

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ
ESCUELA DE POSGRADO



**DISEÑO DE UN SISTEMA DE DIAGNÓSTICO DE FALLAS PARA
LA SUSPENSIÓN SEMI-ACTIVA DE UN VEHÍCULO POR MEDIO
DE OBSERVADORES DE ENTRADAS DESCONOCIDAS,
ESTIMACIÓN PARAMÉTRICA Y REDES NEURONALES**

Tesis para optar el grado de
Magíster en Ingeniería de Control y Automatización

Autor: Elmer Trinidad Calle Chojeda

Asesor: PhD. Antonio M. Morán Cárdenas

Miembros del Jurado :

PhD. Juan Javier Sotomayor Moriano

PhD. Antonio M. Morán Cárdenas

PhD. Carlos Gustavo Pérez Zúñiga

Lima - Perú

2017

DEDICATORIA

Dedico esta tesis a mis padres que han sabido inculcarme los valores de la perseverancia y el respeto, a mis tíos, que sin su apoyo no hubiera podido lograrlo, a mis hermanos y amigos que han sabido darme aliento para seguir adelante.

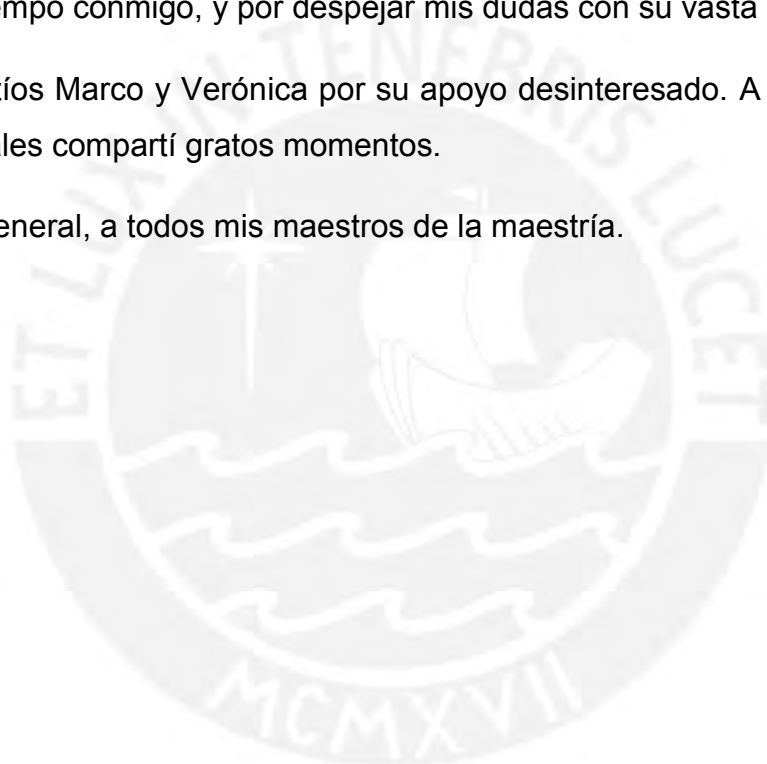


AGRADECIMIENTOS

A mi asesor, el Dr. Antonio Morán, por haber compartido sus conocimientos y su tiempo conmigo, y por despejar mis dudas con su vasta experiencia.

A mis tíos Marco y Verónica por su apoyo desinteresado. A mis amigos con los cuales compartí gratos momentos.

Y en general, a todos mis maestros de la maestría.



RESUMEN

El presente trabajo tiene como propósito el diseño de un sistema que permita realizar el diagnóstico de fallas en los sensores destinados a mejorar el desempeño de la suspensión semi-activa de un vehículo terrestre, como también diagnosticar fugas del líquido magneto-reológico del amortiguador.

Para detectar las fallas en los sensores, se planteó el diseño de un banco de observadores de entradas desconocidas ya que estos tienen la capacidad de lidiar con el desconocimiento del perfil de la carretera, el cual representa una entrada de perturbación no medible para el sistema. La fuga del líquido magneto-reológico del amortiguador se considera como una variación del coeficiente que lo representa, y para detectar esta falla se propuso desarrollar un sistema de estimación paramétrica. Las fallas ocurridas presentan patrones característicos que mediante una red neuronal serán reconocidos y, de esta manera, se puedan aislar las fallas presentes.

Los resultados de simulaciones demuestran que el sistema propuesto posee un buen desempeño de diagnóstico incluso ante la presencia de incertidumbres paramétricas.

CONTENIDO

INTRODUCCIÓN	1
1. ESTADO DEL ARTE DE LOS SISTEMAS DE DIAGNÓSTICO DE FALLAS PARA SUSPENSIONES VEHICULARES	4
1.1. Introducción	4
1.2. Estado del Arte de los Métodos de Diagnóstico de Fallas en la Suspensión de un Vehículo.....	5
1.3. Objetivos de la Tesis.....	7
2. MODELADO DEL SISTEMA DE SUSPENSIÓN SEMI-ACTIVA DE UN VEHÍCULO	9
2.1. Resorte Helicoidal.....	12
2.2. Amortiguador Ideal	12
2.3. Tipos de Suspensiones.....	13
2.4. Modelo de Suspensión Semi-activa.....	15
2.4.1. Modelo de Suspensión Pasiva no Lineal.....	15
2.4.2. Análisis de Estabilidad de la Suspensión Pasiva	17
2.4.3. Amortiguador MR para Suspensión Semi-activa	19
2.5. Control de una Suspensión Semi-activa	26
2.5.1. Metodologías de Control Convencional para Suspensiones.....	26
2.5.2. Metodologías de Control Inteligente para Suspensiones	27
2.5.3. Diseño de un Controlador Sky-hook	28
2.6. Modelo de la Suspensión Semi-activa en Espacio de Estados	29
2.6.1. Comparación de Desempeño entre una Suspensión Pasiva y Suspensión Semi-activa	34
2.7. Fallas a Diagnosticar.....	40
3. DISEÑO DEL SISTEMA DE DIAGNÓSTICO DE FALLAS	43
3.1. Introducción	43
3.2. Observador de Entradas Desconocidas	43
3.3. Estimación Paramétrica Mediante Mínimos Cuadrados.....	46
3.3.1. Predicción de la Salida en un Modelo ARX	48
3.3.2. Método de los Mínimos Cuadrados Lineales.....	49
3.3.3. Mínimos Cuadrados Recursivos con Factor de Olvido	50
3.4. Redes Neuronales.....	53
3.4.1. Perceptrón Multicapa.....	53

3.4.2.	Función de Activación.....	54
3.4.3.	Función de Salida.....	56
3.4.4.	Pesos Sinápticos.....	57
3.4.5.	Algoritmo de Aprendizaje Backpropagation.....	58
3.5.	Diseño de un Banco de Observadores de Entradas Desconocidas.....	61
3.5.1.	Síntesis de la Matriz E para los Observadores.....	65
3.5.2.	Síntesis de la Matriz K.....	66
3.6.	Sistema de Estimación Paramétrica.....	73
3.6.1.	Obtención de Residuales de la Estimación Paramétrica.....	76
3.7.	Diseño de una Red Neuronal para Aislar Fallas.....	79
3.7.1.	Diseño de patrones de entrenamiento.....	79
3.7.2.	Salidas Deseadas.....	80
3.7.3.	Capas intermedias y funciones de activación.....	81
3.7.4.	Entrenamiento de la red neuronal.....	82
3.8.	Pruebas y Resultados.....	84
4.	PROPUESTA DE IMPLEMENTACIÓN.....	100
4.1.	Introducción.....	100
4.2.	Hardware.....	100
4.2.1.	Actuadores.....	100
4.2.2.	Sensores.....	101
4.2.3.	Microcontrolador.....	103
4.3.	Software.....	104
5.	CONCLUSIONES.....	107
6.	REFERENCIAS.....	109
	ANEXO A: Generación de un Perfil de Carretera Aleatorio	
	ANEXO B: Código del Sistema de Diagnóstico de Fallas	

LISTA DE FIGURAS

Figura 2.1. Esquema de una suspensión en un vehículo (Savaresi <i>et al</i> , 2010).....	9
Figura 2.2. Representación de un cuarto de vehículo (Savaresi <i>et al</i> , 2010).....	10
Figura 2.3. Diagrama de Bode de variables de interés vs el perfil de carretera para diferentes coeficientes de amortiguamiento viscoso C_s	11
Figura 2.4. Diagrama de Bode de variables de interés vs el perfil de carretera para diferentes coeficientes de rigidez elástica K_s	11
Figura 2.5. Ejemplo de un resorte helicoidal de acero (Savaresi <i>et al</i> , 2010).....	12
Figura 2.6. Amortiguador pasivo mono-tubo (Savaresi <i>et al</i> , 2010).....	13
Figura 2.7. Forma general del modelo no lineal de una suspensión pasiva.....	15
Figura 2.8. Sistema de Suspensión Pasiva.	17
Figura 2.9. Modelo de un cuarto de vehículo con amortiguador semi-activo (Lam-Do, 2006).....	20
Figura 2.10. Comportamiento de amortiguador MR: con y sin campo magnético (B). (Savaresi <i>et al</i> , 2010)	21
Figura 2.11. Efecto de histéresis en un amortiguador MR real (Xubin-Song, 1999).21	
Figura 2.12. Estructura reológica de un amortiguador MR modelo Bingham (Sapiński <i>et al</i> , 2003).....	22
Figura 2.13. Comportamiento del amortiguador MR ante 5 valores de corriente.	26
Figura 2.14. Control Sky-Hook para suspensión.....	28
Figura 2.15. Diagrama de bloques de suspensión semi-activa con control Sky-Hook.	32
Figura 2.16. Suspensión semi-activa, cálculo de las variables de estado.	32
Figura 2.17. Cálculo de la fuerza del amortiguador MR.....	33
Figura 2.18. Cálculo de corriente aplicada al amortiguador MR mediante Sky-Hook.	33
Figura 2.19. Respuesta del sistema ante una carretera tipo escalón.....	34
Figura 2.20. Corriente aplicada, carretera tipo escalón.	35
Figura 2.21. Respuesta del sistema ante una carretera tipo función seno.	36
Figura 2.22. Corriente aplicada, carretera tipo función seno.	37
Figura 2.23. Respuesta del sistema ante perfil de carretera aleatorio.	37
Figura 2.24. Corriente, carretera tipo ruido blanco.	38
Figura 2.25. Deflexión de la suspensión (estabilidad) para $I = 0A$, $I = 1A$ y $I =$ variable.	38
Figura 2.26. Aceleración de la masa suspendida (confort) para $I = 0A$, $I = 1A$ y $I =$ variable.	39
Figura 2.27. Modelo de falla para señal de salida: a) aditiva; b) multiplicativa (Isermann, 2006).....	41
Figura 3.1. Representación de modelos identificados.	48
Figura 3.2. Estructura de una red neuronal artificial.....	55
Figura 3.3. Modelo de funcionamiento de una Neurona.....	58
Figura 3.4. Sumatoria de entradas multiplicadas por los pesos sinápticos.	58
Figura 3.5. Función de salida.	59
Figura 3.6. Retropropagación del error.....	61

Figura 3.7. Observador con entradas desconocidas.....	63
Figura 3.8. Banco de observadores para generar residuales de salidas.....	64
Figura 3.9. Banco de observadores de entradas desconocidas.....	65
Figura 3.10. Obtención de los residuales a partir de los estados estimados.....	70
Figura 3.11. Estados estimados por observadores de entradas desconocidas.....	71
Figura 3.12. Efecto drift en la estimación de estados.....	72
Figura 3.13. Filtrado de estados estimados por integración.....	73
Figura 3.14. Salidas obtenidas de los estados estimados por los UIO.....	74
Figura 3.15. Diagrama estimador de parámetros.....	76
Figura 3.16. Bloque Estimador de Parámetros.....	76
Figura 3.17. MATLAB Function 1.....	77
Figura 3.18. MATLAB Function 2.....	77
Figura 3.19. MATLAB Function 3.....	77
Figura 3.20. Parámetros estimados.....	78
Figura 3.21. Residuales de la estimación paramétrica.....	79
Figura 3.22. Falla paramétrica, disminución del 10% de C_p	80
Figura 3.23. Error de entrenamiento $\eta=0.01$ con 10 neuronas intermedias.....	85
Figura 3.24. Error de entrenamiento $\eta=0.001$, 100 neuronas intermedias.....	85
Figura 3.25. Desconexión de los tres sensores en diferentes tiempos.....	88
Figura 3.26. Desconexión de los sensores y_2 y y_3	88
Figura 3.27. Desconexión de los sensores y_3 y y_1	89
Figura 3.28. Fuga en el amortiguador MR.....	89
Figura 3.29. Falla positiva menor en el sensor y_1	90
Figura 3.30. Falla negativa menor en el sensor y_1	91
Figura 3.31. Falla positiva mayor en el sensor y_1	91
Figura 3.32. Falla negativa mayor en el sensor y_1	92
Figura 3.33. Falla positiva en el sensor y_2	92
Figura 3.34. Falla negativa en el sensor y_2	93
Figura 3.35. Falla positiva mayor en el sensor y_2	93
Figura 3.36. Falla negativa mayor en el sensor y_2	94
Figura 3.37. Falla positiva menor en el sensor y_3	94
Figura 3.38. Falla negativa menor en el sensor y_3	95
Figura 3.39. Falla positiva mayor en el sensor y_3	95
Figura 3.40. Falla negativa mayor en el sensor y_3	96
Figura 3.41. Diagnóstico de fallas para $1.5ms$	97
Figura 3.42. Diagnóstico de fallas para una masa $0.5ms$	98
Figura 3.43. Diagnóstico de fallas para $1.2Kt$	99
Figura 3.44. Diagnóstico de fallas para $0.8Kt$	100
Figura 4.1. Motor lineal para la excitación de la carretera (Koch et al, 2010).....	103
Figura 4.2. Acelerómetro capacitivo.....	104
Figura 4.3. Sensor LVDT.....	104
Figura 4.4. Célula de carga tracción/compresión.....	105
Figura 4.5. Transductor de efecto Hall.....	105
Figura 4.6. Diagrama de flujo del sistema de diagnóstico de fallas.....	107
Figura 4.7. Diagrama de funcionamiento del sistema de diagnóstico de fallas.....	108

LISTA DE TABLAS

Tabla 2.1. Parámetros de un vehículo comercial.....	19
Tabla 2.2. Parámetros de un amortiguador MR comercial.....	25
Tabla 2.3. Desempeño de la suspensión para diferentes niveles de corriente.....	39
Tabla 2.4. Comparación del desempeño entre una suspensión pasiva y semi-activa.	40
Tabla 2.5. Fallas aditivas en sensores.	41
Tabla 2.6. Falla paramétrica en amortiguador.....	42
Tabla 2.7. Desempeño de la suspensión semi-activa con fallas.....	42
Tabla 3.1. Firma de fallos para el banco de observadores de entradas desconocidas.....	64
Tabla 3.2. Conformación de patrones para red neuronal.....	79
Tabla 3.3. Patrones de entrenamiento.....	80
Tabla 3.4. Patrones entrada-salida para entrenamiento Backpropagation.....	81
Tabla 3.5. Error de entrenamiento.....	83
Tabla 3.6. Código K de fallas diagnosticadas.....	85
Tabla 3.7. Matriz de Firma de Fallas.....	99



INTRODUCCIÓN

En la industria automotriz, el confort y la estabilidad son características esenciales para que el modelo de un vehículo cumpla con las especificaciones que demanda el mercado actual. El confort y la estabilidad nos garantizan las condiciones de comodidad y de seguridad, respectivamente. El sistema de suspensión es el encargado de aislar al chasis del movimiento causado por las irregularidades del terreno y, al mismo tiempo, asegura que las ruedas se mantengan en contacto con la carretera.

La calidad de la actuación de la suspensión no solo afecta directamente al desempeño del manejo y la comodidad del viaje, sino también la seguridad en la conducción, la maniobrabilidad, la estabilidad y el ahorro de combustible. En la actualidad existen tres tipos de suspensiones vehiculares.

En primer lugar, tenemos a las pasivas que solo se encargan de almacenar energía por medio de resortes helicoidales y de disipar la energía mediante amortiguadores. Estos elementos tienen parámetros fijos y son establecidos de acuerdo a su compromiso entre confort y estabilidad.

Luego están las activas, que tienen la capacidad de disipar, almacenar y generar energía ya que cuentan con actuadores que inyectan energía dentro del sistema. Estos sistemas necesitan de sensores para medir la aceleración de la masa suspendida y la de la masa no suspendida, como también sensores que miden el desplazamiento de la suspensión (deflexión). Generalmente, estas suspensiones remueven totalmente del sistema todos los elementos pasivos que son reemplazados por el actuador activo, el cual demanda una gran cantidad de energía para lidiar con las irregularidades del terreno.

Por último, tenemos las suspensiones semi-activas que son una solución promedio entre las dos suspensiones antes mencionadas. Estas cuentan con un amortiguador, el cual posee un coeficiente de amortiguamiento que varía según los requerimientos del sistema. De esta manera este tipo de suspensión solo demanda una pequeña cantidad de energía para el

dispositivo electrónico que controla a este amortiguador. Este sistema necesita también de sensores.

En el mercado existen algunas tecnologías para amortiguadores de suspensiones semi-activas, de las cuales el amortiguador Magneto-Reológico (MR) posee un mejor desempeño y mantiene de manera eficiente la relación entre el confort y la estabilidad. El tiempo de respuesta es alrededor de los 12 ms, posee un bajo consumo de energía y es robusto ante grandes variaciones de temperatura (John C. Dixon, 2007). Pero al integrar nuevos elementos al sistema este aumenta su complejidad, y con ello también se vuelve más propenso a sufrir fallas en sus componentes. Las fallas más comunes que se presentan en el sistema de suspensión son las fallas aditivas (referente a sensores) y las fallas multiplicativas (referente a cambios de los parámetros de los componentes internos).

Con el objeto de brindar una descripción general del presente trabajo, a continuación se describen los diferentes capítulos con los que cuenta.

En el Capítulo 1, se presenta una introducción sobre la problemática de las fallas en el sistema de suspensión de un vehículo terrestre, y en particular, el estado del arte de los métodos de diagnóstico de fallas aplicados en estos sistemas.

En el Capítulo 2, se describe el modelo matemático de una suspensión semi-activa con amortiguador MR. Para el modelo adoptado se diseña un controlador Sky-Hook y se compara su desempeño con una suspensión pasiva. Por último se describen las fallas a diagnosticar y se analiza el deterioro del desempeño del sistema ante determinadas fallas.

En el Capítulo 3, se presenta la teoría de los tres métodos usados para el diagnóstico, observadores de entradas desconocidas, estimación paramétrica por mínimos cuadrados recursivos con factor de olvido y la teoría de redes neuronales. Asimismo, se diseña el sistema de diagnóstico de fallas, que consta de tres subsistemas: un banco de observadores de entradas desconocidas, de donde se obtienen residuales que son sensibles a las fallas en los sensores del sistema, un subsistema de estimación

paramétrica, cuyos residuales servirán para detectar fugas en el amortiguador, y finalmente, una red neuronal para aislar las fallas descritas en el Capítulo 2. Al final del capítulo, se muestran los resultados de las pruebas del diagnóstico, demostrando la eficiencia del sistema desarrollado incluso con parámetros distintos a los usados para su diseño.

En el Capítulo 4, se desarrolla una propuesta de implementación detallando los elementos necesarios para el diseño y construcción de un banco de pruebas prácticas para el sistema de diagnóstico propuesto.

Por último en el Capítulo 5, se presentan las conclusiones analizando los objetivos alcanzados, se incluyen también algunas recomendaciones finales.



