

SISTEMA DE DETECCIÓN, DIAGNÓSTICO Y TOLERANCIA A FALLAS EN UN
SERVOACTUADOR HIDRÁULICO

JUAN FELIPE ORTIZ BELEÑO

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
BUCARAMANGA

2019

SISTEMA DE DETECCIÓN, DIAGNÓSTICO Y TOLERANCIA A FALLAS EN UN
SERVOACTUADOR HIDRÁULICO

JUAN FELIPE ORTIZ BELEÑO

Trabajo de Grado para optar al título de
Mágister en Ingeniería Mecánica

Director

Carlos Borrás Pinilla

Maestría en Ingeniería Mecánica

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOMECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
BUCARAMANGA

2019

DEDICATORIA

A mi abuelo, mi eterna motivación y ejemplo.

A mi mamá, mi gran admiración, mi vida.

A mi familia, mi gran apoyo incondicional.

A mis amigos, mi compañía excepcional.

Juan Felipe Ortiz Beleño

AGRADECIMIENTOS

A la Universidad Industrial de Santander, la Facultad de Ingenierías Físico - Mecánicas y la Escuela de Ingeniería Mecánica por contruir en nuestra formación como ingenieros.

Al director por sus consejos y orientación en el desarrollo de la tesis.

A mis compañeros.

CONTENIDO

	pág.
INTRODUCCIÓN	16
1. DESCRIPCIÓN DEL TRABAJO DE GRADO	18
1.1. DESCRIPCIÓN GENERAL DEL TRABAJO DE GRADO	18
1.2. PLANTEAMIENTO DEL PROBLEMA	18
1.3. JUSTIFICACIÓN	23
2. OBJETIVOS	27
2.1. OBJETIVO GENERAL	27
2.2. OBJETIVOS ESPECÍFICOS	27
3. ESTADO DEL ARTE	28
3.1. SISTEMAS DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS (FDD)	28
3.2. CONTROL TOLERANTE A FALLAS (FTC)	30
4. MODELO MATEMÁTICO DEL SISTEMA TOLERANTE A FALLAS EN EL TRANSDUCTOR DE POSICIÓN LVDT	35
4.1. MODELADO DINÁMICO DEL SISTEMA TOLERANTE A FALLAS	36
4.1.1. Modelo dinámico no lineal	36
4.1.2. Ecuaciones de estado no lineales	39
4.1.3. Linealización del modelo	39
4.2. DISEÑO DEL ALGORITMO DE CONTROL	41
4.2.1. Control PID	41
4.2.2. Control LQR	44
4.2.3. Control LQG	46

4.3. SIMULACIÓN DEL ALGORITMO DE CONTROL	49
4.4. TOMA DE DATOS Y REALIZACIÓN DE PRUEBAS	60
4.5. IMPLEMENTACIÓN DEL SISTEMA DE CONTROL	70
5. MODELO DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS EN EL SELLO DEL PISTÓN DE UN SERVOACTUADOR	82
5.1. ADQUISICIÓN Y ALMACENAMIENTO DE DATOS EN DIFERENTES ES- TADOS DE FALLA	84
5.2. DISEÑO DEL ALGORITMO DE DETECCIÓN Y DIAGNÓSTICO DE FA- LLAS	87
5.2.1. Procesamiento de la señal y selección de características	87
5.2.2. Diseño de la arquitectura de la red neuronal	93
6. RECOMENDACIONES	110
7. TRABAJO FUTURO	111
8. CONCLUSIONES	112
BIBLIOGRAFÍA	114

LISTA DE FIGURAS

	pág.
Figura 1. Representación de las fugas internas del actuador	19
Figura 2. Representación de las fallas en el transductor de posición	20
Figura 3. Representación del ruido generado por fallas en el LVDT	21
Figura 4. Clasificación de los métodos de detección y diagnóstico de fallas	31
Figura 5. Clasificación de los métodos de control tolerantes a falla	34
Figura 6. Tipos posibles de falla en un sistema de lazo cerrado ¹	35
Figura 7. Esquema del sistema hidráulico	37
Figura 9. Modelo no lineal en Simulink	43
Figura 10. Controlador LQR en el modelo no lineal en Simulink	46
Figura 11. Controlador LQG en el modelo no lineal en Simulink	49
Figura 12. Gráfico de Posición vs Tiempo para una señal seno de 0.1[Hz]	52
Figura 13. Gráfico de Voltaje vs Tiempo para una señal seno de 0.1[Hz]	52
Figura 14. Gráfico de Error vs Tiempo para una señal seno de 0.1[Hz]	53
Figura 15. Gráfico de Posición vs Tiempo para una señal seno de 0.1[Hz] con perturbación	54
Figura 16. Gráfico de Voltaje vs Tiempo para una señal seno de 0.1[Hz] con perturbación	54
Figura 17. Gráfico de Error vs Tiempo para una señal seno de 0.1[Hz] con perturbación	55

¹ R. ISERMANN. "Diagnosis Methods for Electronic Controlled Vehicles". En: *VDI Berichte* 1616 (2001), págs. 209-238. DOI: 10.1076/vsd.36.2.77.3554.

Figura 18.	Gráfico de Posición vs Tiempo para una cuadrada de 0.1[Hz]	56
Figura 19.	Gráfico de Voltaje vs Tiempo para una cuadrada de 0.1[Hz]	56
Figura 20.	Gráfico de Error vs Tiempo para una cuadrada de 0.1[Hz]	57
Figura 21.	Gráfico de Posición vs Tiempo para una cuadrada de 0.1[Hz] con perturbación	58
Figura 22.	Gráfico de Voltaje vs Tiempo para una cuadrada de 0.1[Hz] con perturbación	58
Figura 23.	Gráfico de Error vs Tiempo para una cuadrada de 0.1[Hz] con perturbación	59
Figura 24.	Esquema eléctrico e hidráulico del sistema	60
Figura 25.	Representación física del sistema del grupo DICBoT	61
Figura 26.	Recta y ecuación característica del LVDT	62
Figura 27.	Representación de las fallas inducidas en el sistema	63
Figura 28.	Diagrama de Bloques del controlador PID en el software Quarc	64
Figura 29.	Diagrama de Bloques del controlador LQR en el software Quarc	68
Figura 30.	Diagrama de Bloques del controlador LQG en el software Quarc	69
Figura 31.	Gráfico de Posición vs Tiempo para una señal escalón	70
Figura 32.	Gráfico de Voltaje vs Tiempo para una señal escalón	71
Figura 33.	Gráfico de Error vs Tiempo para una señal señal escalón	71
Figura 34.	Gráfico de Posición vs Tiempo para una señal escalón con perturbación	72
Figura 35.	Gráfico de Voltaje vs Tiempo para una señal escalón con perturbación	72
Figura 36.	Gráfico de Error vs Tiempo para una señal escalón con perturbación	73
Figura 37.	Gráfico de Posición vs Tiempo para una señal seno de 0.25[Hz]	73
Figura 38.	Gráfico de Voltaje vs Tiempo para una señal seno de 0.25[Hz]	74
Figura 39.	Gráfico de Error vs Tiempo para una señal seno de 0.25[Hz]	74

Figura 40. Gráfico de Posición vs Tiempo para una señal seno de 0.25[Hz] con perturbación	75
Figura 41. Gráfico de Voltaje vs Tiempo para una señal seno de 0.25[Hz] con perturbación	75
Figura 42. Gráfico de Error vs Tiempo para una señal seno de 0.25[Hz] con perturbación	76
Figura 43. Gráfico de Posición vs Tiempo para una señal cuadrada de 0.25[Hz]	76
Figura 44. Gráfico de Voltaje vs Tiempo para una señal cuadrada de 0.25[Hz]	77
Figura 45. Gráfico de Error vs Tiempo para una señal cuadrada de 0.25[Hz]	77
Figura 46. Gráfico de Posición vs Tiempo para una señal cuadrada de 0.25[Hz] con perturbación	78
Figura 47. Gráfico de Voltaje vs Tiempo para una señal cuadrada de 0.25[Hz] con perturbación	78
Figura 48. Gráfico de Error vs Tiempo señal cuadrada de 0.25[Hz] con perturbación	79
Figura 8. Modelo linealizado en Simulink	81
Figura 49. Modelo general de una neurona con sus posibles modificaciones	82
Figura 50. Clasificación de los modelos de redes neuronales	83
Figura 51. Diagrama de bloques para la toma de datos	85
Figura 52. Curva de flujo de la válvula ²	86
Figura 53. Libro de los datos tomados	87
Figura 54. Señal de posición en cinco condiciones de falla a 0.2 Hz para tipo cuadrada y seno	88
Figura 55. Señal de posición en cinco condiciones de falla a 1 Hz para tipo cuadrada y seno	88

² PARKER ENGINEERINGS. "Valve flow graph". En: (), págs. 1-18.

Figura 56. Señal de posición en cinco condiciones de falla a 5 Hz para tipo cuadrada y seno	89
Figura 57. Diagrama de la arquitectura de la Red Adeline	95
Figura 58. Diagrama de la arquitectura de la Red Perceptron Multicapa con una capa oculta	96
Figura 59. Diagrama de la arquitectura de la Red Perceptron Multicapa con dos capas ocultas	101
Figura 60. Matriz de confusión de la Red Perceptron Multicapa con una capa oculta	104
Figura 61. Matriz de confusión de la Red Perceptron Multicapa con dos capas ocultas	105
Figura 62. Matriz de confusión de la Red Adeline	106
Figura 63. Error cuadrático medio de la Red Perceptron Multicapa con una capa oculta	107
Figura 64. Estado de entrenamiento de la Red Perceptron Multicapa con una capa oculta	107
Figura 65. Error cuadrático medio de la Red Perceptron Multicapa con dos capas ocultas	107
Figura 66. Estado de entrenamiento de la Red Perceptron Multicapa con dos capas ocultas	107
Figura 67. Error cuadrático medio de la Red Adeline	108
Figura 68. Estado de entrenamiento de la Red Adeline	108

LISTA DE TABLAS

	pág.
Tabla 1. Condiciones de falla.	49
Tabla 2. Datos para caracterización del LVDT.	61
Tabla 3. Condiciones de falla.	85

RESUMEN

TÍTULO: SISTEMA DE DETECCIÓN, DISGNÓSTICO Y TOLERANCIA A FALLS EN UN SERVOAC-
TUADOR HIDRÁULICO *

AUTOR: JUAN FELIPE ORTIZ BELEÑO **

PALABRAS CLAVE: MANTENIMIENTO PREDICTIVO, CONTROL ROBUSTO, TOLERANTE A FA-
LLAS, DETECCION, DIAGNOSTICO, REDES NEURONALES.

DESCRIPCIÓN:

Con el fin de promover la investigación y construcción de conocimiento en Sistemas de Mantenimien-
to Predictivo se llevó a cabo una metodología basada en control lineal, no lineal y redes neuronales
artificiales para el desarrollo de un sistema de detección, diagnostico y tolerancia a fallas en un
servoactuador hidráulico.

Con base en el sistema físico, se planteó un modelo matemático para diseñar los algoritmos de
control lineal y no lineal (PID, LQR, LQG) buscando lograr un control de posición tolerante a fallas
por ruido, realizando simulaciones y pruebas reales con la mesa sísmica uniaxial del laboratorio de
Sistemas Dinámicos.

Se implementó un sistema de bypass para simular cinco condiciones de fallas por fugas internas
en el interior del pistón de un servoactuador hidráulico (0 %), 25 %,50 %,75 % y 100 %). Se tomaron
datos de posición para señales seno y cuadrada de frecuencia 0.2Hz, 1Hz y 5Hz para posteriormente
realizar el debido procesamiento de señales y extracción de características, obteniendo una matriz de
características y de objetivos. Con estas matrices se construyeron tres arquitecturas de red neuronal
(adaptativa lineal, perceptron multicapa de una capa oculta y perceptron multicapa de dos capas
ocultas) con el fin de obtener un sistema capaz de detectar y clasificar estas fallas por fugas internas.

La metodología y los algoritmos desarrollados presentaron resultados satisfactorios en términos de
tolerancia a falla al obtener una reducción del error en casi un 40 %, así como la correcta detección,
clasificación de las fallas con una presición del 95 %.

* Tesis de grado de maestría

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Mecánica. Maestría en Ingenie-
ría Mecánica. Director: Carlos Borrás Pinilla.

ABSTRACT

TITLE: FAULT DETECTION, DIAGNOSIS AND TOLERANCE FOR A NONLINEAR HYDRAULIC ACTUATOR *

AUTHOR: JUAN FELIPE ORTIZ BELEÑO **

KEYWORDS: PREDICTIVE MAINTENANCE, ROBUST CONTROL, FAULT TOLERANCE, DETECTION, DIAGNOSIS, NEURAL NETWORK.

DESCRIPTION:

In order to promote research and enhance knowledge in predictive maintenance systems, specifically fault tolerant control algorithms and fault detection and classification systems, in order to carry out a system capable of fault detection, diagnosis and tolerance a methodology based on linear, nonlinear control and artificial neural networks was developed.

Based on the physical system, a mathematical model was posed with the purpose of developing linear control algorithms such as PID and LQR, and robust control algorithms as LQR, seeking to accomplish a great position control with noise tolerance, performing the respective simulations and physical tests with the uniaxial seismic shake table in the Dynamic Systems Laboratory.

A Bypass system that communicate the two chambers of the hydraulic actuator was implemented in order to emulate different conditions of internal leakage inside the piston (0 %), 25 %, 50 %, 75 % y 100 %). Using the previous mathematical model, position data was acquired for sine and square signal with 0.2Hz, 1Hz and 5Hz frequencies for signal processing and feature extraction, obtaining both feature and targets matrices. Moreover, three artificial neural networks architectures were designed to obtain a system capable of fault detection and classification. The enounced methodology and the developed algorithms presented satisfactory results in terms of fault tolerance, giving almost 40 % error reduction, and a correct fault detection and classification with 95 % accuracy.

* Master Thesis

** Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingeniería Mecánica. Maestría en Ingeniería Mecánica. Director: Carlos Borrás Pinilla.

INTRODUCCIÓN

Los sistemas hidráulicos son ampliamente usados en robótica, mecatrónica y otras aplicaciones industriales debido a su gran confiabilidad y alta precisión ¹; es por eso que con el paso de los años, tanto la comunidad científica como la industria están constantemente investigando, diseñando y utilizando técnicas avanzadas de mantenimiento predictivo, como una importante herramienta de gerenciamiento económico y precisa para conocer el estado real del sistema hidráulico en estudio, permitiendo manejar información confiable y controlar mejor parámetros para potenciar la estructura y el plan de mantenimiento de los equipos, además de poder realizar un diagnóstico de las condiciones de los componentes o equipos del sistema y poder determinar las soluciones más adecuadas para cada falla, problema o parte del sistema.

