -0,20 \\ -37,53 & 1,85 & 93,32 & 2,51 & 0,46 \\ -0,64 & 0,86 & 2,51 & 43,27 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,62 \\ -0,02 & 0,004 & -0,01 & -0,03 & 44,53 \end{bmatrix}$$

$$L_{15}^3 = \begin{bmatrix} 95,55 & 14,82 & -37,47 & -0,64 & 1,08 \\ 14,83 & 91,43 & 1,86 & 0,86 & -0,20 \\ -37,44 & 1,86 & 93,33 & 2,51 & 0,46 \\ -0,64 & 0,86 & 2,51 & 43,24 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,62 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,31 \end{bmatrix} \quad L_{16}^3 = \begin{bmatrix} 95,57 & 14,82 & -37,54 & -0,64 & 1,08 \\ 14,82 & 91,27 & 1,86 & 0,86 & -0,20 \\ -37,46 & 1,86 & 95,36 & 2,51 & 0,46 \\ -0,64 & 0,86 & 2,51 & 43,40 & 1,73 \\ 1,08 & -0,20 & 0,46 & 1,73 & 83,62 \\ -0,02 & 0,004 & -0,01 & -0,03 & 45,07 \end{bmatrix}$$

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

El desempeño del observador O^3 es evaluado en la siguiente simulación:

Simulación B.1 Desempeño del observador O^3 ante la presencia de las fallas f_1 , f_2 y f_3 .

Los objetivos de esta simulación son:

1. El análisis del desempeño del O^3 ante la presencia de fallas.
2. La evaluación de los errores de estimación mediante umbrales.
3. Una estructuración de síntomas afines a fallas en particular.

Con el fin de mostrar el desempeño del observador O^3 ante la adición de las fallas mostradas en la Fig**3-13**, éstas son añadidas al modelo no lineal del proceso de fermentación alcohólica. Las condiciones iniciales para el modelo no lineal y el observador O^3 son las mismas que se dieron en la simulación **3.2.1**, las cuales se reescriben a continuación.

$$\dot{x}(0) = [x_1 \ x_2 \ x_3 \ x_4 \ x_5 \ x_6]^T = [0,904677 \ 12,515241 \ 29,738924 \ 3,106953 \ 29,573212 \ 27,053939]^T \quad (\text{B-4})$$

y para el O^3 son:

$$\hat{x}^1(0) = [\hat{x}_1^3 \ \hat{x}_2^3 \ \hat{x}_3^3 \ \hat{x}_4^3 \ \hat{x}_5^3 \ \hat{x}_6^3]^T = [0,7 \ 10 \ 27 \ 2,8 \ 27 \ 25]^T \quad (\text{B-5})$$

En la Fig**B-1** se muestra la respuesta de ambos modelos ante la presencia de fallas. La línea continua en color azul representa las dinámicas de los estados del proceso no lineal, mientras que la línea punteada en color rojo representa los estados estimados por el O^3 .

B.1. Diseño del observador O^3 correspondiente a la matriz C_i^3

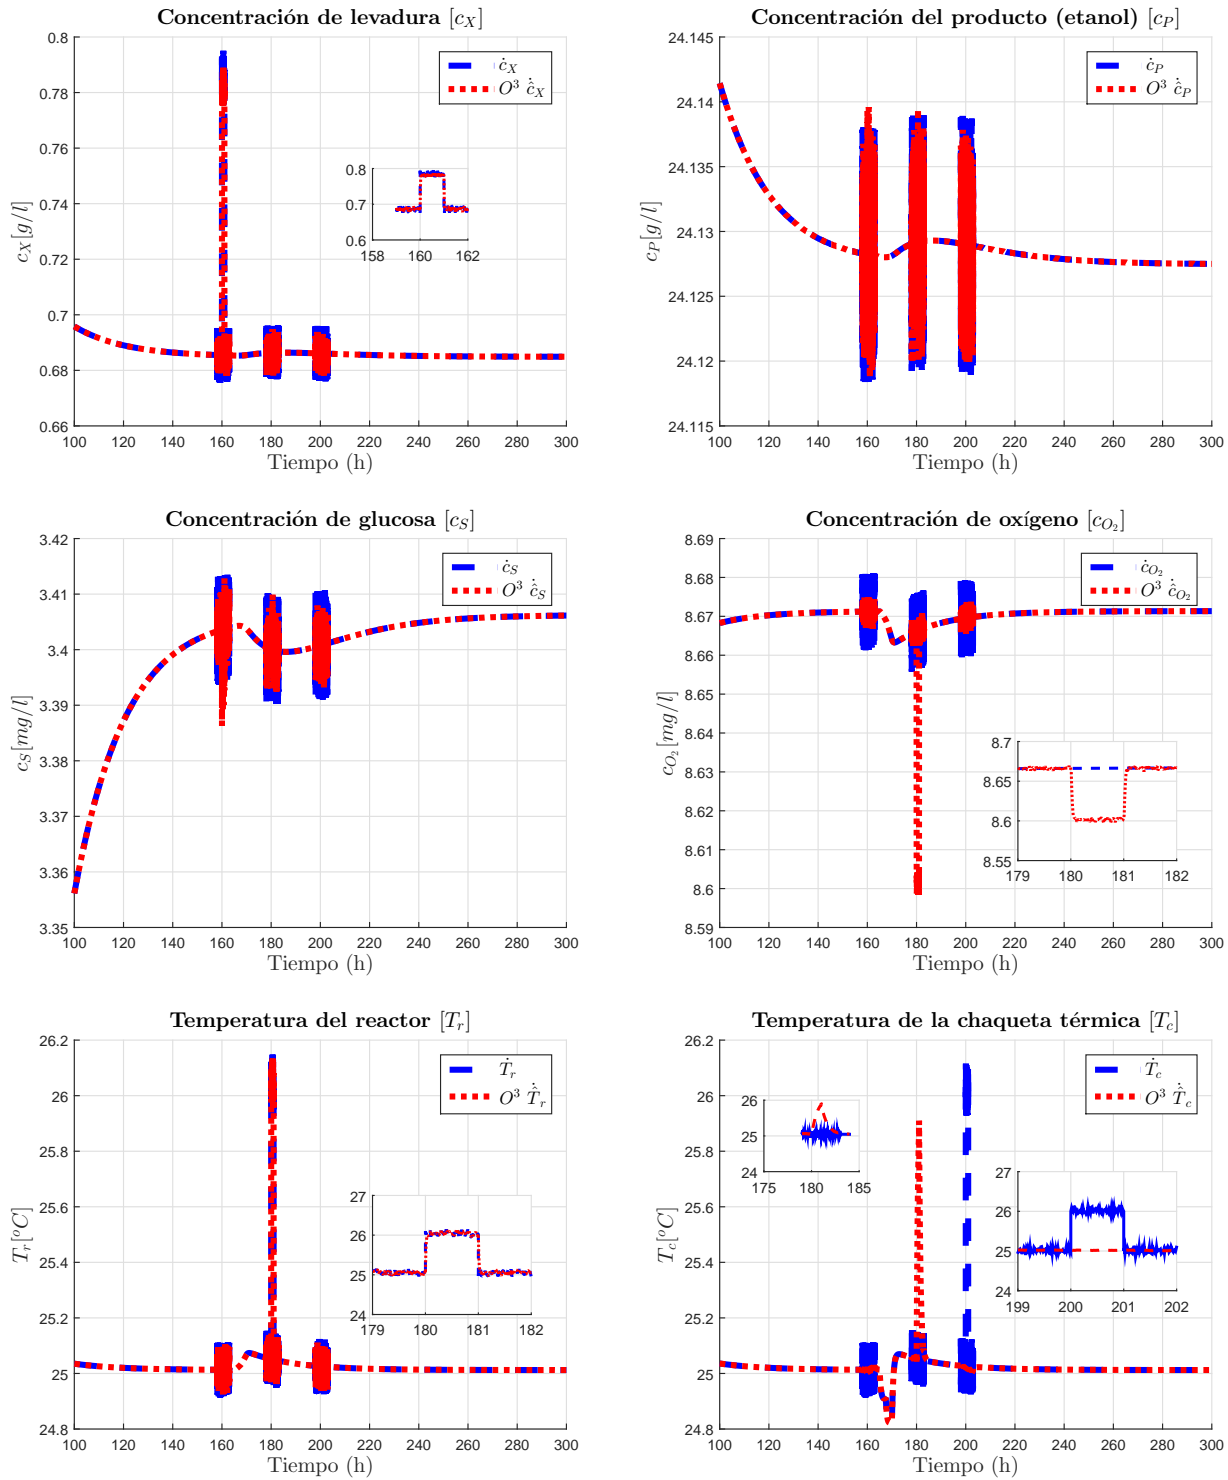


Figura B-1.: Dinámicas del modelo no lineal y del observador O^3 ante la presencia de fallas.

La sensibilidad del O^3 a las fallas se aprecia en el instante que se presenta la falla f_3 . El estado observado \hat{x}_6^3 del O^3 no estima la falla y con ello se genera una diferencia, es decir el O^3 muestra

sensibilidad a f_3 .

Note que, cuando se presenta la falla f_2 en el estado no lineal x_5 el observador la estima de manera adecuada mediante el estado observado \hat{x}_5^3 , pero esa estimación provoca un cambio en la dinámica del estado observado \hat{x}_6^3 como se aprecia en la Fig. **B-1**. Este efecto es derivado del balance de energía del modelo no lineal del proceso de fermentación, del cual se dieron los pormenores en la observación **2.5.1**. Por otro lado, la falla f_1 que incide en el estado no lineal x_1 es estimada de forma correcta por el observador O^3 mediante el estado observado \hat{x}_1^3 .

El error de estimación se calcula mediante la Ec. (3-46), la cual se escribe a continuación:

$$e_\gamma^\tau = x_\gamma - \hat{x}_\gamma^\tau \quad (\text{B-6})$$

Cada error de estimación e_γ^3 es evaluado mediante un umbral, como se muestra en la Fig. **B-2**. La señal de evaluación r_γ^3 , mostrada en dicha figura es el residuo de cada error e_γ^3 , es decir para el error $e_1^3 = x_1 - \hat{x}_1^3 = r_1^3$ se tiene la señal r_1^3 . De manera similar las señales de evaluación r_2^3 , r_3^3 , r_4^3 , r_5^3 y r_6^3 son obtenidas.

B.1. Diseño del observador O^3 correspondiente a la matriz C_i^3

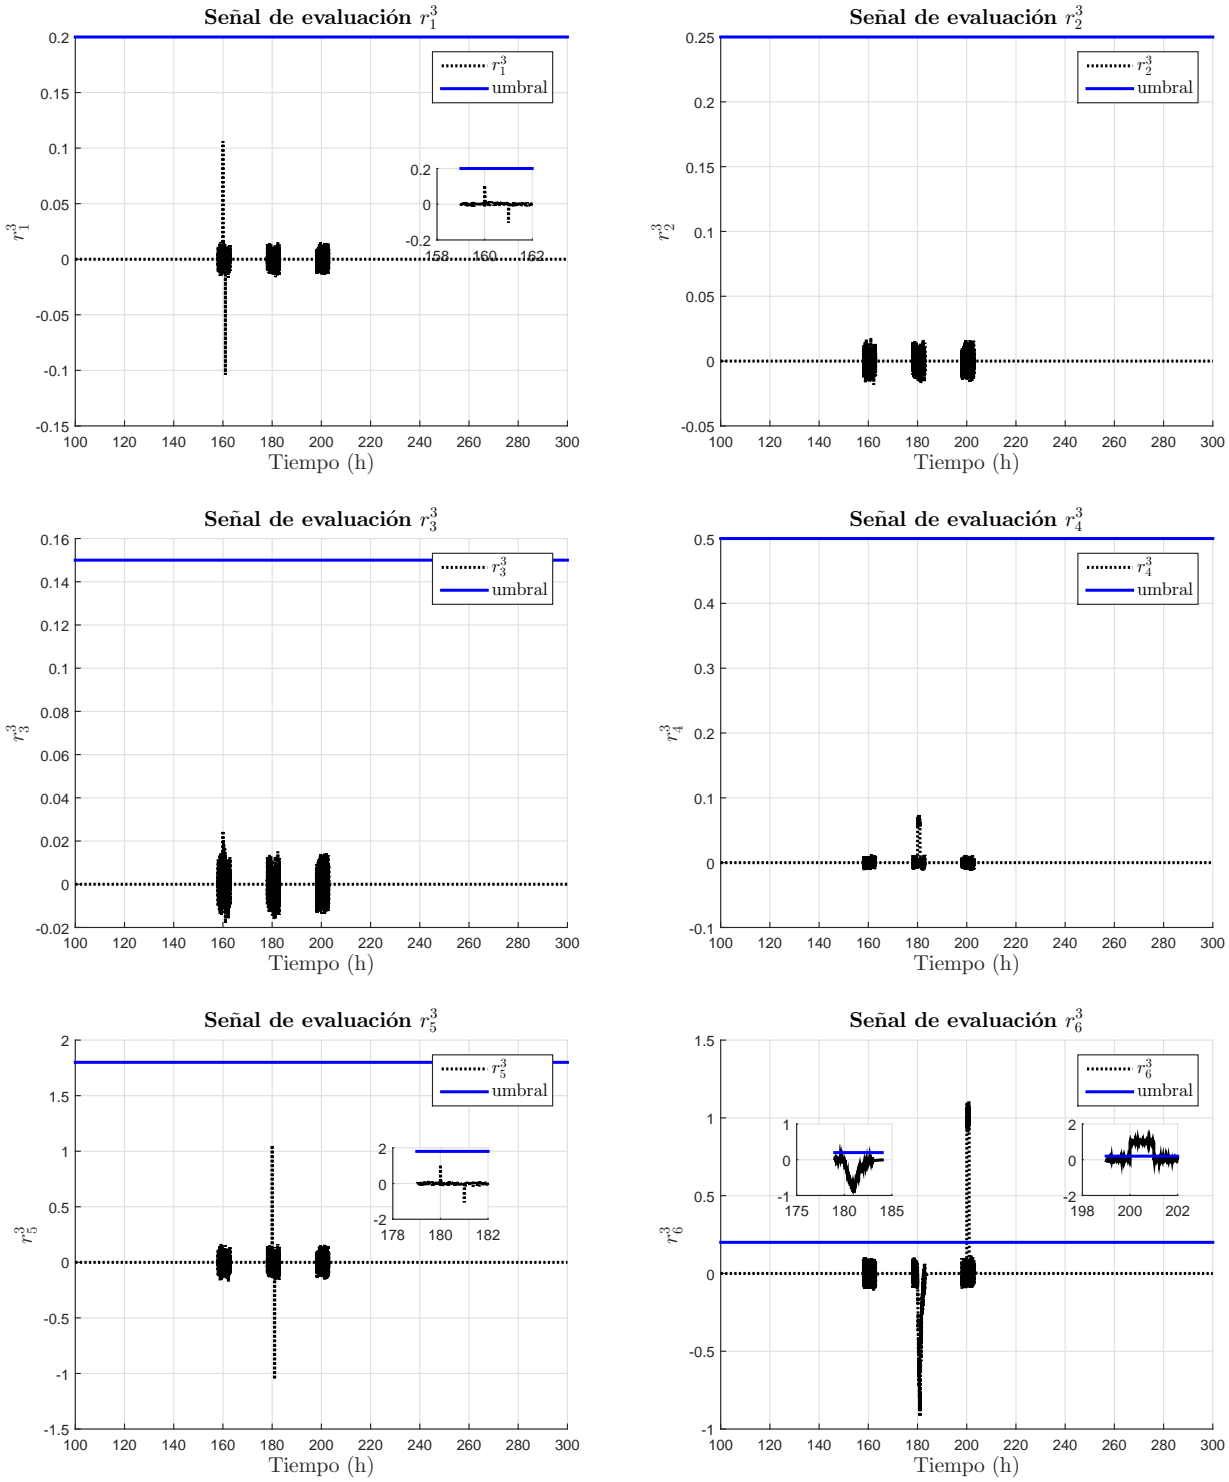


Figura B-2.: Dinámica de los errores de estimación e_γ^3 del O^3 .