1. ESTADO DEL ARTE DE LOS SISTEMAS DE DIAGNÓSTICO DE FALLAS PARA SUSPENSIONES VEHICULARES

1.1. Introducción

La seguridad de los pasajeros es primordial en el diseño de vehículos, y para mantener esta seguridad sus sistemas deben funcionar correctamente. En el sistema de suspensión semi-activa el dispositivo más susceptible a sufrir fallas es el amortiguador MR, debido a posibles fugas del fluido magneto-reológico. Estas fugas producen la variación de los parámetros fijos establecidos en su diseño, como es el coeficiente de amortiguamiento viscoso. Dicha variación de coeficientes da lugar a una pérdida de la fuerza ejercida por el actuador y por lo tanto, empeora el desempeño de la suspensión afectando la maniobrabilidad y el confort directamente.

Por tal razón, los sistemas de suspensión se ven obligados a implementar un sistema de diagnóstico y aislamiento de fallas.

Los métodos de diagnóstico y aislamiento de fallas (FDI) se pueden clasificar en dos grupos: aquellos que requieren un modelo de la dinámica del proceso, conocidos como basados en el modelo, y aquellos en los cuales no se necesita información del modelo, llamados como basados en el conocimiento.

El enfoque conocido como redundancia analítica, se basa en el modelo del sistema, en el que se compara la respuesta del sistema real y la respuesta del modelo. Este resultado de la comparación, conocido como residual, es evaluado para verificar si se encuentra dentro de un rango que indica el normal funcionamiento del sistema o si se encuentra en un estado de falla.

Las fallas en los procesos de ingeniería se clasifican en: fallas en sensores y actuador, llamados fallas de software, y fallas en el proceso donde algunos de los parámetros de la planta varían, ya sea por problemas físicos o mecánicos.

Básicamente, el método más adecuado de diagnóstico y aislamiento de fallas a usar depende en la viabilidad de obtener información correcta, ya sea de un modelo o de sensores del proceso.

1.2. Estado del Arte de los Métodos de Diagnóstico de Fallas en la Suspensión de un Vehículo

En (Hedrick *et al*, 1994), se hace uso de observadores de estado para sistemas no lineales con el objeto de mejorar la calidad de viaje en una suspensión activa, y observadores de estado para sistemas bilineales para reducir la dinámica de la carga del neumático en una suspensión semi-activa de un vehículo pesado. El método propuesto garantiza la convergencia exponencial de las estimaciones, incluso ante la presencia de perturbaciones.

Los parámetros desconocidos de un modelo pueden ser obtenidos experimentalmente usando estimación paramétrica y LOLIMOT (LOcal LLinear MOdel Tree) – un tipo especial de redes neuronales como se muestra en (Fischer *et al*, 2003). Aquí son identificados algunos modelos de suspensión activa, estos modelos son usados para diseñar 3 ecuaciones de paridad. La estimación paramétrica y las ecuaciones de paridad son usadas para la detección e identificación de fallas basados en el modelo. El trabajo se centra en suspensiones activas, las cuales por su alto consumo de energía se tornan muy costosas con lo que su uso se vuelve inviable en vehículos de serie.

En (Shahram *et al*, 2009), se presenta un método basado en la transformada wavelet continua para diagnosticar fallas en un amortiguador. El método analiza la frecuencia natural del sistema y los componentes de frecuencia de la señal con la energía máxima relativa.

En (Yu-mei *et al*, 2009), se analiza la relación de ambigüedad entre los síntomas de la falla y la razón de la falla por medio de lógica difusa. Para ello se forman reglas difusas de diagnóstico de fallas, y se establece un modelo matemático difuso de diagnóstico de fallas difuso. Finalmente por medio una

matriz difusa de diagnóstico de fallas se logra relacionar los síntomas con las causas.

En (Lozoya-Santos *et al*, 2012a), se propone un sistema de detección de fallas para monitorear el actuador de una suspensión semi-activa, donde se trabaja con un amortiguador magneto-reológico. El método se basa en el cálculo de la función de transmisibilidad T_R dada por la magnitud del ratio de salida a entrada entre la aceleración de la masa suspendida y la de la masa no suspendida, las cuales son medidas. Mientras que la transmisibilidad es directamente afectada por la frecuencia de excitación, la cual está dada por el perfil de carretera. En otro párrafo por medio de T_R se conoce el estado del amortiguador. Asimismo, la frecuencia es estimada por medio de la deflexión de la suspensión, z_{def} , ya que no se cuenta con un sensor de la frecuencia de la carretera z_r . La suspensión es un sistema no lineal que filtra algunas frecuencias; por ello, la frecuencia estimada de la carretera podría contener errores y algunas importantes diferencias.

En (Rizvi *et al*, 2013), se utiliza el modelo de una suspensión activa del modelo completo del vehículo para diagnosticar fallas en los actuadores. Además, desarrolla un enfoque basado en observadores de entradas desconocidas (Unknown Input Observer) para desacoplar el sistema de las perturbaciones de la carretera y así el residuo generado tan solo sea sensible a las fallas. Se hace el uso de un banco de observadores para diseñar un esquema de aislamiento de fallas, para aislar el actuador o los actuadores en falla. Pero no se toma en cuenta la dinámica de la fuerza del actuador.

En (Odendaal *et al*, 2014), se diagnostica fallas en el actuador de un avión por medio de un enfoque optimizado de espacios de paridad. El espacio de paridad abarca todas las relaciones que cuantifican las redundancias analíticas disponibles entre las salidas de los sensores y las entradas de los actuadores del sistema. Una matriz de transformación es luego optimizada para transformar esas relaciones de paridad en residuales que son sensibles a fallas específicas del actuador.

En (Hernandez-Alcantara *et al*, 2014), se propone el diseño de un observador de Luenberger para estimar la velocidad, tanto de la masa suspendida como la de la masa no suspendida; todo a partir de un sistema desacoplado de la perturbación introducida por el perfil de carretera. Sin embargo al desacoplar el sistema se introducen problemas de observabilidad.

En (Morales-Menendez *et al*, 2013), se presenta un aplicativo de detección de fallas combinado con un controlador Sky-Hook principalmente orientado a detectar fallas en sensores y actuadores. El esquema de detección de fallas se basa el enfoque de espacio de paridad, ya que la no linealidad del sistema se encuentra solo en las matrices de entrada B y D. Se propone considerar las no linealidades fuera de las matrices, directamente dentro de la entrada de control, quedando así un sistema lineal invariante en el tiempo. El banco de pruebas experimentales usa hardware en el lazo (HiL) para validar este enfoque. Las pruebas concluyen con una eficiente detección de las fallas y bajo costo computacional.

En (Hernandez-Alcantara *et al*, 2015), se hace una comparación entre el desempeño de un observador de entradas desconocidas y un sistema de identificación paramétrica por mínimos cuadrados con factor de olvido para estimar fallas en el actuador de una suspensión semi-activa con amortiguador MR.

En ese sentido, se desea diseñar un sistema de diagnóstico de fallas para la suspensión semi-activa de un vehículo con amortiguador magneto-reológico capaz de responder rápida, precisa y eficientemente con un bajo costo computacional.

1.3. Objetivos de la Tesis

El presente trabajo tiene como objetivo general el diseño de un sistema de diagnóstico de fallas para el sistema de suspensión semi-activa de un vehículo terrestre, empleando el método de redundancia analítica basado en modelo, por medio del uso de observadores de entradas desconocidas y el método de estimación paramétrica por mínimos cuadrados recursivos para

detectar fallas en el sistema, y asimismo el empleo de redes neuronales para el aislamiento de las fallas.

De este objetivo general se desprenden los siguientes objetivos específicos:

- Estudiar el modelo matemático que describe el comportamiento dinámico del sistema de suspensión semi-activa de un vehículo y los métodos de detección y diagnóstico de fallas que se emplean para este sistema.
- Diseñar un controlador Sky-hook para la suspensión semi-activa..
- Diseñar un banco de observadores de entradas desconocidas para detectar fallas aditivas en 3 sensores del sistema (sensor de velocidad de la masa suspendida, sensor de la velocidad de la masa no suspendida y el sensor de la deflexión de la suspensión).
- Diseñar un sistema de detección de fallas multiplicativas usando estimación paramétrica por medio de mínimos cuadrados recursivos con factor de olvido.
- Diseñar y entrenar una red neuronal que permita aislar las fallas.
- Mediante simulaciones probar el funcionamiento del sistema de diagnóstico de fallas y verificar su efectividad y desempeño.
- Desarrollar una propuesta de implementación.

2. MODELADO DEL SISTEMA DE SUSPENSIÓN SEMI-ACTIVA DE UN VEHÍCULO

Básicamente, una suspensión está conformada por 3 elementos principales. Primero el elemento elástico (K), generalmente un resorte helicoidal, el cual ejerce una fuerza proporcional opuesta a la elongación de la suspensión, y soporta toda la carga estática.

Segundo, el elemento amortiguador (C), el cual genera una fuerza proporcional opuesta a la velocidad de elongación de la suspensión. Juega un rol muy importante en el comportamiento dinámico del sistema.

También encontramos un grupo de elementos mecánicos que se encargan de conectar la masa suspendida (chasis) con la masa no suspendida (rueda) como se aprecia en la Figura 2.1.



Figura 2.1. Esquema de una suspensión en un vehículo (Savaresi *et al*, 2010).

El sistema se complementa con la inclusión de otro elemento entre el terreno y la rueda, el neumático (K_t). En el modelo de un cuarto de vehículo (QoV) el

neumático, generalmente se suele modelar como un elemento elástico el cual posee un coeficiente de rigidez fijo, como se aprecia en la Figura 2.2.




Figura 2.2. Representación de un cuarto de vehículo (Savaresi *et al*, 2010).

El principal desafío de los ingenieros diseñadores de suspensiones vehiculares se centra en lograr el balance perfecto entre confort y seguridad. Esto se consigue al variar los valores del coeficiente de rigidez elástica del resorte helicoidal (K_s) y el coeficiente de amortiguamiento viscoso del amortiguador (C_s), Figuras 2.3 y 2.4.

Para evaluar el confort que ofrece un vehículo generalmente se analiza la aceleración y el desplazamiento vertical de la masa suspendida. El ser humano es más sensible a particulares frecuencias; por ejemplo, frecuencias de 1 Hz o menos pueden causar cinetosis en los pasajeros, y aceleraciones verticales con frecuencias entre 4-8 Hz pueden causar problemas estomacales.

Cuando hablamos de seguridad nos referimos al contacto de las ruedas con el terreno, para garantizar esto se debe minimizar la dinámica de la fuerza del neumático, o en todo caso la deflexión del neumático que es proporcional a la fuerza. Lo esencial es minimizar estas variables dentro de la resonancia de la rueda que está entre 10-20 Hz.

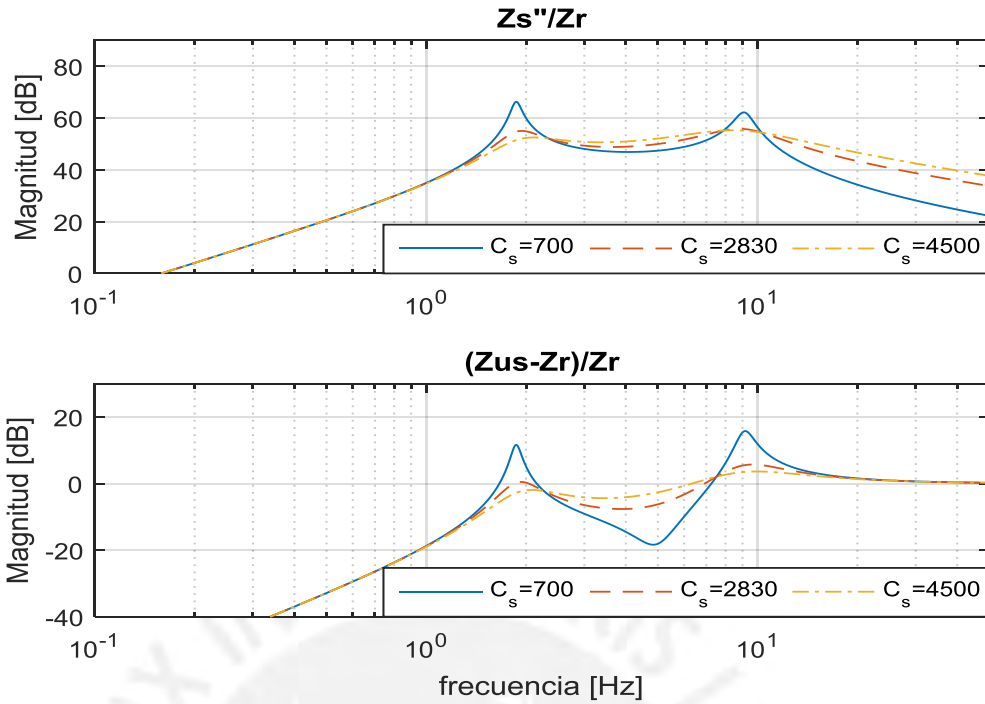


Figura 2.3. Diagrama de Bode de variables de interés vs el perfil de carretera para diferentes coeficientes de amortiguamiento viscoso C_s .

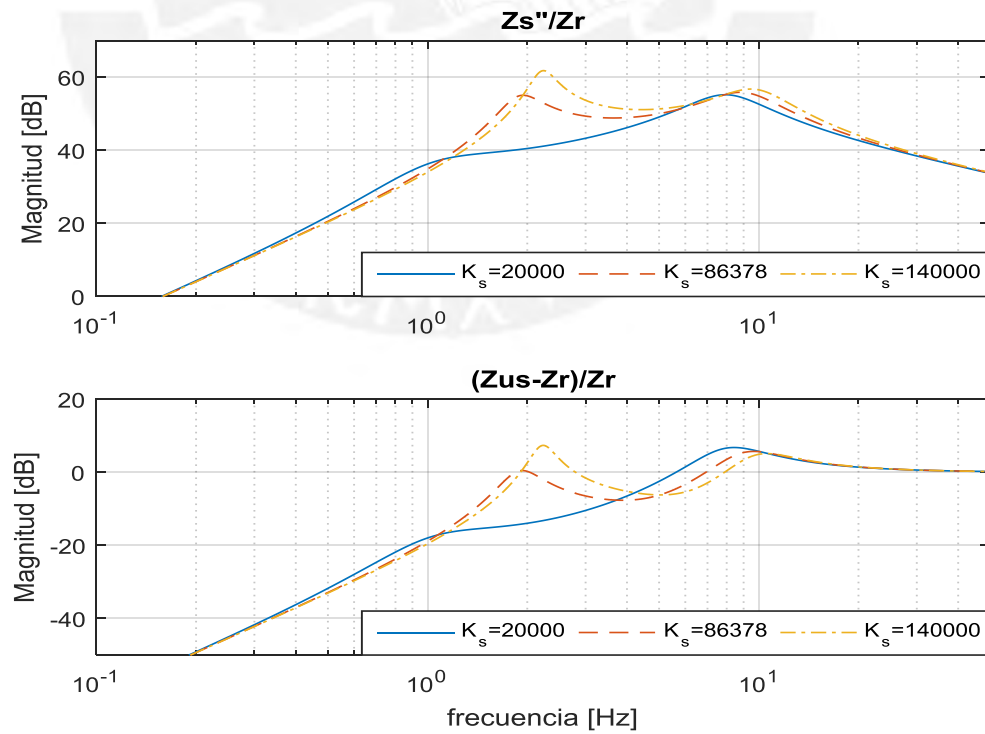


Figura 2.4. Diagrama de Bode de variables de interés vs el perfil de carretera para diferentes coeficientes de rigidez elástica K_s .

2.1. Resorte Helicoidal

Un resorte helicoidal es un elemento mecánico formado por espiras, se caracteriza por un coeficiente de elasticidad K , el cual indica su capacidad para recuperar su longitud inicial cuando desaparecen las fuerzas externas que lo llevaron a deformarse. Esta fuerza producida es la reacción que ofrece su forma helicoidal (Figura 2.5) al producirse una torsión.



Figura 2.5. Ejemplo de un resorte helicoidal de acero (Savaresi et al, 2010).

La rigidez del resorte está dada por la siguiente ecuación.

$$K = \frac{Gd^4}{32R^3n} \quad (2.1)$$

Donde G es el módulo de rigidez del material del que está hecho el resorte, d es el diámetro del hilo, R es el promedio del radio interno del resorte y n es el número de espiras.

2.2. Amortiguador Ideal

En la Figura 2.6, se muestra un amortiguador de un solo tubo simplificado. Este lleva un pistón en su interior, el cual es llenado con aceite, y se mueve de acuerdo a las deflexiones de la suspensión.

El amortiguamiento se logra cuando el aceite pasa a través de unos orificios en el pistón. Se presenta la ecuación de un amortiguador no lineal ideal según la siguiente relación de fuerza-velocidad (Savaresi et al, 2010).

$$F_d = C\dot{x} + F_0 \text{sign}(\dot{x}) \quad (2.2)$$

Donde C es el coeficiente de amortiguamiento viscoso.




Figura 2.6. Amortiguador pasivo mono-tubo (Savaresi et al, 2010).

Los parámetros de la suspensión son seleccionados con el objeto de establecer una relación entre el confort de los pasajeros y la estabilidad del vehículo. Por ello, con el objeto de mejorar la calidad al conducir, es necesario aislar al chasis (o masa suspendida) de las perturbaciones de la carretera y reducir su pico de resonancia cerca de 1Hz, que es sabido que el cuerpo humano es sensible a esta frecuencia. Con respecto a mejorar la estabilidad al conducir es necesario mantener el contacto de la rueda con la carretera; por lo tanto, se debe reducir el pico de resonancia cerca de 10Hz, que es la frecuencia de resonancia de la rueda también llamada masa no suspendida (Fischer *et al*, 2004).

En tal sentido, aislar la masa suspendida de las perturbaciones de la carretera se podría lograr con un amortiguamiento suave permitiendo una larga deflexión de la suspensión. Por otro lado, un mejor contacto con la carretera se lograría con un amortiguamiento rígido, evitando deflexiones innecesarias de la deflexión. En consecuencia, lograr el equilibrio entre estos dos criterios es un conflicto.

2.3. Tipos de Suspensiones

Generalmente, un sistema de suspensión se puede clasificar por la cantidad de energía requerida y el ancho de banda del actuador, que es la rapidez con la que el actuador responde. Específicamente, tres características son tomadas en cuenta: el rango de controlabilidad, que es el rango de fuerzas

que es que capaz de desarrollar el actuador; el ancho de banda de control, que es la rapidez con la que el actuador puede responder; la energía requerida que principalmente se debe al rango de controlabilidad y al ancho de banda de control (Savaresi *et al*, 2010).

Se adoptará las nomenclaturas inicialmente introducidas por (Isermann, 2010).

- Suspensión adaptativa: la acción de control es representada por una relativamente baja modulación del amortiguamiento, así que el rango de control está limitado por las restricciones de pasividad. El amortiguador está caracterizado por un ancho de banda de unos pocos Hertz, ya que no se introduce energía en el sistema y el ancho de banda es relativamente reducido. La energía requerida está limitada a unos pocos Watts.
- Suspensión semi-activa: este sistema se caracteriza por un amortiguador electrónico, el cual puede variar el amortiguamiento con un amplio ancho de banda (generalmente alrededor de 30-40 Hz). Las fuerzas que genera siguen las restricciones de pasividad del amortiguador, así que no se necesita introducir energía en el sistema. Por lo tanto, la energía requerida es solo unas pocas decenas de Watts.
- Suspensión con niveles de carga: este tipo de suspensión es considerada como el primer intento de suspensión activa, ya que es capaz de introducir energía al sistema para cambiar las condiciones de estado estacionario (como respuesta ante un cambio de carga estática). El control actúa en el parámetro del resorte. El ancho de banda está dentro 0.1-1 Hz, pero la energía requerida generalmente son unos cientos de Watts.
- Suspensión activa lenta: en las suspensiones activas las restricciones de pasividad no existen, y se puede introducir energía dentro del sistema. La entrada de control es la fuerza de suspensión F entregada por un actuador, el cual reemplaza los dispositivos pasivos de la suspensión. El ancho de banda está limitado a unos pocos Hertz.