Las fallas son consideradas como un defecto lógico o físico que se presenta de cualquier forma: en los componente del sistema, a nivel de hardware, a nivel de software, entre otras. Es posible que si estas fallas no son controladas dentro de un intervalo de tiempo, generen un disturbio o perturbación permanente y que estos fallos terminen introduciendo errores en el proceso; estos errores llegan a desencadenar una gran cantidad de problemas a nivel de seguridad, integridad, rendimiento. costos y demás. Estos errores pueden seguir presentandose e incrementándose hasta provocar averías que se traducen en un bajo rendimiento del proceso, pérdidas económicas, problemas técnicos y demás.

¹ A SEYEDMIRZABOZORG, A TIVAY y S REZAEI. "Leakage Fault Classification in Hydraulic Actuators Via Multiple Trained Transformations". En: *International Conference on Robotics and Mechatronics, ICROM 2015* (2015), págs. 246-251. DOI: 10.1109/ICRoM.2015.7367792.

La detección y el diagnóstico de fallas busca identificar la causa principal de un funcionamiento defectuoso en el sistema, basado en observaciones externas, intentando predecir los posibles escenarios para disminuir al mínimo la probabilidad de falla en las máquinas críticas en un proceso. Por otro lado, la tolerancia a fallas busca corregir, eliminar o mitigar estas fallas, permitiéndole al sistema trabajar con normalidad, o trabajar con un desempeño inferior ²

El presente proyecto busca fortalecer el área de investigación del grupo DICBoT en técnicas avanzadas de mantenimiento predictivo y gestión de fallas aplicadas a procesos industriales, ofreciendo a quienes cuentan con sistemas hidráulicos el poder conocer el estado del equipo, mediante el diseño de un sistema de detección, diagnóstico y tolerancia al fallo, integrando el procesamiento digital de señales, desarrollos de algoritmos complejos con base en técnicas de control lineal, no lineal y de reconocimiento de patrones, ofreciendo finalmente una contribución significativa a la comunidad científica con los datos y resultados obtenidos al concluir el presente trabajo de investigación.

² & MANI KRISHNA KOREN, I. "Fault-Tolerant Systems". En: *Morgan Kaufmann Publishers* (2018), pág. 2018.

1. DESCRIPCIÓN DEL TRABAJO DE GRADO

1.1. DESCRIPCIÓN GENERAL DEL TRABAJO DE GRADO

1.2. PLANTEAMIENTO DEL PROBLEMA


Con el paso de los años, debido al notorio crecimiento de la industria y la constante búsqueda de mejorar la producción, la realización de un correcto mantenimiento preventivo y predictivo juega un papel fundamental, ya que logra una reducción considerable de las paradas no programadas y daños imprevistos, optimizando el flujo de activos.

En relación con los equipos hidráulicos, es posible encontrar varios tipos de fallas a lo largo de su vida útil. Una de las fallas más comunes en estos actuadores, son las fugas internas de fluido hidráulico a través de los sellos mecánicos en un pistón defectuoso³. Ver Figura No. 1 (Parte superior, encerrado en rojo). Esto puede ser especialmente problemático, debido a que las fugas internas son difíciles de detectar sin desmontar primero el actuador para su completa revisión, además que provoca vibraciones inesperadas en el sistema, saltos repentinos en la posición del actuador, inestabilidad del actuador, etc.

Ahora bien, aunque los procedimientos de mantenimiento de rutina pueden ser eficaces en la reducción de los problemas asociados con las fugas del actuador, es importante contar con una herramienta de detección y diagnóstico del sistema que

³ Ali MADDAHI y col. "Internal Leakage Detection in Electrohydrostatic Actuators Using Multiscale Analysis of Experimental Data". En: (2016), págs. 1-14.

Figura 1. Representación de las fugas internas del actuador




indique la condición de falla en la que se encuentra el mismo⁴, siendo este un reto para la comunidad investigadora regional y nacional.

Otro tipo de falla muy común en actuadores electro-hidráulicos y en los servos de posición, son las fallas en el transductor de posición *LVDT*(*linear variable differential*

⁴ R MANGOUBI. "Robust Estimation and Failure Detection: A Concise Treatment". En: (2012), pág. 218.

transformer)⁵ Ver Figura No. 2 (Parte superior, encerrado en rojo).

Figura 2. Representación de las fallas en el transductor de posición




Esta falla en particular induce en el sistema un ruido inesperado y error en la señal de retroalimentación, generando una señal de error falsa (Ver Figura No. 3), por ende un mal funcionamiento de las máquinas, provocando errores de precisión, po-

⁵ R WITTENBACH. "Detection of Faults in Linear and Rotary Voltage Transducers". En: 12 (2006).

sición, velocidad, fuerza y control en el actuador ⁶.

Figura 3. Representación del ruido generado por fallas en el LVDT



Con base en lo anterior, es importante contar con un sistema de control tolerante a falla (*FTC*, por sus siglas en inglés), el cual pueda mantener el funcionamiento del sistema o mejorar considerablemente el desempeño del mismo, a pesar de los fallos en el transductor de posición *LVDT* y pueda mejorar en gran medida la seguridad y el rendimiento en aplicaciones del sistema hidráulico como maquinaria agrícola, actuadores, industria automotriz y aeroespacial entre otras.⁸

La mayoría de esquemas de mantenimiento de sistemas hidráulicos en Colombia se basan en técnicas correctivas y en algunos casos preventivas, utilizando generalmente técnicas no intrusivas ni destructivas como: análisis de ultrasonido, pruebas de aceite, análisis de vibraciones, entre otros, siendo estos estudios costosos y

⁶ R POLEY. "Signal Conditioning an LVDT Using a TMS320F2812 DSP". En: August (2003), págs. 1-27.

⁸ H ALWI, C EDWARDS y C TAN. "Fault Detection and Fault-Tolerant Control Using Sliding Modes". En: *Advances in industrial control* (2011), 1 online resource (xxvii, 336 p.) DOI: 10.1007/978-0-85729-650-4.

totalmente precisos.

A nivel internacional se está trabajando en el desarrollo de sistemas de detección, diagnóstico y tolerancia a fallas en servoactores hidráulicos ^{9 10}, sin embargo no se evidencian informes o reportes de su implementación en la industria a nivel regional o local, siendo la motivación del autor y el grupo de investigación DICBoT el contribuir con la optimización y mejora de la industria hidráulica nacional, dándole solución a los problemas mencionados anteriormente, mediante el desarrollo del presente trabajo de investigación, siendo demostrable a través de su implementación y validación en el laboratorio de Dinámica Estructural para su posterior divulgación a la comunidad científica e industria hidráulica.

⁹ V MAHULKAR, D ADAMS y M DERRISO. "Adaptive Fault Tolerant Control for Hydraulic Actuators". En: *American Control Conference* (2015), págs. 2242-2247.

¹⁰ B YU, Y SHI y J HUANG. "Modified Generalized Predictive Control of Networked Systems With Application to a Hydraulic Position Control System". En: *Journal of Dynamic Systems, Measurement, and Control* 133.3 (2011), pág. 031009. DOI: 10.1115/1.4003385.

1.3. JUSTIFICACIÓN

Dado el escenario en que se presente cualquier tipo de falla, es indispensable que el controlador implementado tenga la capacidad de mantener el sistema dentro de un rango de operación aceptable ¹¹ con el fin de evitar la inutilización del mismo cuando la falla esté presente y permitir que el sistema continúe funcionando. Es por eso que ante posibles errores en el sensor o la intrusión de perturbaciones y ruidos externos, el sistema detecta estas anomalías, reconoce que está en fallo y se mantiene operacional en ciertos límites mientras se realiza la respectiva corrección ¹².

Las paradas de planta son un problema fundamental en la industria ya que implican retrasar la producción teniendo como consecuencias pérdidas económicas considerables. El poder contar con una herramienta que reaccione ante diferentes condiciones de falla y permita conocer el estado de desgaste del sello del pistón del servoactuador hidráulico, permite predecir el momento del fallo y brinda la posibilidad de corregirlo o planificar las futuras acciones de mantenimiento antes de que éste se ocasione ¹³. Es importante resaltar que para que un sistema reaccione ante una falla, ésta debe ser previamente detectada y diagnosticada ¹⁴.

¹¹ G REN y col. "Position Control of an Electrohydrostatic Actuator With Tolerance to Internal Leakage". En: (2016), págs. 1-9. DOI: 10.1109/TCST.2016.2517568.

¹² M MUENCHOF y R ISERMANN. *Comparison of change detection methods for a residual of a hydraulic servo-axis*. Vol. 16. 1. IFAC, 2005, págs. 317-322. DOI: 10.3182/20050703-6-CZ-1902.01855.

¹³ R. ISERMANN. "Supervision, Fault-Detection and Fault-Diagnosis Methods - An Introduction". En: *Control Engineering Practice* 5.5 (1997), págs. 639-652. DOI: 10.1016/S0967-0661(97)00046-4.

¹⁴ M MUENCHOF, M BECK y R ISERMANN. "Fault-Tolerant Actuators and Drives-Structures, Fault Detection Principles and Applications". En: *Annual Reviews in Control* 33.2 (2009), págs. 136-148. DOI: 10.1016/j.arcontrol.2009.08.002.

Es fundamental que un sistema opere siempre adecuadamente, esto implica una constante revisión del mismo para lograr una detección temprana de las fallas ¹⁵. La tolerancia al fallo es la capacidad de un sistema de mantenerse operacional, sacrificando desempeño, a pesar de que uno o varios componentes del mismo estén en falla. Siendo así, para sistemas críticos o procesos en los que no es ideal detener el equipo para llevar a cabo el respectivo mantenimiento, es necesario implementar un control que pueda mantener el sistema en un punto de operación aceptable en comparación con su estado normal ¹⁶ o una herramienta que informe el estado de desgaste y la condición de falla del mismo. Esta herramienta de control y mantenimiento predictivo al estar bien implementados, logran reducir los altos costos que implica llevar a cabo mantenimiento correctivo y paradas de planta ¹⁷.

De igual manera, se resalta la importancia del presente trabajo al responder a las siguientes preguntas:

- ¿Es posible diseñar, simular e implementar en el laboratorio de Dinámica Estructural un sistema inteligente que pueda detectar, diagnosticar y clasificar diferentes tipos de fallas por fugas internas en pistón de un servoactuador hidráulico, además de un sistema tolerante a fallas en el transductor de posición mediante técnicas avanzadas de control?

¹⁵ R ISERMANN. *Fault-Diagnosis Systems: An Introduction From Fault Detection to Fault Tolerance*. 2006, págs. 1-475. DOI: 10.1007/3-540-30368-5. arXiv: arXiv:1011.1669v3.

¹⁶ L CHIANG y col. *Fault Detection and Diagnosis in Industrial Systems*. 2001. DOI: 10.1007/978-1-4471-0347-9.

¹⁷ T LOUTAS y V KOSTOPOULOS. "Utilising the Wavelet Transform in Condition-Based Maintenance : A Review with Applications". En: *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology* (2012), págs. 273-312.

Para responder a la pregunta, se tiene en cuenta que las redes neuronales son herramientas muy poderosas que dependiendo de su arquitectura y configuración, pueden resolver diferentes problemas y manejar una alta precisión incluso en sistemas no lineales ¹⁸. Gracias a técnicas de procesamiento de señales y extracción de características principales de las señales adquiridas, es posible desarrollar un sistema de detección y diagnóstico de fallas off-line de un servoactuador hidráulico basado en redes neuronales artificiales, el cual reconozca el tipo y severidad de la falla con exactitud.

De igual manera, las técnicas de control tolerantes a falla (*FTC*) suelen ser de naturaleza robusta ya que se tiene que asegurar que el sistema funcione en un rango aceptable ante perturbaciones ¹⁹. Es por eso que teniendo en cuenta las no linealidades de un sistema hidráulico, es posible realizar un control efectivo de la posición de un servoactuador hidráulico tolerante a fallas basado en técnicas avanzadas de control lineal y/o no lineal, para asegurar que el sistema funcione idealmente en todo su rango de operación ²⁰.

Recapitulando, el presente trabajo busca mantener la confiabilidad del actuador y del proceso, al mismo tiempo que disminuir los costos de mantenimiento de estos, mediante el desarrollo de un sistema de detección y diagnóstico off-line de las fallas en el sello del pistón de un servoactuador hidráulico y el diseño de un control de posición tolerante a fallas por ruido y perturbaciones en el transductor de posición;

¹⁸ J ALLEN. "Neural Networks and Speech Processing the Kluwer International Series in Engineering and Computer Science". En: (1991).

¹⁹ R. ISERMANN. "Diagnosis Methods for Electronic Controlled Vehicles". En: *VDI Berichte* 1616 (2001), págs. 209-238. DOI: 10.1076/vsd.36.2.77.3554.

²⁰ H KHALIL. *Nonlinear Systems*. 2001, pág. 767.

ya que como se mencionó anteriormente, la detección temprana de las fallas y su respectiva corrección, mejora considerablemente el comportamiento del sistema, además de evitar paradas indeseadas y pérdidas económicas²¹.

²¹ V VENKATASUBRAMANIAN y col. "A Review of Process Fault Detection and Diagnosis Part III: Qualitative Models and Search Strategies". En: *Computers & Chemical Engineering* 27.3 (2003), págs. 293-311. DOI: 10.1016/S0098-1354(02)00160-6.

2. OBJETIVOS

2.1. OBJETIVO GENERAL

- Diseñar, simular y validar experimentalmente un sistema de detección, diagnóstico y tolerancia a fallas en un servoactuador hidráulico basado en redes neuronales y control automático como técnica avanzada de mantenimiento predictivo.

2.2. OBJETIVOS ESPECÍFICOS

- Diseñar un algoritmo de control tolerante a fallas en el transductor de posición (LVDT), basado en técnicas de control lineal y no lineal.
- Diseñar un algoritmo basado en redes neuronales artificiales, para la detección y clasificación fuera de línea de daños en los sellos del pistón del servoactuador hidráulico dinámico del grupo de investigación DICBoT en el laboratorio de Dinámica Estructural, para cinco condiciones de fallas de flujo (flujo de fugas internas del 0 %, 25 %, 50 %, 75 % y el 100 %).
- Simular el comportamiento de los algoritmos diseñados, para evaluar su desempeño por medio de herramientas computacionales como Matlab y Simulink verificando la correcta detección, diagnóstico y tolerancia a fallas.
- Validar experimentalmente el sistema de detección, diagnóstico y tolerancia a fallas en el servoactuador hidráulico del grupo de investigación DICBoT en el laboratorio de Dinámica Estructural.

3. ESTADO DEL ARTE

Debido al constante avance tecnológico, y siendo necesario conocer el estado de los componentes críticos del sistema o garantizar que ante algún tipo de falla sobre estos, el sistema puede continuar trabajando, evitando incidentes, catástrofes y garantizando la seguridad, mantenibilidad, confiabilidad, entre otras ²¹, se empezaron a desarrollar sistemas de detección y diagnóstico de fallos (*FDD*, por sus siglas en inglés) y de control tolerantes a falla *FTC*.

3.1. SISTEMAS DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS (*FDD*)

Los sistemas *FDD* pueden ser desarrollados de forma cuantitativa o cualitativa y se clasifican en: basados en el modelo dinámico y basados en datos recopilados. Cada uno de ellos posee diferentes métodos cuantitativos y cualitativos ²². Es posible obtener una representación global de las técnicas de detección, diagnóstico y clasificación de fallas en la Figura 4.