El valor del umbral de evaluación es establecido de manera a priori, por el diseñador. Es decir, el diseñador cuenta con los conocimientos necesarios y suficientes obtenidos ya sea de manera analítica o

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

empírica para establecer el valor de un umbral para cada señal de evaluación. Así, cuando un umbral es superado por una señal de evaluación se genera un síntoma en particular. Por ejemplo, cuando se presentan la falla f_3 su umbral es superado por su señal de evaluación y se genera el síntoma s_6^3 , como se muestra en la Fig. B-3.

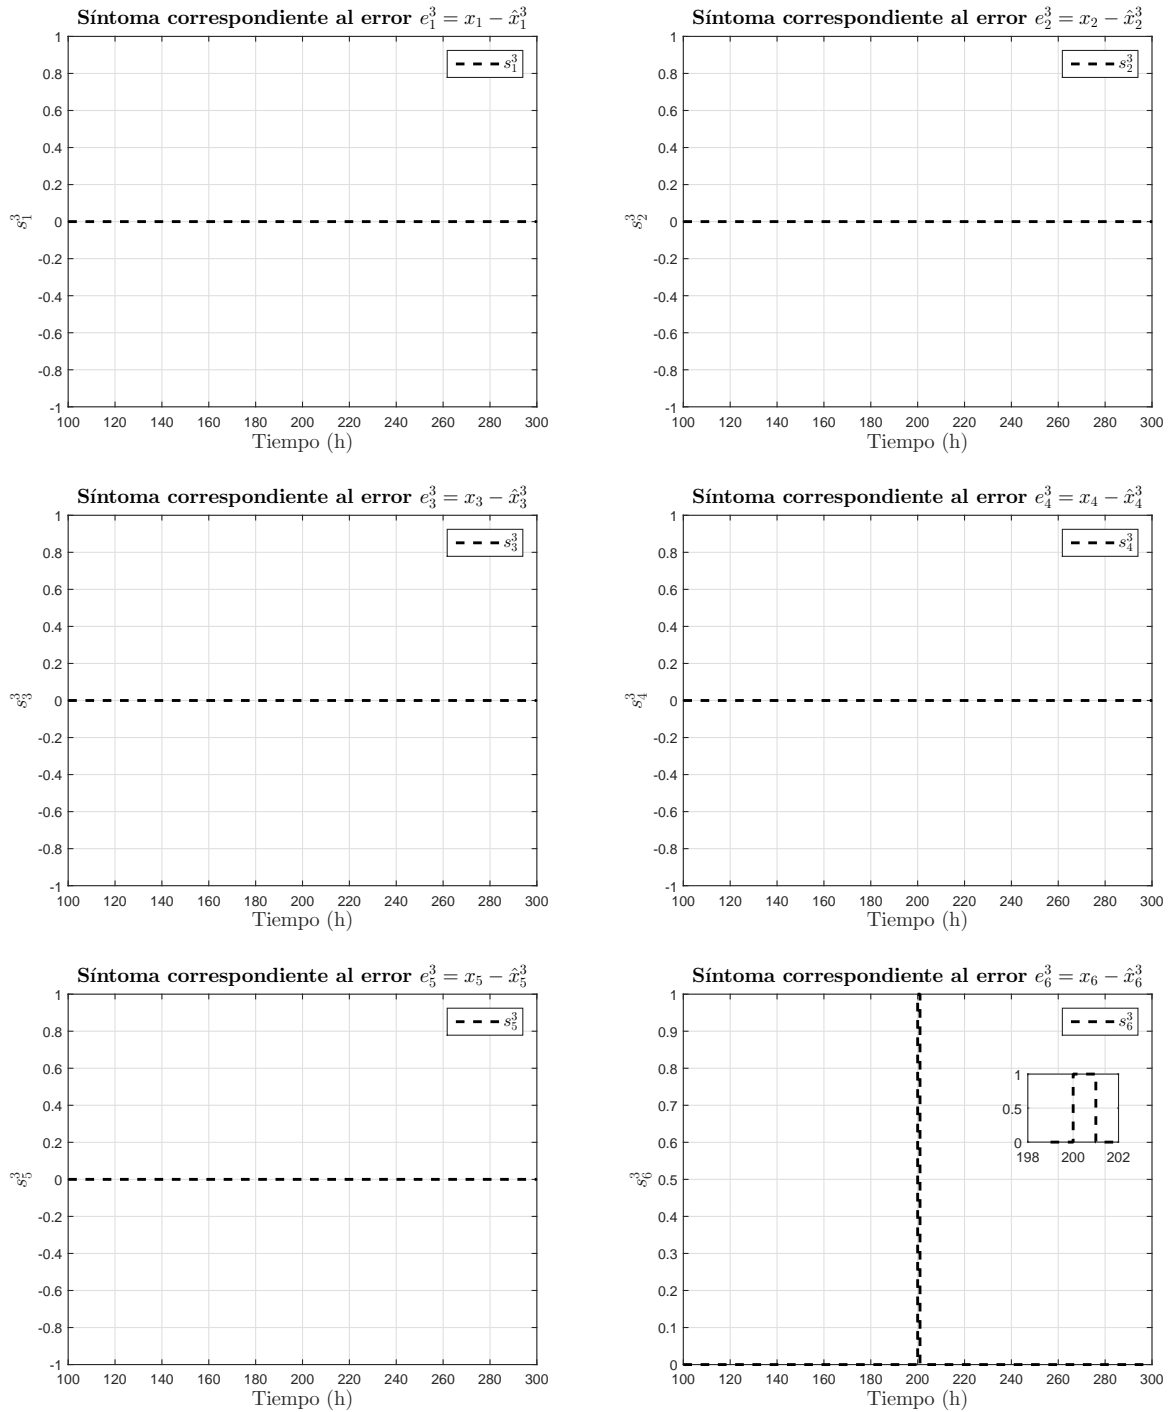


Figura B-3.: Síntomas s_γ^1 generados a partir de la evaluación de los errores de estimación e_γ^1 .

En la Fig.B-3 se muestra la dinámica de los síntomas s_γ^1 obtenidos mediante el análisis de la señal de evaluación o residuo r_γ^3 . La diferencia de un residuo y un síntoma, es que el síntoma mantiene un valor constante durante el tiempo en que el residuo supera el umbral establecido para él, aunque el valor del residuo varíe durante este tiempo. Es por ello que las dinámicas de los s_γ^3 mostrados en la Fig.B-3 mantiene dos valores 0 o 1. Cuando el valor un es 1 indica la presencia de una falla y en caso contrario 0 indica que no existe falla. Por ejemplo, cuando s_6^3 vale 1 indica la presencia de la falla f_3 .

B.2. Diseño del observador O^4 correspondiente a la matriz C_i^4

A diferencia del diseño del observador O^3 , el diseño del observador O^4 parte de la matriz C_i^4 , la cual se reescribe en la Ec.B-8. Esto con el fin de formar el banco de observadores como se muestra en la Fig.3-7. Por lo tanto, a partir de la matriz C_i^4 y del observador presentado en la Ec.(3-30), el modelo matemático que representa al observador O^4 es:

$$\begin{aligned}\dot{\hat{x}}^4 &= \sum_{i=1}^{16} \phi_i(\hat{z})(A_i \hat{x}^4 + B_{vi} F_c + L_i^4 (y - \hat{y}^4)) + B_{nv} F_{in} + E \\ \hat{y}^3 &= C_i^4 \hat{x}^4\end{aligned}\tag{B-7}$$

donde A_i , B_{vi} , B_{nv} , y E son matrices de dimensiones adecuadas que conforman al modelo T-S denotado en la Ec.(3-17), \hat{x}^4 es el vector de estados estimados y \hat{y}^4 las salidas del observador O^4 corresponde a la matriz C_i^4 denotada en la Ec.(3-40) y que se reescribe a continuación:

$$C_i^4 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}\tag{B-8}$$

A partir de la matriz C_i^4 , note que los estados medibles del proceso en el diseño del O^4 son x_1 , x_2 , x_3 , x_4 , x_6 y el no medible es x_5 . Por lo tanto, en el diseño del observador, las variables programadas z_1, z_2 , z_3 y z_4 descritas en la Ecs.(3-3), (3-4), (3-5) y (3-6), respectivamente, únicamente la variable programada z_1 debe de ser reconstruida dado que depende del estado no medible x_5 . Entonces, la estimación de la variable programada \dot{z}_1 tiene que ser utilizada en el observador, y la Ec.(3-35) puede ser satisfecha con $\mu = 1$. De modo que, para el cálculo de las ganancias del O^4 las condiciones dadas en la Ec.(3-36) pueden ser transformadas en LMI, mediante el siguiente cambio de variable $M_i^4 = P^4 L_i^4$, $i = 1, 2, \dots, m$, de tal manera que las nuevas condiciones son:

$$\begin{aligned}\mathcal{H}(P^4 A_i^4 - M_i^4 L_i^4) &< -Q^4 \\ \begin{pmatrix} Q^4 - \mu^2 I & P^4 \\ P^4 & I \end{pmatrix} &\geq 0\end{aligned}\tag{B-9}$$

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

para $i = 1, 2, \dots, m$, siendo $m = 16$. Por lo tanto, el cálculo de las ganancias para el O^4 es mediante la solución las LMI formuladas en la Ec.(3-43) mediante el Toolbox de Yalmip para MatLab 2014b [Lofberg \(2004\)](#). Las ganancias obtenidas son:

$$L_1^4 = \begin{bmatrix} 95,17 & 14,12 & -38,66 & 0,46 & -0,67 \\ 14,12 & 89,83 & -0,42 & 0,23 & 0,08 \\ -38,65 & -0,43 & 91,66 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,23 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 61,21 \\ -0,69 & 0,09 & 0,75 & 0,72 & 87,04 \end{bmatrix} \quad L_2^4 = \begin{bmatrix} 95,17 & 14,12 & -38,65 & 0,46 & -0,67 \\ 14,12 & 85,83 & -0,42 & 0,23 & 0,08 \\ -38,67 & -0,43 & 83,58 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,22 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 60,76 \\ -0,69 & 0,09 & 0,75 & 0,72 & 92,53 \end{bmatrix}$$

$$L_3^4 = \begin{bmatrix} 95,17 & 14,12 & -38,67 & 0,46 & -0,67 \\ 14,12 & 89,83 & -0,42 & 0,23 & 0,08 \\ -38,66 & -0,42 & 89,34 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,23 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 189,05 \\ -0,69 & 0,09 & 0,75 & 0,72 & 90,26 \end{bmatrix} \quad L_4^4 = \begin{bmatrix} 95,82 & 14,13 & -38,67 & 0,46 & -0,67 \\ 14,11 & 89,66 & -0,42 & 0,23 & 0,08 \\ -38,67 & -0,43 & 91,48 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,24 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 69,38 \\ -0,69 & 0,09 & 0,75 & 0,72 & 92,69 \end{bmatrix}$$

$$L_5^4 = \begin{bmatrix} 95,17 & 14,12 & -38,67 & 0,46 & -0,67 \\ 14,12 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,64 & -0,43 & 91,48 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,20 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 190,54 \\ -0,69 & 0,09 & 0,75 & 0,72 & 96,04 \end{bmatrix} \quad L_6^4 = \begin{bmatrix} 95,82 & 14,11 & -38,67 & 0,46 & -0,67 \\ 14,11 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,67 & -0,43 & 91,48 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,20 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 66,88 \\ -0,69 & 0,09 & 0,75 & 0,72 & 93,00 \end{bmatrix}$$

$$L_7^4 = \begin{bmatrix} 95,82 & 14,09 & -38,67 & 0,46 & -0,67 \\ 14,09 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,67 & -0,43 & 91,48 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,18 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 54,73 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,67 \end{bmatrix} \quad L_8^4 = \begin{bmatrix} 95,82 & 14,10 & -38,67 & 0,46 & -0,67 \\ 14,09 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,66 & -0,43 & 91,48 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,20 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 56,76 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,62 \end{bmatrix}$$

$$L_9^4 = \begin{bmatrix} 95,20 & 14,07 & -38,67 & 0,46 & -0,67 \\ 14,07 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,67 & -0,43 & 89,32 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,14 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 56,44 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,65 \end{bmatrix} \quad L_{10}^4 = \begin{bmatrix} 95,20 & 14,07 & -38,67 & 0,46 & -0,67 \\ 14,07 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,67 & -0,43 & 89,31 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,21 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 52,69 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,53 \end{bmatrix}$$