- Suspensión completamente activa: la diferencia con la suspensión anterior es con respecto al ancho de banda. El actuador de la suspensión completamente activa es capaz de reaccionar en unos pocos milisegundos (ancho de banda 20-30Hz). Como se puede apreciar el ancho de banda es casi el mismo que la suspensión semi-activa, pero ya que su rango de controlabilidad es mucho mayor, la energía total requerida se multiplica a unas decenas de Kilo-Watts.

2.4. Modelo de Suspensión Semi-activa

2.4.1. Modelo de Suspensión Pasiva no Lineal

El propósito del presente trabajo solo se enfoca en la dinámica vertical del vehículo, que es la que está directamente influenciada por el sistema de suspensión. La dinámica lateral y la longitudinal no se considerarán.

En los trabajos de investigación relacionados con sistemas de suspensión, frecuentemente se utiliza un modelo de suspensión de un cuarto de vehículo. Este modelo simplifica muchas complicaciones que se presentan cuando se usa un modelo completo de vehículo, pues en los modelos completos se deben considerar características como el derrape y cabeceo que están relacionados con la dinámica longitudinal y lateral del vehículo.

De forma general el modelo no lineal de una suspensión pasiva de un cuarto de vehículo se considera con la siguiente expresión (Savaresi et al, 2010) (ver Figura 2.7).




Figura 2.7. Forma general del modelo no lineal de una suspensión pasiva.

$$\begin{cases} m_s \ddot{z}_s(t) = -F_k(t) - F_d(t) - F_L(t) + m_s g \\ m_{us} \ddot{z}_{us}(t) = F_k(t) + F_d(t) - F_{kt}(t) - F_{dt}(t) - m_{us} g \end{cases} \quad (2.3)$$

Donde $F_k(t)$ y $F_d(t)$ son funciones que describen la fuerza vertical del resorte y del amortiguador de la suspensión, respectivamente. $F_{kt}(t)$ y $F_{dt}(t)$ describen la fuerza vertical de rigidez y de amortiguamiento del neumático, respectivamente. La aceleración de la gravedad es representada por g . Del mismo modo M y m representan la masa del chasis y de la rueda, que vendrán a ser llamadas masa suspendida y masa no suspendida, respectivamente. $z_s(t)$ y $z_{us}(t)$ representan el desplazamiento de la masa suspendida y la masa no suspendida respectivamente. Finalmente, $z_r(t)$ representa las perturbaciones verticales de la carretera y $F_L(t)$ representa una perturbación vertical de carga.

Mediante algunas consideraciones se linealiza el sistema.

La perturbación de carga vertical generalmente se usa para análisis de transferencia de carga cuando se estudian las maniobras de conducción y frenado, tales efectos no se consideran en este trabajo; por lo tanto no será considerada como una entrada del sistema:

$$F_L(t) = 0 \quad (2.4)$$

Para el neumático, la descripción lineal de la fuerza de rigidez que ejerce se considera según la ecuación.

$$F_{kt}(t) = K_t(z_{us}(t) - z_r(t)) \quad (2.5)$$

Y se considera despreciable su fuerza de amortiguamiento, pues en la práctica el coeficiente de amortiguamiento es mucho menor que su coeficiente de rigidez, por tal motivo puede ser ignorado.

$$F_{dt}(t) = 0 \quad (2.6)$$

Para el resorte de la suspensión la descripción lineal sería.

$$F_k(t) = -K_s(z_s(t) - z_{us}(t)) \quad (2.7)$$

Para el amortiguador de la suspensión la descripción lineal sería.

$$F_d(t) = -C_s(\dot{z}_s(t) - \dot{z}_{us}(t)) \quad (2.8)$$

El modelo simplificado y lineal de una suspensión pasiva de un cuarto de vehículo quedaría de la siguiente manera.

$$\begin{cases} m_s \ddot{z}_s(t) = -K_s(z_s(t) - z_{us}(t)) - C_s(\dot{z}_s(t) - \dot{z}_{us}(t)) \\ m_{us} \ddot{z}_{us}(t) = K_s(z_s(t) - z_{us}(t)) + C_s(\dot{z}_s(t) - \dot{z}_{us}(t)) - K_t(z_s(t) - z_r(t)) \end{cases} \quad (2.9)$$

En la Figura 2.8 se puede observar la configuración del diagrama de bloques de la suspensión pasiva en Simulink.

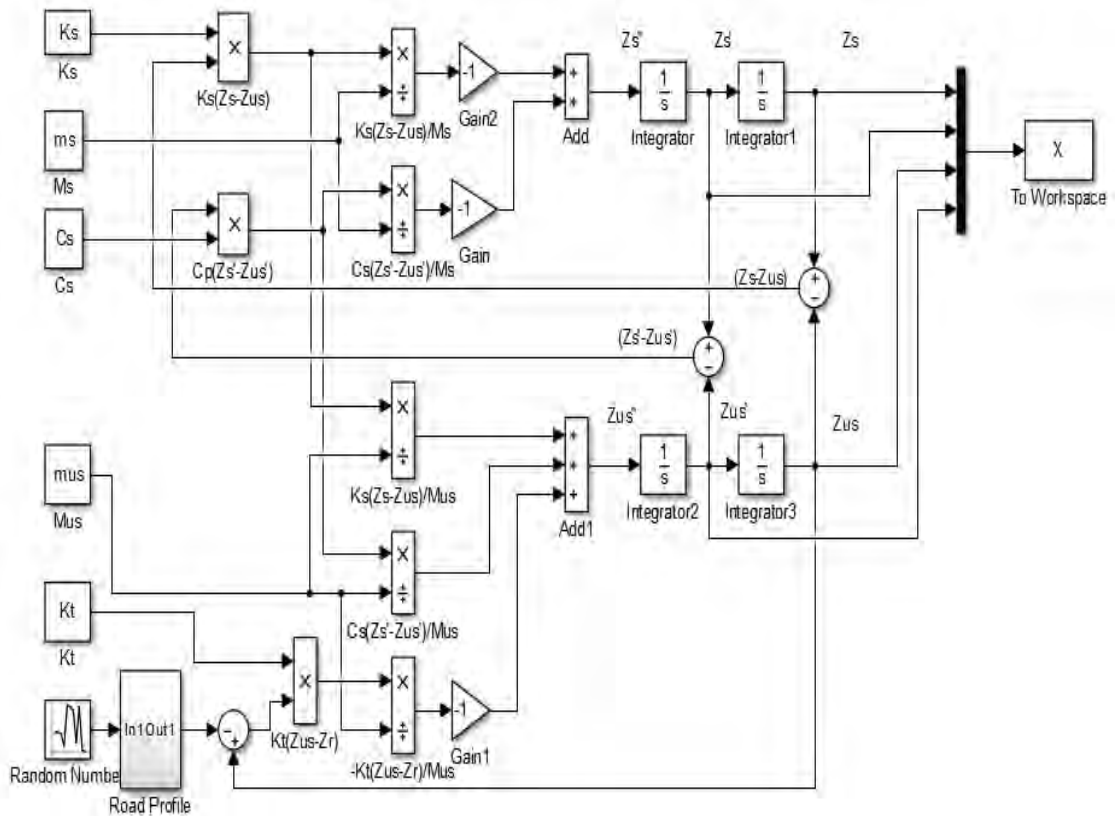


Figura 2.8. Sistema de Suspensión Pasiva.

2.4.2. Análisis de Estabilidad de la Suspensión Pasiva

La rigidez efectiva de la suspensión es llamada “tasa de paseo” y se determina mediante:

$$RR = \frac{K_s K_t}{K_s + K_t} \quad (2.10)$$

En ausencia de amortiguador, la frecuencia natural de amortiguamiento para cada esquina del vehículo puede ser determinada de:

$$\omega_n = \sqrt{\frac{RR}{m_s}} \left(\frac{rad}{s} \right) \quad (2.11)$$

La resonancia ocurre a la frecuencia natural amortiguada.

$$\omega_d = \omega_n \sqrt{1 - \zeta^2} \left(\frac{rad}{s} \right) \quad (2.12)$$

$$\zeta = \frac{C_s}{\sqrt{4K_s m_s}} \quad (2.13)$$

Para un buen viaje el coeficiente de amortiguamiento (ζ) debe estar entre $0.2 \leq \zeta \leq 0.4$

Para el modo de la masa suspendida se tiene.

$$RR = \frac{86\,378(270\,000)}{86\,378 + 270\,000}$$

$$RR = 65\,441.918$$

$$\omega_n = \sqrt{\frac{65\,441.918}{470}} \left(\frac{rad}{s} \right)$$

$$\omega_n = 11.8 \left(\frac{rad}{s} \right) = 1.88 \text{ (Hz)} \quad (2.14)$$

Y su coeficiente de amortiguamiento

$$\zeta = 2 \frac{830.86}{\sqrt{4(86\,378)(470)}}$$

$$\zeta = 0.22 \quad (2.15)$$

Que se encuentra dentro del rango garantizado para un buen desempeño. La frecuencia amortiguada será.

$$\omega_d = 11.8 \sqrt{1 - (0.22)^2} \left(\frac{rad}{s} \right)$$

$$\omega_d = 11.51 \left(\frac{rad}{s} \right) = 1.83 \text{ (Hz)} \quad (2.16)$$

Para el modo de la masa no suspendida se tendría la frecuencia natural igual a:

$$\omega_n = \sqrt{\frac{K_t}{m_{us}}} \left(\frac{rad}{s} \right)$$

$$\omega_n = \sqrt{\frac{270\,000}{110}} \left(\frac{rad}{s} \right)$$

$$\omega_n = 49.54 \left(\frac{rad}{s} \right)$$

$$\omega_n = 7.88 \text{ (Hz)} \quad (2.17)$$

Los parámetros de un modelo validado del vehículo se obtuvieron de (Varrier *et al*, 2013) y se muestran en la Tabla 2.1.

Tabla 2.1. Parámetros de un vehículo comercial

parámetro	Valor	unidades
m_s	470	Kg
K_s	86 378	N/m
C_s	2 830.86	Ns/m
m_{us}	110	Kg
K_t	270 000	N/m

2.4.3. Amortiguador MR para Suspensión Semi-activa

Como se mencionó antes, una suspensión semi-activa posee un amortiguador con un coeficiente de amortiguamiento variable que se ajusta de acuerdo a los requerimientos impuestos por el perfil de carretera. Al variar

el coeficiente de amortiguamiento variará también la fuerza ejercida, ver Figura 2.9.

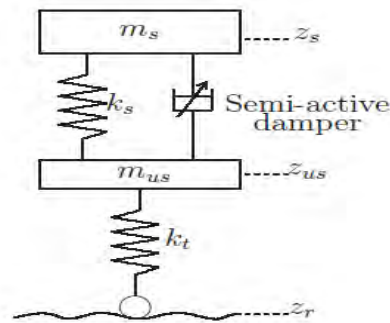


Figura 2.9. Modelo de un cuarto de vehículo con amortiguador semi-activo (Lam-Do, 2006).

La fuerza ejercida por el amortiguador semi-activo depende de su tipo, y de las consideraciones que se tengan en cuenta. Las dos tecnologías más resaltantes son los amortiguadores electro-reológicos y los amortiguadores magneto-reológicos. Ambos tipos de amortiguadores están rellenos con un fluido reológico, el cual cambia su viscosidad al variar el campo eléctrico o magnético, según sea el caso, cambiando así su coeficiente de amortiguamiento.

Un fluido magneto-reológico está compuesto por aceite (generalmente se usa aceite de silicona) y partículas sensibles a los campos magnéticos (por ejemplo, partículas de hierro). Cuando no existe ningún campo magnético el fluido MR se comporta como líquido, y cuando se le aplica un campo magnético las partículas del fluido MR forman cadenas, variando así la viscosidad del fluido.

En un amortiguador MR el pistón posee unos orificios, los cuales incluyen unas bobinas que son alimentadas con corriente por medio de un par de cables que salen al exterior del dispositivo. Al recibir corriente las bobinas crean un campo magnético el cual modifica la viscosidad del fluido MR, haciendo que sea más difícil que este atraviese los orificios del pistón, ver Figura 2.10. De esta manera, el pistón podría ser visto como una válvula MR.




Figura 2.10. Comportamiento de amortiguador MR: con y sin campo magnético (B). (Savaresi *et al*, 2010)

Este tipo de amortiguador se ve afectado por efectos de histéresis, como se puede ver en el trabajo realizado en (Xubin-Song, 1999) donde se experimentó con un amortiguador real de la marca LORD, la gráfica que se obtuvo de su experimento la podemos ver en la Figura 2.11.

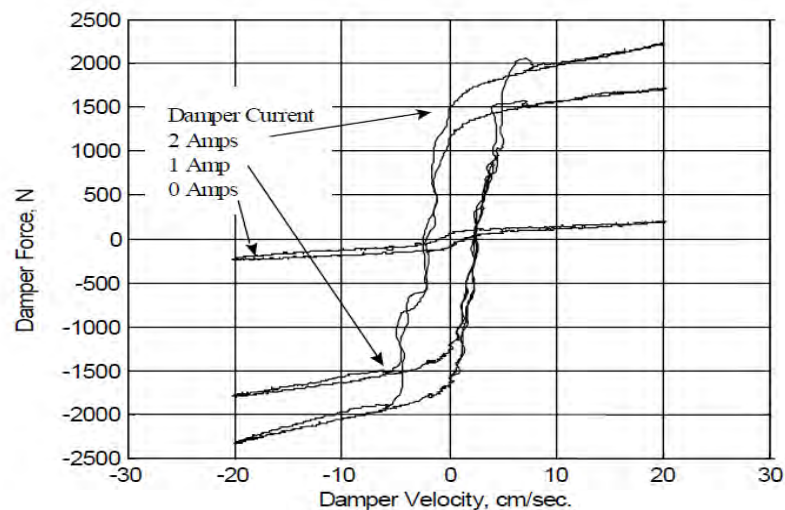


Figura 2.11. Efecto de histéresis en un amortiguador MR real (Xubin-Song, 1999).

Los modelos más usados para trabajar con amortiguadores MR son principalmente dos, a partir de los cuales se han creado variaciones que se asemejan mejor en algunos aspectos a los amortiguadores reales. A

continuación, se mencionan los modelos que mejor representan el comportamiento de histéresis y se describen sus principales características.

2.4.3.1. Modelo Bingham

El comportamiento visco-plástico de tensión-deformación se utiliza en el modelo de Bingham. El modelo contiene una zona muerta o un salto discontinuo en la respuesta fuerza-velocidad del amortiguador.

En el modelo Bingham existe un elemento de fricción de Coulomb f_c , que representa la magnitud de la histéresis y se encuentra localizado paralelamente al elemento de amortiguamiento representado por c_0 , como se puede ver en la Figura 2.12.




Figura 2.12. Estructura reológica de un amortiguador MR modelo Bingham (Sapiński *et al*, 2003).

De acuerdo al modelo MR de Bingham, para velocidades del pistón diferentes de cero \dot{x} , la fuerza de amortiguamiento F puede expresarse como (Sapiński *et al*, 2003):

$$F = f_c \operatorname{sgn} \dot{x} + c_0 \dot{x} + f_0 \quad (2.18)$$

Donde f_c es fuerza de fricción, c_0 es el coeficiente viscoso, f_0 es la fuerza debido a la presencia del acumulador. Esta última simplificación en el modelo resulta de la suposición de que la elasticidad que reemplaza la actividad del acumulador posee una rigidez baja y característica lineal.

2.4.3.2. Modelo Bouc-Wen

Este modelo contiene componentes de amortiguamiento viscoso, resorte y un componente de histéresis. El modelo puede ser descrito por la ecuación de la fuerza y la variable de histéresis.

$$F = c_0\dot{x} + kx + \alpha z + f_0 \quad (2.19)$$

$$\dot{z} = \delta\dot{x} - \beta\dot{x}|z|^n - \gamma z|\dot{x}||z|^{n-1} \quad (2.20)$$

Donde $\alpha, \beta, \delta, \gamma, n$ son los parámetros del modelo y z es la variable de histéresis. Nota que cuando $\alpha = 0$, el modelo representa un amortiguador convencional.

2.4.3.3. Modelo Adoptado de Amortiguador MR

En el presente trabajo se ha considerado una adaptación del modelo semi-fenomenológico de (Guo *et al*, 2006; Lozoya-Santos *et al*, 2009). En términos de expresiones matemáticas el modelo hace uso de una función tangente hiperbólica que representa la histéresis, y de dos funciones lineales que representan el coeficiente viscoso y el coeficiente de rigidez y se representa por:

$$F = c_p\dot{x}_{def} + k_px_{def} + \alpha z \quad (2.21)$$

$$z = \tanh(a_v\dot{x}_{def} + a_d x_{def}) \quad (2.22)$$

Se debe notar que el modelo contiene solo una simple tangente hiperbólica, y es computacionalmente eficiente en el contexto de la estimación paramétrica y la subsecuente inclusión en el diseño e implementación de un controlador. En el siguiente párrafo, se hace una descripción y un análisis de los parámetros.

El amortiguador MR está compuesto por un pistón, un cilindro y una cámara de gas. Se divide en la cámara superior y la cámara inferior por medio del pistón, y está relleno con el fluido MR. Existe un pistón flotante entre el cilindro y la cámara de gas (cámara inferior), el cual es usado con el objeto de compensar el volumen inducido por el movimiento del pistón principal. También la cámara de gas, la cual está llena de un gas nitrógeno, actúa como un acumulador para absorber la variación de la presión de la cámara más baja del amortiguador inducida por el rápido movimiento del pistón.

Asumiendo que el fluido MR es no compresible y que la presión en la cámara se encuentra uniformemente distribuida (Min-Sang *et al*, 2011). Para un fluido laminar en el ducto anular, la resistencia del fluido está dada por

$$R_e = 8\eta \frac{L}{\pi \left[R_o^4 - R_i^4 - \frac{(R_o^2 - R_i^2)^2}{\ln \frac{R_o}{R_i}} \right]} \quad (2.23)$$

Donde η es la viscosidad del fluido MR y L es la longitud del ducto anular. R_o y R_i son el radio interior del pistón exterior y el radio exterior del pistón interior, respectivamente. En el caso de que el fluido sea compresible, su resistencia no será constante ya que la caída de presión en la cámara variará. Esto podría ocurrir en el caso de presentarse una fuga del líquido MR.

Asumiendo que el gas no intercambia calor con su entorno, y por lo tanto considerando su relación como una variación adiabática, en la cámara de gas se cumple que:

$$C_g = \frac{V_o}{P_o k} \quad (2.24)$$

Donde V_o y P_o son el volumen y la presión inicial del gas respectivamente, y k es el ratio de calor específico. Por otro lado, la caída de presión debido al incremento de la tensión elástica del fluido MR está dada por.

$$P_{MR} = 2 \frac{c L_p}{h} \tau_y(B) \quad (2.25)$$

Donde c es un coeficiente que depende del perfil de velocidad del fluido y tiene un valor entre 2.0 a 3.0, L_p es la longitud del polo magnético, h es la separación del conducto anular, y $\tau_y(B)$ es la tensión elástica causada por la densidad B del flujo magnético. Por lo tanto, la fuerza del amortiguador propuesto puede ser descrito como

$$F_D = K_p x_p + C_p \dot{x}_p + F_{MR} \quad (2.26)$$

Donde

$$K_p = \frac{A_r^2}{C_g}, \quad C_p = (A_p - A_r)^2 R_e$$

$$F_{MR} = P_{MR} \tanh(a_v \dot{z}_{def} + a_d z_{def})$$

Con x_p y \dot{x}_p como el desplazamiento y la velocidad del pistón respectivamente, A_p y A_r representan el área del pistón y el área del vástago del pistón respectivamente.