En 1988 Michele Baseville trabajó en un modelo estadístico para la detección de cambios en señales y sistemas ²⁰. ²³. En 1991 R.J.Patton planteó la detección y diagnóstico de fallas en sistemas aeroespaciales utilizando redundancia analítica ²⁴, el análisis realizado arrojó resultados satisfactorios mediante el uso de modelos

²² Venkat VENKATASUBRAMANIAN y col. "A Review of Process Fault Detection and Diagnosis Part I: Qualitative Models and Search Strategies". En: *Computers & Chemical Engineering* 27.3 (2003), págs. 293-311. DOI: 10.1016/S0098-1354(02)00160-6.

²³ M BASEVILLE. "Detecting Changes in Signals and Systems-A survey". En: *Automatica* 24.3 (1988), págs. 309-326. DOI: 10.1016/0005-1098(88)90073-8.

²⁴ R.J. Patton. "Fault Detection and Diagnosis in Aerospace Systems Using Analytical Redundancy".

simplificados del proceso.

En 1993 Janos Gertler empleó observadores en el espacio de estados y ecuaciones de paridad para la generación de residuales en un sistema basado en el modelo para el diagnóstico de fallas *Gertler1997*. Posteriormente Rolf Isermann en 1997 trabajó en diferentes métodos de supervisión, detección y diagnóstico de fallas (Generadores de síntomas, observadores, filtros de Kalman) ¹³, para en el 2001 implementar la técnica de *FDD* en vehículos controlados eléctricamente mediante estimación de parámetros, ecuaciones de paridad y lógica fuzzy ¹⁹.

P. Garimella y B. Yao trabajaron en el 2004 en un sistema *FDD* basado en modelo aplicado a un cilindro electrohidráulico utilizando observadores robustos adaptativos *ARO* con el fin de reducir problemas de incertidumbre en el modelo e incrementar la sensibilidad del sistema de detección de fallas, considerando varios tipos de fallos ²⁵.

En el 2006 los autores H. Liu, S. Wang y P. Outyang desarrollaron un sistema de diagnóstico de fallas en un servo de posición hidráulico utilizando una red neuronal de dos etapas basada en funciones radiales (*RBF*) entrenándola para obtener residuales del sistema y lograr la correcta clasificación ²⁶.

En 2011 S. Oviedo, C. Borrás y J. Quiroga utilizaron herramientas de inteligencia

En: *Computing & Control Engineering Journal* 2.3 (1991), pág. 127. DOI: 10.1049/cce:19910031.

²⁵ P GARIMELLA y B YAO. "Model Based Fault Detection of an Electro-Hydraulic Cylinder". En: *American Control Conference, 2005. Proceedings of the 2005 July 2005* (2005), 484 -489 vol. 1. DOI: 10.1109/ACC.2005.1469982.

²⁶ H LIU, S WANG y P OUYANG. "Fault Diagnosis in a Hydraulic Position Servo System Using RBF Neural Network". En: *Chinese Journal of Aeronautics* 19.4 (2006), págs. 346-353. DOI: 10.1016/S1000-9361(11)60339-7.

artificial y modelos basados en datos, para la detección y diagnóstico de fallas en un motor eléctrico utilizando máquinas de soporte vectorial en donde se validó el desempeño del algoritmo clasificando exitosamente cada condición de falla estipulada ²⁷

En 2014 J. Kolodzieg realizó un sistema *FDD* para actuadores electromecánicos basados en datos del sistema y utilizando técnicas de extracción de características y clasificadores Bayesianos concluyendo que esta técnica se puede implementar incluso en máquinas rotativas obteniendo un buen desempeño ²⁸.

En 2016 los autores A. Maddahi, S. Member y W. Kinsner proponen un modelo para detección de fugas internas en actuadores electrohidrostáticos usando análisis multiescala partiendo de datos experimentales, analizando presiones, caudales etc. provenientes del actuador obteniendo como resultado la correcta detección de diferentes tipos de severidad de falla ³.


3.2. CONTROL TOLERANTE A FALLAS (FTC)

Gracias a la fundamentación teórica y los sistemas de detección y diagnóstico, ciertos investigadores se enfocaron en el desarrollo de sistemas tolerantes al fallo. Estos sistemas se clasifican en activos y pasivos. Los pasivos son generalmente controladores robustos, mientras que los activos se reconfiguran para seguir ejerciendo el control ²². Esto está representado en la Figura 5.

²⁷ S OVIEDO, J QUIROGA y C BORRÁS. "Motor Current Signature Analysis and Negative Sequence Current Based Stator Winding Short Fault Detection in an Induction Motor". En: *Dyna rev.fac.nac.minas* 78.170 (2011), págs. 214-220.

²⁸ J KOLODZIEJ. "A Data-Driven Methodology for Fault Detection in Electromechanical Actuators". En: 136.July (2014), págs. 1-16. DOI: 10.1115/1.4026835.

Figura 4. Clasificación de los métodos de detección y diagnóstico de fallas



F. Lin, R.Wai y C. Lee implementaron en 1999 un control de posición para un motor ultrasónico mediante una red neuronal fuzzy, entrenada en línea mediante una *ley de adaptación Delta* obteniendo una convergencia ideal de la red y un excelente desempeño del controlador en términos de estabilidad, robustez y precisión ²⁹.

En 2003, J.Huang y F.Lewis propusieron un sistema de control predictivo para sistemas no lineales con retrasos e incertidumbres. Los autores comprobaron la estabilidad del sistema desarrollado según el método de Lyapunov, y obtuvieron finalmente una red neuronal adaptativa de una capa con retrasos de tiempo ³⁰.

²⁹ F LIN, R WAI y C LEE. "Fuzzy Neural Network Position Controller for Ultrasonic Motor Drive Using Push-Pull DC-DC Converter". En: *IEE Proc.-Control Theory Appl* 146.1 (1999).

³⁰ J HUANG y F LEWIS. "Neural-network predictive control for nonlinear dynamic systems with time-delay". En: *IEEE Transactions on Neural Networks* 14.2 (2003), págs. 377-389.

En el año 2006 B. Åkesson y H. Toivonen aplicaron un controlador por redes neuronales al modelo óptimo predictivo para un sistema no lineal. La ley de control es representada por la red neuronal como un aproximador, el cual fue entrenado para minimizar la función de costo del sistema J . Esta configuración presentó mejores resultados en términos de precisión con respecto a un modelo de control predictivo (*MPC por sus siglas en inglés*)³¹.

S. Yildirim en el año 2008 propuso el uso de una red neuronal recurrente híbrida para el control de posición de un robot caminante de cuatro piernas, logrando el control eficientemente, aumentando la robustez y precisión frente a otras técnicas de control de posición³².

En 2010 Karpenko³³ realizó un control tolerante a fallas para un actuador electrohidráulico en la presencia de incertidumbres y operando bajo carga variable con fugas internas en el sello del pistón del actuador. El controlador fue capaz de compensar las fugas internas con un flujo máximo hasta del 40 %, requiriendo solamente la retroalimentación del transductor de posición, siendo atractivo para la implementación.

J. Fan, Y. Zhang y Z. Zheng implementaron en el 2013 la técnica de observadores adaptativos en un sistema hidráulico con el fin de estabilizar el lazo cerrado de con-

³¹ B ÅKERSON y H TOIVONEN. "A neural network model predictive controller". En: *Journal of Process Control* 16.9 (2006), págs. 937-946. DOI: 10.1016/j.jprocont.2006.06.001.

³² AŖ YILDIRIM. "A proposed hybrid neural network for position control of a walking robot". En: *Nonlinear Dynamics* 52.3 (2008), págs. 207-215. DOI: 10.1007/s11071-007-9272-8.

³³ M KARPENKO y N SEPEHRI. "Quantitative Fault Tolerant Control Design for a Leaking Hydraulic Actuator". En: *Journal of Dynamic Systems Measurement and Control-Transactions of the Asme* 132.5 (2010), págs. -. DOI: Artn054505\DOI10.1115/1.4001707.

trol en la presencia de fallas en el actuador, planteando también la posibilidad de modelar el sistema como no lineal mediante la ayuda del posicionamiento de un polo del sistema ³⁴. En este mismo año, M. Abdullah desarrolló un control de posición para un motor DC basado en redes neuronales artificiales siendo entrenada con un controlador PID, para después realizar corrección de errores y ajustes de la matriz de peso para que el controlador resultara lo más preciso posible ³⁵.

En el 2015 J.Yao, G.Yang y Z.Jiao realizaron un control de posición para actuadores hidráulicos vía *feedback linearization*, ya que debido a las perturbaciones externas, es posible que el sistema termine con errores en estado estacionario. Para el desarrollo del controlador, el autor trabajó el sistema en lazo cerrado, haciendo uso del dominio de la frecuencia y se usó *backstepping* para lidiar con las perturbaciones del sistema hidráulico. Como resultado, el controlador garantizó excelente y preciso seguimiento y corrección del error, manteniendo una alta respuesta dinámica ³⁶.


En 2016 G. Ren, M. Esfandiari y J. Song desarrollaron un control de posición para un actuador electrostático utilizando la teoría de realimentación cuantitativa (*QFT*), cuyos resultados demuestran un error en la posición del actuador en estado estacionario de aproximadamente 0.1[mm] con un flujo de pérdidas internas de 8.5 [L/min] ¹¹.

³⁴ J FAN, Y ZHANG y Z ZHENG. "Adaptive Observer-Based Integrated Fault Diagnosis and Fault-Tolerant Control Systems Against Actuator Faults and Saturation". En: *Journal of Dynamic Systems, Measurement, and Control* 135.4 (2013), pág. 041008. DOI: 10.1115/1.4023763.

³⁵ M ABDULLAH. "Neural Network Controller Design for Position Control System Improvement". En: *Thesis Master* June (2013).

³⁶ J. YAO, G. YANG y Z. JIAO. "High dynamic feedback linearization control of hydraulic actuators with backstepping". En: *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering* 229.8 (2015), págs. 728-737. DOI: 10.1177/0959651815581555.


Figura 5. Clasificación de los métodos de control tolerantes a falla



4. MODELO MATEMÁTICO DEL SISTEMA TOLERANTE A FALLAS EN EL TRANSDUCTOR DE POSICIÓN LVDT

La tolerancia se denota como el intento de contener las consecuencias de fallas o averías presentes en un sistema de manera que éste pueda seguir funcionando, sin importar que maneje un desempeño o rendimiento inferior ¹². La mejor manera de lograrlo es mediante la redundancia de componentes, unidades o subsistemas. Sin embargo, por costos, practicidad o complejidad no es siempre posible implementar redundancia de componentes. En un sistema de control en lazo cerrado de un servoactuador, las fallas y perturbaciones pueden estar presentes a lo largo de todo el proceso (ver figura 6), por lo cual es recomendado contar con un modelo tolerante a fallas basado en redundancia analítica en el algoritmo de control ¹².

Figura 6. Tipos posibles de falla en un sistema de lazo cerrado³⁷



En el caso de las fallas por ruido o por error de medición en el transductor de po-

sición LVDT, el proceso está siendo afectado por perturbaciones y fallas aditivas³⁸, por lo que con base en la literatura se propone realizar un controlador lineal cuadrático gaussiano (LQG), el cual vincula en su modelo y rechaza estas perturbaciones, buscando mejorar significativamente la tolerancia a estas fallas.

En el presente Capítulo se formula todo el conjunto de ecuaciones que describen el comportamiento del servoactuador hidráulico dinámico; es decir; realizar su modelado matemático. Con base en este modelo se realiza el respectivo diseño del algoritmo de control por medio de un LQG y la respectiva comparación con modelos menos robustos como el LQR o PID. Se realiza la respectiva simulación con el fin observar el comportamiento del sistema y confirmar el correcto desarrollo del modelo para posteriormente tomar datos y realizar pruebas y ajustes en el controlador y finalmente implementarlo en el banco del laboratorio de dinámica estructural del grupo DICBoT.

4.1. MODELADO DINÁMICO DEL SISTEMA TOLERANTE A FALLAS


Con base en la dinámica del sistema, los componentes (actuador, servoválvula, entre otras) y características físicas (segunda ley de Newton, ley de continuidad) es posible desarrollar un modelo matemático dinámico del mismo.

4.1.1. Modelo dinámico no lineal La representación esquemática del sistema en mención se muestra en la figura 7. Teniendo en cuenta el sistema real y físico y con el fin de desarrollar el modelo dinámico lo más preciso posible, se tiene en cuenta que el actuador hidráulico es de doble vástago y es comandado por una

³⁸ Syed Abu NAHIAN y col. "Modeling and fault tolerant control of an electro-hydraulic actuator". En: *International Journal of Precision Engineering and Manufacturing* 17.10 (2016), págs. 1285-1297. DOI: 10.1007/s12541-016-0153-2.

servoválvula. El objetivo del modelo es que el actuador o el supuesto a mover, siga una trayectoria de desplazamiento x especificada de la forma más precisa y óptima.

Figura 7. Esquema del sistema hidráulico



El modelo dinámico y matemático no lineal se deriva del análisis del actuador y de la servoválvula.

Análisis del actuador Es posible representar la dinámica del movimiento de la carga del actuador aplicándole Ley de Newton sobre el mismo. Se expresa median-

te:

$$M\ddot{x}_p = A_p P_L - B\dot{x}_p - Kx_p \quad (1)$$

donde las constantes M , B y K son la masa de la carga, el coeficiente de fricción viscosa y la rigidez de la carga respectivamente. x_p es el desplazamiento del actuador y A_p el área anular del pistón. P_L es el diferencial de presión en el interior del pistón, definido como $P_L = P_1 - P_2$.

Para la dinámica del actuador es posible al aplicar el principio de continuidad sobre el mismo, obteniendo:

$$Q_L = A_p \dot{x}_p + \frac{V_t}{4\beta} \dot{P}_L \quad (2)$$

donde β es el módulo de Bulk efectivo y V_t el volumen total de fluido hidráulico en el interior de las cámaras del actuador y las tuberías del sistema y Q_L es el flujo suministrado por la servoválvula para mover la carga, definido como $Q_L = (Q_1 + Q_2)/2$.

Análisis de la servoválvula El flujo suministrado por la servoválvula está directamente relacionada con el desplazamiento del spool a través de la siguiente ecuación asumiendo que los orificios son simétricos:

$$Q_L = C_d w x_v \sqrt{\frac{P_S - P_L}{\rho}} \quad (3)$$

donde C_d es el coeficiente de descarga a través de los orificios, w es el gradiente de área del orificio, x_v es el desplazamiento del spool, P_S es la presión de suministro y ρ es la densidad del fluido hidráulico.

La relación entre el voltaje de control y el desplazamiento del spool se obtiene a partir de la siguiente ecuación diferencial de segundo orden:

$$u = \frac{1}{k_v} \left(\frac{1}{\omega_v^2} \ddot{x}_v + \frac{2\zeta_v}{\omega_v} \dot{x}_v + x_v \right) \quad (4)$$

donde k_v , ζ_v y ω_v son la ganancia, el coeficiente de amortiguamiento y la frecuencia natural de la servoválvula y u es el voltaje de control.