$$L_{11}^4 = \begin{bmatrix} 95,20 & 14,06 & -38,65 & 0,46 & -0,67 \\ 14,06 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,66 & -0,43 & 91,48 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,18 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 52,56 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,55 \end{bmatrix} \quad L_{12}^4 = \begin{bmatrix} 95,82 & 14,06 & -38,64 & 0,46 & -0,67 \\ 14,06 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,65 & -0,43 & 89,29 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,22 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 61,60 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,63 \end{bmatrix}$$

$$L_{13}^4 = \begin{bmatrix} 95,20 & 14,07 & -38,65 & 0,46 & -0,67 \\ 14,07 & 89,66 & -0,43 & 0,23 & 0,08 \\ -38,64 & -0,43 & 89,29 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,21 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 66,10 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,77 \end{bmatrix} \quad L_{14}^4 = \begin{bmatrix} 95,20 & 14,08 & -38,65 & 0,46 & -0,67 \\ 14,06 & 89,83 & -0,43 & 0,23 & 0,08 \\ -38,65 & -0,43 & 89,29 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,20 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 64,10 \\ -0,69 & 0,09 & 0,75 & 0,72 & 86,72 \end{bmatrix}$$

$$L_{15}^4 = \begin{bmatrix} 95,82 & 14,09 & -38,64 & 0,46 & -0,67 \\ 14,09 & 89,83 & -0,43 & 0,23 & 0,08 \\ -38,65 & -0,43 & 89,29 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,17 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 166,95 \\ -0,69 & 0,09 & 0,75 & 0,72 & 89,61 \end{bmatrix} \quad L_{16}^4 = \begin{bmatrix} 95,82 & 14,09 & -38,66 & 0,46 & -0,67 \\ 14,09 & 89,83 & -0,43 & 0,23 & 0,08 \\ -38,65 & -0,43 & 89,29 & -0,21 & 0,73 \\ 0,46 & 0,23 & -0,21 & 48,19 & 0,70 \\ -0,69 & 0,08 & 0,74 & 0,71 & 166,82 \\ -0,69 & 0,09 & 0,75 & 0,72 & 89,61 \end{bmatrix}$$

A partir de las ganancias obtenidas para O^4 . La siguiente simulación muestra el desempeño del observador O^4 ante una señal de control $F_c = 18l/h$ y la presencia de las fallas f_1 , f_2 , y f_3 , cuya dinámica se muestra en la Fig.3-13. Dichas fallas son las mismas que se utilizaron en la Simulación B.1, donde la falla f_1 se presenta en el sensor de la concentración de la levadura x_1 ; la falla f_2 corresponde al sensor x_5 que mide la temperatura del reactor; y la falla f_3 se presenta en el sensor x_6 que mide la temperatura de la chaqueta térmica.

Simulación B.2 Desempeño del observador O^4 ante la presencia de fallas f_1 , f_2 y f_3 .

Los objetivos de esta simulación son:

1. El análisis del desempeño del O^4 ante la presencia de fallas.
2. La evaluación de los errores de estimación mediante umbrales.
3. Una estructuración de síntomas afines a fallas en particular.

Con el fin de mostrar el desempeño del O^4 ante la adición de las fallas mostradas en la Fig.3-13, éstas son añadidas al modelo no lineal del proceso de fermentación alcohólica. Las condiciones iniciales para el modelo no lineal y el observador son las mismas que se dieron para la simulación 3.2.1.

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

En la Fig. B-4 se muestra la respuesta del modelo no lineal en líneas continuas en color azul y la dinámica del observador en líneas punteadas de color rojo.

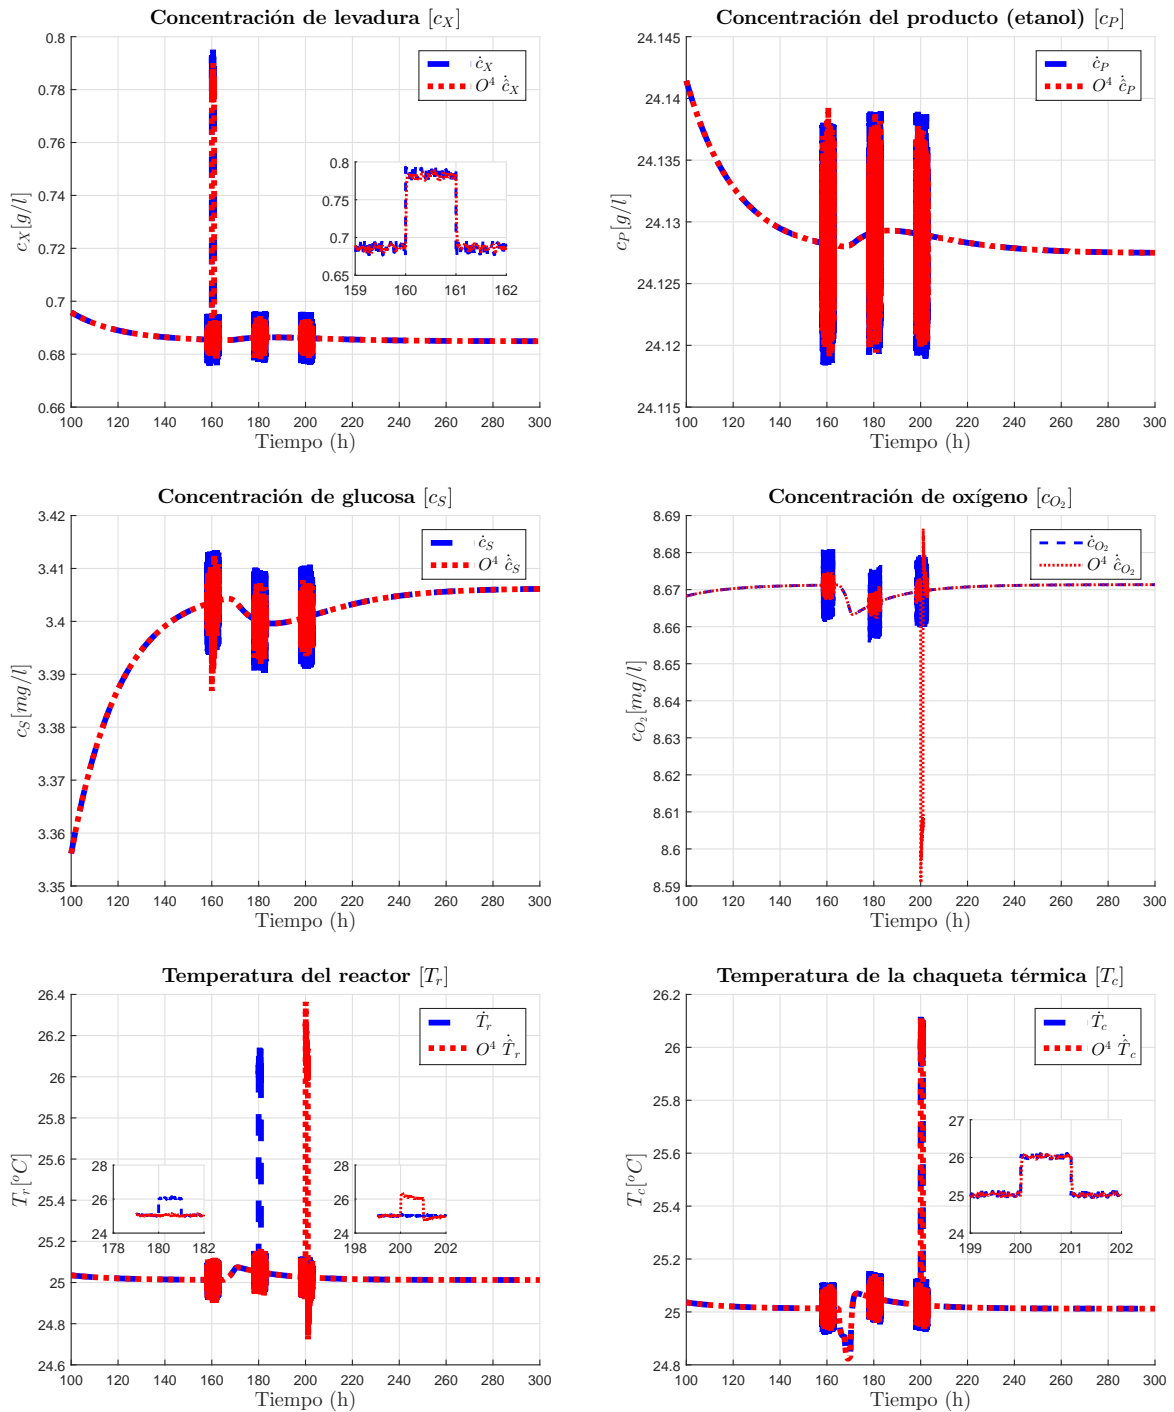


Figura B-4.: Dinámicas del modelo no lineal y del observador O^4 ante la presencia de fallas.

La sensibilidad del O^4 a las fallas se aprecia en el instante que se presenta la falla f_2 . El estado obser-

vado \hat{x}_5^4 no estima la falla y con ello se genera una diferencia, entre el estado no lineal x_5 y el estado estimado x_5^4 .

Cuando se manifiesta la falla f_1 en el estado no lineal x_1 el observador O^4 la estima de manera correcta mediante el estado estimado \hat{x}_1^4 . Sin embargo, cuando se manifiesta la falla f_3 sobre el estado no lineal x_6 el observador estima de manera correcta la falla, mediante el estado observado \hat{x}_6^4 . Pero dicha estimación, repercute en el estado estimado \hat{x}_5^4 creando un cambio en su dinámica con respecto al estado no lineal x_5 del modelo no lineal. Este cambio es derivado del estrecho acoplamiento del balance de energía que presenta el modelo no lineal del proceso de fermentación alcohólica como se mencionó en la Observación 2.5.1.

Por otra parte, como se mencionó en la simulación 3.2.1, el error de estimación se calcula mediante la Ec.3-46. Por lo tanto, se obtendrán valores positivos y negativos. Por ejemplo, en el error e_5^4 , que corresponde a la diferencia entre el estado no lineal x_5 y el estado estimado \hat{x}_5^4 se genera una primer diferencia positiva en el instante que se presenta la falla f_2 y con ello se puede generar una señal de evaluación o residuo; sin embargo, cuando se presenta la falla f_3 la diferencia es negativa y se evita una falsa alarma. Es importante evitar las falsas alarmas, puesto que pueden generar falsos síntomas y con ello falsas localizaciones de fallas. Otro punto es que si la falsa alarma pertenece a una falla que al ocurrir se dé la orden del paro en el desarrollo del proceso de fermentación alcohólica causará la pérdida del producto.

La evaluación de los errores e_γ^4 se realiza mediante umbrales como se muestra en la Fig.B-5. La señal de evaluación r_γ^4 , mostrada en dicha figura es el residuo de cada error e_γ^4 , es decir para el error $e_1^4 = x_1 - \hat{x}_1^4 = r_1^4$ se tiene la señal r_1^4 . De manera similar las señales de evaluación r_2^4 , r_3^4 , r_4^4 , r_5^4 y r_6^4 son obtenidas.