Los parámetros del modelo validado son adoptados con base en (Varrier *et al*, 2013; Lozoya-Santos *et al*, 2012b) y se muestran en la Tabla 2.2. El modelo del amortiguador viene representado por la siguiente ecuación:

$$F_D = K_p z_{def} + C_p \dot{z}_{def} + f_c v \tanh(a_v \dot{z}_{def} + a_d z_{def}) \quad (2.27)$$

Donde:

$z_{def} = (z_s - z_{us})$ es la deflexión de la suspensión.

v : entrada de control del amortiguador (corriente eléctrica).

f_c : es el coeficiente de fricción.

C_p : es el coeficiente de amortiguamiento viscoso.

K_p : es el coeficiente de rigidez elástica.

a_v y a_d : son coeficientes que caracterizan el comportamiento de histéresis.

Tabla 2.2. Parámetros de un amortiguador MR comercial.

parámetro	Valor	unidades
C_p	2 830.86	Ns/m
K_p	-7 879.21	N/m
a_v	37.85	s/m
f_c	600.95	Ns/A
k_t	270 000	N/m
a_d	22.15	1/m

Se realizaron algunas simulaciones para observar el desempeño del modelo elegido. Ante una excitación sinusoidal amplitud 1 cm con una frecuencia de 3Hz. Se probó el amortiguador para corrientes constantes de 0, 0.25, 0.5, 0.75 y 1 amperios, los resultados se muestran en la Figura 2.13.




Figura 2.13. Comportamiento del amortiguador MR ante 5 valores de corriente.

Se puede observar que a mayor corriente aplicada al amortiguador mayor es la fuerza ejercida. Con esta fuerza más grande se puede tener un mejor control de las variables de interés que son la aceleración de la masa suspendida y la deflexión de la suspensión.

2.5. Control de una Suspensión Semi-activa

Se puede decir que el control de un sistema de suspensión es un problema multi-objetivo, porque se debe mejorar la maniobrabilidad, incrementar el confort y reducir la potencia del controlador (Hurel *et al*, 2013). A continuación, se analizan algunas estrategias de control convencional e inteligente.

2.5.1. Metodologías de Control Convencional para Suspensiones

Estas basan su diseño en un modelo matemático del sistema.

2.5.1.1. Control PID

En (Xubin-Song, 1999), se propone controladores PID con doble realimentación: una interna para el control de fuerza y otra externa para el control de la deflexión de la suspensión.

2.5.1.2. Control Sky-hook y Ground-hook

El control Sky-hook asume la existencia de un amortiguador ficticio conectado entre la masa suspendida y el cielo que se encuentra estacionario. Se enfoca en mejorar el confort al tratar de reducir la aceleración de la masa suspendida, pero descuida la maniobrabilidad.

El control Ground-Hook trabaja de forma inversa, y asume un amortiguador ficticio en el suelo, tratando de regular la fuerza transmitida del suelo a la suspensión, mejorando de esta manera la maniobrabilidad pero deteriorando el confort.

Trabajando estas dos técnicas en conjunto, se puede mejorar ambas características.

2.5.1.3. El Control Óptimo LQ

Se usa cuando un sistema lineal utiliza una función cuadrática en la optimización. En el caso del sistema de suspensión la incertidumbre viene dada por el perfil de carretera, las restricciones se caracterizan en el índice de rendimiento usando las medias cuadráticas de la aceleración de la masa suspendida, la deflexión de la suspensión y la deflexión del neumático (Ekoru *et al*, 2011).

2.5.2. Metodologías de Control Inteligente para Suspensiones

Las metodologías de control inteligente facilitan el trabajo con sistemas no lineales, con incertidumbres e imprecisiones.

2.5.2.1. Control Difuso

Mediante variables lingüísticas forma algoritmos de control que emulan la lógica humana, pero no necesitan un conocimiento exacto del sistema.

Asimismo, se puede generar el coeficiente de amortiguamiento mediante un reducido número de reglas difusas.

2.5.2.2. Control Neuronal

A partir de modelos neuronales, se obtienen algoritmos de entrenamiento supervisados y no supervisados, una red neuronal puede ser entrenada para controlar el sistema de suspensión, consigue emular un controlador existente.

2.5.3. Diseño de un Controlador Sky-hook

Dentro de los enfoques que se revisaron con respecto al control de sistemas de suspensión semi-activas tenemos dos principales: a) los que se centran en validación experimental y b) técnicas que aún no son validadas (Lozoya-Santos *et al*, 2011).

Dentro de los enfoques de validación experimental, se tiene el más ampliamente desarrollado controlador Sky-hook.

El control Sky-hook permite variar el coeficiente de amortiguamiento entre un valor alto y un valor bajo, adaptándose al perfil de carretera y a las necesidades que se presentan, ver Figura 2.14.

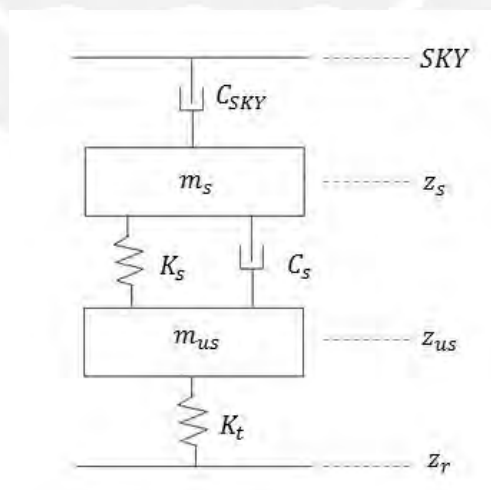


Figura 2.14. Control Sky-Hook para suspensión.

La velocidad relativa de la masa suspendida con la masa no suspendida sería $\dot{z}_{def} = \dot{z}_s - \dot{z}_{us}$, y será positiva cuando las masas se estén alejando.

Supongamos que la masa suspendida se está alejando de la masa no suspendida con un velocidad positiva (dirección positiva z_s) y necesitaremos que la fuerza aplicada sea en dirección negativa de z_s .

$$F_{SKY} = -C_{SKY}\dot{z}_s \quad (2.28)$$

El amortiguador estará en tensión y necesitamos saber si es capaz de ejercer esta fuerza (en dirección negativa z_s) para ello.

$$F_{CONTROLABLE} = -C_{CONTROLABLE}\dot{z}_{def} \quad (2.29)$$

Entonces, el coeficiente de amortiguamiento controlable será:

$$C_{CONTROLABLE} = C_{SKY} \frac{\dot{z}_s}{\dot{z}_{def}} \quad (2.30)$$

Por lo tanto, la fuerza solo se ejerce cuando ambas velocidades tienen el mismo signo:

$$\dot{z}_s \dot{z}_{def} \geq 0 \quad F_{SA} = C_{SKY}\dot{z}_s \quad (2.31)$$

$$\dot{z}_s \dot{z}_{def} < 0 \quad F_{SA} = 0 \quad (2.32)$$

La ley de control que aplica este enfoque es:

$$F_{SA} = \begin{cases} C_{sky} \dot{z}_s & \dot{z}_s(\dot{z}_s - \dot{z}_{us}) \geq 0 \\ 0 & \dot{z}_s(\dot{z}_s - \dot{z}_{us}) < 0 \end{cases} \quad (2.33)$$

Para nuestro caso usamos esta definición para encontrar la corriente que será aplicada.

$$I = \begin{cases} K|\dot{z}_s| & \dot{z}_s(\dot{z}_s - \dot{z}_{us}) \geq 0 \\ 0 & \dot{z}_s(\dot{z}_s - \dot{z}_{us}) < 0 \end{cases} \quad (2.34)$$

Donde K es una constante que mediante pruebas se determinó que valdrá 10.

2.6. Modelo de la Suspensión Semi-activa en Espacio de Estados

Para poder realizar el control Sky-hook es necesario contar con dos señales de salida de la suspensión, la velocidad de la masa suspendida \dot{z}_s y la velocidad de la deflexión de la suspensión \dot{z}_{def} . Pero esta segunda señal se

puede conseguir de dos formas: midiendo la velocidad de la masa no suspendida \dot{z}_{us} y restándola con \dot{z}_s , o de lo contrario medir la deflexión de la suspensión z_{def} y por medio de derivación numérica obtener \dot{z}_{def} .

Dadas las características del sistema solo es viable medir tres variables, que son: la aceleración de masa suspendida, la aceleración de la masa no suspendida que se puede realizar por medio de acelerómetros, y la deflexión de la suspensión que se puede hacer con un transformador diferencial de variación lineal (LVDT). Los valores de las velocidades podrán ser obtenidas por integración.

Para simplificar los problemas de diseño y evitar complicaciones matemáticas, se asume que es posible la medición directa de $y_1 = \dot{z}_s$ y $y_2 = \dot{z}_{us}$. Además de estas dos señales también se estará midiendo $y_3 = z_{def}$, ya que esta información es necesaria para la estimación paramétrica que se explicará más adelante.

Estableciendo el vector de estados como la posición de la masa suspendida, la velocidad de la masa suspendida, la posición de la masa no suspendida y la velocidad de la masa no suspendida.

$$x_1 = z_s \quad x_2 = \dot{z}_s \quad x_3 = z_{us} \quad x_4 = \dot{z}_{us} \quad (2.35)$$

Donde:

$$\dot{x}_1 = x_2 \quad (2.36a)$$

$$\dot{x}_2 = -\frac{K_s}{m_s} (x_1 - x_3) - \frac{F_D}{m_s} \quad (2.36b)$$

$$\dot{x}_3 = x_4 \quad (2.36c)$$

$$\dot{x}_4 = \frac{K_s}{m_{us}} (x_1 - x_3) + \frac{F_D}{m_{us}} - \frac{K_t}{m_{us}} (x_3 - x_r) \quad (2.36d)$$

Donde x_r es la perturbación del perfil de carretera z_r , Además:

$$F_D = K_p(x_1 - x_3) + C_p(x_2 - x_4) + f_c v \tanh(a_v(x_2 - x_4) + a_d(x_1 - x_3))$$

La no linealidad de la señal de control se deja fuera de la matriz B tal que:

$$u = f_c v \tanh(a_v(x_2 - x_4) + a_d(x_1 - x_3)) \quad (2.37)$$

Luego el modelo en espacio de estados queda de la siguiente manera.

$$\dot{x}(t) = Ax(t) + Bu(t) + B_z z_r(t) \quad (2.38)$$

$$y(t) = Cx(t) + D_f f(t) \quad (2.39)$$

Donde:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \\ \dot{x}_4 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ -\frac{K_p+K_s}{m_s} & -\frac{C_p}{m_s} & \frac{K_p+K_s}{m_s} & \frac{C_p}{m_s} \\ 0 & 0 & 0 & 1 \\ \frac{K_p+K_s}{m_{us}} & \frac{C_p}{m_{us}} & -\frac{K_p+K_s+K_t}{m_{us}} & -\frac{C_p}{m_{us}} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} + \begin{bmatrix} 0 \\ -1 \\ 0 \\ 1 \end{bmatrix} u + \begin{bmatrix} 0 \\ 0 \\ 0 \\ \frac{k_t}{m_{us}} \end{bmatrix} z_r \quad (2.40a)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} x_2 \\ x_4 \\ x_1 - x_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & -1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ f_3 \end{bmatrix} \quad (2.40b)$$

Los eigenvalores de la matriz son:

$$p_{1,2} = -14.1896 \pm 54.6330i$$

$$p_{3,4} = -1.6895 \pm 11.7784i$$

Se observa que existen dos pares de polos conjugados con parte real negativa. Tomando la parte real del modo más rápido es posible ver que su constante de tiempo es igual 70.5 ms y la del modo más lento es 0.592 s .

Las mediciones de las velocidades están muestreadas con un intervalo de tiempo T_s . Este intervalo debe ser elegido de tal manera que sea posible capturar la dinámica de los modos dominantes del sistema. Idealmente, el intervalo de tiempo deberá ser una décima parte del modo más rápido (Ersanilli *et al*, 2009); es decir, en este caso $T_s = 7 \text{ ms}$ ó 143 Hz .

El diagrama de bloques en Simulink de la suspensión semi-activa queda como en la Figura 2.15.

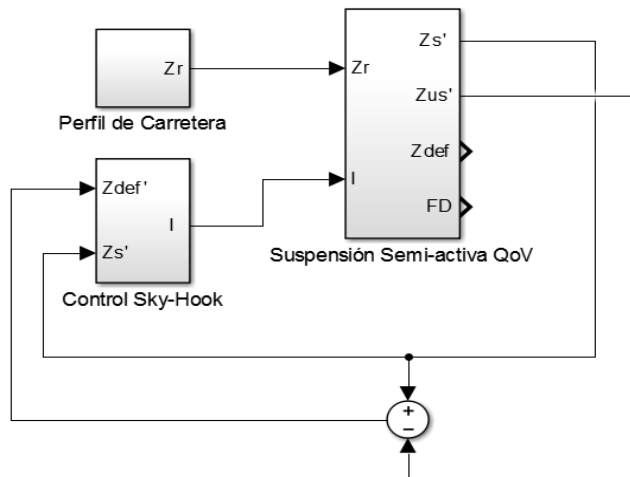


Figura 2.15. Diagrama de bloques de suspensión semi-activa con control Sky-Hook.

El bloque “*Perfil de Carretera*” genera el camino “ z_r ” que representa la perturbación no medible. Su desarrollo se presenta más adelante.

Dentro del bloque de la suspensión que recibe como entradas la corriente calculada del controlador Sky-Hook, y también el perfil de carretera, se calcula los valores de las variables de estado, como se puede ver en la Figura 2.16.

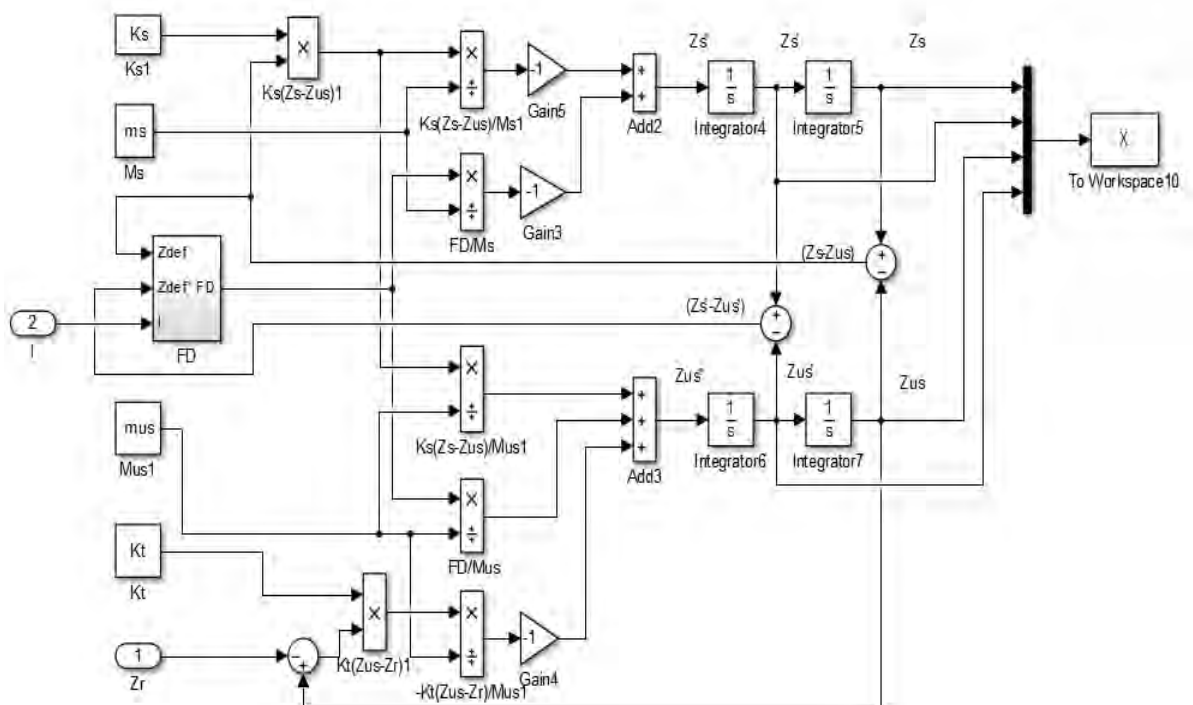


Figura 2.16. Suspensión semi-activa, cálculo de las variables de estado.

En la Figura 2.17 vemos el bloque FD, donde se calcula la fuerza del amortiguador.

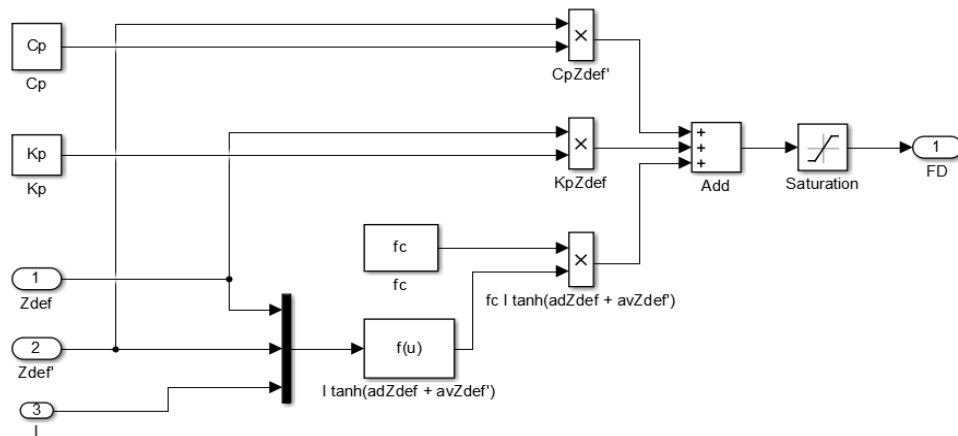


Figura 2.17. Cálculo de la fuerza del amortiguador MR.

Que tiene como entradas, la deflexión de la suspensión y la velocidad de la deflexión de la suspensión. Además, de la corriente aplicada al amortiguador MR.

La corriente que se aplica al amortiguador MR, se genera con la ley de control del controlador Sky-Hook como se ve en la Figura 2.18.

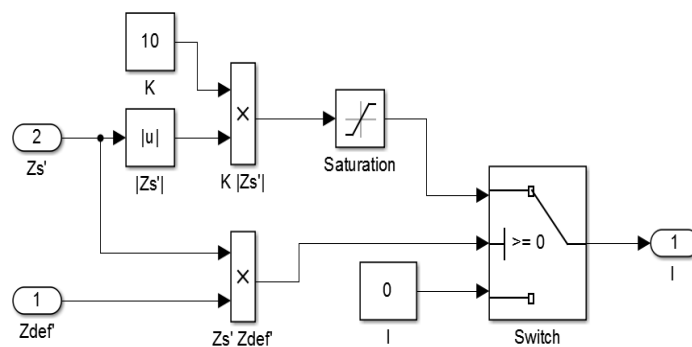


Figura 2.18. Cálculo de corriente aplicada al amortiguador MR mediante Sky-Hook.

Como podemos ver se analiza el valor de la velocidad de la masa suspendida y de la velocidad de la deflexión de la suspensión. Se decide el valor de la corriente, y se limita a 1 amperio que es la corriente máxima que soportan las bobinas internas del amortiguador MR.