4.1.2. Ecuaciones de estado no lineales Usando las ecuaciones (1), (2), (3) y (4) y definiendo los estados del sistema como $x_1 = x_p$, $x_2 = \dot{x}_p$, $x_3 = P_L$, $x_4 = x_v$ y $x_5 = \dot{x}_v$, es posible construir las ecuaciones de estado no lineales de la forma:

$$\dot{x}_1 = x_2 \quad (5)$$

$$\dot{x}_2 = \frac{1}{M} [A_p x_3 - B x_2 - K x_1] \quad (6)$$

$$\dot{x}_3 = \frac{4\beta}{V_t} \left[C_d w x_4 \sqrt{\frac{P_S - x_3}{\rho}} - A_p x_2 \right] \quad (7)$$

$$\dot{x}_4 = x_5 \quad (8)$$

$$\dot{x}_5 = \omega_v^2 \left[k_v u - \frac{2\zeta_v}{\omega_v} x_5 - x_4 \right] \quad (9)$$

4.1.3. Linealización del modelo Para la linealización de las ecuaciones de estados del sistema, es necesario hacerlo alrededor de un punto de operación denotado con el subíndice o .

$$\Delta \dot{x}_1 = \Delta x_2 \quad (10)$$

$$\Delta \dot{x}_2 = \frac{1}{M} [A_p \Delta x_3 - B \Delta x_2 - K \Delta x_1] \quad (11)$$

$$\Delta \dot{x}_3 = \frac{4\beta}{V_t} [k_f \Delta x_4 - k_p \Delta x_5 - A_p \Delta x_2] \quad (12)$$

$$\Delta \dot{x}_4 = \Delta x_5 \quad (13)$$

$$\Delta \dot{x}_5 = \omega_v^2 \left[k_v \Delta u - \frac{2\zeta_v}{\omega_v} \Delta x_5 - \Delta x_4 \right] \quad (14)$$

El prefijo Δ representa una perturbación alrededor del punto de operación, es decir, $\Delta x_p = x_p - x_{po}$. Los coeficientes k_f y k_p son obtenidos de la linealización de la ecuación (?? y son denotan como ganancia en flujo y coeficiente de presión-flujo respectivamente y se representan como:

$$k_f = C_d w \sqrt{\frac{P_S - P_{Lo}}{\rho}} \quad (15)$$

$$k_p = \frac{C_d w x_{vo}}{2\sqrt{\rho(P_S - P_{Lo})}} \quad (16)$$

En las ecuaciones (17) y (18) se enuncian las ecuaciones correspondientes a la representación en espacio de estados del sistema linealizado.

$$\begin{bmatrix} \Delta \dot{x}_1 \\ \Delta \dot{x}_2 \\ \Delta \dot{x}_3 \\ \Delta \dot{x}_4 \\ \Delta \dot{x}_5 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ -K/M & -B/M & A_p/M & 0 & 0 \\ 0 & -4\beta A_p/V_t & -4\beta k_p/V_t & 4\beta k_f/V_t & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & -\omega_v^2 & -2\zeta_v \omega_v \end{bmatrix} \begin{bmatrix} \Delta x_1 \\ \Delta x_2 \\ \Delta x_3 \\ \Delta x_4 \\ \Delta x_5 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ k_v \omega_v^2 \end{bmatrix} [\Delta u] \quad (17)$$

$$\Delta y = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta x_1 \\ \Delta x_2 \\ \Delta x_3 \\ \Delta x_4 \\ \Delta x_5 \end{bmatrix} \quad (18)$$

4.2. DISEÑO DEL ALGORITMO DE CONTROL

4.2.1. Control PID El control PID es una estrategia de control clásica que consta en tres acciones principales. La proporcional incrementa la velocidad con la que el sistema responde, la integral reduce el error en estado estacionario y la derivativa regula la velocidad en la que el error cambia ²⁵. En este caso se utilizará el control PID como comparativo con los otros controladores a desarrollar.

La función de transferencia del controlador se representa en la ecuación (19) :

$$PID(s) = K_p + \frac{K_i}{s} + K_d s \quad (19)$$


Dónde K_p , K_i y K_d son las ganancias proporcional, integral y derivativa respectivamente.

Con el modelo linealizado de la sección anterior se construyó el diagrama de bloques en Simulink de la figura 8 para sintonizar las constantes del controlador PID. Para la sintonización de las ganancias se utilizó la técnica de **Ziegler-Nichols** mediante los siguientes pasos :

- Se establecen las constantes en cero.
- Se aumenta la ganancia proporcional hasta que obtener una respuesta satisfactoria.
- Se aumenta la ganancia integral para corregir el error en estado estacionario.
- Se aumenta la ganancia derivativa para reducir el sobre impulso y las oscilaciones se ajusta la constante derivativa.

Estas constantes fueron debidamente sintonizadas e implementadas en el modelo no lineal del actuador representado en la figura 9

Figura 9. Modelo no lineal en Simulink



4.2.2. Control LQR El control óptimo consiste en obtener un vector de señales de control $\mathbf{u}(t)$ que ante cualquier estado inicial $\mathbf{x}(t_0)$, transfiera el estado a la región deseada en el espacio de estados minimizando el índice de comportamiento³⁹. Es necesario que el sistema sea controlable para garantizar la existencia de un vector de control óptimo; para esto, suponiendo un t_0 , el sistema es controlable si puede transferir desde cualquier estado inicial $\mathbf{x}(t_0)$, a cualquier otro estado mediante un vector de control en un intervalo de tiempo finito ⁴⁰.

Teniendo en cuenta un sistema dinámico lineal de la forma de la ecuación 20:

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \quad (20)$$

La matriz de controlabilidad se define por la ecuación (21):

$$\mathbf{P}_c = \begin{bmatrix} \mathbf{A} & \mathbf{A}\mathbf{B} & \dots & \mathbf{A}^{n-1}\mathbf{B} \end{bmatrix} \quad (21)$$

en donde n es el número de estados que tiene el sistema. Para que se considere que es completamente controlable, el determinante de la ecuación (21) debe ser diferente de cero. Es posible calcular el determinante del sistema con las ecuaciones (17) y (18):

$$\mathbf{P}_c = \begin{bmatrix} \mathbf{A} & \mathbf{A}\mathbf{B} & \mathbf{A}^2\mathbf{B} & \mathbf{A}^3\mathbf{B} & \mathbf{A}^4\mathbf{B} \end{bmatrix} \quad (22)$$

por ende el sistema es controlable, de esta manera con el control LQR se busca encontrar un vector de control óptimo de la forma de la ecuación (23), que minimice

³⁹ K OGATA. *Modern Control Engineering*. 1980.

⁴⁰ C BORRAS, J ORTIZ y J. SARMIENTO. "Dynamic Model and Control Design for a Nonlinear Hydraulic Actuator". En: *ASME 2018 International Mechanical Engineering Congress and Exposition* (2018), pág. 2018.

la función de costos de la ecuación (24):

$$\mathbf{u}(t) = -\mathbf{K}\mathbf{x} \quad (23)$$

$$J = \int_0^{\infty} (\mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{U}^T \mathbf{R} \mathbf{u}) dt \quad (24)$$


Las matrices **Q** y **R** son matrices de penalización de estados; **Q** es una matriz hermitiana definida positiva, semidefinida positiva o simétrica real y penaliza los estados, mientras que **R** es una matriz hermitiana definida positiva o simétrica real y penaliza la señal de control. La matriz **K** es la matriz de ganancias que minimiza la ecuación (24) y con el controlador LQR se busca obtener la matriz **K** óptima, resolviendo la ecuación matricial reducida de Ricatti (Ecuación (25)) con el fin hallar la matriz **P**, para finalmente hallar **K**, mediante el reemplazo de **R** en la ecuación (26)

$$\mathbf{A}^T \mathbf{P} + \mathbf{P} \mathbf{A} - \mathbf{P} \mathbf{B} \mathbf{R}^{-1} \mathbf{B}^T \mathbf{R} + \mathbf{Q} = 0 \quad (25)$$

$$\mathbf{K} = \mathbf{R}^{-1} \mathbf{B}^T \mathbf{P} \quad (26)$$

Se construyó el diagrama de bloques del controlador LQR implementado en el sistema no lineal en Simulink de la figura (10).

Figura 10. Controlador LQR en el modelo no lineal en Simulink



4.2.3. Control LQG El controlador lineal cuadrático gaussiano (LQG) es una técnica de control robusto que considera el análisis de perturbaciones en el sistema y ruidos de medición. Para el diseño del controlador es necesario cumplir con el principio de separación, el cual consiste en la división en dos problemas independientes: un estimador lineal cuadrático (LQE) o filtro de Kalman, con un regulador lineal cuadrático (LQR) ⁴¹.

Para el caso de estudio y del diseño del controlador LQG, se tomará el regulador lineal cuadrático (LQR) y se continuará con el estimador lineal cuadrático (LQE) mediante el diseño de un filtro de Kalman considerando el sistema de la forma de las ecuaciones (27) y (28):

$$\dot{\mathbf{x}} = \mathbf{Ax} + \mathbf{Bu} + \mathbf{v} \quad (27)$$

$$\dot{\mathbf{y}} = \mathbf{Cx} + \mathbf{w} \quad (28)$$

⁴¹ PM MÄÄKILÄ. "Kalman Filtering and Linear Quadratic Gaussian Control PT II". En: (2004), págs. 1-31.

siendo este sistema controlable y observable y siendo $\mathbf{v}$ el ruido blanco gaussiano aditivo sistema y $\mathbf{w}$ el ruido de medición.

En este caso como no se tiene la medición de todos los estados del sistema no es posible considerar $u = -kx$, es por esto que se tiene un vector de estados estimado $\hat{x}$ con un error de estimación ϵ generado por un filtro de Kalman de tal manera que $u = -k_r \hat{x}$ se mantenga óptimo para el desarrollo del problema ²⁰.

Se considera el error de estimación como:

$$\epsilon = x - \hat{x} \quad (29)$$

$$\dot{\epsilon} = \dot{x} - \dot{\hat{x}} \quad (30)$$

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

considerando las ecuaciones (27), (28), (29), (30) y (31) es posible construir:

$$\dot{\hat{x}} = \mathbf{A}\hat{x} + \mathbf{B}\mathbf{K}_r\hat{x} + \mathbf{v} \quad (32)$$

$$\dot{\hat{x}} = \mathbf{A}\hat{x} - \mathbf{B}\mathbf{K}_r\mathbf{x} + \mathbf{B}\mathbf{K}_r(\mathbf{x} - \hat{x}) + \mathbf{v} \quad (33)$$

Para el diseño del filtro de Kalman es necesario incorporar un modelo del disturbio en el controlador para poder hacer que el sistema continúe funcionando a pesar de que esté presente la falla o el disturbio ¹⁵, a esto se le conoce como principio del modelo interno. Se espera que el error de estimación y el vector de estados se mantenga estable a pesar de las perturbaciones y fallas; por esta razón es necesario construir un modelo aumentado que incluya la dinámica de las mismas.

La dinámica del error de estimación está representada mediante la ecuación (35), el modelo de la planta aumentada se representa por la ecuación (36) y la ganancia L del filtro de Kalman es posible diseñarse mediante la ecuación (34)

$$\dot{\hat{\mathbf{x}}} = \mathbf{A}\hat{\mathbf{x}} + \mathbf{B}\mathbf{u} + \mathbf{K}_f\mathbf{y} - \mathbf{K}_f\mathbf{C}\hat{\mathbf{x}} + \mathbf{v} \quad (34)$$

$$\dot{\epsilon} = (\mathbf{A} - \mathbf{K}_f\mathbf{C})\epsilon + \mathbf{v} - \mathbf{K}_f\mathbf{w} \quad (35)$$


$$\begin{bmatrix} \dot{x} \\ \dot{\epsilon} \end{bmatrix} = \begin{bmatrix} (A - BK_r) & BK_r \\ 0 & (A - K_fC) \end{bmatrix} \begin{bmatrix} x \\ \epsilon \end{bmatrix} + \begin{bmatrix} I & 0 \\ I & -K_f \end{bmatrix} \begin{bmatrix} v \\ w \end{bmatrix} \quad (36)$$

Es posible observar que los valores propios del *fullstate* siguen estables mediante el controlador LQR desarrollado, y la dinámica de los estados estimados mantienen los valores propios del filtro de Kalman o estimador LQE.

Con el fin de diseñar el algoritmo de control LQG para que el servoactuador hidráulico sea tolerante a fallas por ruidos y perturbaciones en el transductor de posición, es necesario definir las variables estadísticas de los ruidos y perturbaciones v y w como: V la covarianza de las perturbaciones y W la covarianza del ruido.

Se construyó el diagrama de bloques en Simulink del controlador LQQ y se representa en la figura 11.

Figura 11. Controlador LQG en el modelo no lineal en Simulink



4.3. SIMULACIÓN DEL ALGORITMO DE CONTROL

Para la simulación y el modelo se utilizaron los valores de la mesa sísmica, propiedades y características de los diferentes componentes del sistema servo hidráulico representadas en la tabla 1

Tabla 1. Condiciones de falla.

Nombre	Símbolo	Valor
Masa del sistema	M	85.3[Kg]
Coeficiente de amortiguamiento	C_a	[N s/m]
Constante de Rigidez	K	0[N/m]
Coeficiente de descarga	C_d	0.6
Gradiente de área	ρ	2.0.02075[m]
Ganancia Servoválvula	K_v	4.06E-5 [m/V]
Frecuencia natural	ω_v	150[Hz]
Coeficiente de amortiguamiento	ζ_v	0.7
Diámetro del pistón	D_p	0.0635 [m]
Diámetro del vástago	D_v	0.0445 [m]
Volumen total	V_T	4.34E-4 [m ³]
Módulo de Bulk	β	689E6 [Pa]
Densidad	ρ	2.07E7 [$\frac{kg}{m^3}$]
Presión de suministro	P_s	2.07E7

El controlador PID se sintonizó empíricamente mediante la estrategia de Ziegler-Nichols obteniendo las ganancias representadas por 37:

$$\begin{aligned}
 K_{proporcional} &= 100 \\
 K_{integral} &= 0 \\
 K_{derivativa} &= 0
 \end{aligned}
 \tag{37}$$

El controlador LQR se diseñó con las matrices de penalización P y Q , obteniendo finalmente el vector $K_{control}$ de realimentación de estados. Las matrices Q y R son

representadas en (38) y el vector de realimentación de estados por (39).

$$Q = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0.001 & 0 & 0 & 0 \\ 0 & 0 & 4.534E-15 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (38)$$

$$R = [0.0001]$$

$$K_{control} = 1.0E4 \cdot [0.0100 \quad -0.0023 \quad -0.000 \quad 1.6670 \quad 0.0085] \quad (39)$$

El controlador LQG fue diseñado con los valores V y W , representados en (40)

$$V = 0.01 \cdot \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (40)$$

$$W = 0.005$$

Ejecutando el algoritmo diseñado y realizando la simulación de los tres controladores para señales seno y cuadrada de $0.1[Hz]$ y una amplitud de $x_{set} = 0.125[m]$ con y sin perturbaciones. Las perturbaciones se tomaron como un ruido blanco de amplitud máxima $\pm 10\%$ de x_{set} que afecta directamente la realimentación de la posición x_p al sistema.