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

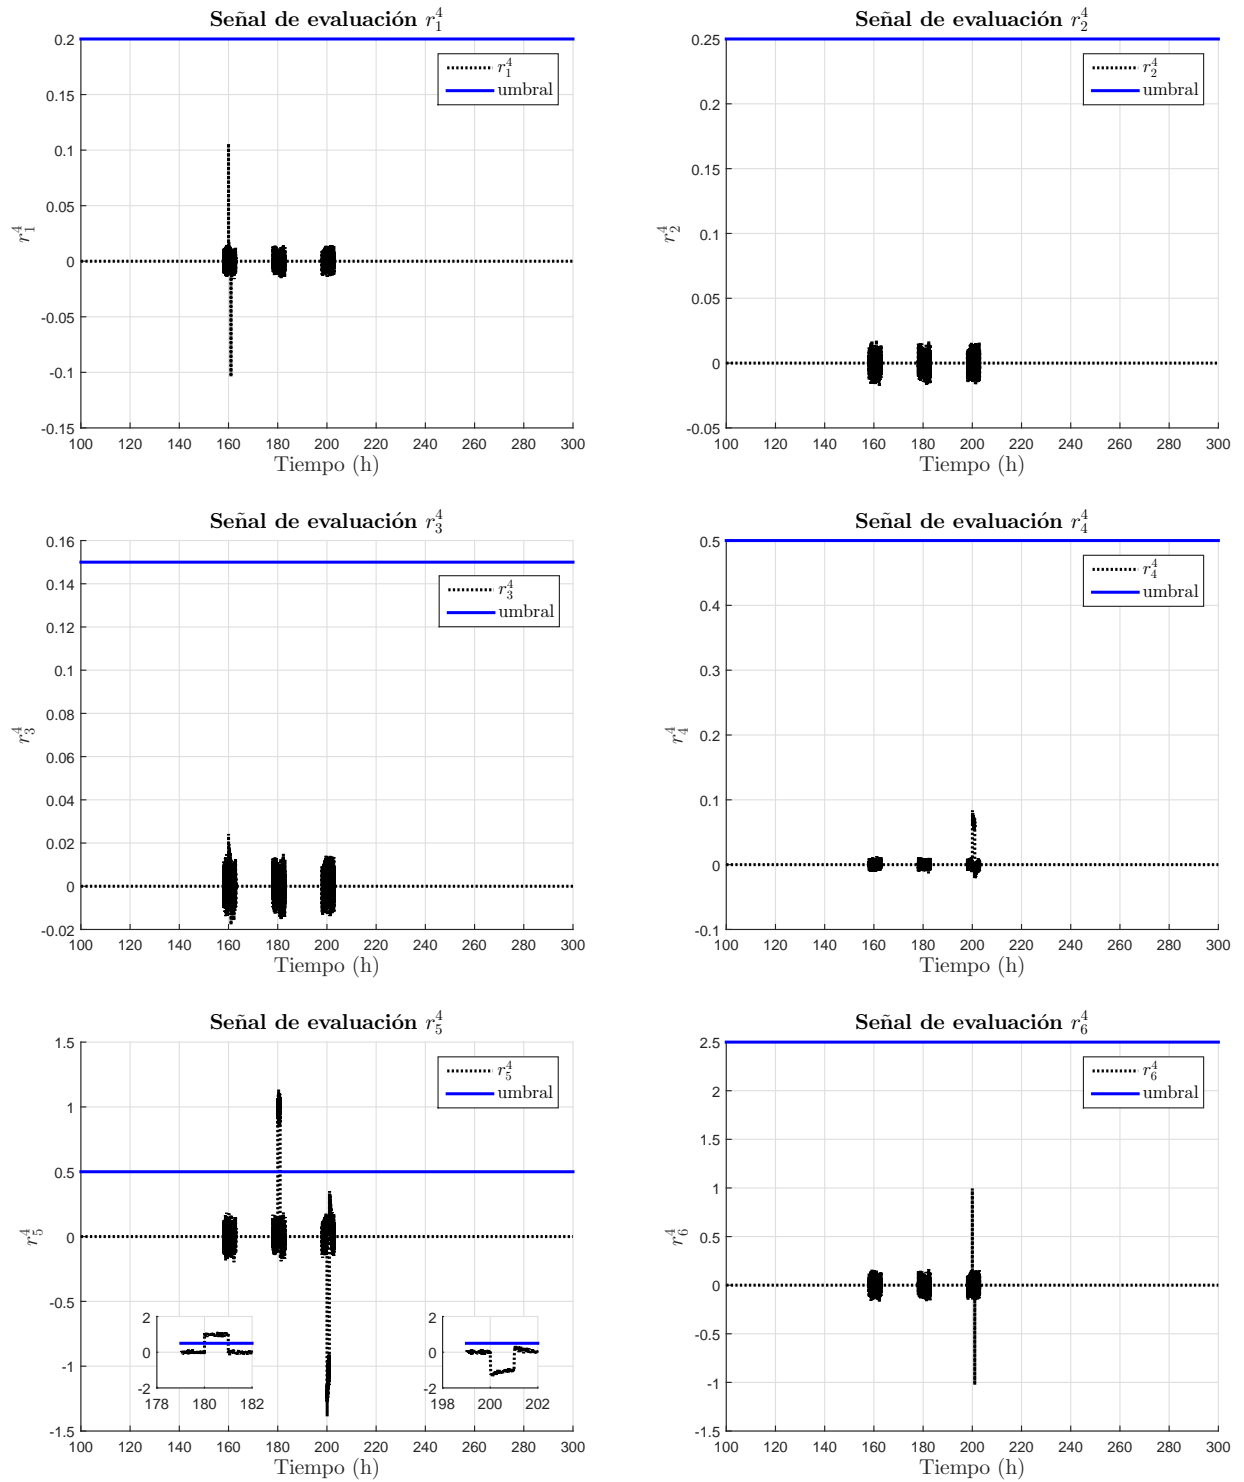


Figura B-5.: Dinámica de los errores de estimación e_γ^4 del O^4 .

El valor del umbral de evaluación es establecido de manera a priori, por el diseñador. Recordemos que si el diseñador cuenta con los conocimientos necesarios y suficientes puede establecer el valor de un um-

B.2. Diseño del observador O^4 correspondiente a la matriz C_i^4

bral para cada señal de evaluación. Así, cuando un umbral es superado por una señal de evaluación se genera un síntoma en particular. Por ejemplo, cuando se presenta la falla f_2 su umbral de la falla es superado por su respectiva señal de evaluación y se genera el síntoma s_5^4 , como se muestra en la Fig.3-19.

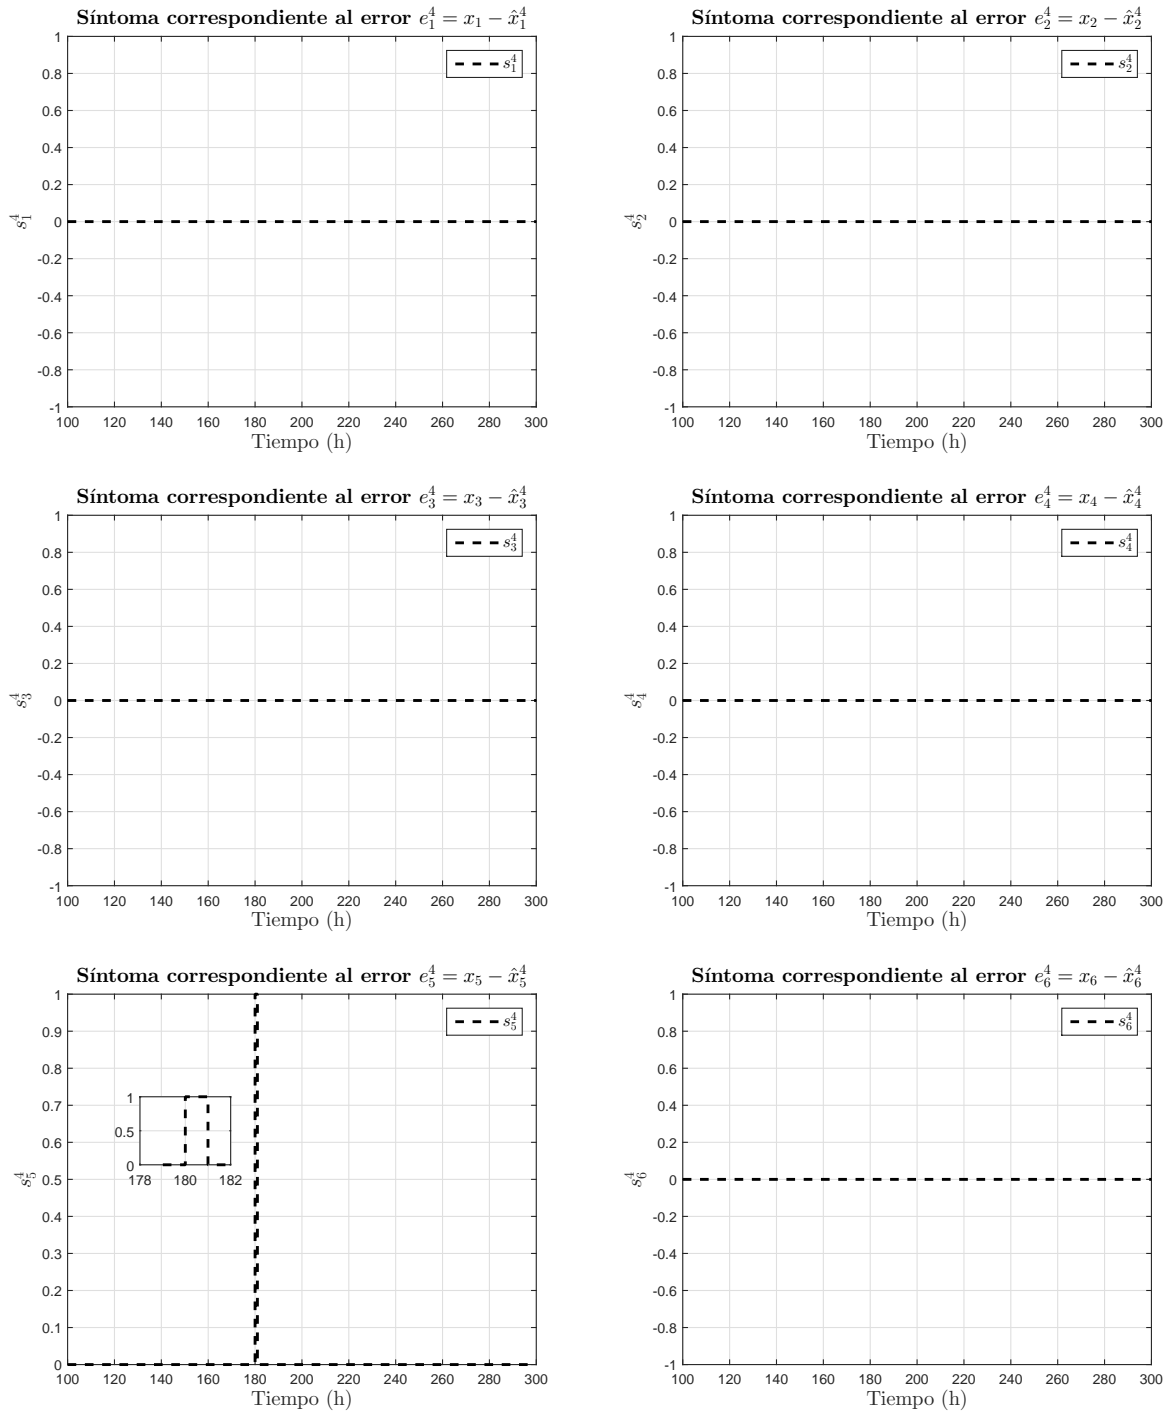


Figura B-6.: Síntomas S_{Υ}^4 generados a partir de la evaluación de los errores de estimación e_{γ}^4 .

En la Fig. B-6 se muestra la dinámica del síntoma s_{γ}^4 obtenido mediante el análisis de la señal de evaluación o residuo r_{γ}^4 . Las dinámicas de los s_{γ}^4 muestran que solo se mantienen dos valores 0 o 1, y cuando el valor es 1 indica la presencia de una falla, en caso contrario el valor 0 indica que no existe falla. Por ejemplo, cuando s_2^2 vale 1 indica la presencia de la falla f_2 .

B.3. Diseño del observador O^5

A diferencia del diseño de los observador O^3 y O^4 , el diseño del observador O^5 parte de la matriz C_i^5 , la cual se reescribe en la Ec. B-11. Esto con el fin de formar el banco de observadores como se muestra en la Fig. 3-7. Por lo tanto, a partir de la matriz C_i^5 y del observador presentado en la Ec. (3-30), el modelo matemático que representa al observador O^5 es:

$$\begin{aligned}\dot{\hat{x}}^5 &= \sum_{i=1}^{16} \phi_i(\hat{z})(A_i \hat{x}^5 + B_{vi} F_c + L_i^5 (y - \hat{y}^5)) + B_{nv} F_{in} + E \\ \hat{y}^5 &= C_i^5 \hat{x}^5\end{aligned}\tag{B-10}$$

donde A_i , B_{vi} , B_{nv} , y E son matrices de dimensiones adecuadas que conforman al modelo T-S denotado en la Ec. (3-17), \hat{x}^5 es el vector de estados estimados y \hat{y}^5 las salidas del observador O^5 corresponde a la matriz C_i^5 denotada en la Ec. (3-40), la cual se reescribe a continuación:

$$C_i^5 = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}\tag{B-11}$$

A partir de la matriz C_i^5 , note que los estados medibles del proceso en el diseño del O^5 son x_2 , x_3 , x_4 , x_5 y x_6 y el no medible es x_1 . Por lo tanto, el diseño del observador, las variables programadas z_1, z_2, z_3 y z_4 descritas en la Ecs. (3-3), (3-4), (3-5) y (3-6), respectivamente, no se debe de reconstruir ninguna variable programada, dado que ninguna depende del estado no medible x_1 . Entonces, en el diseño del observador O^5 la Ec. (3-35) puede ser satisfecha con $\mu = 1$. De modo que, para el cálculo de las ganancias del O^5 las condiciones dadas en la Ec. (3-36) pueden ser transformadas en LMI, mediante el siguiente cambio de variable $M_i^5 = P^5 L_i^5$, $i = 1, 2, \dots, m$, de tal manera que las nuevas condiciones son:

$$\begin{aligned}\mathcal{H}(P^5 A_i^5 - M_i^5 L_i^5) &< -Q^5 \\ \begin{pmatrix} Q^5 - \mu^5 I & P^5 \\ P^5 & I \end{pmatrix} &\geq 0\end{aligned}\tag{B-12}$$

para $i = 1, 2, \dots, m$, siendo $m = 16$. Por lo tanto, las ganancias para el O^5 son encontradas resolviendo las LMI formuladas en la Ec. (3-43) mediante el Toolbox de Yalmip para MatLab 2014b Lofberg (2004). Las ganancias obtenidas son:

$$L_1^5 = \begin{bmatrix} 38,22 & -107,41 & 1,16 & 2,30 & 0,42 \\ 95,69 & -20,70 & -1,55 & 1,52 & -2,81 \\ -21,21 & 161,52 & -3,66 & -4,64 & -2,04 \\ -1,74 & -2,78 & 52,89 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 76,10 & 9,23 \\ -2,85 & -1,7 & 1,39 & 9,17 & 27,29 \end{bmatrix} \quad L_2^5 = \begin{bmatrix} 40,08 & -92,78 & 1,15 & 2,30 & 0,42 \\ 104,54 & -18,46 & -1,55 & 1,52 & -2,81 \\ -22,05 & 129,24 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,79 & 52,82 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 99,84 & -19,75 \\ -2,85 & -1,70 & 1,39 & 9,78 & 109,92 \end{bmatrix}$$

$$L_3^5 = \begin{bmatrix} 44,76 & -112,06 & 1,16 & 2,30 & 0,42 \\ 127,14 & -21,40 & -1,55 & 1,52 & -2,81 \\ -24,10 & 171,86 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 52,92 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 86,71 & 9,71 \\ -2,85 & -1,70 & 1,39 & 9,70 & 110,97 \end{bmatrix} \quad L_4^5 = \begin{bmatrix} 45,02 & -119,69 & 1,16 & 2,30 & 0,42 \\ 128,36 & -22,59 & -1,55 & 1,52 & -2,81 \\ -24,23 & 188,71 & -3,66 & -4,64 & -2,04 \\ -1,75 & -2,77 & 52,88 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 99,82 & -5,09 \\ -2,85 & -1,70 & 1,39 & -19,77 & 110,91 \end{bmatrix}$$

$$L_5^5 = \begin{bmatrix} 40,09 & -93,14 & 1,16 & 2,30 & 0,42 \\ 104,55 & -18,54 & -1,55 & 1,52 & -2,81 \\ -22,09 & 129,81 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,79 & 53,00 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 98,88 & 9,67 \\ -2,85 & -1,70 & 1,39 & 9,68 & 25,57 \end{bmatrix} \quad L_6^5 = \begin{bmatrix} 39,93 & -93,11 & 1,16 & 2,30 & 0,42 \\ 104,50 & -18,53 & -1,55 & 1,52 & -2,81 \\ -22,02 & 129,80 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,79 & 53,09 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 98,88 & -19,76 \\ -2,85 & -1,70 & 1,39 & -19,72 & 108,41 \end{bmatrix}$$