2.6.1. Comparación de Desempeño entre una Suspensión Pasiva y Suspensión Semi-activa

Para probar el desempeño de la suspensión semi-activa con control sky-hook, este se comparará con el desempeño de una suspensión pasiva. Se consideran tres perfiles de carretera: una entrada tipo escalón con 5 mm de amplitud que aparece en el segundo 5 de la simulación, una función seno de 10 mm de amplitud y una frecuencia de 3 Hz, y un perfil de carretera aleatorio cuyo diseño se muestra en el Anexo A.

2.6.1.1. Respuesta en el Tiempo a Entrada escalón

En la Figura 2.19, se puede observar que la suspensión semi-activa (línea azul) posee una mejor amortiguación que la suspensión pasiva (línea roja) ante la entrada tipo escalón.

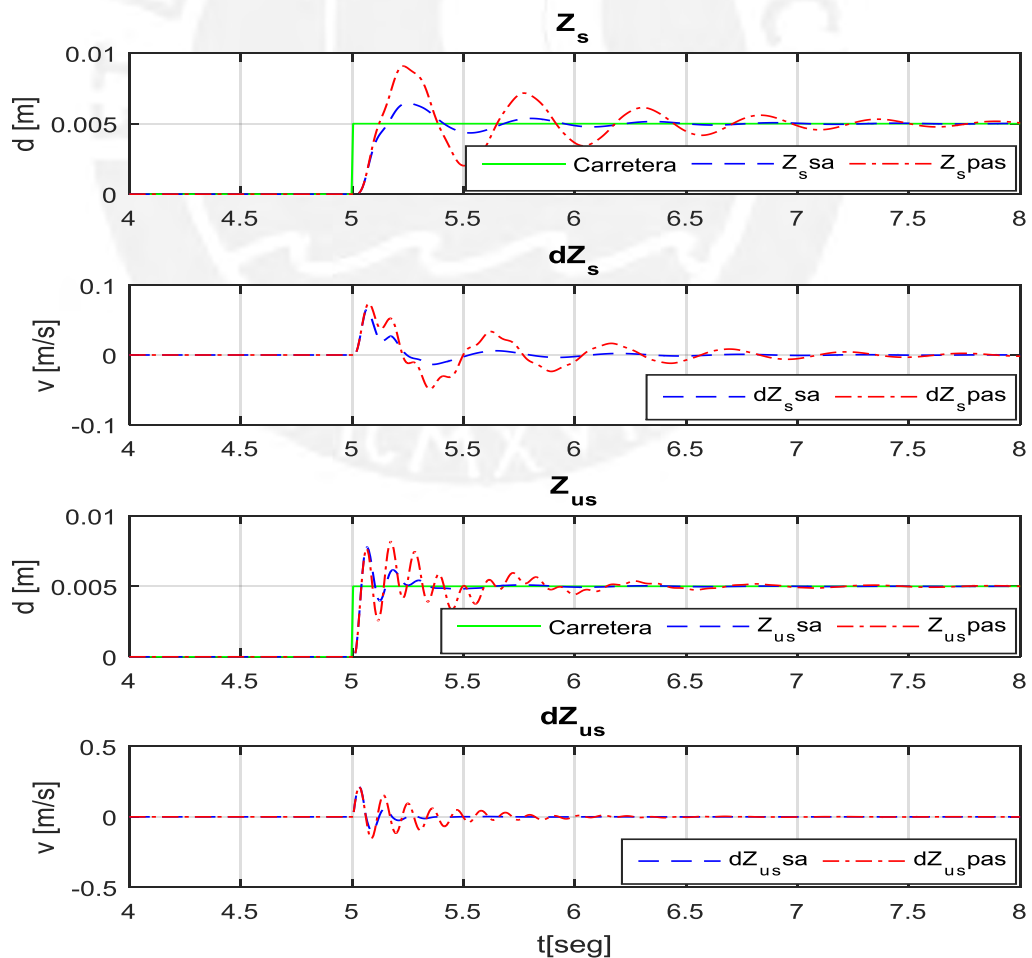


Figura 2.19. Respuesta del sistema ante una carretera tipo escalón.

La masa suspendida converge rápidamente a su estado estacionario en el caso de la suspensión semi-activa, para la suspensión pasiva el tiempo de convergencia es mucho mayor. Además, es posible notar el mayor sobreimpulso que existe para la suspensión pasiva.

La velocidad tanto de la masa suspendida como la de la masa no suspendida, tienen casi el mismo sobreimpulso para ambos tipos de suspensiones, aunque es posible notar que para la suspensión semi-activa existen menos oscilaciones, esto demuestra el mejor desempeño del control Sky-hook para este sistema, mejorando el confort y la estabilidad en el manejo.

En la Figura 2.20 se puede observar la corriente que se aplicó al amortiguador MR.

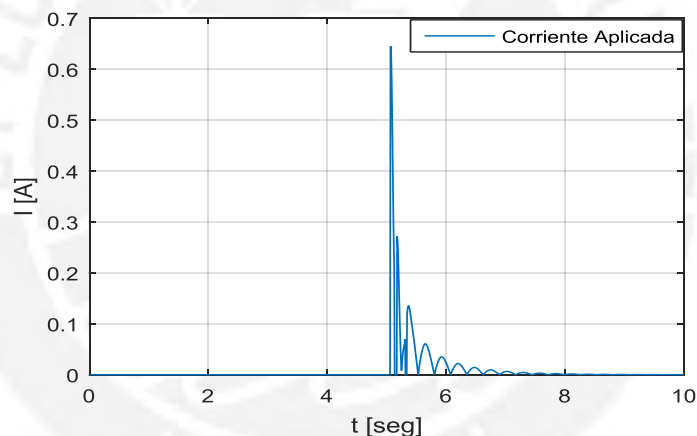


Figura 2.20. Corriente aplicada, carretera tipo escalón.

La corriente máxima que se puede inyectar al amortiguador MR es de 1 amperio y como se puede notar, no fue necesario aplicar este valor. Además, solo fue necesario inyectar corriente en el momento de la aparición del escalón, hasta que el sistema volvió a estabilizarse, en aproximadamente 1 segundo de tiempo. Con esto se pudo lograr que las masas converjan rápidamente a la nueva posición impuesta por la carretera.

2.6.1.2. Respuesta en el Tiempo a Entrada Senoidal

En la Figura 2.21, es posible observar que para una carretera tipo una función seno, el desplazamiento de la masa suspendida se presenta

desfasado del camino, para ambos tipos de suspensión, pero se puede notar que la suspensión semi-activa (línea azul) atenúa mejor la amplitud del perfil del camino.




Figura 2.21. Respuesta del sistema ante una carretera tipo función seno.

Para la masa no suspendida se observa que la suspensión pasiva tiene una mejor atenuación del perfil del camino. Esto se debe a que el control Skyhook tiene como principal función mejorar el confort del vehículo.

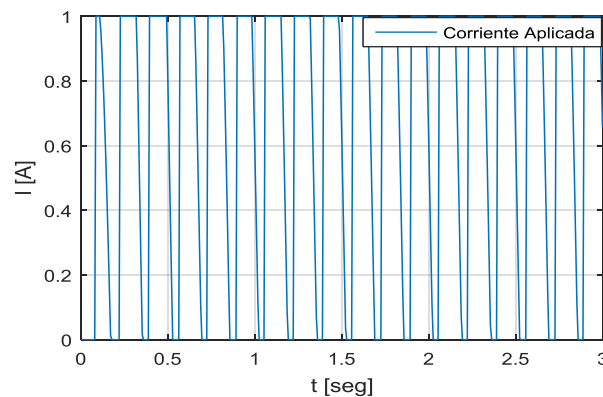


Figura 2.22. Corriente aplicada, carretera tipo función seno.

La corriente aplicada mostrada en la Figura 2.22, es mayor llegando al límite permitido, pero se debe notar que la magnitud de la carretera es mayor que en el caso anterior.

2.6.1.3. Entrada Perfil de Carretera Aleatorio

Por último, se prueba con un perfil de carretera aleatorio. Este tipo de perfil de carretera será el usado en todas las pruebas posteriores, ya que en la práctica los perfiles de carretera reales poseen estas características.

En la Figura 2.23, se observa como la suspensión actúa como un filtro, atenuando las altas frecuencias. Ambas suspensiones atenúan las irregularidades de la carretera mejorando así el confort del viaje.

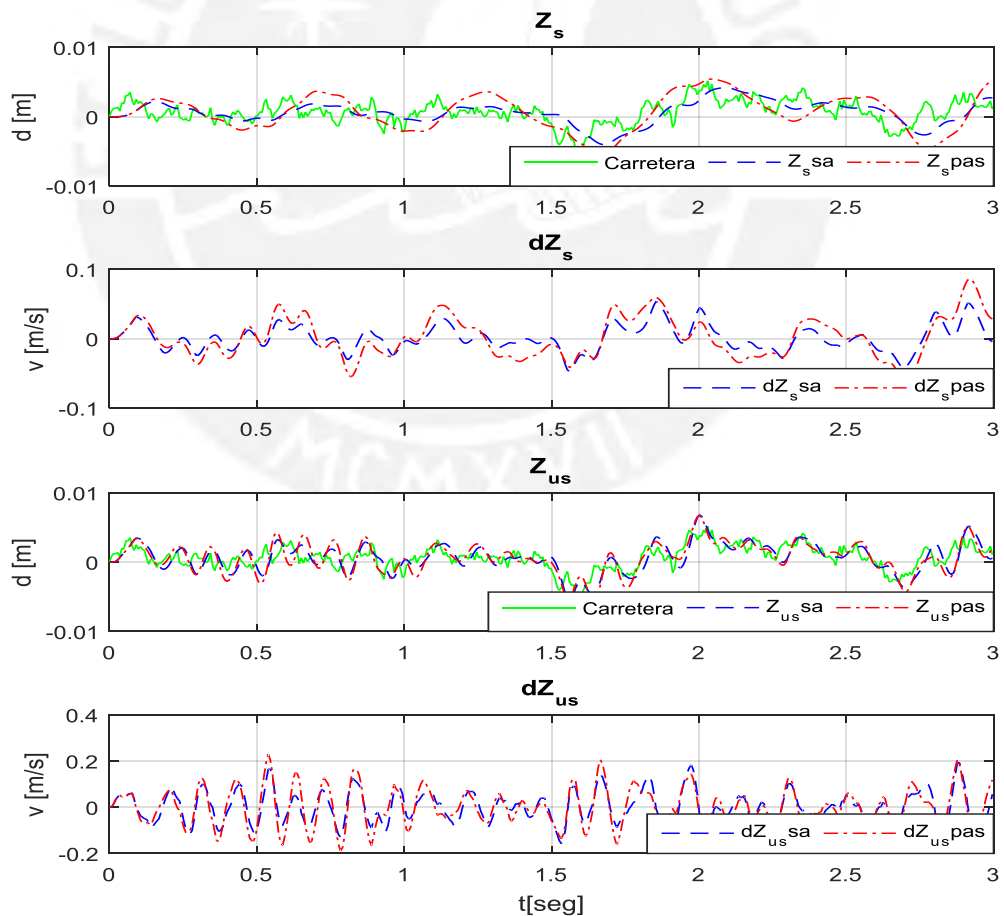


Figura 2.23. Respuesta del sistema ante perfil de carretera aleatorio.

Es posible notar que la suspensión semi-activa tiene un mejor desempeño al atenuar mejor las irregularidades. En la Figura 2.24 se observa la corriente aplicada al amortiguador MR ante este tipo de perfil de carretera.




Figura 2.24. Corriente, carretera tipo ruido blanco.

Se necesita también conocer cómo este tipo de suspensión influye en la deflexión de la suspensión, la cual está directamente relacionada con la estabilidad del sistema. Para ello la estabilidad del vehículo se evaluará mediante la deflexión de la suspensión, y el confort se hará mediante el análisis de la aceleración de la masa suspendida.

Se estudian tres casos, aplicando una corriente constante igual a cero amperios (sin control), una corriente constante igual a 1 amperio y una corriente variable (aplicando el controlador sky-hook).

En las Figuras 2.25 y 2.26 se puede ver los resultados de esta prueba.




Figura 2.25. Deflexión de la suspensión (estabilidad) para $I=0A$, $I=1A$ y I = variable.




Figura 2.26. Aceleración de la masa suspendida (confort) para $I = 0A$, $I = 1A$ y $I = \text{variable}$.

Para un análisis numérico de estas variables se usará el valor RMS (Root Mean Square).

$$x_{RMS} = \sqrt{\frac{x_1^2 + x_2^2 + x_3^2 + \dots + x_N^2}{N}} \quad (2.41)$$

Con lo cual se obtiene la Tabla 2.3.

Tabla 2.3. Desempeño de la suspensión para diferentes niveles de corriente.

Valor RMS	($I = 0A$)	($I = 1A$)	($I = \text{var}$)
\ddot{Z}_s (Confort)	0.8154	0.9931	0.6354
Z_{def} (Estabilidad)	0.0032	0.0015	0.0022
\ddot{Z}_{us}	5.7603	2.3638	4.1352

Como se puede observar, existe un trade-off entre la estabilidad y el confort. Cuando la corriente es alta el confort es bajo (se endurece la suspensión), pero la estabilidad es mejor (no hay deflexiones innecesarias); y cuando la corriente es baja, la estabilidad es mala pero el confort mejora. Cuando la corriente es controlada (variable) podemos observar que la estabilidad y el confort se encuentran promediados entre los valores máximos y mínimos que presentan los anteriores casos de corriente fija demostrando así que este tipo de suspensiones mejoran tanto el confort como la estabilidad.

En la Tabla 2.4, se evidencia en cuanto mejoran el confort y la estabilidad de una suspensión semi-activa (corriente variable), con respecto a una suspensión pasiva (corriente igual a cero).

Tabla 2.4. Comparación del desempeño entre una suspensión pasiva y semi-activa.

Valor RMS	Pasiva	Semi-activa	%
\ddot{Z}_s (Confort)	0.8154	0.6354	-22.08%
Z_{def} (Estabilidad)	0.0032	0.0022	-31.25%
\ddot{Z}_{us}	5.7603	4.1352	-28.21%

2.7. Fallas a Diagnosticar

Para un buen funcionamiento del método de diagnóstico las fallas deberán ser bien diseñadas. Las posibles causas de la aparición de fallas en un sistema pueden deberse a aspectos como mal diseño o mal ensamblaje, malas maniobras o falta de mantenimiento, desgaste por envejecimiento, etc. Estas, además, pueden aparecer durante el funcionamiento de forma repentina como *offsets* o en forma gradual (Isermann, 2006).

La presencia de fallas puede hacerse evidente mediante la variación de señales o parámetros. Las variaciones de señales se conocen como fallas aditivas, porque la variable $Y_u(t)$ es afectada por la adición de $f(t)$.

$$Y(t) = Y_u(t) + f(t) \quad (2.42)$$

Las variaciones de parámetros, se conocen como fallas multiplicativas, ya que la variable de entrada $U(t)$ también es multiplicada por $f(t)$, ver Figura 2.27.

$$\begin{aligned} Y(t) &= (a + \Delta a)U(t) = aU(t) + \Delta aU(t) \\ &= Y_u(t) + f(t)U(t) \end{aligned} \quad (2.43)$$




Figura 2.27. Modelo de falla para señal de salida: a) aditiva; b) multiplicativa (Isermann, 2006).

Para el sistema se han considerado las fallas que afectan directamente al desempeño de la suspensión. El control Sky-hook empleado hace uso de la información de dos sensores: sensor de velocidad de masa suspendida y sensor de velocidad de masa no suspendida. Con información errónea se calcularía y aplicaría una variable de control inexacta. Asimismo, el amortiguador MR no produciría la fuerza necesaria para el control adecuado si hubiese una fuga del líquido MR. Para poder monitorear esta fuga se necesita conocer el valor de la deflexión de la suspensión, la cual se obtiene por medio de otro sensor. Es por ello que se consideran fallas aditivas en estos tres sensores, y una falla multiplicativa representada por la variación del coeficiente de amortiguamiento viscoso.

Las fallas se presentan como un offset de la medida real. Las fallas aditivas se consideran como positivas y negativas. Las magnitudes de las fallas para cada sensor se establecieron según su valor RMS (aprox. 50%) como se muestra en la siguiente tabla.

Tabla 2.5. Fallas aditivas en sensores.

Valor RMS	Falla aditiva
Sensor \dot{Z}_s 0.024	± 0.012
Sensor \dot{Z}_{us} 0.0788	± 0.04
Sensor Z_{def} 0.0023	± 0.0012

La falla multiplicativa se considera como una variación mayor del 5% del coeficiente C_p .

Tabla 2.6. Falla paramétrica en amortiguador.

Fallas Paramétricas	Mayor de 5%
Variación C_p 2830.86	-141.54

En la Tabla 2.7 se puede notar como las fallas por desconexión de los sensores afectan al desempeño de la suspensión.

Tabla 2.7. Desempeño de la suspensión semi-activa con fallas.

Falla sensor	RMS	Sin Falla	Falla	%
Sensor \dot{Z}_s	\dot{Z}_s	0.6435	0.8352	29.79%
	Z_{def}	0.0022	0.0033	50.00%
	\ddot{Z}_{us}	4.1578	5.8608	40.96%
Sensor \dot{Z}_{us}	\dot{Z}_s	0.6435	0.6721	4.44%
	Z_{def}	0.0022	0.0022	0%
	\ddot{Z}_{us}	4.1578	3.7784	-9.13%
Sensor Z_{def}	\dot{Z}_s	0.6435	0.6435	0%
	Z_{def}	0.0022	0.0022	0%
	\ddot{Z}_{us}	4.1578	4.1578	0%
Varia C_p 5%	\dot{Z}_s	0.6435	0.6519	1.31%
	Z_{def}	0.0022	0.0023	4.54%
	\ddot{Z}_{us}	4.1578	4.4181	6.26%
Varia C_p 30%	\dot{Z}_s	0.6435	0.9227	43.39%
	Z_{def}	0.0022	0.0036	80.00%
	\ddot{Z}_{us}	4.1578	8.6825	108.82%

Se concluye que las fallas más críticas son las relacionadas con el sensor de la velocidad de la masa suspendida y la fuga del líquido MR del amortiguador. Por lo tanto se procede al desarrollo del sistema de diagnóstico de fallas.

3. DISEÑO DEL SISTEMA DE DIAGNÓSTICO DE FALLAS

3.1. Introducción

En esta sección, se desarrolla el sistema de diagnóstico de fallas, el cual está conformado por tres subsistemas.

El primero, detecta fallas por desconexión de sensores y está basado en un banco de observadores de entradas desconocidas, los cuales estiman los estados de la suspensión, y a partir de los que se obtienen las salidas estimadas, con las que se obtienen seis residuales al compararlas con las salidas medidas.

El segundo, detecta fallas multiplicativas en el amortiguador MR a través de un sistema de estimación paramétrica, el cual monitorea los coeficientes del amortiguador MR. Los parámetros estimados son comparados con los parámetros nominales.

El tercer método empleado detecta fallas aditivas en los sensores por medio de una red neuronal entrenada, la cual recibe como entradas los estados estimados por los observadores de entradas desconocidas.

Las simulaciones y los resultados se muestran al final de este capítulo.

3.2. Observador de Entradas Desconocidas

Consideramos el sistema lineal invariante en el tiempo

$$\dot{x} = Ax + Bu + Dd \quad (3.1a)$$

$$y = Cx \quad (3.1b)$$

Donde $x \in R^n$, $u \in R^k$, $d \in R^m$, $y \in R^p$ son el vector de estados, el vector de entradas conocidas, el vector de perturbaciones desconocidas y el vector de mediciones, respectivamente. A, B, D y C son matrices constantes con dimensiones adecuadas. Asumimos que $p \geq m$ y, $rank(D) = m$ y $rank(C) = p$.