Para la señal seno sin perturbaciones, los gráficos de posición, voltaje de control y error absoluto para los tres controladores se representan en las figuras 12, 13 y 14.

Figura 12. Gráfico de Posición vs Tiempo para una señal seno de 0.1[Hz]




Figura 13. Gráfico de Voltaje vs Tiempo para una señal seno de 0.1[Hz]





Figura 14. Gráfico de Error vs Tiempo para una señal seno de 0.1[Hz]



Para la señal seno con perturbaciones, los gráficos de posición, voltaje y error para los tres controladores se representan en las figuras 15, 16 y 17.

Figura 15. Gráfico de Posición vs Tiempo para una señal seno de 0.1[Hz] con perturbación




Figura 16. Gráfico de Voltaje vs Tiempo para una señal seno de 0.1[Hz] con perturbación





Figura 17. Gráfico de Error vs Tiempo para una señal seno de 0.1[Hz] con perturbación



Para la señal cuadrada sin perturbaciones, los gráficos de posición, voltaje y error para los tres controladores se representan en las figuras 18, 19 y 20.

Figura 18. Gráfico de Posición vs Tiempo para una cuadrada de 0.1[Hz]




Figura 19. Gráfico de Voltaje vs Tiempo para una cuadrada de 0.1[Hz]





Figura 20. Gráfico de Error vs Tiempo para una cuadrada de 0.1[Hz]



Para la señal cuadrada con perturbaciones, los gráficos de posición, voltaje y error para los tres controladores se representan en las figuras 21, 22 y 23.

Figura 21. Gráfico de Posición vs Tiempo para una cuadrada de 0.1[Hz] con perturbación




Figura 22. Gráfico de Voltaje vs Tiempo para una cuadrada de 0.1[Hz] con perturbación





Figura 23. Gráfico de Error vs Tiempo para una cuadrada de 0.1[Hz] con perturbación



4.4. TOMA DE DATOS Y REALIZACIÓN DE PRUEBAS

Para la toma de datos y realización de pruebas de la implementación de los algoritmos de control anteriormente diseñados y simulados, se utilizó la mesa sísmica hidráulica uniaxial del Laboratorio de Sistemas Dinámicos compuesta de una unidad de potencia MTS SilentFlo 910, un cilindro Parker de alta repuesta dinámica, un transductor de posición *LVDT* con su demodulador, una servoválvula Moog 76-263 con su sistema de amplificación, una tarjeta de adquisición de datos y prototipo rápido Quanser Q8-USB, un computador con los software Matlab y Simulink y drivers necesarios para la ejecución del script y fuentes auxiliares para el montaje eléctrico e hidráulico de las figuras 24 y 25.

Figura 24. Esquema eléctrico e hidráulico del sistema




Figura 25. Representación física del sistema del grupo DICBoT




Se caracterizó del transductor de posición LVDT tomando tres puntos sobre el actuador, midiendo la señal de voltaje que el transductor arrojaba y posición del cilindro en ese instante. Estos puntos son representados en la tabla 2 y teniendo en cuenta que el recorrido total del actuador es de 2[in] (254[mm]), se obtuvo la gráfica de la figura 26.

Tabla 2. Datos para caracterización del LVDT.

Señal del LVDT [V]	Posición [m]
7.650	-0.127
6.610	0.000
5.546	0.127


Figura 26. Recta y ecuación característica del LVDT



Con el fin de tener una medición precisa y comparar los controladores adecuadamente, los algoritmos de control diseñados fueron implementados en Simulink con el Software Quarc, junto con un control proporcional P básico para centrar el cilindro en ($x_p = [0]$) y un sistema de cambio automático del controlador.


Se creó en Simulink una señal de ruido blanco con una frecuencia de 10[Hz] y una amplitud que oscila entre $\pm 5\%$ del *setpoint* establecido (0.125[m]). Esta señal de perturbación simula las fallas aditivas en el transductor de posición y se añadió directamente en el lazo de realimentación de la posición. Esta señal fue creada para garantizar que todos los algoritmos sean afectados por exactamente la misma señal de perturbación.

Figura 27. Representación de las fallas inducidas en el sistema



El nuevo diagrama del controlador PID implementado en la mesa sísmica se representa en la figura 28. Para mejorar el desempeño fue necesario modificar las constantes experimentalmente, las ganancias sintonizadas del PID en este caso están representadas por la figura 41 y fueron sintonizadas según el método de Ziager-Nichols enunciado anteriormente. Se destaca que al no contar con ganancia derivativa es un controlador PI.

Figura 28. Diagrama de Bloques del controlador PID en el software Quarc



$$\begin{aligned}
 K_{proporcional} &= 92 \\
 K_{integral} &= 0.7 \\
 K_{derivativa} &= 0
 \end{aligned}
 \tag{41}$$

Para poder realizar la implementación del controlador LQR en la mesa sísmica es necesario diseñar un observador de estados de orden completo, para estimar estados del sistema ya que no se cuenta con una medición completa directa. Conociendo que el sistema es de la forma de la ecuación (17), que es controlable y observable, y que el estado a controlar es x_1 , se define el modelo matemático del

observador como:

$$\dot{\tilde{x}} = A\tilde{x} + Bu + K_e(y - C\tilde{x}) = (A - K_eC)\tilde{x} + Bu + K_ey \quad (42)$$

Donde $\tilde{x}$ es el vector de estado estimado y $C\tilde{x}$ es la salida estimada. Las entradas al observador son la salida y y la entrada de control u . K_e es la matriz de ganancia del observador y es una matriz de ponderación al término de corrección que involucra la diferencia entre la salida medida y la salida estimada ³⁹.

El error del observador se obtiene al restar las ecuaciones (17) y (42) y se define la diferencia entre $\dot{x}$ y $\dot{\tilde{x}}$ como el error e , entonces:

$$\dot{e} = \dot{x} - \dot{\tilde{x}} = (A - K_eC)(x - \tilde{x}) = (A - K_eC)e \quad (43)$$

El problema matemático del diseño del observador de orden completo es el mismo del de asignación de polos, de tal manera que es posible ajustar el comportamiento dinámico según los valores propios deseados. El método de asignación de polos recomienda seleccionarlos al menos 5 veces **mas grandes** que el polo más lento del controlador. En este caso, después de repetidas simulaciones, se escogieron los polos sobre el eje x del semiplano negativo representados en la ecuación (44)

$$\begin{aligned} \mu_1 &= -650 \\ \mu_2 &= -651 \\ \mu_3 &= -652 \\ \mu_4 &= -653 \\ \mu_5 &= -654 \end{aligned} \quad (44)$$

Sea el sistema definido por las ecuaciones 17 y 18, al diseñar el observador de orden completo se obtiene la solución del problema de asignación de polos para el

sistema dual dado por las ecuaciones:

$$\dot{\mathbf{z}} = \mathbf{A}^* \mathbf{z} + \mathbf{C}^* v \quad (45)$$

$$n = \mathbf{B}^* \mathbf{z} \quad (46)$$

Donde la señal de control v es $v = -\mathbf{K}\mathbf{z}$.

La matriz de ganancias de realimentación $\mathbf{K}$ se determina de forma que la matriz $\mathbf{A}^* - \mathbf{C}^* \mathbf{K}$ produzca un conjunto de valores propios deseados $(\mu_1, \mu_2, \dots, \mu_n)$. Ya que el polinomio característico y el del observador tienen valores propios iguales, es posible decir que $\mathbf{K}_e = \mathbf{K}^*$.

Para el cálculo de la matriz de ganancias del observador es importante tener en cuenta la fórmula de Ackermann enunciada en (47)

$$\mathbf{K} = \begin{bmatrix} 0 & 0 & \dots & 0 & 1 \end{bmatrix} \begin{bmatrix} \mathbf{C}^* & \mathbf{A}^* \mathbf{C}^* & \dots & (\mathbf{A}^*)^{n-1} \mathbf{B} \end{bmatrix}^{-1} \phi(\mathbf{A}) \quad (47)$$

Finalmente es posible obtener la matriz de ganancias del observador mediante $\mathbf{K}^*$ en la ecuación (48)

$$\mathbf{K}_e = \mathbf{K}^* = \phi \mathbf{A}^{**} = \begin{bmatrix} \mathbf{C} \\ \mathbf{CA} \\ \vdots \\ \mathbf{CA}^{n-2} \\ \mathbf{CA}^{n-1} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix} = \phi(\mathbf{A}) \begin{bmatrix} \mathbf{C} \\ \mathbf{CA} \\ \vdots \\ \mathbf{CA}^{n-2} \\ \mathbf{CA}^{n-1} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 1 \end{bmatrix} \quad (48)$$


Donde ϕ es el polinomio característico para el observador $\phi(s) = (s - \mu_1)(s - \mu_2) \dots (s - \mu_n)$. La matriz de ganancias del observador obtenida mediante la formula de Ack-

man es representada en (49)

$$\mathbf{K}_e = \begin{bmatrix} -2.857E2 \\ 2.479E6 \\ -2.799E14 \\ 2.5015E2 \\ -3.245E4 \end{bmatrix} \quad (49)$$

Finalmente el nuevo diagrama del controlador LQR con el observador implementado en la mesa sísmica se representa en la figura (29), las nuevas matrices de penalización P y Q sintonizadas en la ecuación (50), y la matriz de realimentación en (51)

Figura 29. Diagrama de Bloques del controlador LQR en el software Quarc



$$Q = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1E-5 & 0 & 0 & 0 \\ 0 & 0 & 4.534E-15 & 0 & 0 \\ 0 & 0 & 0 & 1E-5 & 0 \\ 0 & 0 & 0 & 0 & 1E-5 \end{bmatrix} \quad (50)$$

$$R = [0.0001]$$


$$K_{control} = 1.0E4 \cdot [0.0100 \quad -0.0024 \quad -0.000 \quad 4.3170 \quad 0.0002] \quad (51)$$

El nuevo diagrama del controlador LQG implementado en la mesa sísmica se representa en la figura 30. Las constantes fueron modificadas experimentalmente para sintonizar correctamente el algoritmo y tener el mejor desempeño posible; los valores de V y W se enuncian en la ecuación (52) y la matriz de ganancias del Filtro de Kalman utilizado se enuncia en la ecuación (52):

Para la sintonización del controlador LQG se resalta que:

- Se tomaron las mismas matrices Q y R de penalidad del regulador lineal cuadrático
- Se asumieron las **propiedades** estadísticas de los posibles ruidos:
- Modificación gradual por **prueba y error** mediante repetidas simulaciones hasta alcanzar un desempeño y respuesta deseada.

Figura 30. Diagrama de Bloques del controlador LQG en el software Quarc



$$V = 0.1 \cdot \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (52)$$

$$W = 0.0041$$

$$K_{control} = 1.0E8 \cdot \begin{bmatrix} 0.000 & 0.000 & -2.789 & 0.000 & 0.000 \end{bmatrix} \quad (53)$$

4.5. IMPLEMENTACIÓN DEL SISTEMA DE CONTROL

Para la señal seno sin perturbaciones, los gráficos de posición, voltaje de control y error absoluto para los tres controladores se representan en las figuras 31, 32 y 33.

Figura 31. Gráfico de Posición vs Tiempo para una señal escalón




Figura 32. Gráfico de Voltaje vs Tiempo para una señal escalón




Figura 33. Gráfico de Error vs Tiempo para una señal señal escalón




Figura 34. Gráfico de Posición vs Tiempo para una señal escalón con perturbación




Figura 35. Gráfico de Voltaje vs Tiempo para una señal escalón con perturbación




Figura 36. Gráfico de Error vs Tiempo para una señal escalón con perturbación




Figura 37. Gráfico de Posición vs Tiempo para una señal seno de 0.25[Hz]




Figura 38. Gráfico de Voltaje vs Tiempo para una señal seno de 0.25[Hz]




Figura 39. Gráfico de Error vs Tiempo para una señal seno de 0.25[Hz]




Figura 40. Gráfico de Posición vs Tiempo para una señal seno de 0.25[Hz] con perturbación




Figura 41. Gráfico de Voltaje vs Tiempo para una señal seno de 0.25[Hz] con perturbación




Figura 42. Gráfico de Error vs Tiempo para una señal seno de 0.25[Hz] con perturbación




Figura 43. Gráfico de Posición vs Tiempo para una señal cuadrada de 0.25[Hz]




Figura 44. Gráfico de Voltaje vs Tiempo para una señal cuadrada de 0.25[Hz]




Figura 45. Gráfico de Error vs Tiempo para una señal cuadrada de 0.25[Hz]




Figura 46. Gráfico de Posición vs Tiempo para una señal cuadrada de 0.25[Hz] con perturbación




Figura 47. Gráfico de Voltaje vs Tiempo para una señal cuadrada de 0.25[Hz] con perturbación





Figura 48. Gráfico de Error vs Tiempo señal cuadrada de 0.25[Hz] con perturbación



De las gráficas 31, 32 y 33 es posible afirmar que tanto el controlador PID como el LQR logran llegar al valor deseado en $0.8[s]$, mientras que el controlador LQG tarda $1.35[s]$ en lograrlo, además de presentar un pequeño porcentaje de overshoot de aproximadamente 4 %. A pesar de esto, el controlador LQG es el que menor error absoluto y en estado estacionario posee, además de tener un consumo energético ligeramente menor a los demás.


De la respuesta ante perturbaciones de las figuras 34, 35 y 36 se observa que el controlador PID y LQR están afectados significativamente por la perturbación en el transductor de posición, mientras que el controlador LQG se mantiene operativo con pequeñas oscilaciones, tolerando y amortiguando las fallas presentes. De igual forma se observa también que la señal de control es totalmente suavizada y no varía con la frecuencia de las perturbaciones, reduciendo notablemente el consumo energético y el error.

En las figuras 37, 38 y 39 se evidencia que aunque los tres controladores logran realizar un buen seguimiento de la señal deseada y rápida respuesta, el controlador LQG es ligeramente más rápido, reduciendo el error de seguimiento y teniendo un mejor desempeño. También es importante destacar que la señal de control para este escenario en los controles PID y LQR tienen oscilaciones notorias, las cuales se reflejan en un mayor consumo energético.

En las figuras 40, 41 y 42 se representa la respuesta ante perturbaciones en las que nuevamente el controlador LQG es el único capaz de tolerar las fallas por ruido presentes en el transductor de posición, al no presentar movimientos bruscos o indeseados y que pongan en riesgo alguna parte del proceso, obteniendo una gran reducción en el error y en el consumo de la señal de control, al no presentar oscilaciones y cambios repentinos de voltaje, siendo éste más seguro y beneficioso para cualquier proceso.