$$L_7^5 = \begin{bmatrix} 40,10 & -93,13 & 1,16 & 2,30 & 0,42 \\ 104,53 & -18,53 & -1,55 & 1,52 & -2,81 \\ -22,09 & 129,80 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,79 & 52,99 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,32 & -19,77 \\ -2,85 & -1,70 & 1,39 & -19,71 & 108,56 \end{bmatrix} \quad L_8^5 = \begin{bmatrix} 40,07 & -93,09 & 1,16 & 2,30 & 0,42 \\ 104,52 & -18,47 & -1,55 & 1,52 & -2,81 \\ -22,05 & 129,76 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,79 & 53,02 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,39 & -19,77 \\ -2,85 & -1,70 & 1,39 & -19,68 & 108,62 \end{bmatrix}$$

$$L_9^5 = \begin{bmatrix} 40,06 & -93,09 & 1,16 & 2,30 & 0,42 \\ 104,52 & -18,48 & -1,55 & 1,52 & -2,81 \\ -22,01 & 129,77 & -3,66 & -4,64 & -2,04 \\ -1,75 & -2,79 & 53,05 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,39 & 9,71 \\ -2,85 & -1,70 & 1,39 & -5,09 & 109,75 \end{bmatrix} \quad L_{10}^5 = \begin{bmatrix} 40,07 & -115,53 & 1,16 & 2,30 & 0,42 \\ 104,53 & -21,92 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,33 & -3,66 & -4,64 & -2,04 \\ -1,75 & -2,77 & 52,98 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,39 & 9,71 \\ -2,85 & -1,70 & 1,39 & 9,68 & 110,73 \end{bmatrix}$$

$$L_{11}^5 = \begin{bmatrix} 40,06 & -115,52 & 1,16 & 2,30 & 0,42 \\ 104,52 & -21,92 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,32 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 53,04 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,39 & -5,95 \\ -2,85 & -1,70 & 1,39 & -5,95 & 110,73 \end{bmatrix} \quad L_{12}^5 = \begin{bmatrix} 40,06 & -115,52 & 1,16 & 2,30 & 0,42 \\ 104,52 & -21,91 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,33 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 53,01 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,32 & 9,71 \\ -2,85 & -1,70 & 1,39 & 9,71 & 110,73 \end{bmatrix}$$

$$L_{13}^5 = \begin{bmatrix} 40,07 & -115,51 & 1,16 & 2,30 & 0,42 \\ 104,53 & -21,91 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,31 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 53,00 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 76,07 & 10,13 \\ -2,85 & -1,70 & 1,39 & 9,70 & 110,73 \end{bmatrix} \quad L_{14}^5 = \begin{bmatrix} 40,07 & -115,38 & 1,16 & 2,30 & 0,42 \\ 104,52 & -21,89 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,26 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 53,10 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,32 & 10,13 \\ -2,85 & -1,70 & 1,39 & 10,13 & 110,73 \end{bmatrix}$$

$$L_{15}^5 = \begin{bmatrix} 40,08 & -115,46 & 1,16 & 2,30 & 0,42 \\ 104,53 & -21,90 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,29 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 53,12 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,32 & 9,90 \\ -2,85 & -1,70 & 1,39 & 9,90 & 110,84 \end{bmatrix} \quad L_{16}^5 = \begin{bmatrix} 40,08 & -115,44 & 1,16 & 2,30 & 0,42 \\ 104,53 & -21,90 & -1,55 & 1,52 & -2,81 \\ -22,03 & 179,28 & -3,65 & -4,64 & -2,04 \\ -1,75 & -2,77 & 53,10 & 2,46 & 1,39 \\ 1,16 & -3,34 & 2,46 & 97,32 & 9,70 \\ -2,85 & -1,70 & 1,39 & 9,70 & 110,73 \end{bmatrix}$$

A partir de las ganancias obtenidas para O^5 , la siguiente simulación muestra el desempeño del observador ante la adición de fallas en el proceso no lineal y con una señal de control $F_c = 18l/h$.

Simulación 5.3 Desempeño del observador O^5 ante la presencia de las fallas f_1 , f_2 y f_3 .

Los objetivos de esta simulación son:

1. El análisis del desempeño del O^5 ante la presencia de fallas.
2. La evaluación de los errores de estimación mediante umbrales.
3. Una estructuración de síntomas afines a fallas en particular.

Con el fin de mostrar el desempeño del O^5 ante la adición de las fallas mostradas en la Fig. 3-13, éstas son añadidas al modelo no lineal del proceso de fermentación alcohólica. Las condiciones iniciales para el modelo no lineal y el observador son las mismas que se dieron para la simulación 3.2.1. En la Fig. B-7 se muestra la respuesta tanto del proceso como del O^5 ante la presencia de fallas. De la cual, las líneas continuas en color azul representan la dinámica del modelo no lineal y las líneas punteadas de color rojo la dinámica del observador.

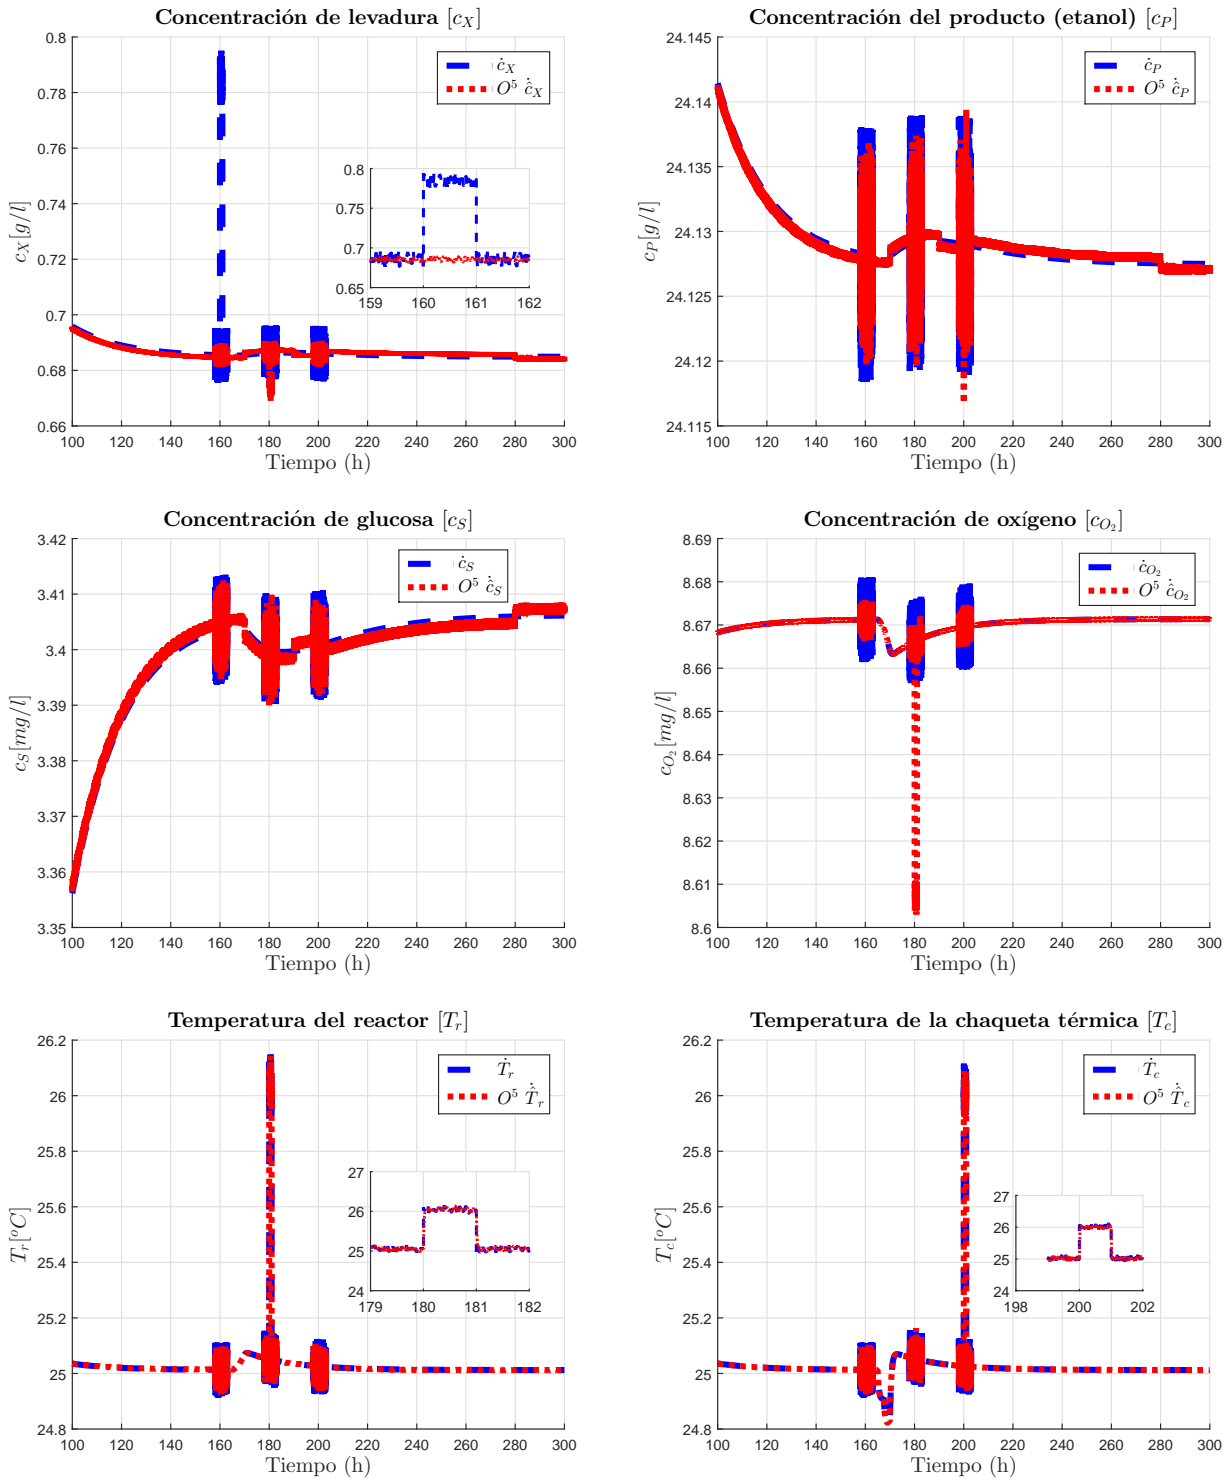


Figura B-7.: Dinámicas del modelo no lineal y del observador O^5 ante la presencia de fallas.

La sensibilidad del O^5 a las fallas se aprecia en el instante que se presenta la falla f_1 . El estado observado \hat{x}_1^5 no estima la falla y con ello se genera una diferencia, entre el estado no lineal x_1 y el estado

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

observado O_1^5 .

El observador O^5 no es sensible a las fallas f_2 y f_3 , dado que tiene acceso a los estados no lineales x_5 y x_6 donde repercuten respectivamente dichas fallas, las cuales son estimadas de manera correcta como se aprecia en la Fig. **B-7**.

La evaluación de los errores e_γ^5 se realiza mediante umbrales como se muestra en la Fig. **B-8**. La señal de evaluación r_γ^5 , mostrada en dicha figura es el residuo de cada error e_γ^5 , es decir para el error $e_1^5 = x_1 - \hat{x}_1^5 = r_1^5$ se tiene la señal r_1^5 . De manera similar las señales de evaluación r_2^5 , r_3^5 , r_4^5 , r_5^5 y r_6^5 son obtenidas.