Con estas suposiciones es posible diseñar un observador de orden completo con el fin de estimar todas las variables del vector de estados.

La dinámica del observador de entradas desconocidas puede ser representada como (Sfaihi *et al*, 2004):

$$\dot{z} = Nz + Ly + Gu \quad (3.2a)$$

$$\hat{x} = z - Ey \quad (3.2b)$$

Donde $z \in R^n$ y $\hat{x} \in R^n$ es el vector de estados observados. N , L , G y E son matrices desconocidas con dimensiones apropiadas que deberán ser diseñadas tal que \hat{x} converja asintóticamente a x .

Para garantizar la convergencia de \hat{x} a x se debe demostrar que el error de estimación sea igual a cero asintóticamente.

$$e = \hat{x} - x \quad (3.3)$$

La dinámica del error del observador es equivalente a:

$$\dot{e} = Ne + (NP + LC - PA)x + (G - PB)u - PDv \quad (3.4)$$

con

$$P = I_n + EC \quad (3.5)$$

Es así que se debe cumplir que:

$$NP + LC - PA = 0 \quad (3.6)$$

$$G - PB = 0 \quad (3.7)$$

$$(I_n + EC)D = 0 \quad (3.8)$$

N debe ser una matriz estable. Resolviendo (3.6)-(3.8) se obtienen las matrices N , L , G y E :

$$N = PA - KC \quad (3.9)$$

con

$$K = L + NE \quad (3.10)$$

$$L = K(I_p + CE) - PAE \quad (3.11)$$

$$G = PB \quad (3.12)$$

$$(I_n + EC)D = 0 \quad (3.13)$$

De esta manera la ecuación dinámica del observador (3.2).

$$\dot{z} = (PA - KC)z + (K(I_p + CE) - PAE)y + PBu \quad (3.14a)$$

$$\hat{x} = z - Ey \quad (3.14b)$$

Entonces, el problema se limita a encontrar

- La matriz E tal que $(I_n + EC)D = 0$.
- La matriz K tal que $N = PA - KC$ sea estable.

Síntesis de la matriz E

De (3.13) se puede decir que

$$ECD = -D \quad (3.15)$$

Si $\text{rango}(CD) = m$, entonces se puede decir que E existe y la solución de (3.13) se puede escribir como:

$$E = -D(CD)^+ + Y(I_p - D(CD)(CD)^+) \quad (3.16)$$

Mientras (CD) sea una matriz de rango completo y Y una matriz aleatoria con dimensiones apropiadas, $(CD)^+$ es la matriz inversa generalizada de (CD) dada por:

$$(CD)^+ = ((CD)^T(CD))^{-1}(CD)^T \quad (3.17)$$

Síntesis de la matriz K

Para obtener un matriz estable $(PA - KC)$, se pueden fijar sus eigenvalores en lado izquierdo del plano complejo. Si el par (PA, C) es observable, entonces los eigenvalores de $(PA - KC)$ pueden ser establecidos adecuadamente sabiendo elegir la matriz K.

3.3. Estimación Paramétrica Mediante Mínimos Cuadrados

La identificación nos permite crear representaciones matemáticas de diferentes sistemas dinámicos a partir de datos experimentales (medidas).

El objeto de la identificación paramétrica es encontrar un modelo de un sistema que mejor lo represente, y parte de la selección de la estructura del modelo. Los parámetros del modelo se determinan mediante algoritmos conocidos como Técnicas de Estimación de Parámetros. Los modelos matemáticos que se utilizan se componen de una parte determinística y una estocástica (representa los disturbios que afectan el sistema y serán concentrados a la salida $y(t)$) (Figura 3.1).

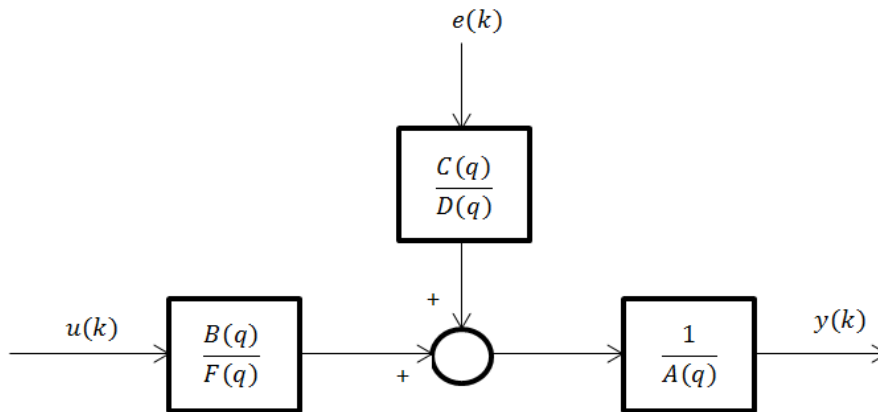


Figura 3.1. Representación de modelos identificados.

El modelo de la Figura 3.1 puede ser representado en términos de polinomios de grado finito como:

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}e(k) \quad (3.18)$$

Donde $A(q), B(q), C(q), D(q)$ y $F(q)$ son polinomios en el operador desplazamiento q .

$$A(q) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_{n_a}q^{-n_a}$$

$$B(q) = b_1q^{-1} + b_2q^{-2} + \dots + b_{n_b}q^{-n_b}$$

$$C(q) = 1 + c_1q^{-1} + c_2q^{-2} + \dots + c_{n_c}q^{-n_c}$$

$$D(q) = 1 + d_1q^{-1} + d_2q^{-2} + \dots + d_{n_d}q^{-n_d}$$

$$F(q) = 1 + f_1q^{-1} + f_2q^{-2} + \dots + f_{n_f}q^{-n_f}$$

Los diferentes tipos de estructuras para la representación de sistemas dinámicos LTI como: *FIR* (*Finite Impulse Response*), *ARX* (*Auto-Regresive with eXternal input*), *ARMAX* (*Auto-Regresive Moving Average with eXternal input*), *OE* (*Output Error*) y *BJ* (*Box and Jenkins*) son casos especiales de (3.18).

Los coeficientes de cada polinomio son los parámetros del modelo a estimar. El vector de parámetros se denominará θ , y la estructura seleccionada para representar el sistema μ , y está dada por:

$$\mu = \{\mu(\theta) / \theta \in D_u\} \quad \text{y} \quad \theta \in D_u \subset R^d$$

Cada modelo particular $\mu(\theta)$ depende del vector de parámetros θ . Es necesario utilizar un modelo particular $\mu(\theta)$ para hacer la predicción $\hat{y}(k/k-1)$, el error de predicción se obtiene comparando la salida del sistema con la salida predicha por el modelo, este modelo depende del vector de parámetros θ , por tal motivo se utilizará la siguiente notación:

$$e(k, \theta) = y(k) - \hat{y}(k, \theta) \quad (3.19)$$

Un modelo bueno tendrá un error de predicción pequeño, por ello, una medida de calidad podría ser la suma de los cuadrados de los errores de predicción:

$$J_N(\theta) = \frac{1}{N} \sum_{k=1}^N e^2(k, \theta) \quad (3.20)$$

Por lo tanto el modelo óptimo dentro de la estructura seleccionada μ , será aquel que minimiza (3.20) y se denominará $\hat{\theta}_N$:

$$\hat{\theta}_N = \arg \min_{\theta \in D_u} J_N(\theta) \quad (3.21)$$

3.3.1. Predicción de la Salida en un Modelo ARX

Esta estructura asigna a los polinomios $C(q)$, $D(q)$ y $F(q)$ un valor de 1. Su ecuación general es la siguiente:

$$A(q)y(k) = B(q)u(k) + e(k)$$

$$y(k) = \frac{B(q)}{A(q)}u(k) + \frac{1}{A(q)}e(k)$$

$$\hat{y}(k, \theta) = [1 - A(q)]y(k) + B(q)u(k)$$

$$\hat{y}(k, \theta) = \sum_{l=1}^{n_a} -a_l y(k-l) + \sum_{l=1}^{n_b} b_l u(k-l)$$

Que en notación vectorial sería:

$$\hat{y}(k, \theta) = [a_1 \ a_2 \ \dots \ a_{n_a} \ b_1 \ b_2 \ \dots \ b_{n_b}] \begin{bmatrix} -y(k-1) \\ -y(k-2) \\ \vdots \\ -y(k-n_a) \\ u(k-1) \\ u(k-2) \\ \vdots \\ u(k-n_b) \end{bmatrix}$$

$$\hat{y}(k, \theta) = \theta^T \Phi(k) = \Phi^T(k) \theta \quad (3.22)$$

Donde:

$\theta = [a_1 \ a_2 \ \dots \ a_{n_a} \ b_1 \ b_2 \ \dots \ b_{n_b}]^T$ es el vector de parámetros.

$\Phi(k) = [-y(k-1) \ -y(k-2) \ \dots \ -y(k-n_a) \ u(k-1) \ u(k-2) \ \dots \ u(k-n_b)]^T$ es el vector de regresión.

Se observa claramente la dependencia lineal entre $\hat{y}(k, \theta)$ y θ , por eso es llamado vector de regresión lineal.

3.3.2. Método de los Mínimos Cuadrados Lineales

Los métodos de predicción de error, se basan en la solución de un problema de minimización. Como se mencionó antes, la función a minimizar que se utilizará está dada por la suma de los cuadrados de los errores de predicción. La minimización se resuelve utilizando técnicas matemáticas, una de tales técnicas es el método de los mínimos cuadrados.

Dado un conjunto de N pares de medidas de entrada salida $\{y(k), u(k)\}_N$, y dada la estructura del modelo, pero con parámetros desconocidos, se debe encontrar el $\hat{\theta}_N$ que minimiza:

$$J_N(\theta) = \frac{1}{N} \sum_{k=1}^N \frac{1}{2} e^2(k, \theta) \quad (3.23)$$

$\hat{\theta}_N$ se denomina vector de parámetros estimados.

$$\hat{\theta}_N = \arg \min_{\theta \in D_u} J_N(\theta) \quad (3.24)$$

Para las estructuras *ARX* el modelo de regresión es lineal en θ

$$\hat{y}(k, \theta) = \Phi^T(k) \theta \quad (3.25)$$

Para modelos de regresión lineal, $J_N(\theta)$ puede escribirse como:

$$J_N(\theta) = \frac{1}{N} \sum_{k=1}^N \frac{1}{2} [y(k) - \Phi^T(k) \theta]^2 \quad (3.26)$$

En la solución óptima $\hat{\theta}_N$, el gradiente de $J_N(\theta)$ con respecto a θ es cero.

$$\frac{\partial J_N}{\partial \theta} = 0$$

La derivada del término que aparece dentro de la sumatoria está dada por:

$$\frac{\partial}{\partial \theta} \left(\frac{1}{2} [y(k) - \Phi^T(k) \theta]^2 \right) = -\Phi(k) [y(k) - \Phi^T(k) \theta] \quad (3.27)$$

Al reemplazar en $\frac{\partial J_N}{\partial \theta}$ se tiene:

$$\frac{\partial J_N}{\partial \theta} = -\frac{1}{N} \sum_{k=1}^N \Phi(k)[y(k) - \Phi^T(k)\theta] = 0$$

$$\left[\frac{1}{N} \sum_{k=1}^N \Phi(k)\Phi^T(k) \right] \theta = \frac{1}{N} \sum_{k=1}^N \Phi(k)y(k) \quad (3.28)$$

La solución óptima $\hat{\theta}_N$ se calcula de:

$$\left[\frac{1}{N} \sum_{k=1}^N \Phi(k)\Phi^T(k) \right] \hat{\theta}_N = \frac{1}{N} \sum_{k=1}^N \Phi(k)y(k) \quad (3.29)$$

La solución de estas *Ecuaciones Normales* está dada por (Rengifo, 1999):

$$\hat{\theta}_N = \left[\frac{1}{N} \sum_{k=1}^N \Phi(k)\Phi^T(k) \right]^{-1} \frac{1}{N} \sum_{k=1}^N \Phi(k)y(k) \quad (3.30)$$

Siempre y cuando $\left[\frac{1}{N} \sum_{k=1}^N \Phi(k)\Phi^T(k) \right]$ sea invertible.

El término $\frac{1}{N} \sum_{k=1}^N \Phi(k)\Phi^T(k)$ se denominará Matriz de Covarianza del vector de regresión $\Phi(k)$ y se denotará por $R(N)$, donde el superíndice d se refiere a la cantidad de parámetros a estimar $d = \text{Dimensión}(\theta)$, R_Φ^d es una matriz cuadrada de dimensión $d \times d$.

$$\hat{\theta}_N = [R(N)]^{-1} \left[\frac{1}{N} \sum_{k=1}^N \Phi(k)y(k) \right] \quad (3.31)$$

3.3.3. Mínimos Cuadrados Recursivos con Factor de Olvido

Es posible asignar ponderaciones a las mediciones con el objeto de mejorar la rapidez de convergencia de los parámetros del modelo $\beta(N, t)$.

$$J_N(\theta) = \sum_{t=1}^N \beta(N, t)[y(t) - \Phi^T(t)\theta]^2$$

La expresión general para la estimación sería:

$$\hat{\theta}_N = \left[\sum_{t=1}^N \beta(N, t) \Phi(t) \Phi^T(t) \right]^{-1} \sum_{t=1}^N \beta(N, t) \Phi(t) y(t) \quad (3.32)$$

Para un tiempo cualquiera:

$$\hat{\theta}_t = \left[\sum_{k=1}^t \beta(t, k) \Phi(k) \Phi^T(k) \right]^{-1} \sum_{k=1}^t \beta(t, k) \Phi(k) y(k) \quad (3.33)$$

Para poder usar el anterior algoritmo en forma recursiva se debe definir la secuencia de ponderación $\beta(t, k)$ como:

$$\beta(t, k) = \lambda(t) \beta(t-1, k) \quad 1 \leq k \leq t-1$$

$$\beta(t, t) = 1$$

Es posible reescribir $R(t)$

$$R(t) = \lambda(t) R(t-1) + \Phi(t) \Phi^T(t) \quad (3.34)$$

A λ se lo conoce como factor de olvido y su valor puede estar entre 0 y 1, los valores de λ cercanos a 1 producen convergencias lentas pero con menor sensibilidad al ruido, cuando λ es menor la velocidad de convergencia de los parámetros aumenta pero la inmunidad al ruido disminuye.

El algoritmo recursivo general para la estimación de parámetros viene dado por la siguiente ecuación:

$$\hat{\theta}(k) = \hat{\theta}(k-1) + L(k) (y(k) - \hat{y}(k)) \quad (3.35)$$

Donde $L(k)$ es el factor de corrección que indica como el error de predicción de la salida afecta a la actualización de la estimación de los parámetros. De (Isermann *et al*, 2011) se obtiene:

$$L(k) = R(k)^{-1} \Phi(k) \quad (3.36)$$

Se define $P(k) = R(k)^{-1}$. Es necesario calcular $P(k)$ en cada iteración, para evitar el costo computacional que esto implica, es posible usar el siguiente lema de inversión de matrices (Ryba, 2012):

$$[A + BCD]^{-1} = A^{-1} - A^{-1}B[DA^{-1}B + C^{-1}]^{-1}DA^{-1}$$

Se acomoda (3.34) tal que $A = \lambda(k)R(k-1)$, $B = D^T = \Phi(k)$, $C = 1$. Con lo que se obtiene:

$$P(k) = \frac{1}{\lambda(k)} \left[P(k-1) - \frac{P(k-1)\Phi(k)\Phi^T(k)P(k-1)}{\lambda(k) + \Phi^T(k)P(k-1)\Phi(k)} \right] \quad (3.37)$$

Para resolver (3.35) y hallar los parámetros se necesita calcular $L(k)$

$$L(k) = R(k)^{-1} \Phi(k) = \frac{P(k-1)\Phi(k)}{\lambda(k) + \Phi^T(k)P(k-1)\Phi(k)} \quad (3.38)$$

Una buena práctica es elegir $P(k-1)$ inicial como un valor grande (10^6) y $\hat{\theta}(k-1)$ inicial como cero. El algoritmo de estimación recursiva tendrá los siguientes pasos.

1. Inicializar $P(0)$ y $\hat{\theta}(0)$
2. Obtener el vector de regresión $\Phi(k)$ con las mediciones.
3. Calcular el error de predicción $e_p(k) = y(k) - \Phi^T(k)\theta(k-1)$
4. Calcular el factor de corrección o ganancia $L(k)$
5. Calcular parámetros estimados $\hat{\theta}(k)$
6. Calcular la matriz de covarianzas $P(k)$
7. Aumentar k y repetir desde 2.

3.4. Redes Neuronales

Las redes neuronales son modelos artificiales basados en el comportamiento del cerebro humano. Una red neuronal está conformada por un conjunto de neuronas situadas en diferentes capas (capa de entrada, capas ocultas o intermedias y capa de salida) y que se hallan interconectadas entre sí, para producir una salida a partir de ciertas entradas.

3.4.1. Perceptrón Multicapa

Es una red multicapa conformada por una capa de entrada, una o más capas ocultas, y una capa de salida. Esto permite lidiar con problemas de no linealidad. Cada neurona está conectada con todas las neuronas de la siguiente capa como se aprecia en la Figura 3.2.

En la primera capa las neuronas reciben solo una entrada. El valor de salida después de ser procesado por esta neurona pasa a la siguiente capa, donde cada neurona es alimentada por más de una entrada. Aquí las neuronas ponderan dichas entradas multiplicando cada una de ellas por un respectivo peso, originando así una salida que pasa a la siguiente capa, donde cada entrada también es multiplicada por un peso antes de ser sumadas y procesadas por las neuronas.

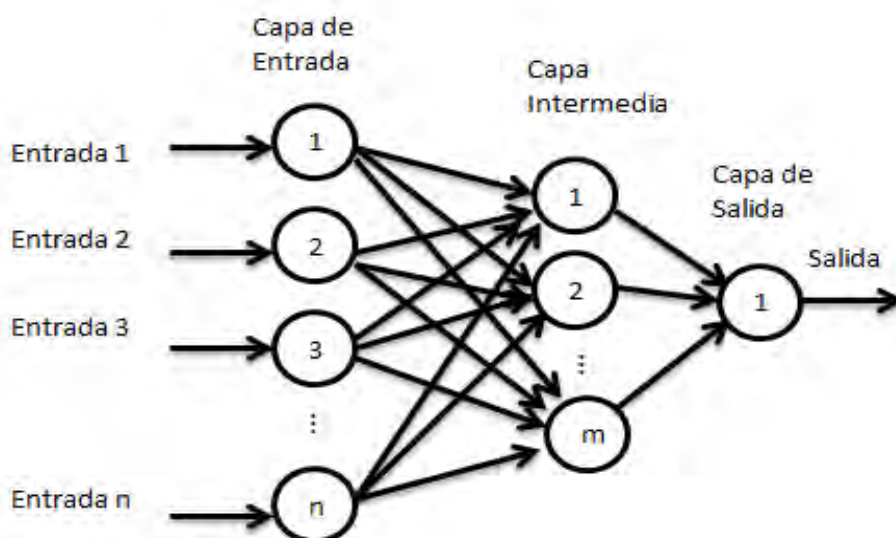


Figura 3.2. Estructura de una red neuronal artificial.

- **Capa de entrada:** esta capa está conformada por las neuronas que reciben a las entradas (patrones). Estas neuronas no procesan información, y las salidas son las mismas que las entradas.
- **Capa oculta o intermedia:** pueden ser una o más capas. La primera capa oculta está conformada por las neuronas que reciben las salidas de la capa de entrada multiplicadas por sus respectivos pesos. Al aumentar las capas intermedias, generalmente se logra aumentar el rendimiento de la red.
- **Capa de salida:** está conformada por la neuronas que reciben como entradas las salidas de la(s) capa(s) intermedia(s) multiplicadas por sus respectivos pesos. Normalmente, la salida de esta capa es la salida de la red neuronal.