El comportamiento de los controladores para la señal cuadrada, representado en las figuras 43, 44 y 45 es muy similar a la respuesta escalón, a diferencia en que tanto el error absoluto como el voltage promedio de control para el controlador LQG se reducen debido al cambio periódico de la señal. De igual manera pasa para el caso de estar el sistema en fallo de las figuras 46, 47 y 48


Figura 8. Modelo linealizado en Simulink



5. MODELO DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS EN EL SELLO DEL PISTÓN DE UN SERVOACTUADOR

Para los sistemas de detección y diagnóstico de fallas en general, no es fundamental o no se requiere conocer específicamente el funcionamiento o la estructura interna del proceso o sistema, sólo tener una relación entre la señal de entrada y la de salida. Las redes neuronales artificiales son un modelo matemático inspirado a partir de la sinapsis de las neuronas del cerebro, diseñado como herramienta de aprendizaje automático e inteligente y construido como un mapa de aprendizaje que relaciona matemáticamente la entrada con la salida ⁴. Es por eso que con el paso de los años se han convertido en una de las técnicas más utilizadas para la detección y diagnóstico de fallas debido a su practicidad, versatilidad y posibilidad de variar diferentes parámetros, manteniendo el esquema general de la neurona (ver Figura 49).


Figura 49. Modelo general de una neurona con sus posibles modificaciones



Es posible realizar una clasificación de las redes neuronales artificiales según su

entrada o salida de datos, tipo de entrenamiento y su regla de aprendizaje. El aprendizaje supervisado permite deducir una función a partir de la relación y el entrenamiento de la red con datos de entrada y salida. El objetivo del aprendizaje supervisado es el de crear una función capaz de predecir el valor correspondiente a cualquier objeto de entrada válida después de haber visto una serie de ejemplos ⁴². Por otro lado, el aprendizaje no supervisado modela las entradas como variables aleatorias, construyendo un modelo de densidad para un conjunto de datos, un *cluster* o una agrupación de los datos. Se tienen otros tipos derivados de estos o que combinan o refuerzan su estructura, como el aprendizaje reforzado o el aprendizaje híbrido. De manera general, es posible clasificar las redes neuronales artificiales según la figura 50

Figura 50. Clasificación de los modelos de redes neuronales



En el presente Capítulo se lleva a cabo lo correspondiente con el desarrollo del modelo de detección y diagnostico de fallas en el sello del pistón del servoactuador

⁴² S KOTSIANTIS, I. ZAHARAKIS y P. PINTELAS. "Paper 1 (20)". En: *Artificial Intelligence Review* 26 (2006), págs. 159-190. DOI: 10.1007/s10462-007-9052-3. arXiv: /www.informatica.si/index.php/informatica/article/view/148 [http:].


hidráulico dinámico del laboratorio de Dinámica Estructural del grupo DICBoT. Se inició por la adquisición y almacenamiento de datos en los cinco estados de falla a analizar, para posteriormente realizar el respectivo procesamiento de la señal y extracción de características, con el fin diseñar el algoritmo de detección y diagnóstico de fallas por medio de redes neuronales artificiales y finalmente realizar la validación del algoritmo de detección y diagnóstico de fallas diseñado.

5.1. ADQUISICIÓN Y ALMACENAMIENTO DE DATOS EN DIFERENTES ESTADOS DE FALLA

Para la adquisición y almacenamiento de los datos en las cinco diferentes condiciones de falla, se utilizó la mesa sísmica uniaxial del Laboratorio de Sistemas Dinámicos de la sección 4.4. Se diseñó e implementó en la mesa sísmica un sistema de conexión o *bypass* entre las dos cámaras, unidos por una válvula de aguja de doble paso *Parker 10V2071-HC* con el fin de lograr la simulación de las fugas internas en las dos cámaras del cilindro, haciendo posible dicha simulación en las cinco diferentes condiciones de falla deseadas. La válvula para tubería de $\frac{1}{4}$ " cuenta con coeficiente de descarga $c_v = 0.20$, un diámetro del orificio de $d = 3.18[mm]$.

Para la toma de datos fue necesario realizar un control proporcional **P** con base al modelo matemático realizado en el capítulo anterior y crear el diagrama de bloques en Simulink de la figura 51, teniendo en cuenta que los datos de entrada (Analog Input) son los datos del transductor de posición LVDT y los datos de salida (Analog Output) son los que van hacia la servoválvula con el fin de lograr la posición deseada, en este caso 2 [in].

Figura 51. Diagrama de bloques para la toma de datos




Se almacenaron datos de posición y tiempo por medio de la tarjeta QUANSER Q8-USB en grupos de cinco vectores con el fin de reducir los errores humanos y de instrumentación. Estos datos fueron tomados para una amplitud de cuatro pulgadas y frecuencias de 0.2Hz, 1Hz y 5Hz para onda cuadrada y sinusoidal en diferentes condiciones de falla, las cuales son enunciadas en la tabla 3:

Tabla 3. Condiciones de falla.

Condición de falla	Flujo de fugas internas
Sin desgaste	0 %
Desgaste leve	25 %
Desgaste medio	50 %
Desgaste alto	75 %
Desgaste crítico	100 %


El porcentaje de flujo de fugas internas está directamente relacionado con la curva de apertura de la válvula representada en la figura 52.

Figura 52. Curva de flujo de la válvula⁴³



Estos datos de posición y tiempo fueron tomados para cada condición de falla en dos bloques o *sets* de datos. El primero se utiliza exclusivamente para el diseño del algoritmo de detección, diagnóstico y clasificación de fallas, y el otro para realizar la validación del algoritmo. Fueron almacenados archivos *.mat* con los respectivos datos para los seis diferentes tipos de señales (Cuadrada 0.2 Hz, Cuadrada 1 Hz, Cuadrada 5 Hz, Seno 0,2 Hz, Seno 1Hz y Seno 5 Hz respectivamente) y seguidamente se promediaron los cinco vectores de posición tomados para cada caso de estudio, quedando el archivo listo para cargar y trabajar de la figura 53 .

Figura 53. Libro de los datos tomados



Las matrices cargadas son las enunciadas en la figura 53 y pueden ser fácilmente cargadas mediante *load*, estando estas listas para trabajar.

5.2. DISEÑO DEL ALGORITMO DE DETECCIÓN Y DIAGNÓSTICO DE FALLAS

5.2.1. Procesamiento de la señal y selección de características Se graficaron los datos de los seis tipos de señales diferentes bajo las cinco condiciones de falla posibles y se muestran en las figuras 54, 55 y 56.

Figura 54. Señal de posición en cinco condiciones de falla a 0.2 Hz para tipo cuadrada y seno




Figura 55. Señal de posición en cinco condiciones de falla a 1 Hz para tipo cuadrada y seno





Figura 56. Señal de posición en cinco condiciones de falla a 5 Hz para tipo cuadrada y seno



Debido a que no es muy notoria la diferencia entre cada tipo de falla en cada tipo de señal estudiada, y que no es recomendable utilizar matrices de entrada muy grandes a la red neuronal; es necesario realizar el respectivo procesamiento de las señales y extracción de sus características principales con el fin de reducir considerablemente los datos de entrada y por ende el gasto computacional.

La extracción de características es un proceso en el cual se toman datos que caracterizan y hacen diferente a una señal de otra similar a simple vista. En este caso se escogieron las siguientes características a extraer:

- Valor RMS: El valor cuadrático medio es una medida estadística de la magnitud de una cantidad variable. Puede calcularse para una serie de valores discretos o para una función matemática de variable continua.

Algunas veces la variable toma valores positivos y negativos, como ocurre, por ejemplo, en los errores de medida. En tal caso se puede estar interesado en obtener un promedio que no recoja los efectos del signo. Este problema se resuelve, mediante la denominada media cuadrática. Consiste en elevar al

cuadrado todas las observaciones (así los signos negativos desaparecen), en obtener después su media aritmética y en extraer, finalmente, la raíz cuadrada de dicha media para volver a la unidad de medida original. La desviación estandar es una media cuadrática.

$$x_{rms} = \sqrt{\frac{\sum_{k=1}^K (x(k))^2}{K}} \quad (54)$$

- Rango intercuantil: Representa la diferencia entre el tercer cuanti(Q_3) y el primer cuantil Q_1 y se utiliza para visualizar la varianza de una variable y se representa por:

$$RQ = Q_3 - Q_1 \quad (55)$$

- Valor máximo: Corresponde al mayor valor positivo en los datos de estudio

$$x_{max} = \max(x) \quad (56)$$

- Valor mínimo: Valor máximo: Corresponde al mínimo valor negativo en los datos de estudio

$$x_{max} = \min(x) \quad (57)$$

- PCA: El análisis de los componentes principales intenta describir un conjunto de datos en términos de nuevas variables o componentes no relacionadas, generando una distribución normal multivariante con dos ejes de componentes principales.
- Valor medio: Corresponde al valor representativo central de observaciones secuenciales y estrechamente relacionadas entre sí, tales como tasas de: interés, inflación, devaluación, variación, crecimiento, disminución. El promedio

geométrico de los valores:

$$x_m = \frac{1}{K} \sum_{i=1}^K x(k) \quad (58)$$

- **Curtosis:** Es una medida estadística que describe el apuntamiento o achataamiento de una cierta distribución con respecto a una distribución normal. La kurtosis positiva indica una distribución relativamente apuntada, y la negativa indica una distribución relativamente achatada. En una distribución normal la kurtosis es igual a 3, a los valores mayores a 3 se los llama kurtosis excesiva. El caso de kurtosis excesiva indica que hay una mayor probabilidad de que los retornos observados estén más alejados de la media que en una distribución normal. Leptokurtosis se denomina al atributo de una distribución con muy altos índices de kurtosis⁴⁴.

$$x_{kurto} = \frac{\sum_{k=1}^K (x(k) - x_m)^4}{(K - 1)x_{std}^3} \quad (59)$$

- **Skewness:** La oblicuidad (*Skewness*) es una medida estadística que describe la simetría de la distribución alrededor de un promedio. Si el sesgo es igual a cero, la distribución es simétrica; si el sesgo es positivo la distribución una tendrá una cola asimétrica extendida hacia los valores positivos. Un sesgo negativo indica una distribución con una cola asimétrica extendida hacia los valores negativos.

$$x_{skew} = \frac{\sum_{k=1}^K (x(k) - x_m)^3}{(K - 1)x_{std}^3} \quad (60)$$

- **Envolvente:** En física e ingeniería, la envolvente de una señal oscilante es una curva suave la cual rodea sus extremos. Esta generalmente generaliza el

⁴⁴ "Minimum variance control (AALTO UNIVERSITY)". En: (2015), págs. 1-10.

concepto de una frecuencia constante.

- Desviación estándar: La desviación estándar es la medida de dispersión más común, que indica qué tan dispersos están los datos con respecto a la media. Mientras mayor sea la desviación estándar, mayor será la dispersión de los datos.

El símbolo (sigma) σ se utiliza frecuentemente para representar la desviación estándar de una población, mientras que s se utiliza para representar la desviación estándar de una muestra. La variación que es aleatoria o natural de un proceso se conoce comúnmente como ruido.

La desviación estándar se puede utilizar para establecer un valor de referencia para estimar la variación general de un proceso.

$$x_{std} = \sqrt{\frac{\sum_{k=1}^K (x(k) - xm)^2}{K - 1}} \quad (61)$$

Debido a que el tipo de datos es de forma periódica y no de distribución normal, características como el rango intercuantil, PCA, Curtosis, Skweness y Varianza darían datos erróneos o sin sentido, es por esto que finalmente se escogieron las siguientes características a trabajar:

- Valor RMS
- Valor máximo
- Desviación estándar
- Envolvente
- Valor mínimo

Para que una red neuronal pueda desarrollarse y lograr el objetivo principal que es clasificar y clusterizar los datos, es necesario ingresar al menos más de un espécimen por caso de estudio. En este caso se tomarán tres especímenes por caso de estudio, dividiendo la señal tomada en tres secciones y ejecutando el algoritmo de extracción de características realizado, con en fin de tener una matriz de características.

Se organizaron los tres vectores de características por cada caso de estudio; al ser 6 tipos de señal estudiadas y 5 escenarios de falla por tipo de señal, se tienen 30 casos de estudio, obteniendo como resultado una matriz de características de (5x90). Para el caso de la matriz de objetivos o Target se organizaron 30 filas, una por cada caso de estudio, esperando que la red neuronal sea capaz de clasificar cada uno de los treinta tipos, de modo que la matriz de objetivos o Target quedaría de (30x90)

5.2.2. Diseño de la arquitectura de la red neuronal La gran demanda de sistemas de detección de fallas atrae la atención de muchas aplicaciones complejas, costosas y esenciales para nuestro diario vivir, como sistemas de potencia, aeronáutica y redes de telecomunicación. Los sistemas tradicionales de diagnóstico de fallas eran basados en la redundancia de hardware y lógica; con el rápido desarrollo de sistemas digitales de computación y procesamiento de señales, los sistemas de detección y diagnóstico de fallas basados en redundancia funcional (aproximación de software) está empezando a incrementar su uso y popularidad.⁴⁵

⁴⁵ R. SONG. "Fault Detection and Isolation in Fluid Power Systems Using a Parametric Estimation Method". En: (2002), págs. 144-149.

Se desarrollaron las tres redes neuronales más comúnmente utilizadas en la literatura frente al problema de la detección y diagnóstico de las fallas con el fin de determinar la mejor opción para la respectiva solución del problema. Estas redes a utilizar fueron:

- Red Perceptron Multicapa de 1 capa oculta
- Red Perceptron Multicapa de 2 capas ocultas
- Red Lineal Adaptativa (Adaline)


Diseño de la arquitectura de la red Adaline Se construyó una red Adaptativa Lineal (Adaline) respetando la arquitectura general de la misma, utilizando una sola capa n de neuronas, de $m = n$ salidas; una matriz x de entrada perteneciente al espacio R^i . Por cada neurona en la red, corresponde una matriz w de pesos que relaciona directamente la entrada con la salida de la neurona y una constante b o *bias*⁴⁶. Es posible describir la salida de la red neuronal mediante la función de activación de la ecuación (62) :

$$y = \sum_{i=1}^n x_i w_i \quad (62)$$

Para el caso de estudio se tiene como matriz de entrada la matriz de características **p** de dimensión $[5 \times 90]$, una capa de $n = 30$ neuronas lineales (función de transferencia *purelin*) y una matriz de objetivos t de dimension $[30 \times 90]$ con un esquema general representado en la figura 57. Denotando la salida de la red neuronal como a , ésta se puede escribir mediante la ecuación (63:)

⁴⁶ C BORRAS. "Pattern Recognition in Hydraulic Backlash using Neuronal Network". En: *University of Oklahoma* 1 (2001), pág. 113. DOI: 10.1017/CB09781107415324.004. arXiv: arXiv:1011.1669v3.