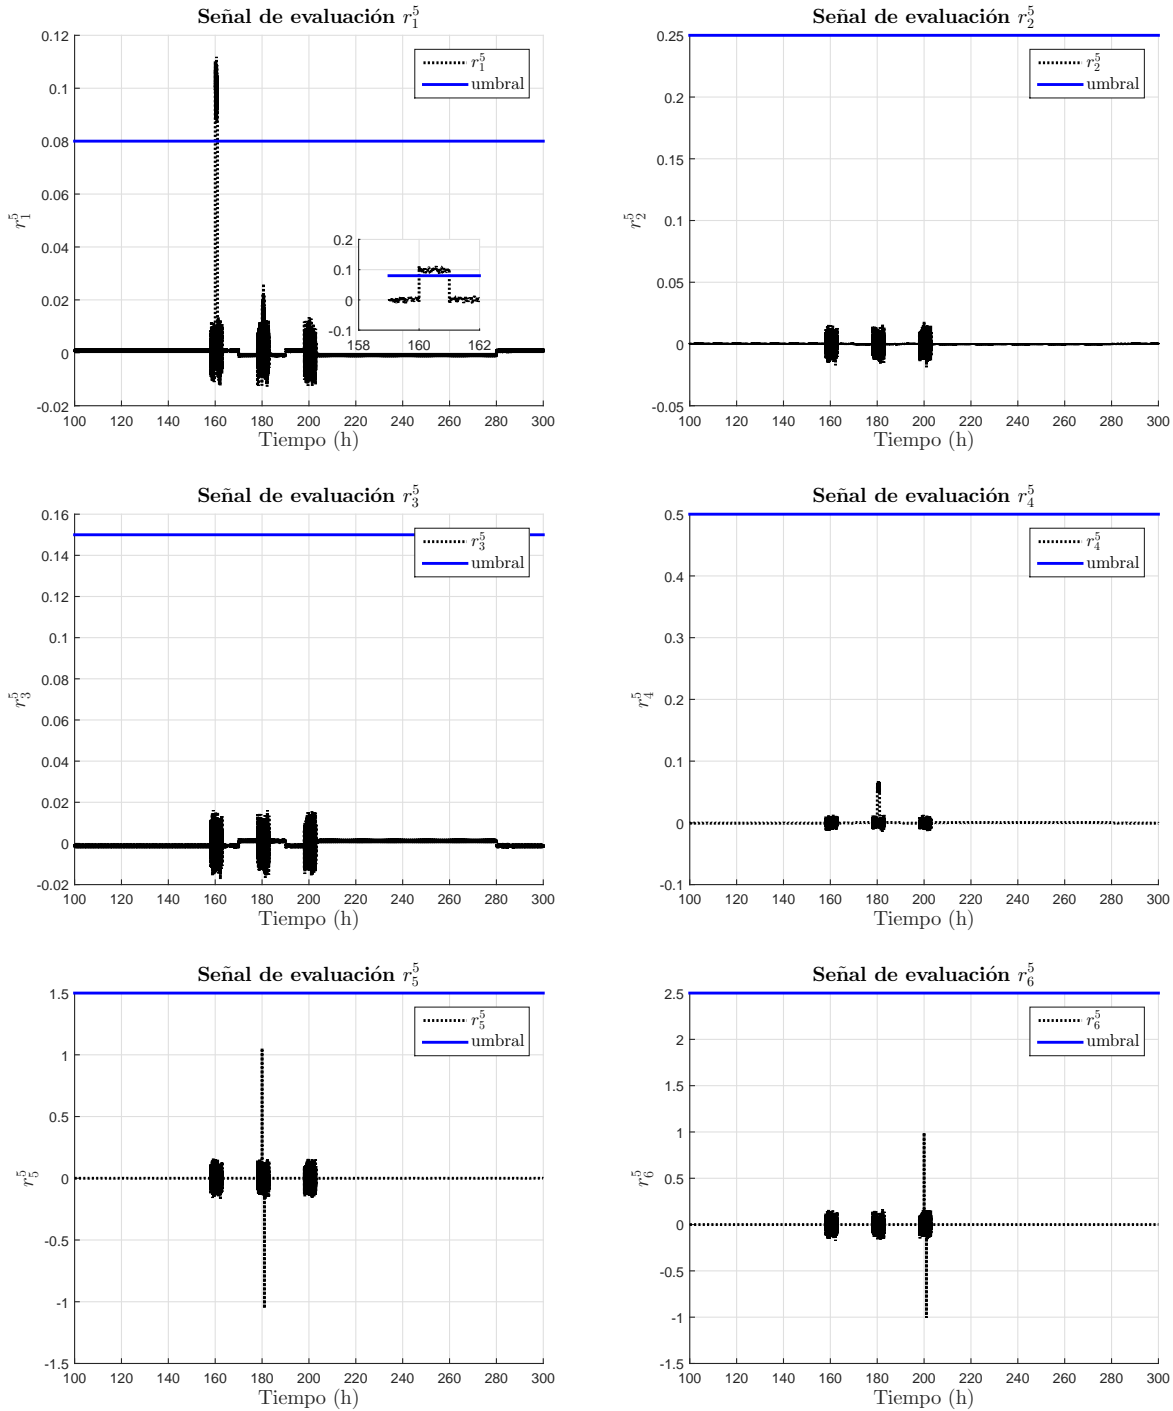


Figura B-8.: Dinámica de las señales de evaluación r_γ^5 del O^5 .

El valor del umbral de evaluación es establecido de manera a priori, por el diseñador. Recordemos que si el diseñador cuenta con los conocimientos necesarios y suficientes puede establecer el valor de un umbral para cada señal de evaluación. Así, cuando un umbral es superado por una señal de evaluación se genera un síntoma en particular. Por ejemplo, cuando se presentan la falla f_1 su umbral es superado

B. Anexo B: Diseño de los observadores O^3 , O^4 y O^5

por su respectiva señal de evaluación y se genera el síntoma s_1^2 , como se muestra en la Fig. B-9.

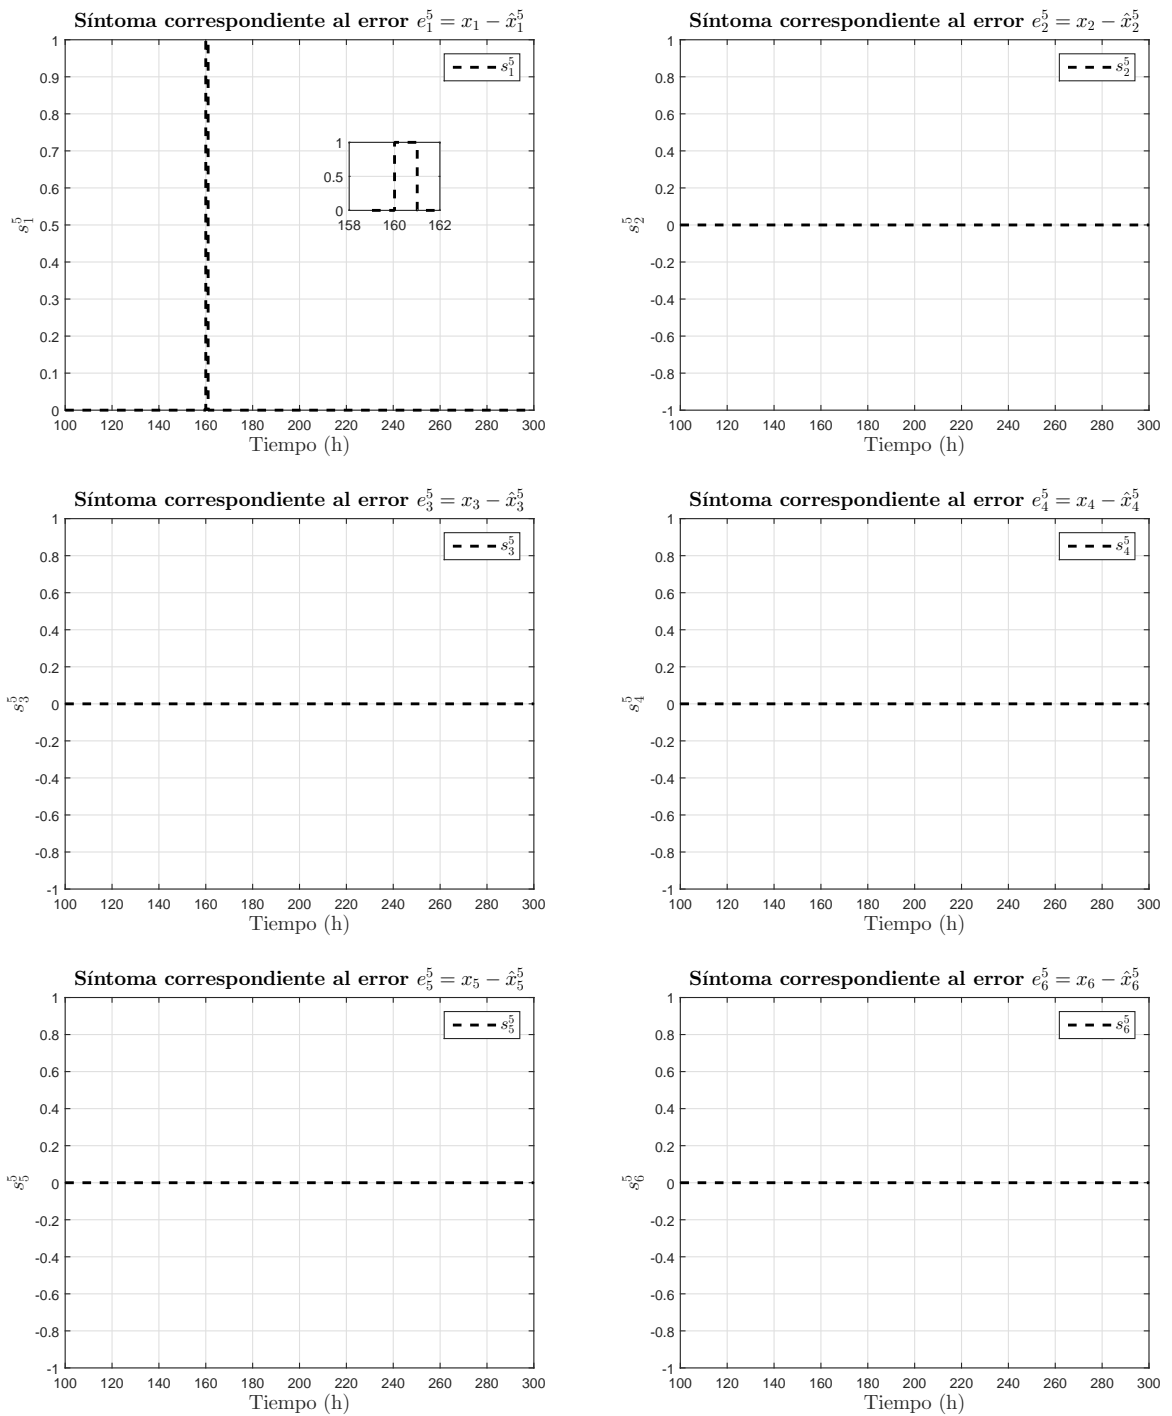


Figura B-9.: Síntomas s_γ^5 generados a partir de la evaluación de los errores de estimación e_γ^5 .

En la Fig. 3-19 se muestra la dinámica de los síntomas s_γ^5 obtenidos mediante el análisis de la señal de evaluación o residuo r_γ^5 . Las dinámicas de los s_γ^5 muestran que solo se mantienen dos valores 0 o

1, y cuando el valor un es 1 indica la presencia de una falla, en caso contrario el valor 0 indica que no existe falla. Por ejemplo, cuando s_1^5 vale 1 indica la presencia de la falla f_1 .

Anexo C: Algunas propiedades de las matrices.

La traza de A es la suma de los elementos de la diagonal principal de A y que se denota como $tr\Delta$, siendo

$$tr\{A\} = \sum_{i=1}^n \alpha_{ii} \quad (\text{C-1})$$

Sea $A, B \in \mathbb{R}^{m \times n}$ y $\alpha \in \mathbb{R}$ las propiedades formales de la transpuesta de una matriz son:

1. $tr\{\alpha A\} = \alpha tr\{A\}$
2. $tr\{A + B\} = tr\{A\} + tr\{B\}$
3. $tr\{AB\} = tr\{BA\}$

Si $A = \alpha_{ij} \in \mathbb{R}^m$ entonces la transpuesta de A escrita como A^T , es la matriz $A^T = \gamma_{ij}$, donde $\gamma_{ij} = \alpha_{ij}$ para todas las i y j .

La transpuesta de A es la matriz que se obtiene intercambiando los renglones de A con las columnas de A . Las propiedades formales básicas de la transpuesta son:

1. $(A^T)^T = A$
2. $(A + B)^T = A^T + B^T$
3. $(AB)^T = B^T A^T$

por lo que si $a \in \mathbb{R}^m$, $b \in \mathbb{R}^m$, $M \in \mathbb{R}^{m \times q}$, $N \in \mathbb{R}^{q \times m}$, entonces

$$a^T M N b = tr\{M N b a^T\} = tr\{N b a^T M\} = tr\{b a^T M N\} \quad (\text{C-2})$$

Normas y cotas superiores de productos vectoriales y matrices

La norma de $\|x\|$, sea x un vector, es una función de valor real con las siguientes propiedades:

C. Anexo C: Algunas propiedades de las matrices.

1. $\|x\| \geq 0 \forall x \in \mathbb{R}^n$, con $\|x\| = 0 \Leftrightarrow x = 0$.
2. $\|x + y\| \leq \|x\| + \|y\|, \forall x, y \in \mathbb{R}^n$.
3. $\|\alpha x\| = |\alpha| \|x\|, \forall \alpha \in \mathbb{R} \text{ y } x \in \mathbb{R}^n$.

Las tres normas usadas comúnmente son $\|x\|_1, \|x\|_\infty$ y $\|x\|_2$ o norma euclidiana, las cuales se definen como:

$$\|x\|_p = (|x_1|^p + \cdots + |x_n|^p)^{\frac{1}{p}}, \quad 1 \leq p \leq \infty \quad (\text{C-3})$$

$$\|x\|_\infty = \max_i |x_i| \quad (\text{C-4})$$

$$\|x\|_2 = \|x\| = (x_1^2 + \cdots + x_n^2)^{\frac{1}{2}} = (x^T x)^{\frac{1}{2}} \quad (\text{C-5})$$

Para todo $x \in \mathbb{R}^n, y \in \mathbb{R}^n$. Las normas matriciales más comunes son:

$$\|A\|_1 = \max_j \sum_{i=1}^m |a_{ij}|, \quad \|A\|_2 = [\lambda_{\max}(A^T A)]^{\frac{1}{2}}, \quad \|A\|_\infty = \max_i \sum_{j=1}^m |a_{ij}|$$

Con las propiedades anteriores se pueden definir los siguientes axiomas, para lo cual considere que $a, b \in \mathbb{R}^n$:

$$a^T b \leq \frac{1}{2} a^T a + \frac{1}{2} b^T b = \frac{1}{2} \|a\|^2 + \frac{1}{2} \|b\|^2 \quad (\text{C-6})$$

$$a^T b \leq \|a\| \cdot \|b\| \quad (\text{C-7})$$

$$x^T y \leq \|x\|_2 \cdot \|y\|_1 \quad (\text{C-8})$$

$$\|x\|_1 \geq \|x\|_2 \quad (\text{C-9})$$

Sea $sign(a)$ la función signo de a , siendo $sign(a) := [sign(a_1), sign(a_2), \dots, sign(a_n)]^T$ de modo que es fácil definir el siguiente axioma:

$$\|a\|_1 = \sum_{i=1}^n |a_i| = \sum_{i=1}^n a_i \cdot sign(a_i) \quad (\text{C-10})$$

o bien,

$$\|a\|_1 = a^T \cdot sign(a) \quad (\text{C-11})$$

Anexo D: Sistema neurolocalizador ante la presencia de fallas x_2 , x_3 y x_4

En este anexo el sistema neurolocalizador de fallas es analizado cuando se presentan fallas en los sensores correspondientes a los estados no lineales x_2 , x_3 y x_4 del modelo no lineal del proceso de fermentación alcohólica.