Es posible aumentar el número de capas de entrada, de salida o intermedias, como también puede aumentarse el número de neuronas por cada capa. La arquitectura de la red será uno de los aspectos más complejos de definir al momento de entrenar y conseguir las salidas anheladas.

Después de haber definido la arquitectura de la red, es necesario asignar a cada neurona una función. Con esto se trata de explicar cómo será procesada la información dentro de cada neurona.

3.4.2. Función de Activación

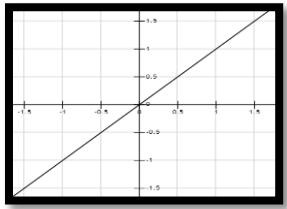
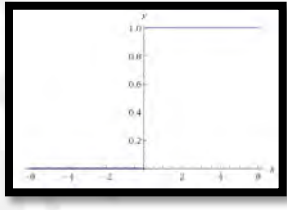
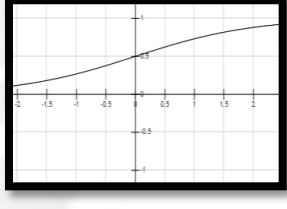
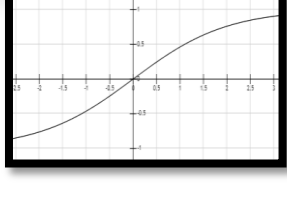
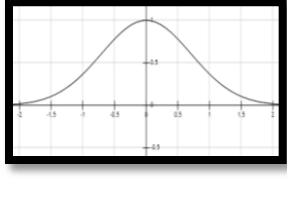
La función de activación se entiende como la acción que ejecuta una neurona para obtener una salida a partir de la entrada o entradas que llegan a ella (Figura 3.3). Esta función se emplea para limitar el rango de valores de salida de la neurona. Generalmente, los valores de salida están entre (0,1) ó (-1,1), como también podrían ser adoptados otros valores según la aplicación. Existen muchas funciones de activación, y se deberán elegir unas u otras de acuerdo al problema que se requiera resolver.

Estas funciones de activación deberán cumplir algunas condiciones como (Martín del Brío et al, 2007):

- Ser continuas

- Ser diferenciables en cada uno de sus puntos
- Ser monótonas no decrecientes.

Las funciones de activación más usadas son las que se mencionan a continuación:

	Función	Rango	Gráfica
Lineal	$f(x) = x$	$[-\infty, +\infty]$	
Escalón	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	$[0, +1]$	
Sigmoidea tipo 1	$f(x) = \frac{1}{1 + e^{-m}}$	$[0, +1]$	
Sigmoidea tipo 2	$f(x) = \frac{2}{1 + e^{-m}} - 1$	$[-1, +1]$	
Gaussiana	$f(x) = e^{-m^2}$	$[0, +1]$	




Figura 3.3. Modelo de funcionamiento de una Neurona.

3.4.3. Función de Salida

Esta función provee la salida global de la neurona en función del estado de activación actual. Con frecuencia la función de salida es una función de identidad, con lo cual la salida de la neurona será el estado de activación de la misma.

Cada neurona recibe en forma vectorial todas las entradas $(x_1, x_2, x_3, \dots, x_m)$. Cada una de estas entradas son multiplicadas por sus respectivos pesos sinápticos, luego de esto se suman. El resultado de la sumatoria se conoce como el estímulo de la neurona, ver Figura 3.4.




Figura 3.4. Sumatoria de entradas multiplicadas por los pesos sinápticos.

Donde

x_j : es la entrada j de la red neuronal.

w_j : es peso sináptico correspondiente a la entrada j .

Luego, este estímulo es procesado en el interior de la neurona por medio de su función de activación, ver Figura 3.5.

$$Y_i = \varphi(X^T W + b) \quad (3.39)$$

Donde

φ : es la función de activación.

b : es un parámetro de sesgo o bias, puede existir o no.

Y_i : es el estado de activación.

Considerando la función de salida como una función identidad se tendría que la salida (y_i) es igual al estímulo (Y_i) de la neurona.

$$y_i = Y_i$$




Figura 3.5. Función de salida.

3.4.4. Pesos Sinápticos

Los pesos sinápticos son valores que representan la intensidad de interacción entre cada neurona presináptica y una neurona postsináptica. Estos pesos guardan el conocimiento adquirido durante el entrenamiento de la red neuronal.

En un principio es posible establecer estos pesos sinápticos como nulos o aleatorios. Al proceso de entrenar la red neuronal se lo conoce como aprendizaje. El proceso de aprendizaje generalmente es iterativo, actualizando los pesos en cada iteración hasta que la red alcanza su rendimiento deseado.

Los tipos de aprendizaje básicos más utilizados son dos: el supervisado y el no supervisado.

3.4.5. Algoritmo de Aprendizaje Backpropagation

El entrenamiento de una red con arquitectura perceptrón multicapa (MLP) suele realizarse mediante el algoritmo de retropropagación de errores (BP), motivo por el cual al conjunto arquitectura MLP + aprendizaje BP se lo suele conocer como red de retropropagación o BPN (Martín del Brío et al, 2007).

Su funcionamiento consiste en el aprendizaje de un grupo de pares entrada-salida. Primero, se ingresa un patrón de entrada como estímulo para la primera capa de la red, la que se propaga a través de todas las capas siguientes ejecutando sus funciones de activación hasta generar una salida, la cual se compara con la salida deseada y se obtiene el error para cada neurona de salida.

$$y_k = w_{1k}n_1 + w_{2k}n_2 + \dots + w_{jk}n_j \quad (3.40)$$

Donde

$$n_j = f(m_j) \quad (3.41)$$

$$m_j = v_{1j}x_1 + v_{2j}x_2 + \dots + v_{ij}x_i \quad (3.42)$$

A continuación, estos errores se propagan hacia atrás, partiendo de la capa de salida hacia todas las neuronas de las capas intermedias como se aprecia en la Figura 3.6. El proceso se repite capa por capa hasta que todas las neuronas hayan recibido un error que describa su aportación relativa al error total (Hilera et al, 2000).

$$e_k = y_k - \bar{y}_k \quad (3.43)$$

Ya que la salida se tiene neuronas lineales, el error retropropagado en la salida será $\bar{e}_k = e_k$.

El objetivo principal es entrenar la red mediante un conjunto de patrones de entrenamiento y de validación, con el fin de reajustar los pesos sinápticos (v_{ij} y w_{jk}) para minimizar el error total. Para un grupo de salidas igual a k . El objetivo es minimizar J .




Figura 3.6. Retropropagación del error.

$$J = \frac{1}{2} e_1^2 + \frac{1}{2} e_2^2 + \frac{1}{2} e_3^2 + \dots + \frac{1}{2} e_k^2 \quad (3.44)$$

Para minimizar el error, es necesario calcular el gradiente del error en un punto del espacio generado por el conjunto de pesos. Se deberá tomar la dirección negativa del gradiente para obtener el mayor decremento del error cuadrático y de esta forma su minimización.

$$w_{jk} = w_{jk} - \eta \frac{dJ}{dw_{jk}} \quad (3.45)$$

$$\frac{dJ}{dw_{jk}} = \frac{dJ}{dy_k} \cdot \frac{dy_k}{dw_{jk}}$$

$$\frac{dJ}{dw_{jk}} = \bar{e}_k n_j \quad (3.46)$$

$$v_{ij} = v_{ij} - \eta \frac{dJ}{dv_{ij}} \quad (3.47)$$

$$\frac{dJ}{dv_{ij}} = \frac{dJ}{dy_k} \cdot \frac{dy_k}{dv_{ij}}$$

$$\frac{dJ}{dv_{ij}} = \bar{e}_k w_{jk} \frac{dn_j}{dv_{ij}}$$

Derivando (3.41) y (3.42)

$$\frac{dn_j}{dv_{ij}} = \frac{dn_j}{dm_j} \frac{dm_j}{dv_{ij}} = f'(m_j) x_i$$

Arreglando se obtiene

$$\frac{dJ}{dv_{ij}} = \bar{\bar{e}}_j x_i \quad (3.48)$$

Con

$$\bar{\bar{e}}_j = (w_{j1} \bar{e}_1 + w_{j2} \bar{e}_2 + \dots + w_{jk} \bar{e}_k) f'(m_j) \quad (3.49)$$

3.5. Diseño de un Banco de Observadores de Entradas Desconocidas

Con el fin de diseñar un generador de residuales se procede al desarrollo de un banco de observadores de entradas desconocidas, según el diagrama mostrado en la Figura 3.7.

El principal obstáculo en el diseño de observadores tradicionales para este sistema es el desconocimiento del perfil de carretera, ya que su medición solo se puede realizar mediante sensores altamente costosos. Bajo esta premisa se propone desarrollar observadores de entradas desconocidas para desacoplar la perturbación, y los estados puedan ser estimados asintóticamente. De esta manera, los residuales serán sensibles a las fallas presentes en los sensores e insensibles a la perturbación del camino.

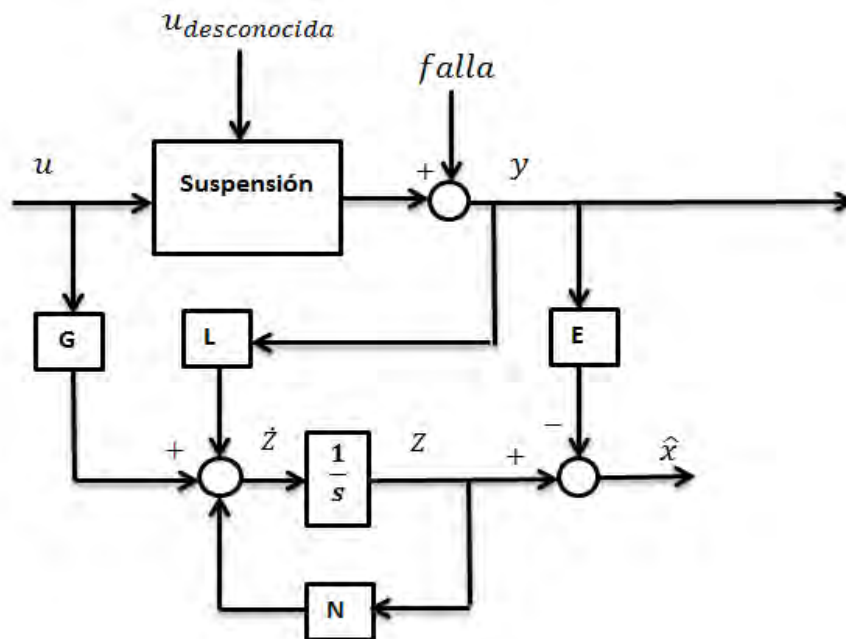


Figura 3.7. Observador con entradas desconocidas.

Se tiene el sistema LTI de la suspensión semi-activa descrito por las ecuaciones (3.50) y (3.51).

$$\dot{x}(t) = Ax(t) + Bu(t) + B_z z_r(t) \quad (3.50)$$

$$y(t) = Cx(t) + D_f f(t) \quad (3.51)$$

Con $x \in R^4, u \in R^1, z_r \in R^1, y \in R^3$, y las matrices con parámetros fijos:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \\ \dot{x}_4 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ -\frac{K_p+K_s}{m_s} & -\frac{c_p}{m_s} & \frac{K_p+K_s}{m_s} & \frac{c_p}{m_s} \\ 0 & 0 & 0 & 1 \\ \frac{K_p+K_s}{m_{us}} & \frac{c_p}{m_{us}} & -\frac{K_p+K_s+K_t}{m_{us}} & -\frac{c_p}{m_{us}} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} + \begin{bmatrix} 0 \\ -1 \\ 0 \\ 1 \end{bmatrix} u + \begin{bmatrix} 0 \\ 0 \\ 0 \\ \frac{k_t}{m_{us}} \end{bmatrix} z_r \quad (3.52a)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} x_2 \\ x_4 \\ x_1 - x_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & -1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} f_1 \\ f_2 \\ f_3 \end{bmatrix} \quad (3.52b)$$

El vector $f(t) = [f_1 \ f_2 \ f_3]$ tomará valores diferentes de cero solo durante la presencia de fallas. En este trabajo, estas señales son representadas por funciones escalón y su magnitud esta especificada en la Sección 2.7.

Para poder lograr que los observadores diseñados sean sensibles a determinadas fallas e insensibles a otras se propone diseñar tres observadores, alimentando a cada observador con una variable medida diferente como se observa en la figura 3.8.

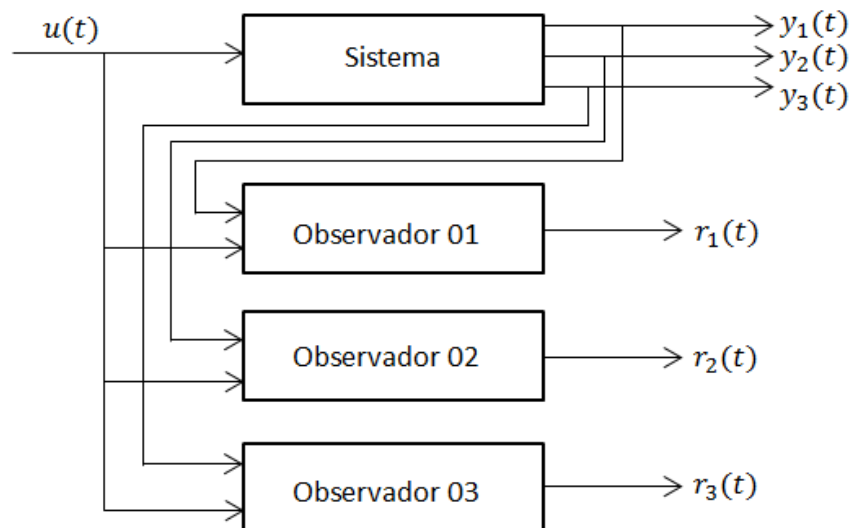


Figura 3.8. Banco de observadores para generar residuales de salidas.

Esta configuración se conoce como Esquema de Observadores Dedicados (DOS del inglés Dedicated Observer Scheme). El número de observadores es igual al número de salidas medidas. Cada observador es alimentado con

solo una de las salidas y todas las entradas del sistema. De esta manera, una falla en el salida y_i afecta solo a los residuales generados por el observador i (Simani et al, 2002).

Otro enfoque es el también conocido Esquema de Observadores Generalizados (GOS del inglés Generalized Observer Scheme). Al contrario del enfoque anterior en este caso se alimenta a todos los observadores con todas las entradas y todas las salidas menos una, a la cual no será sensible.

Es necesario cumplir con las condiciones de observabilidad para desarrollar cualquiera de estos dos enfoques.

Aunque los observadores de entradas desconocidas son una buena opción para lidiar con el problema de la perturbación de la carretera, por problemas de observabilidad no es posible diseñar un banco de observadores con el enfoque DOS. La variable medida por el sensor y_2 está directamente afectada por la perturbación y contiene toda la información necesaria para una correcta estimación de los estados.

La solución adoptada se centra en diseñar un banco que consta de dos observadores de entradas desconocidas y estos estarán configurados de la siguiente manera (ver Figura 3.9).

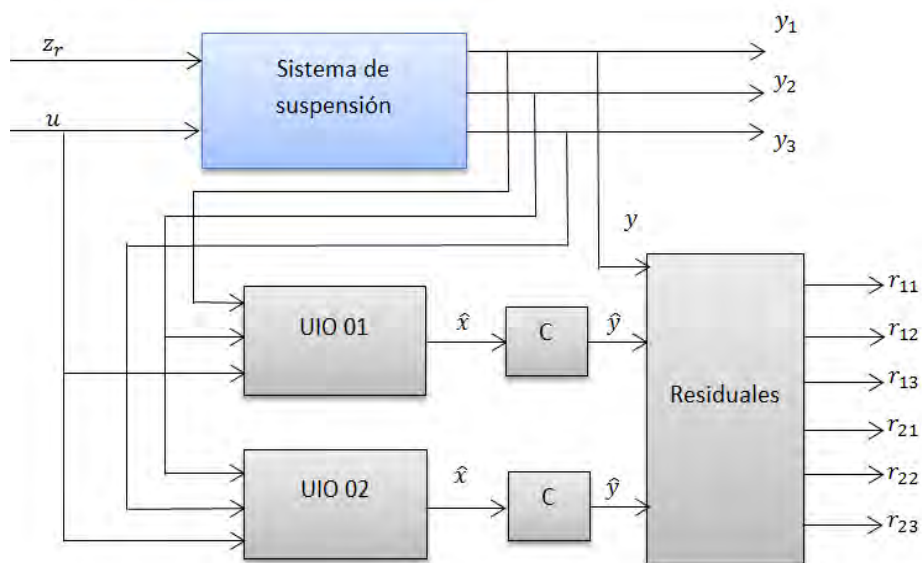


Figura 3.9. Banco de observadores de entradas desconocidas.

- El primero, estará alimentado con la entrada de control y dos salidas, la velocidad de la masa suspendida (y_1) y la velocidad de la masa no suspendida (y_2).
- El segundo, estará alimentado con la entrada de control y dos salidas, la velocidad de la masa no suspendida (y_2) y la deflexión de la suspensión (y_3).

Como se observa en la Figura 3.9, ambos observadores son alimentados con la variables medida y_2 y ambos serán sensibles a las fallas ocurridas en este sensor. En la Tabla 3.1 se muestra las firmas de fallos para el caso de presencia de fallas simples. De esta manera se demuestra que la capacidad de aislamiento del esquema presentado no es muy buena.

Tabla 3.1. Firma de fallos para el banco de observadores de entradas desconocidas.

	f_u	f_{y_1}	f_{y_2}	f_{y_3}
r_{11}	1	1	1	0
r_{12}	1	1	1	0
r_{13}	1	1	1	0
r_{21}	1	0	1	1
r_{22}	1	0	1	1
r_{23}	1	0	1	1

Los residuales que son afectados por las fallas en la entrada y las salidas están descritos con un dígito “1”, mientras que un “0” significa que ese residual no se ve afectado por la falla en tal entrada o salida. Según la Tabla 3.1 se puede concluir que una falla en el sensor y_1 es solo reconocida por el observador 01, y una falla en el sensor y_3 es sólo reconocida por el

observador 02, pero una falla en el sensor y_2 será reconocida por los dos observadores.

Además, la entrada de control esta descrita por la ecuación (3.53), donde solo la corriente puede ser medida directamente, la parte no lineal correspondiente a la tangente hiperbólica puede ser calculada con los valores de \dot{z}_{def} y z_{def} , mientras que f_c se mantiene constante.

$$u = f_c v \tanh(a_v \dot{z}_{def} + a_d z_{def}) \quad (3.53)$$

Con el fin de evitar que esta variable dependa de las fallas de los sensores, los valores de \dot{z}_{def} y z_{def} se obtendrán por medio de los estados estimados de cada observador.

Bajo estas consideraciones las matrices C de los observadores serán:

$$C_1 = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.54)$$

$$C_2 = \begin{bmatrix} 0 & 0 & 0 & 1 \\ 1 & 0 & -1 & 0 \end{bmatrix} \quad (3.55)$$

Se evalúa la existencia de una matriz E para cada caso, para ello el rango de CB_z deberá ser igual al número de estados perturbados.

$$\text{rango}(C_1 B_z) = 1$$

$$\text{rango}(C_2 B_z) = 1$$

Los dos casos cumplen con esta condición por lo tanto E existe para ambos.