Figura 57. Diagrama de la arquitectura de la Red Adeline



$$a = \text{purelin}(n) = Wp + b \quad (63)$$

Para el entrenamiento de la red neuronal se utilizó el método de descenso por gradiente basado el cual actualiza las matrices de los pesos y el bias según las ecuaciones (64) y (65)

$$W(k+1) = W(k) + 2\alpha e(k)p^T(k) \quad (64)$$

$$b(k+1) = b(k) + 2\alpha e(k) \quad (65)$$

Donde α es la constante de aprendizaje, k es el número de iteraciones y e es el error de cada iteración. El valor inicial de la matriz de pesos y el bias es cero y se realizan $k = 1, 2, \dots, N$ iteraciones hasta que se cumple con la condición del error cuadrático medio (algoritmo *LMS*). El error en cada iteración es calculado mediante la ecuación (66)

$$e(k)^2 = (t - (Wp(k) + b))^2 \quad (66)$$


Diseño de la arquitectura de la red Perceptrón Multicapa con una capa oculta

Se construyó una red Perceptrón Multicapa con $m = 1$ capas ocultas de $n = 30$ neuronas en la capa oculta, la matriz de entrada p y la matriz de objetivos t . Se estableció la función de transferencia de la red como la función *sigmoid* la cual relaciona la entrada con la salida según la ecuación (67)

$$a = \text{logsig}(n) = \frac{1}{e^{Wp+b}} \quad (67)$$

Para este tipo de problema y debido al tipo de red, se recomienda utilizar el método de entrenamiento basado en *backpropagation*^{47 31}. esquema de la red se representa en la figura 58 y la ecuación general de salida de la red en cada capa se representa en la ecuación (68)

Figura 58. Diagrama de la arquitectura de la Red Perceptron Multicapa con una capa oculta



Para una red con m capas, es posible representar la salida de cada capa mediante la ecuación 68, la salida en la primera capa se representa como $a^0 = p$ y en la última como $a = p^m$.

⁴⁷ M HAGAN, H DEMUTH y B HE. "Neural network design". En: (1996).

$$a^{m+1} = f^{m+1}(W^{m+1}a^m + b^{m+1}) = 0, 1, \dots, (m-1) \quad (68)$$

El algoritmo *Backpropagation* utiliza el error cuadrático medio como índice de desempeño; de esta manera utilizando el método de descenso por gradiente se representa este índice de desempeño en la iteración k en la ecuación (69).

$$\hat{F}(x) = (t(k) - a(k))^T(t(k) - a(k)) = e^T(k)e(k) \quad (69)$$

La matriz de peso y bias según el método de descenso por gradiente se representa en (70) y (71):

$$W_{i,j}^m(k+1) = W_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial W_{i,j}^m} \quad (70)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (71)$$

Según la regla de la cadena, es posible representar las ecuaciones (70) y (71) como (72) y (73) :

$$\frac{\partial \hat{F}}{\partial W_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \cdot \frac{\partial n_i^m}{\partial W_{i,j}^m} \quad (72)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \cdot \frac{\partial n_i^m}{\partial b_i^m} \quad (73)$$

La sensibilidad s_i^m de $\hat{F}$ a cambios en el i esimo elemento de la red en la capa m se define como:

$$s_i^m = \frac{\partial \hat{F}}{\partial n_i^m} \quad (74)$$

De esta manera las ecuaciones (72) y (73) se reemplazan por (75) y (76)

$$\frac{\partial \hat{F}}{\partial W_{i,j}^m} = s_i^m a_j^{m-1} \quad (75)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m \quad (76)$$

Entonces la relación de la matriz de sensibilidad se puede expresar por la ecuación (77):

$$S^M = -2\dot{F}^M(n^M)(t - a) \quad (77)$$

Las nuevas fórmulas de actualización de las matrices de peso y bias mediante el descenso de gradiente se representan en (78) y (79)

$$W^m(k+1) = W^m(k) - \alpha S^m(a^{m-1})T \quad (78)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (79)$$

En donde

$$s^m = \frac{\partial \hat{F}}{\partial n^m} = [\frac{\partial \hat{F}}{\partial n_1^m}, \frac{\partial \hat{F}}{\partial n_2^m}, \dots, [\frac{\partial \hat{F}}{\partial n_1^m}, \frac{\partial \hat{F}}{\partial n_2^m}, \dots, \frac{\partial \hat{F}}{\partial n_{s^m}^m}]^T \quad (80)$$

Para derivar la relación de las sensibilidades se utiliza la matriz jacobiana de la

ecuación (81)

$$\frac{\partial n^{m+1}}{\partial n^m} = \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_1^{m+1}}{\partial n_{sm}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_2^{m+1}}{\partial n_{sm}^m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial n_{sm}^{m+1}}{\partial n_1^m} & \frac{\partial n_{sm}^{m+1}}{\partial n_2^m} & \dots & \frac{\partial n_{sm}^{m+1}}{\partial n_{sm}^m} \end{bmatrix} \quad (81)$$

considerando el elemento i, j en la matriz:

$$\frac{\partial n_1^{m+1}}{\partial n_1^m} = w_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} = w_{i,j}^{m+1} \dot{f}_m(n_j^m) \quad (82)$$

De esta manera, la ecuación(81) puede ser reescrita como:

$$\frac{\partial n^{m+1}}{\partial n^m} = W^{m+1} \dot{F}^M(n^m) \quad (83)$$

En donde:

$$\dot{F}^M(n^m) = \begin{bmatrix} \dot{f}^m(n_1^m) & 0 & \dots & 0 \\ 0 & \dot{f}^m(n_2^m) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \dot{f}^m(n_{sm}^m) \end{bmatrix} \quad (84)$$

Estas sensibilidades son propagadas hacia atrás desde la última a la primera capa según lo representa la ecuación (85)

$$s^m \rightarrow s^{m-1} \rightarrow \dots \rightarrow s^2 \rightarrow s^1 \quad (85)$$

La nueva relación de la sensibilidad se puede escribir mediante la ecuación

$$\begin{aligned} s^m &= \frac{\partial \hat{F}}{\partial n^m} = \left(\frac{\partial n^{m+1}}{\partial n^m} \right)^T \frac{\partial \hat{F}}{\partial n^{m+1}} \\ s^m &= \dot{F}^m(n^m) (W^{m+1})^T s^{m+1} \end{aligned} \quad (86)$$

Esta relación es iniciada en la capa final de la red según la ecuación (87)

$$\begin{aligned} s_i^m &= \frac{\partial \hat{F}}{\partial n_1^m} = \left(\frac{\partial ((t-a)^T (t-a))}{\partial n^M} \right) = \frac{\sum_{j=1}^{S^M} (t_j - a_j)^2}{\partial n_j^M} \\ &= -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} = -2(t_i - a_i) \dot{f}^m(n_i^m) \end{aligned} \quad (87)$$

Quedando la ecuación general representada en (88)

$$s^M = -2\dot{F}^M(n^M)(t - a) \quad (88)$$

Diseño de la arquitectura de la red Perceptrón Multicapa con dos capa oculta


Se construyó una red Perceptrón Multicapa con $m = 2$ capas ocultas de $n_1 = 32$ y $n_1 = 16$ neuronas en la capa oculta, la matriz de entrada p y la matriz de objetivos t . Se estableció la función de transferencia de la red como la función *sigmoid* la cual relaciona la entrada con la salida según la ecuación (89)

$$\begin{aligned} a_1 &= \text{logsig}(n) \\ a_2 &= \text{logsig}(n) \end{aligned} \quad (89)$$

El esquema de esta red se representa en la figura 59 y sus ecuaciones se basan en las mismas de la red Perceptrón Multicapa con una capa oculta. Con el fin de mejorar la velocidad de convergencia, reducción de oscilación de la actualización de las matrices de pesos y aumentar la precisión, se propone como método de entrenamiento el algoritmo de *Levenberg - Marquardt* ⁴⁸. Éste algoritmo combina el método de descenso de gradiente, el de Gauss - Newton con propagación hacia atrás.

⁴⁸ N LUMA y T MOHAMMED. "Improve Levenberg-Marquardt Training Algorithm for Feed Forward Neural Networks". En: November (2018).

Figura 59. Diagrama de la arquitectura de la Red Perceptron Multicapa con dos capas ocultas



El algoritmo de Levenberg - Marquardt le da solución al problema de convergencia de Newton y a la no invertibilidad de la relación de las matrices Jacobiana y Hessiana $H = J^T J$ ⁴⁹, haciendo la aproximación de la ecuación (90)

$$H \approx J^T J + \mu I \quad (90)$$

Computando el gradiente mediante $g = J^T e$, se obtiene la ecuación general de actualización de pesos para el algoritmo de Levenberg - Marquardt (91)

$$W_{k+1} = W_k - [J^T J + \mu I]^{-1} J^T e \quad (91)$$

A pesar de las grandes ventajas que trae consigo una red neuronal, esta tiene un dos problemas a la hora del diseño. El primer problema aborda los datos ingresados a la red neuronal, ya que si son más o menos de los soportados por la arquitectu-

⁴⁹ L CHEN y col. "Levenberg-marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system". En: *IEEE Transactions on Industrial Informatics* 14.8 (2018), págs. 3436-3446. DOI: 10.1109/TII.2017.2777460.

ra diseñada, pueden causar un sobreentrenamiento o infraentrenamiento de la red, generando resultados erróneos a la hora de la clasificación. El segundo problema implica en el caer en un mínimo local y que por esto los resultados no cumplan con el margen de error y tolerancias deseados⁵⁰.

Aunque la selección del número de capas y el número de neuronas por cada capa es una decisión principal a la hora del diseño de la arquitectura de la red neuronal, no existe una regla general, si no que es el diseñador quien lo establece según su experiencia, intuición y ensayo.

Para el diseño de la arquitectura de la red neuronal, según investigadores, expertos e ingenieros⁵¹, es importante tener en cuenta lo siguiente:

- El gradiente varía según el índice de desempeño fijado.
- A medida que la complejidad entre la entrada y salida, el número de neuronas en la capa oculta debería aumentar
- Si se aumenta el número de variables de salida, la complejidad de la red aumenta, por ende el número de neuronas por capa debería aumentar
- El número de datos de entrenamiento que se tienen, fija un límite superior del número de neuronas en la capa oculta

Con el fin de facilitar los cálculos matemáticos, se hizo uso del toolbox de matlab *Neural Network Toolbox* especificando los parámetros de índice de desempeño, al-

⁵⁰ J ALLEN. "Neural Networks and Speech Processing the Kluwer International Series in Engineering and Computer Science". En: (1991).

⁵¹ S ALSMADI, K OMAR y S NOAH. "Back Propagation Algorithm : The Best Algorithm Among the Multi-layer Perceptron Algorithm". En: *Journal of Computer Science* 9.4 (2009), págs. 378-383.

goritmo de entrenamiento y procesamiento de los datos. Para las tres redes neuronales diseñadas y mencionadas anteriormente se realizó la división de los datos de entrenamiento según (92) y las reglas de entrenamiento y de desempeño utilizadas fueron las indicadas en (93).

$$\begin{aligned}\text{Entrenamiento} &= 70 \% \\ \text{Test} &= 15 \% \\ \text{Validación} &= 15 \%\end{aligned}\tag{92}$$

$$\begin{aligned}\text{Entrenamiento} &= \textit{Levenverg - Marquart} \\ \text{Desempeño} &= \textit{MeanSquaredError}\end{aligned}\tag{93}$$

Es importante recordar que para los tres casos la matriz de entrada fue **I** y la de objetivos fue **T** y se establecieron el número de neuronas para las tres redes neuronales según 94

$$\begin{aligned}MLP1(n = 30) \\ MLP1(n_1 = 30; n_2 = 30) \\ Adeline(n = 30)\end{aligned}\tag{94}$$

siendo n el número de neuronas en la capa oculta, y el subíndice 1 y 2 representa el número de capa oculta en el caso de la red perceptrón multicapa.

Después del respectivo entrenamiento, se realizó la respectiva validación de las redes neuronales diseñadas, utilizando el segundo set de datos tomado con el fin de verificar la correcta detección y clasificación de las fallas mediante las matrices de confusión de los tres tipos de redes se representa en las figuras 60, 61 y 62

Se espera que para una señal de entrada, debidamente procesada y con las respectivas características extraídas (Matriz 5x1), la red neuronal sea capaz de producir un vector de salida (30x1) de ceros y unos, en donde toda la columna es de ceros, y la fila en la cual se ubica el uno, indica el tipo de señal, la frecuencia y el tipo de estado de falla en el que se encuentra.

Figura 60. Matriz de confusión de la Red Perceptron Multicapa con una capa oculta





Figura 61. Matriz de confusión de la Red Perceptron Multicapa con dos capas ocultas

[illegible]

Figura 62. Matriz de confusión de la Red Adeline



El desempeño para los tres tipos de redes está representado en las figuras 63, 65 y 67 y el estado de entrenamiento para los tres tipos de redes está representado en las figuras 64, 66 y 68.

Figura 63. Error cuadrático medio de la Red Perceptron Multicapa con una capa oculta




Figura 64. Estado de entrenamiento de la Red Perceptron Multicapa con una capa oculta




Figura 65. Error cuadrático medio de la Red Perceptron Multicapa con dos capas ocultas




Figura 66. Estado de entrenamiento de la Red Perceptron Multicapa con dos capas ocultas




Figura 67. Error cuadrático medio de la Red Adeline





Figura 68. Estado de entrenamiento de la Red Adeline



La matriz de confusión es una herramienta que permite entender cómo está trabajando el modelo clasificador, generalmente se utiliza como referencia para analizar el desempeño del modelo ante la clasificación de cada caso de estudio. Para el caso de la red Perceptron Multicapa con una capa oculta (Figura 60) se observa un buen desempeño para la clasificación de las 30 condiciones de falla, logrando un 95.7% de clasificación, presentando problemas con los datos 15 y 24. La red Perceptron Multicapa de dos capas ocultas también presentó problemas en la clasificación de estos mismos sets de datos, y adicionalmente errores de clasificación en 4, reduciendo su desempeño a un 90% como se evidencia en su respectiva matriz de confusión (Figura 61). Finalmente la Red Adeline presentó el desempeño más bajo con un 83.3% al tener problemas reconociendo los datos 4,13,20,24 y 29 representados en la Figura 62.

Las figuras 63, 63 y 63 indican el comportamiento del error en cada iteración del modelo, permitiendo notar que para la Red Perceptrón Multicapa con dos capas ocultas le fue más fácil alcanzar el error mínimo aceptado al lograrlo con 12 iteracio-

nes, seguido de la Red Perceptrón Multicapa con una capa oculta con 21 iteraciones y finalmente la red Adeline con 36 iteraciones.

El estado de entrenamiento para los tres modelos de red neuronal se representa en las figuras 64, 64 y 64, pudiendo observar el comportamiento del gradiente y de μ , llegando en todos los casos al mínimo admisible según los parámetros estipulados al inicio del diseño de las redes.

6. RECOMENDACIONES

Probar otros métodos de control no lineal como control por superficies deslizantes como método de control tolerante a fallas en el transductor de posición.

Adicionar más sensores a la hora de la toma de la señal para tener un mayor rango de características y así posiblemente reducir el número de neuronas, haciendo el algoritmo más sencillo lo que conlleva a un menor gasto computacional.