Simulación D.1 x_2 , x_3 y x_4

La dinámica de las fallas es mostrada en la Fig. **D-1**. La falla f_{x_2} corresponde al sensor del estado no lineal x_2 que es la concentración del producto (etanol), la falla f_{x_3} corresponde al sensor del estado no lineal x_3 que es la concentración de la glucosa en el mosto y la falla f_{x_4} corresponde al sensor del estado no lineal x_4 que es la concentración de oxígeno en la reacción. La primera falla en presentarse es la falla f_{x_2} en la hora 185, en forma de escalón con una magnitud de 0,1 g/l y que se mantiene hasta la hora 187,5 en donde se presenta un nuevo cambio en escalón de la misma magnitud llevando el valor de la falla a 0,2 g/l, valor que se mantiene hasta la hora 190 instante en que un escalón negativo de magnitud $-0,2$ g/l regresa a cero el valor de la falla f_{x_2} . La segunda falla en presentarse es la falla f_{x_3} en la hora 210, en forma de escalón con una magnitud de 0,1 g/l y que se mantiene hasta la hora 112,5 en donde se presenta un nuevo cambio en escalón de la misma magnitud llevando el valor de la falla a 0,2 g/l, valor que se mantiene hasta la hora 215 instante en que un escalón negativo de magnitud $-0,2$ g/l regresa a cero el valor de la falla f_{x_2} . La falla f_{x_4} es la tercera en presentarse a la hora 227,5, en forma de escalón con una magnitud de 0,1 g/l y que se mantiene hasta la hora 230 en donde se presenta un nuevo cambio en escalón de la misma magnitud llevando el valor de la falla a 0,2 g/l, valor que se mantiene hasta la hora 232,5 instante en que un escalón negativo de magnitud $-0,2$ g/l regresa a cero el valor de la falla f_{x_4} .

Por último, las tres fallas se presentan en el mismo instante y con idéntica dinámica, empezando en

D. Anexo D: Sistema neurolocalizador ante la presencia de fallas x_2 , x_3 y x_4

el hora 247,5, en forma de escalón con una magnitud de 0,1 g/l y que se mantienen hasta la hora 250 en donde se presenta un nuevo cambio en escalón de la misma magnitud llevando las a un valor de 0,2 g/l a cada una, valor que mantienen hasta la hora 252,5 instante en que un escalón negativo en cada falla de magnitud $-0,2 g/l$ regresando a cero el valor de cada falla. Aunado a cada falla, también se presenta una señal de ruido que afecta a todos los sensores del proceso no lineal de fermentación alcohólica.

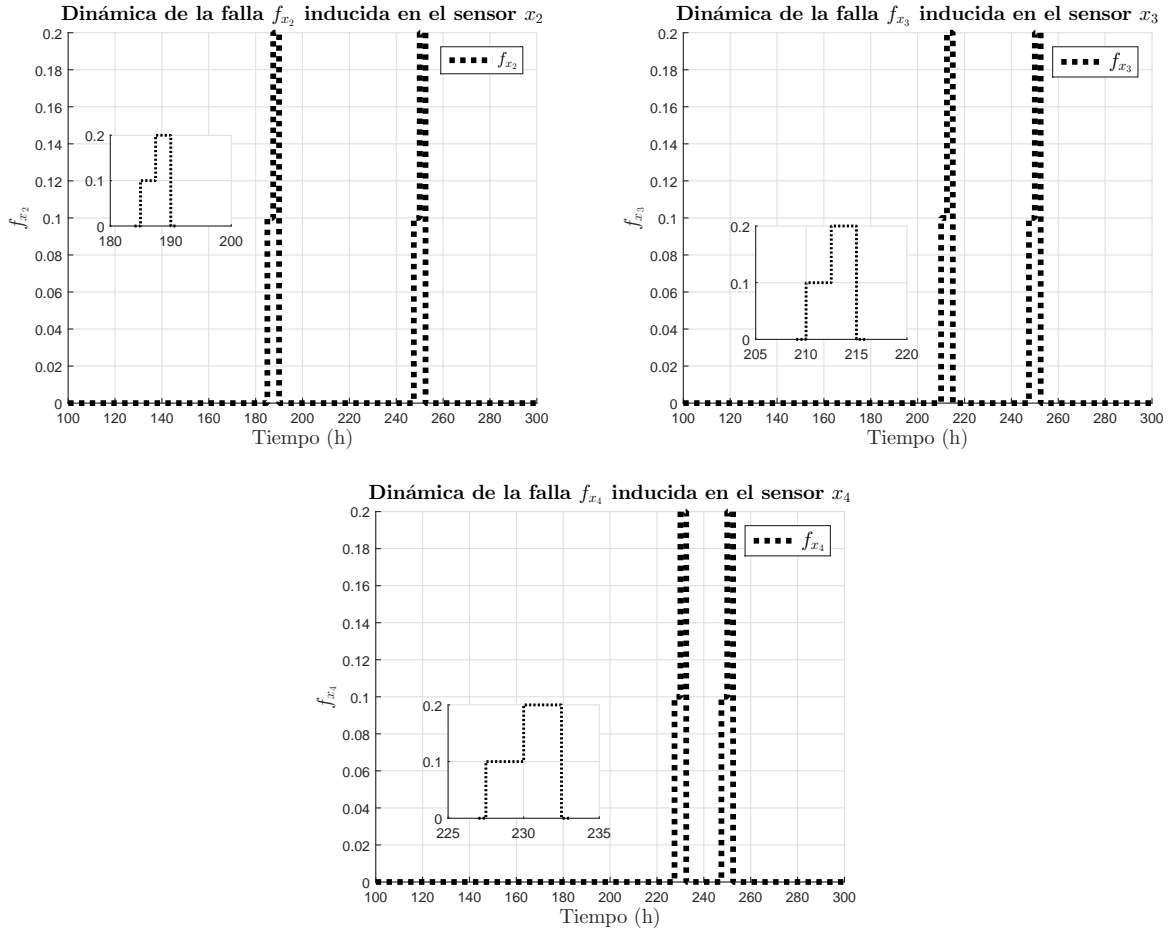


Figura D-1.: Dinámicas de las fallas f_{x_2} , f_{x_3} y f_{x_4} .

La consecuencia de inducir las fallas f_{x_2} , f_{x_3} y f_{x_4} al modelo no lineal del proceso de fermentación alcohólica se muestra en la Fig.D-2, en la cual también se realiza la comparativa de la dinámica del modelo no lineal con la dinámica del observador O^1 . El estado observado que más se ve afectado con las fallas f_{x_2} , f_{x_3} y f_{x_4} es estado no lineal \hat{x}_1^1 , principalmente con las fallas f_{x_2} y f_{x_3} , que son las influyen directamente en los estados no lineales x_2 y x_3 , respectivamente. Este suceso se debe a la dependencia entre estos tres estados (x_1 , x_2 y x_3) como se ha mencionado en el balance de masas del proceso de fermentación alcohólica. En cambio los estados no lineales x_2 , x_3 y x_4 son reconstruidos de manera correcta, aunque en sus respectivos sensores son en donde inciden las fallas f_{x_2} , f_{x_3} y f_{x_4} , respectivamente, por los estados estimados \hat{x}_2^1 , \hat{x}_3^1 y \hat{x}_4^1 . Esto es debido a que en el diseño de cada observador se tenía acceso a la medición de dichos estados no lineales. Por último, los estados

observados \hat{x}_5^1 y \hat{x}_6^1 son reconstruidos de manera correcta por el observador O^1 , de hecho estos estados les afecta en mayor medida los ruidos que se han presentado en sus respectivos sensores.

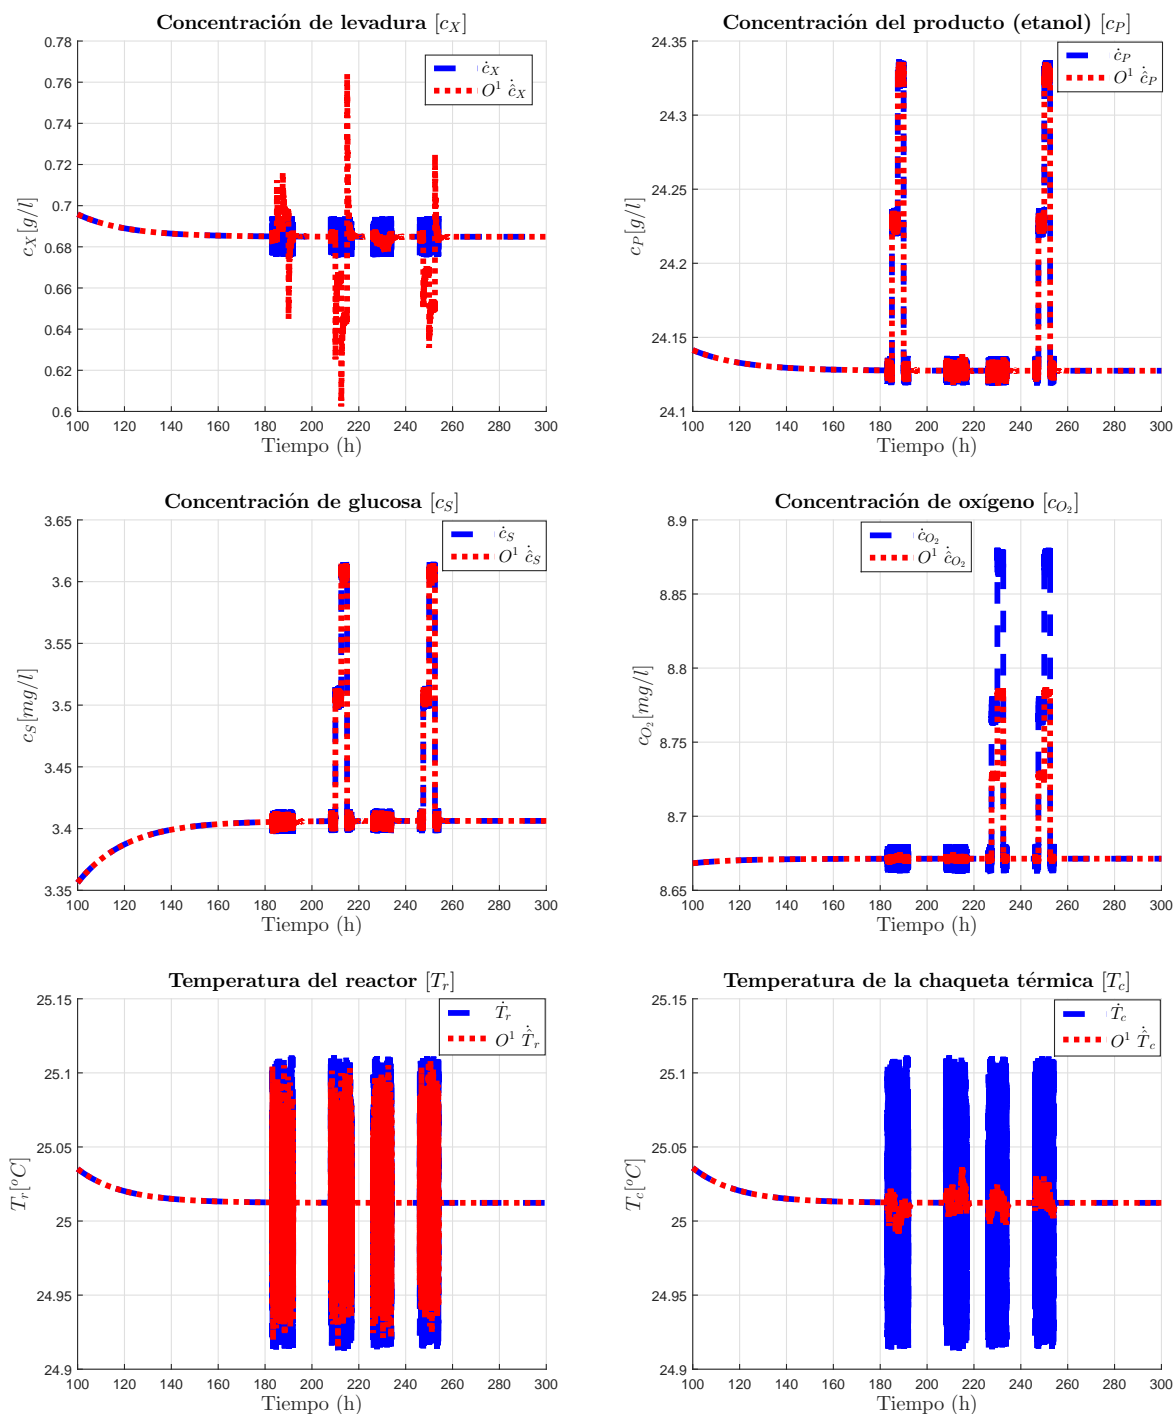


Figura D-2.: Dinámicas del modelo no lineal y del observador O^1 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} .

En la Fig.D-3 se muestran las señales de evaluación que se generaron mediante la estimación del modelo no lineal del proceso de fermentación alcohólica a través del observador O^1 , con sus respectivos umbrales de evaluación. La señal que logra rebasar su respectivo umbral es la que se genera de la diferencia del $x_1 - \hat{x}_1^1$. Lo anterior es provocado por la falla f_{x_3} que afecta la dinámica del estado no lineal x_3 que es la concentración de la glucosa.