Trabajar otras estrategias de *Machine Learning* como máquinas de soporte vectorial y *deep learning*

Aplicar la metodología trabajada para la detección de fallas en el sello del pistón en otros servoactuadores hidráulicos

7. TRABAJO FUTURO

Es posible desarrollar a futuro un algoritmo de control no lineal robusto que pueda reconocer que el sistema presenta fallas en el sello del pistón del servo actuador hidráulico y corregir inmediatamente dicho problema, permitiendo así que el sistema continúe trabajando a pesar de que presente fallas

Se espera que se desarrolle este algoritmo de tal modo que se pueda implementar en línea con el sistema y que corrija las fallas en tiempo real.

8. CONCLUSIONES

- Se desarrolló el modelado dinámico matemático de un servoactuador hidráulico de doble vástago.
- Se diseñaron dos algoritmos de control tolerantes a fallas (LQR y LQG) en el transductor de posición (LVDT) basados en técnicas de control lineal y no lineal, teniendo en cuenta el comportamiento y naturaleza de las perturbaciones.
- Se realizó la simulación y comparación por medio de herramientas computacionales de los algoritmos desarrollados para señales cuadrada y seno sin perturbaciones y con perturbaciones del 10 % siendo el control (LQG) el único que puede tolerar las fallas, logrando una reducción del error de aproximadamente el 40 % frente a los controles PID y LQR.
- Se validaron y compararon experimentalmente los tres controladores para señal escalón, seno y cuadrada sin fallas y con fallas por perturbaciones en el transductor de posición de forma de ruido blanco, con amplitud del 5 % del *setpoint*, siendo el control (LQG) el único sistema tolerante a estas fallas, manteniéndose siempre operativo, sin saltos indeseados en la señal de control y con una reducción del error de aproximadamente el 45 % frente a los controles PID y LQR.
- Se observó que el control LQR es ligeramente más rápido que el PID, mantiene un consumo energético menor y un error absoluto un 10 % menor; a pesar de esto, los dos controladores mantienen un comportamiento muy similar ante las fallas en el sensor de posición y no es posible apaciguarlas ni tolerarlas.

- Se diseñó un algoritmo basado en redes neuronales artificiales para la detección y clasificación off-line de los fallos en los sellos del pistón del servomotor hidráulico dinámico del grupo de investigación DICBoT en el laboratorio de Dinámica Estructural para cinco condiciones de falla (flujo de fugas internas del (0 %, 25 %, 50 %, 75 % y el 100 %)).
- Se llevó a cabo el proceso de extracción de características para las señales de posición ante diferentes condiciones de falla, obteniendo una reducción de gasto computacional y de precisión en la clasificación de las fallas.
- Las características que aportan información significativa, correcta y con sentido para la señal de posición para diferentes tipos de fallas son el valor RMS, el valor máximo, valor mínimo, el promedio del valor absoluto de la envolvente y la desviación estándar.
- Se validó experimentalmente mediante la utilización de un set de datos desconocido para las tres redes, obteniendo un porcentaje de clasificación del 95 % para la red perceptrón multicapa de una capa oculta, de 90 % para la red perceptrón multicapa de dos capas ocultas y de un 87 % para la red Adaline, siendo esta la que maneja el menor desempeño y realizó el mayor número de iteraciones.
- El algoritmo clasificador diseñado basado en una Red Perceptron Multicapa de una capa oculta de $n = 30$ neuronas es capaz de clasificar la señal de entrada según el tipo de señal (seno o cuadrado), la frecuencia en la que se encontraba operando (5Hz, 1Hz o 0.2 Hz) y el tipo de falla en el que se encontraba (porcentaje de flujo de fugas internas del (0 %, 25 %, 50 %, 75 % y el 100 %) teniendo 30 casos de estudio y logrando una precisión del 95 %

BIBLIOGRAFÍA

- ABDULLAH, M. "Neural Network Controller Design for Position Control System Improvement". En: *Thesis Master* June (2013) (vid. pág. 33).
- ACOSTA, M y C ZULUAGA. "Tutorial Sobre Redes Neuronales Aplicadas en Ingenieri Electrica y su Implementacion en un Sitio Web". En: (2000) (vid. pág. 21).
- ÅKERSON, B y H TOIVONEN. "A neural network model predictive controller". En: *Journal of Process Control* 16.9 (2006), págs. 937-946. DOI: 10.1016/j.jprocont.2006.06.001 (vid. págs. 32, 96).
- ALLEN, J. "Neural Networks and Speech Processing the Kluwer International Series in Engineering and Computer Science". En: (1991) (vid. págs. 25, 102).
- ALSMADI, S, K OMAR y S NOAH. "Back Propagation Algorithm : The Best Algorithm Among the Multi-layer Perceptron Algorithm". En: *Journal of Computer Science* 9.4 (2009), págs. 378-383 (vid. pág. 102).
- ALWI, H, C EDWARDS y C TAN. "Fault Detection and Fault-Tolerant Control Using Sliding Modes". En: *Advances in industrial control* (2011), 1 online resource (xxvii, 336 p.) DOI: 10.1007/978-0-85729-650-4 (vid. pág. 21).
- BASEVILLE, M. "Detecting Changes in Signals and Systems-A survey". En: *Automatica* 24.3 (1988), págs. 309-326. DOI: 10.1016/0005-1098(88)90073-8 (vid. pág. 28).

- BORRAS, C. "Pattern Recognition in Hydraulic Backlash using Neuronal Network". En: *University of Oklahoma* 1 (2001), pág. 113. DOI: 10.1017/CB09781107415324.004. arXiv: arXiv:1011.1669v3 (vid. pág. 94).
- BORRAS, C, J ORTIZ y J. SARMIENTO. "Dynamic Model and Control Design for a Nonlinear Hydraulic Actuator". En: *ASME 2018 International Mechanical Engineering Congress and Exposition* (2018), pág. 2018 (vid. pág. 44).
- CHEN, L y col. "Levenberg-marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system". En: *IEEE Transactions on Industrial Informatics* 14.8 (2018), págs. 3436-3446. DOI: 10.1109/TII.2017.2777460 (vid. pág. 101).
- CHIANG, L y col. *Fault Detection and Diagnosis in Industrial Systems*. 2001. DOI: 10.1007/978-1-4471-0347-9 (vid. pág. 24).
- ENGINEERINGS, PARKER. "Valve flow graph". En: (), págs. 1-18 (vid. pág. 86).
- FAN, J, Y ZHANG y Z ZHENG. "Adaptive Observer-Based Integrated Fault Diagnosis and Fault-Tolerant Control Systems Against Actuator Faults and Saturation". En: *Journal of Dynamic Systems, Measurement, and Control* 135.4 (2013), pág. 041008. DOI: 10.1115/1.4023763 (vid. pág. 33).
- GARIMELLA, P y B YAO. "Model Based Fault Detection of an Electro-Hydraulic Cylinder". En: *American Control Conference, 2005. Proceedings of the 2005 July 2005* (2005), 484 -489 vol. 1. DOI: 10.1109/ACC.2005.1469982 (vid. págs. 29, 41).
- HAGAN, M, H DEMUTH y B HE. "Neural network design". En: (1996) (vid. pág. 96).

- HUANG, J y F LEWIS. "Neural-network predictive control for nonlinear dynamic systems with time-delay". En: *IEEE Transactions on Neural Networks* 14.2 (2003), págs. 377-389 (vid. pág. 31).
- ISERMANN, R. "Diagnosis Methods for Electronic Controlled Vehicles". En: *VDI Berichte* 1616 (2001), págs. 209-238. DOI: 10.1076/vsd.36.2.77.3554 (vid. págs. 25, 29, 35).
- ISERMANN, R. *Fault-Diagnosis Systems: An Introduction From Fault Detection to Fault Tolerance*. 2006, págs. 1-475. DOI: 10.1007/3-540-30368-5. arXiv: arXiv:1011.1669v3 (vid. págs. 24, 47).
- ISERMANN, R. "Supervision, Fault-Detection and Fault-Diagnosis Methods - An Introduction". En: *Control Engineering Practice* 5.5 (1997), págs. 639-652. DOI: 10.1016/S0967-0661(97)00046-4 (vid. págs. 23, 29).
- KARPENKO, M y N SEPEHRI. "Quantitative Fault Tolerant Control Design for a Leaking Hydraulic Actuator". En: *Journal of Dynamic Systems Measurement and Control-Transactions of the Asme* 132.5 (2010), págs. -. DOI: Artn054505\ DOI 10.1115/1.4001707 (vid. pág. 32).
- KHALIL, H. *Nonlinear Systems*. 2001, pág. 767 (vid. págs. 25, 28, 47).
- KOŁODZIEJ, J. "A Data-Driven Methodology for Fault Detection in Electromechanical Actuators". En: 136.July (2014), págs. 1-16. DOI: 10.1115/1.4026835 (vid. pág. 30).
- KOREN, I., & MANI KRISHNA. "Fault-Tolerant Systems". En: *Morgan Kaufmann Publishers* (2018), pág. 2018 (vid. pág. 17).

- KOTSIANTIS, S, I. ZAHARAKIS y P. PINTELAS. "Paper 1 (20)". En: *Artificial Intelligence Review* 26 (2006), págs. 159-190. DOI: 10.1007/s10462-007-9052-3. arXiv: /www.informatica.si/index.php/informatica/article/view/148 [http:] (vid. pág. 83).
- LIN, F, R WAI y C LEE. "Fuzzy Neural Network Position Controller for Ultrasonic Motor Drive Using Push-Pull DC-DC Converter". En: *IEE Proc.-Control Theory Appl* 146.1 (1999) (vid. pág. 31).
- LIU, H, S WANG y P OUYANG. "Fault Diagnosis in a Hydraulic Position Servo System Using RBF Neural Network". En: *Chinese Journal of Aeronautics* 19.4 (2006), págs. 346-353. DOI: 10.1016/S1000-9361(11)60339-7 (vid. pág. 29).
- LOUTAS, T y V KOSTOPOULOS. "Utilising the Wavelet Transform in Condition-Based Maintenance : A Review with Applications". En: *Advances in Wavelet Theory and Their Applications in Engineering, Physics and Technology* (2012), págs. 273-312 (vid. pág. 24).
- LUMA, N y T MOHAMMED. "Improve Levenberg-Marquardt Training Algorithm for Feed Forward Neural Networks". En: November (2018) (vid. pág. 100).
- MÄÄKILÄ, PM. "Kalman Filtering and Linear Quadratic Gaussian Control PT II". En: (2004), págs. 1-31 (vid. pág. 46).
- MADDAHI, Ali y col. "Internal Leakage Detection in Electrohydrostatic Actuators Using Multiscale Analysis of Experimental Data". En: (2016), págs. 1-14 (vid. págs. 18, 30).

MAHULKAR, V, D ADAMS y M DERRISO. "Adaptive Fault Tolerant Control for Hydraulic Actuators". En: *American Control Conference* (2015), págs. 2242-2247 (vid. pág. 22).

MANGOUBI, R. "Robust Estimation and Failure Detection: A Concise Treatment". En: (2012), pág. 218 (vid. págs. 19, 82).

"Minimum variance control (AALTO UNIVERSITY)". En: (2015), págs. 1-10 (vid. pág. 91).

MUENCHOF, M, M BECK y R ISERMANN. "Fault-Tolerant Actuators and Drives-Structures, Fault Detection Principles and Applications". En: *Annual Reviews in Control* 33.2 (2009), págs. 136-148. DOI: 10.1016/j.arcontrol.2009.08.002 (vid. pág. 23).

MUENCHOF, M y R ISERMANN. *Comparison of change detection methods for a residual of a hydraulic servo-axis*. Vol. 16. 1. IFAC, 2005, págs. 317-322. DOI: 10.3182/20050703-6-CZ-1902.01855 (vid. págs. 23, 35).

NAHIAN, Syed Abu y col. "Modeling and fault tolerant control of an electro-hydraulic actuator". En: *International Journal of Precision Engineering and Manufacturing* 17.10 (2016), págs. 1285-1297. DOI: 10.1007/s12541-016-0153-2 (vid. pág. 36).

OGATA, K. *Modern Control Engineering*. 1980 (vid. págs. 44, 65).

OVIEDO, S, J QUIROGA y C BORRÁS. "Motor Current Signature Analysis and Negative Sequence Current Based Stator Winding Short Fault Detection in an Induction Motor". En: *Dyna rev.fac.nac.minas* 78.170 (2011), págs. 214-220 (vid. pág. 30).

- Patton, R.J. "Fault Detection and Diagnosis in Aerospace Systems Using Analytical Redundancy". En: *Computing & Control Engineering Journal* 2.3 (1991), pág. 127. DOI: 10.1049/cce:19910031 (vid. pág. 28).
- POLEY, R. "Signal Conditioning an LVDT Using a TMS320F2812 DSP". En: August (2003), págs. 1-27 (vid. pág. 21).
- REN, G y col. "Position Control of an Electrohydrostatic Actuator With Tolerance to Internal Leakage". En: (2016), págs. 1-9. DOI: 10.1109/TCST.2016.2517568 (vid. págs. 23, 33).
- SEYEDMIRZABOZORG, A, A TIVAY y S REZAEI. "Leakage Fault Classification in Hydraulic Actuators Via Multiple Trained Transformations". En: *International Conference on Robotics and Mechatronics, ICROM 2015* (2015), págs. 246-251. DOI: 10.1109/ICRoM.2015.7367792 (vid. pág. 16).
- SONG, R. "Fault Detection and Isolation in Fluid Power Systems Using a Parametric Estimation Method". En: (2002), págs. 144-149 (vid. pág. 93).
- VENKATASUBRAMANIAN, V y col. "A Review of Process Fault Detection and Diagnosis Part III: Qualitative Models and Search Strategies". En: *Computers & Chemical Engineering* 27.3 (2003), págs. 293-311. DOI: 10.1016/S0098-1354(02)00160-6 (vid. págs. 26, 28).
- VENKATASUBRAMANIAN, Venkat y col. "A Review of Process Fault Detection and Diagnosis Part I: Qualitative Models and Search Strategies". En: *Computers & Chemical Engineering* 27.3 (2003), págs. 293-311. DOI: 10.1016/S0098-1354(02)00160-6 (vid. págs. 28, 30).

WITTENBACH, R. "Detection of Faults in Linear and Rotary Voltage Transducers".
En: 12 (2006) (vid. pág. 20).

YAO, J., G. YANG y Z. JIAO. "High dynamic feedback linearization control of hydraulic actuators with backstepping". En: *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering* 229.8 (2015), págs. 728-737. DOI: 10.1177/0959651815581555 (vid. pág. 33).

YILDIRIM, A. "A proposed hybrid neural network for position control of a walking robot". En: *Nonlinear Dynamics* 52.3 (2008), págs. 207-215. DOI: 10.1007/s11071-007-9272-8 (vid. pág. 32).

YU, B, Y SHI y J HUANG. "Modified Generalized Predictive Control of Networked Systems With Application to a Hydraulic Position Control System". En: *Journal of Dynamic Systems, Measurement, and Control* 133.3 (2011), pág. 031009. DOI: 10.1115/1.4003385 (vid. pág. 22).