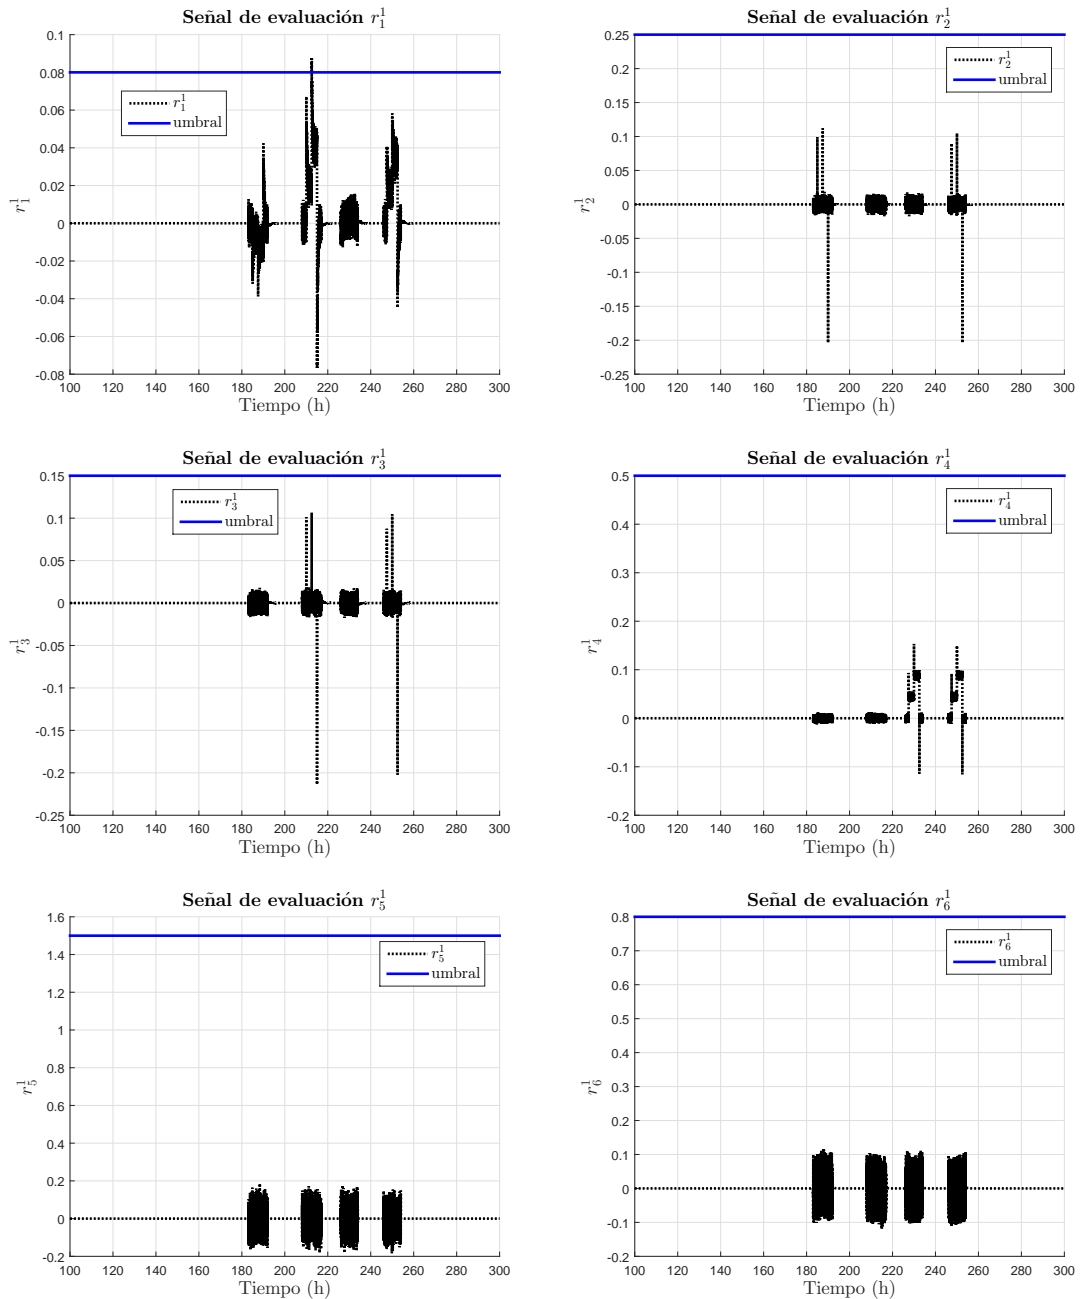


Figura D-3.: Dinámica de las señales de evaluación r_γ^1 del O^1 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} .

En la Fig. D-3 se observó que la señal de evaluación r_1^1 logro superar su umbral de evaluación, con lo cual se genera su respectivo síntoma como se muestra en la Fig. D-4, aunque el síntoma que se genera es de una duración muy pequeña.

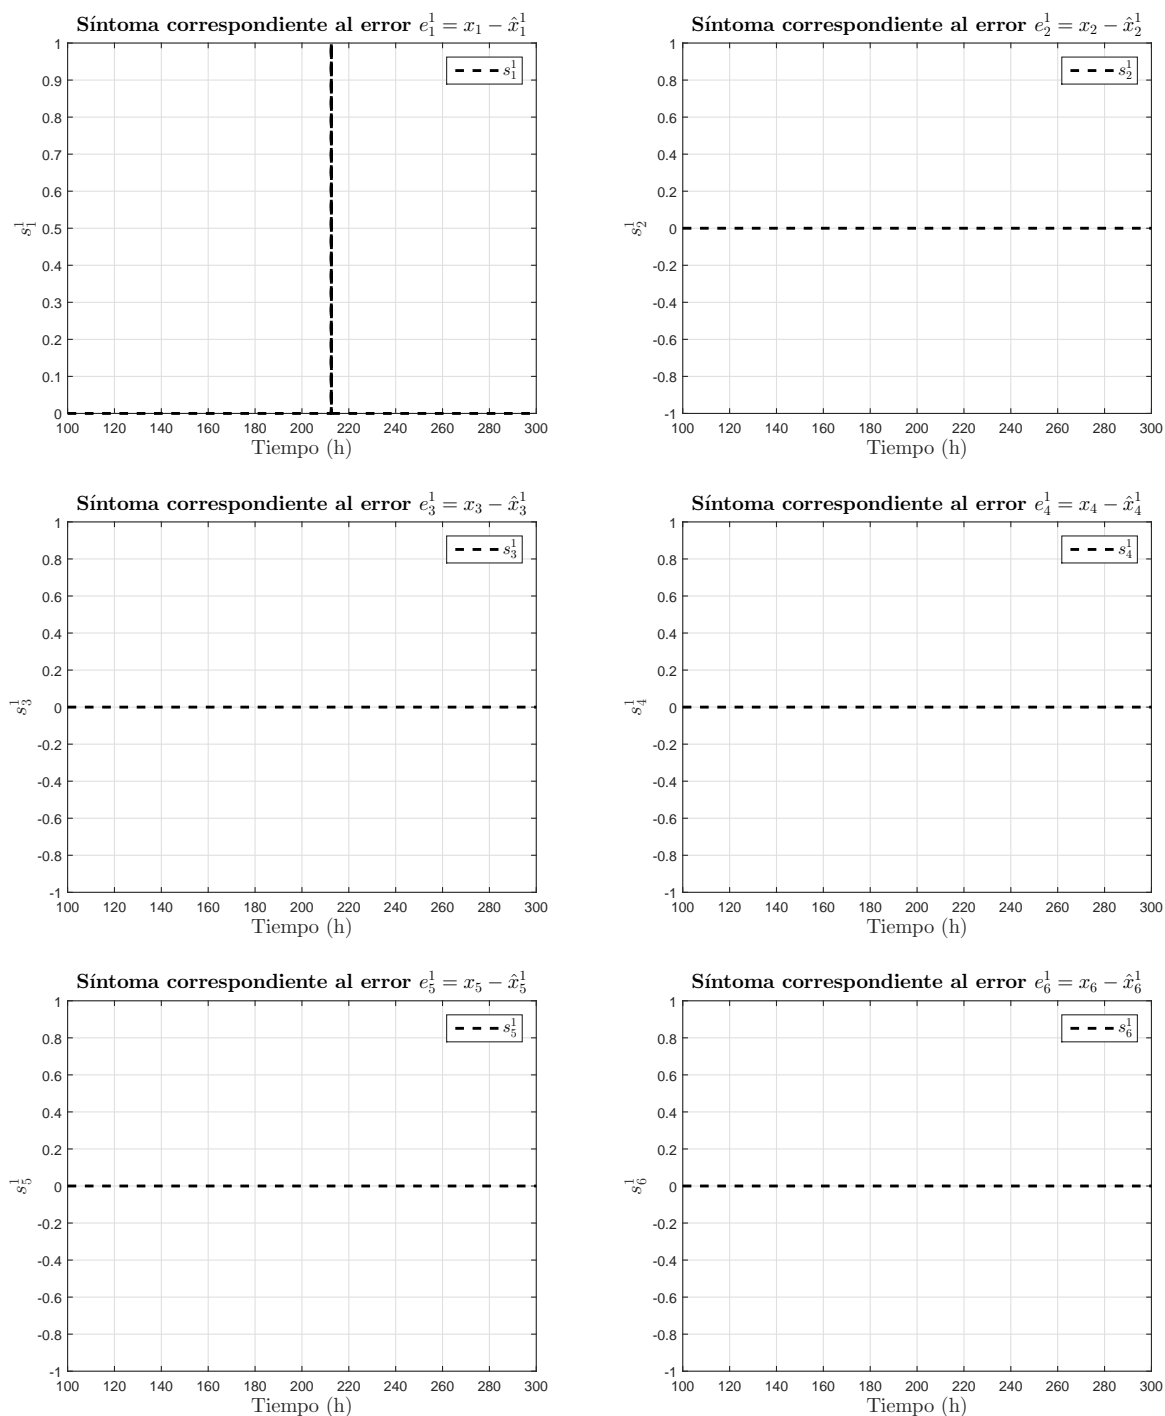


Figura D-4.: Síntomas s_Γ^1 generados a partir de la evaluación de los errores de estimación e_γ^1 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} .

D. Anexo D: Sistema neurolocalizador ante la presencia de fallas x_2 , x_3 y x_4

El observador O^1 a generado un pequeño síntoma por el cambio en escalón negativo que se presenta en la falla f_{x_3} . Caso similar pasa con los observadores O^2 y O^5 , como se muestra en la Fig.D-5.

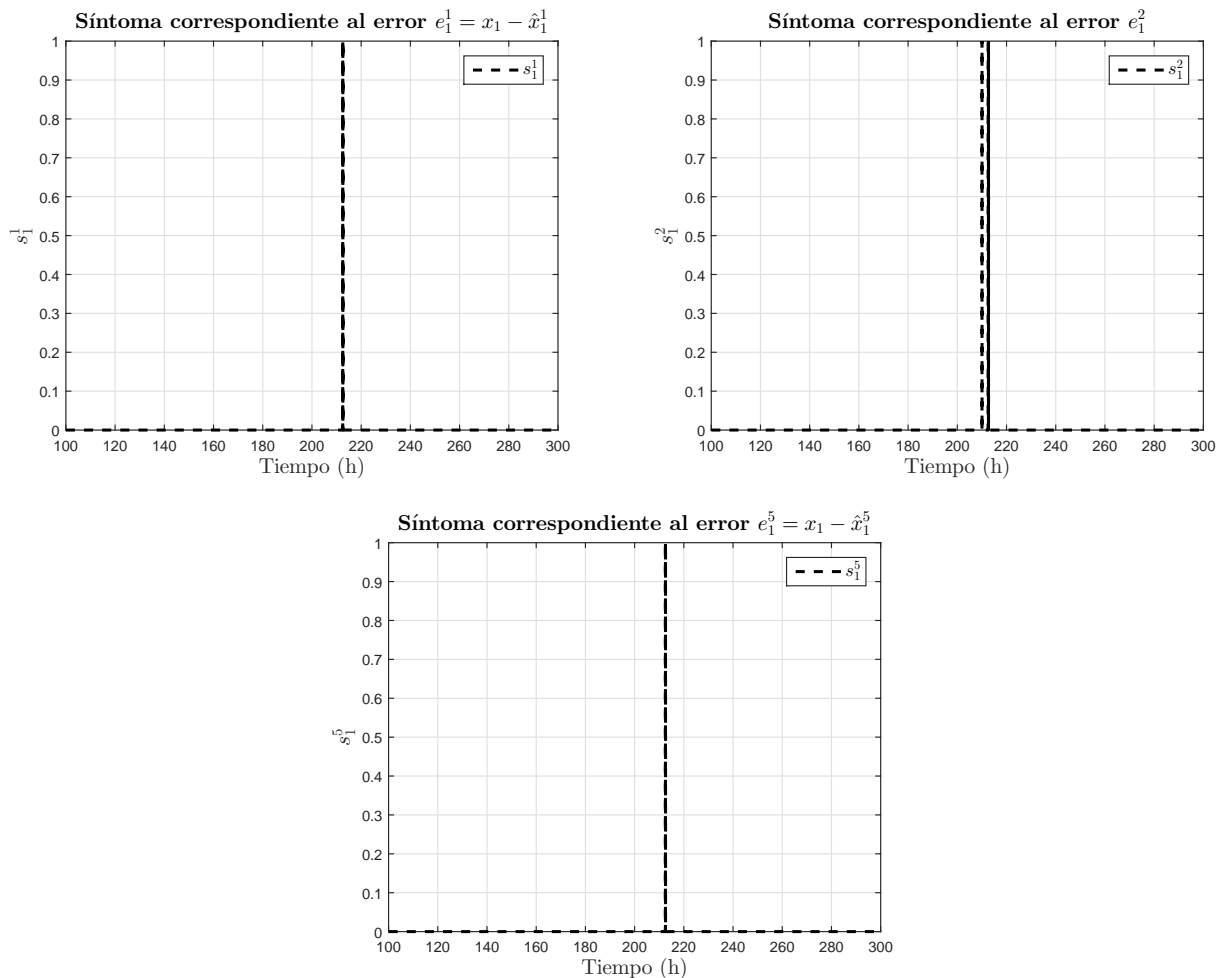




Figura D-5.: Síntomas s_γ^5 generados a partir de la evaluación de los errores de estimación e_γ^5 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} .

Derivado de los síntomas provocados por la falla f_{x_3} , se genera la falsa alarma a_1 que indica la existencia de la falla f_1 en el sensor correspondiente al estado no lineal x_1 . El período de tiempo de esta falsa alarma es muy pequeño, con lo cual no es suficiente para considerar una alarma verdadera tal y como se muestra en la Fig.D-6.

Neurolocalización de f_1 correspondiente al sensor de x_1



Neurolocalización de f_2 correspondiente al sensor de x_5



Neurolocalización de f_3 correspondiente al sensor de x_6




Figura D-6.: Síntomas s_{γ}^5 generados a partir de la evaluación de los errores de estimación e_{γ}^5 ante la presencia de fallas f_{x_2} , f_{x_3} y f_{x_4} .



**TECNOLÓGICO
NACIONAL DE MÉXICO**

cenidet[®]
Centro Nacional de Investigación
y Desarrollo Tecnológico