3.5.1. Síntesis de la Matriz E para los Observadores

De la ecuación (3.17) se obtiene la inversa generalizada para ambos casos

$$(C_1 D)^+ = [0 \quad 0.4074 \times 10^{-3}]$$

$$(C_2 D)^+ = [0.4074 \times 10^{-3} \quad 0]$$

Se eligen aleatoriamente dos matrices Y con las dimensiones apropiadas.

$$Y_1 = \begin{bmatrix} -0.4092 & 0.3926 \\ -1.1424 & 1.3018 \\ -0.6249 & -0.5936 \\ -1.1687 & 0.4364 \end{bmatrix}$$

$$Y_2 = \begin{bmatrix} -1.4092 & 0.0093 \\ 0.1424 & -6.3018 \\ 6.6249 & 0.5936 \\ -1.1687 & 9.4364 \end{bmatrix}$$

Con lo cual, de (3.16) las matrices E para cada observador quedan de la siguiente manera:

$$E_1 = \begin{bmatrix} -0.4092 & 0 \\ -1.1424 & 0 \\ -0.6249 & 0 \\ -1.1687 & -1 \end{bmatrix}$$

$$E_2 = \begin{bmatrix} 0 & 0.0093 \\ 0 & -6.3018 \\ 0 & 0.5936 \\ -1 & 9.4364 \end{bmatrix}$$

3.5.2. Síntesis de la Matriz K

Se analiza la observabilidad para cada caso. De (3.5) se obtienen las matrices P .

$$P_1 = \begin{bmatrix} 1 & -0.4092 & 0 & 0 \\ 0 & -0.1424 & 0 & 0 \\ 0 & -0.6249 & 1 & 0 \\ 0 & -1.1687 & 0 & 0 \end{bmatrix}$$

$$P_2 = \begin{bmatrix} 1.0093 & 0 & -0.0093 & 0 \\ -6.3018 & 1 & 6.3018 & 0 \\ 0.5936 & 0 & 0.4064 & 0 \\ 9.4364 & 0 & -9.4364 & 0 \end{bmatrix}$$

Si el par (P, A) es observable, entonces se podrá hallar un K que permite mover arbitrariamente los polos de N tal que se vuelva estable.

$$O_1 = [C_1; C_1 P_1 A; C_1 (P_1 A)^2; C_1 (P_1 A)^3]$$

$$O_2 = [C_2; C_2 P_2 A; C_2 (P_2 A)^2; C_2 (P_2 A)^3]$$

El rango de ambas matrices O muestra que no son observables, sólo son detectables.

$$\text{rango}(O_1) = 3$$

$$\text{rango}(O_2) = 3$$

Los dos sistemas son observables, se elige las matrices K tal que $(PA - KC)$ sea estable.

Para que $(PA - KC)$ sea estable, sus eigenvalores deben estar ubicados en el lado izquierdo del plano complejo. Una manera de encontrar una matriz K que cumpla esta condición es hacer que N sea una matriz diagonal y contenga a los polos del observador deseados, haciendo uso de la pseudo-inversa se puede obtener resultados satisfactorios.

$$N = \begin{bmatrix} -p_1 & 0 & 0 & 0 \\ 0 & -p_2 & 0 & 0 \\ 0 & 0 & -p_3 & 0 \\ 0 & 0 & 0 & -p_4 \end{bmatrix}$$

$$N = PA - KC$$

Entonces:

$$K = PA \text{ pinv}(C) - N \text{ pinv}(C)$$

$$K_1 = \begin{bmatrix} 3.4647 & -2.4647 \\ 30.8577 & -0.8577 \\ 3.7638 & -2.7638 \\ 7.0392 & 2.9608 \end{bmatrix}$$

$$K_2 = \begin{bmatrix} -0.0093 & 15.0000 \\ 12.3249 & -166.9804 \\ 0.4064 & -5.0000 \\ 0.5636 & 0 \end{bmatrix}$$

De (3.11) se obtienen las matrices L .

$$L_1 = \begin{bmatrix} -11.2738 & -2.4647 \\ -8.5432 & -0.8577 \\ -18.7436 & -2.7638 \\ -46.7417 & -7.0392 \end{bmatrix}$$

$$L_2 = \begin{bmatrix} -0.0093 & 12.5951 \\ 12.3249 & -244.6495 \\ 0.4064 & 1.6624 \\ -9.4364 & 153.8303 \end{bmatrix}$$

Con todas las matrices diseñadas se procede a obtener los estados estimados. Además, después de obtener los estados estimados estos serán multiplicados por la matriz C para obtener las salidas estimadas. Estas salidas se comparan con las salidas reales medidas para finalmente obtener los residuales, ver Figura 3.10.

$$\dot{z} = Nz + Ly + Gu \quad (3.56a)$$

$$\hat{x} = z - Ey \quad (3.56b)$$

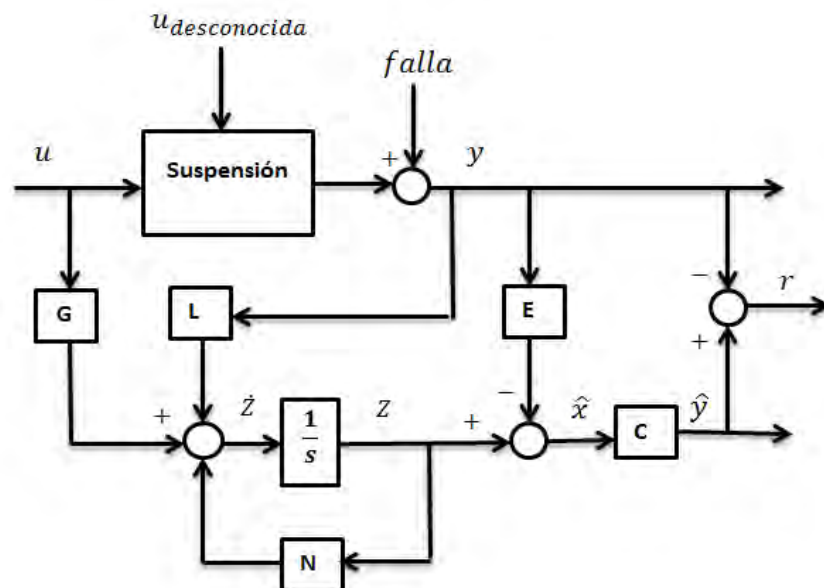


Figura 3.10. Obtención de los residuales a partir de los estados estimados.

En la Figura 3.11, se puede observar como los estados estimados convergen rápidamente a los valores reales.




Figura 3.11. Estados estimados por observadores de entradas desconocidas.

Se puede notar que los estados \hat{z}_s y \hat{z}_{us} de ambos observadores mantienen un error. Esto se debe a que ambos se obtienen de la integración de otros estados, $\dot{\hat{z}}_s$ y $\dot{\hat{z}}_{us}$ respectivamente. Es por ello que se mantiene un error de integración cuando las condiciones iniciales son desconocidas. Esto será más evidente cuando ocurra una falla, es posible observar esto en la Figura 3.12, donde se ha simulado una falla en uno de los tres sensores usados, la falla aparece en forma de escalón a partir del segundo 2, y su efecto en los estados afectados estimados por los observadores se hace cada vez más evidente. A esto se lo conoce como *efecto drift*,

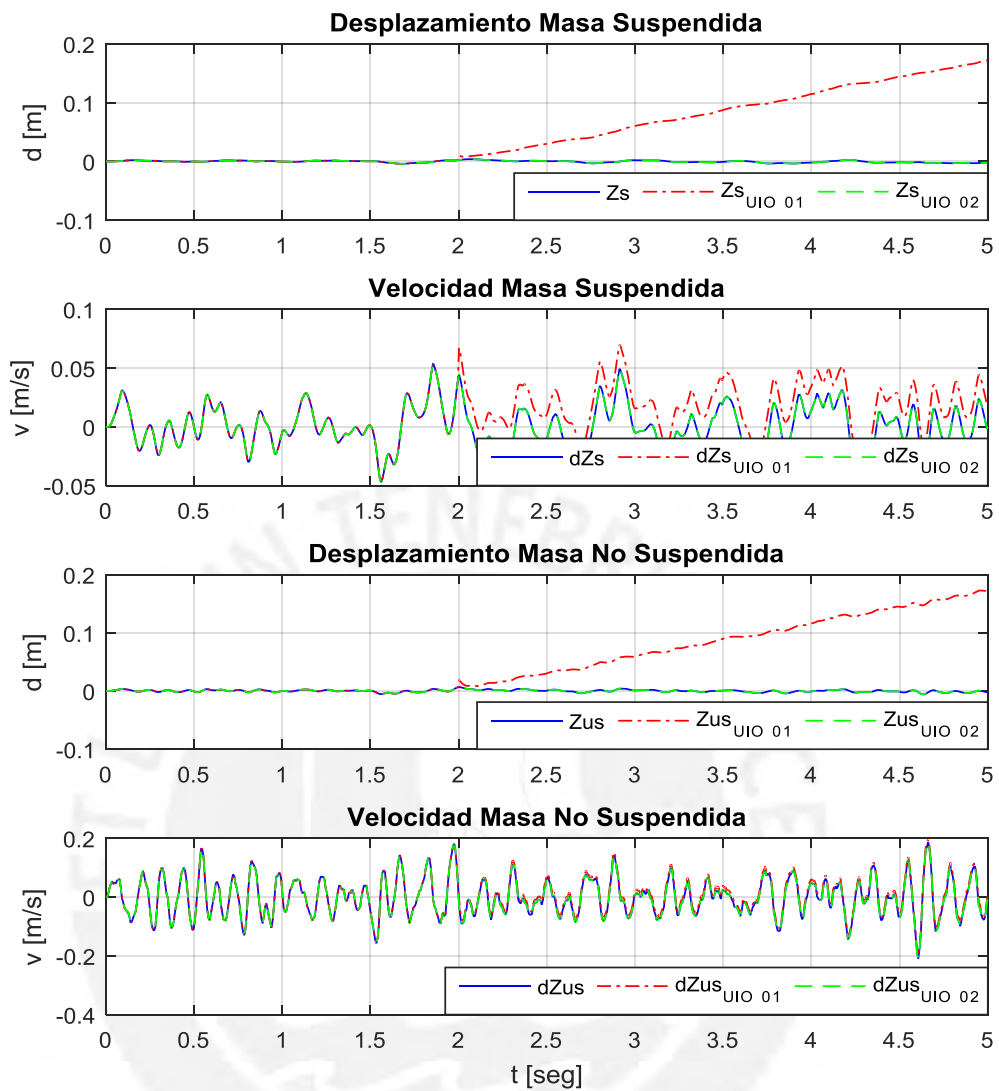


Figura 3.12. Efecto drift en la estimación de estados.

Como se puede observar para una falla, en este caso en el sensor de velocidad de la masa suspendida, el observador 01 se ve afectado por el efecto drift. Para evitar esto se agrega un filtro pasa altas a cada estado que se obtiene por integración.

$$Z_{s,us_f} = \frac{s}{s+1} Z_{s,us} \quad (3.57)$$

Con lo que se consigue una respuesta como en la Figura 3.13.

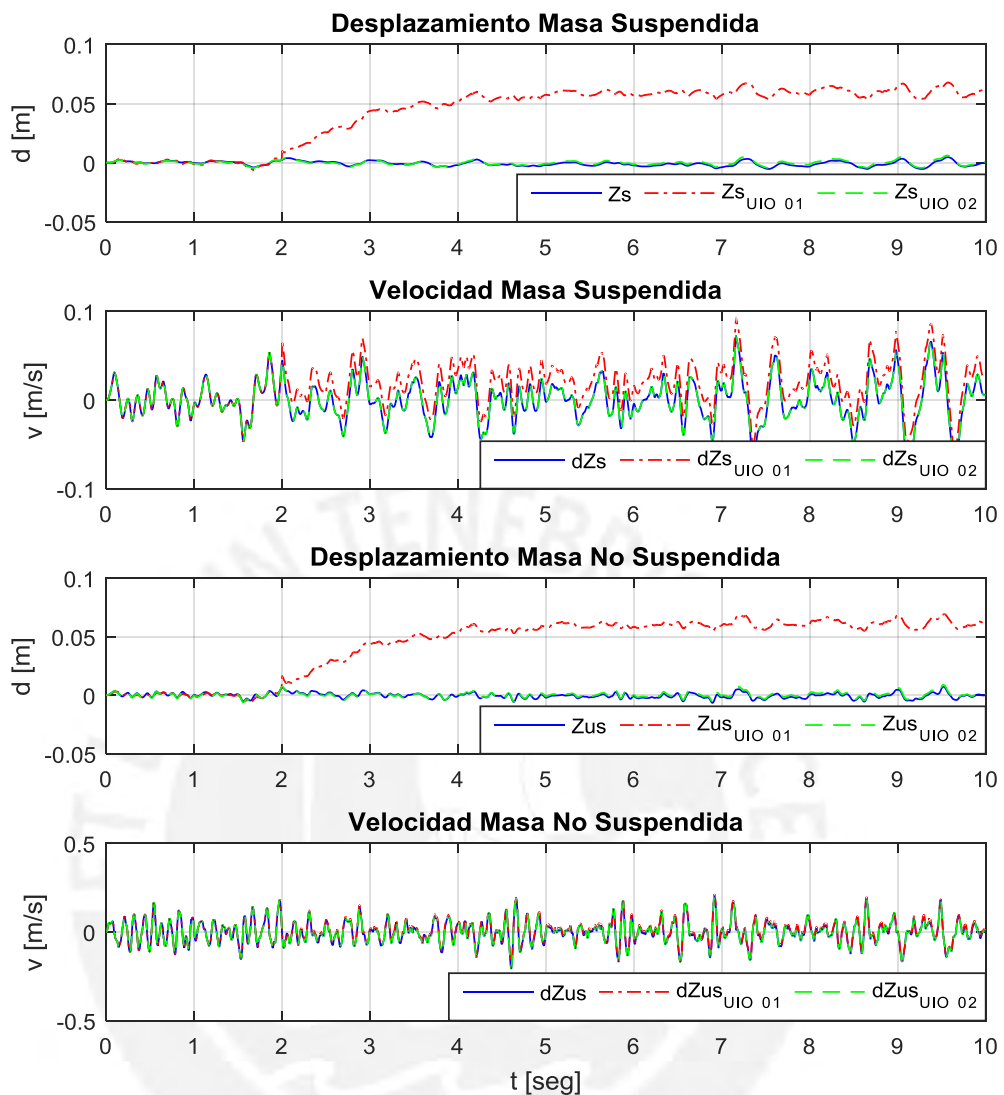


Figura 3.13. Filtrado de estados estimados por integración.

De esta manera, cuando ocurra una falla aditiva en cualquiera de los sensores, los estados estimados no se verán afectados por el efecto drift. Este hecho nos beneficia en cuanto que los estados estimados responderán de manera diferente ante determinadas fallas. De esta manera se pueden usar los estados estimados, \hat{z}_s y \hat{z}_{us} , de ambos observadores para aislar las fallas ocurridas como se verá más adelante cuando se hable del diseño de una red neuronal para aislar fallas aditivas en los sensores.

Las salidas estimadas calculadas a partir de los estados estimados cuando no ocurren fallas las podemos ver en la Figura 3.14.




Figura 3.14. Salidas obtenidas de los estados estimados por los UIO.

Como se puede observar, la estimación de las salidas para condiciones iniciales desconocidas es bastante buena. Las líneas rojas y verdes pertenecen a las salidas obtenidas a partir de los observadores 01 y 02, respectivamente. Se puede notar que las salidas convergen velozmente hacia las salidas reales. Los residuales ($r_{11}, r_{12}, r_{13}, r_{21}, r_{22}, r_{23}$) se obtienen restando las salidas estimadas con las salidas medidas.

El diagnóstico de fallas por desconexión de sensores se realizará al verificar que las salidas medidas son diferentes a las salidas estimadas.

3.6. Sistema de Estimación Paramétrica

En esta sección el problema que se trata de resolver es el diagnóstico de fallas dentro del amortiguador MR, las fallas consideradas son del tipo paramétricas. El método empleado es la estimación de los parámetros de la ecuación que describe al amortiguador y compararlos con los valores nominales correspondientes. De esta manera es posible monitorear los residuales y así conocer si ha ocurrido alguna falla considerable.

Para ello se usará la ecuación que describe la fuerza del amortiguador MR de (2.27).

$$F_D = K_p z_{def} + C_p \dot{z}_{def} + f_c v \tanh(a_v \dot{z}_{def} + a_d z_{def}) \quad (3.58)$$

Se puede notar que para estimar esta fuerza se necesita algunas mediciones como la propia fuerza del amortiguador, la deflexión de la suspensión y su respectiva velocidad. Ya que no es posible medir la fuerza interna del amortiguador, esta se conseguirá calculándola a partir de las otras mediciones y la corriente aplicada.

$$F_I = f_c v \tanh(a_v \dot{z}_{def} + a_d z_{def}) \quad (3.59)$$

De (3.22) se tiene.

$$\hat{y}(k, \theta) = \theta^T \Phi(k)$$

Que en notación vectorial quedaría como:

$$\hat{y}(k, \theta) = [K_p \ C_p \ 1] \begin{bmatrix} z_{def} \\ \dot{z}_{def} \\ F_I \end{bmatrix} \quad (3.60)$$

Donde:

$\theta = [K_p \ C_p \ 1]^T$ es el vector de parámetros.

$\Phi(k) = [z_{def} \ \dot{z}_{def} \ F_I]^T$ es el vector de regresión.

El diagrama de bloque en Simulink del sistema de identificación paramétrica se muestra en la Figura 3.15.

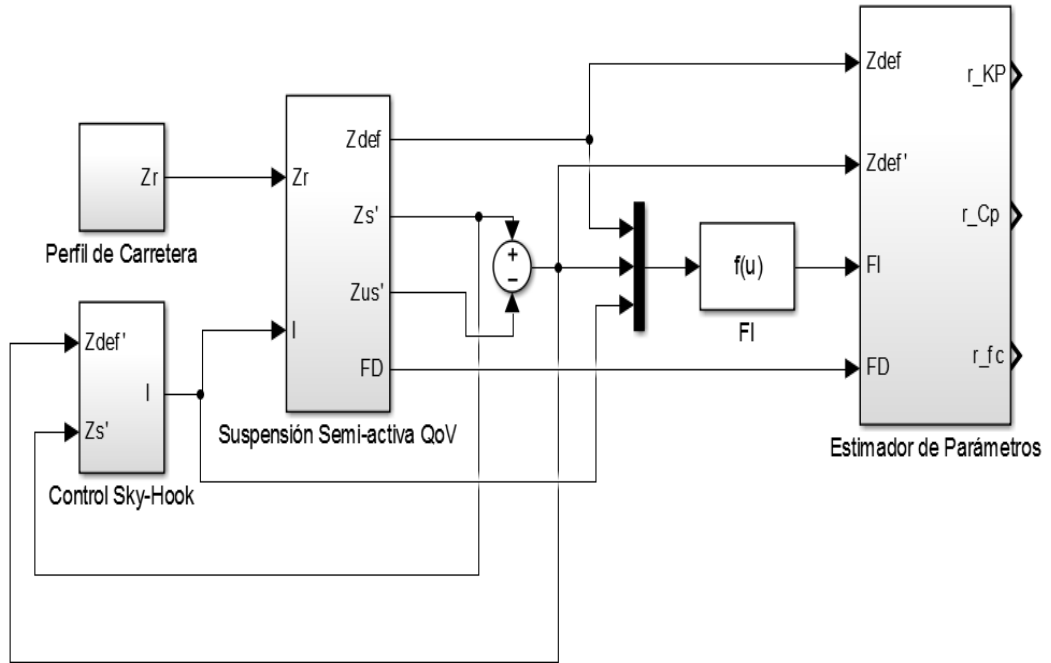


Figura 3.15. Diagrama estimador de parámetros.

Dentro del bloque *Estimador de Parámetros*, se está calculando la matriz de covarianza de los coeficientes P y la matriz de ganancia L , ver Figura 3.16.

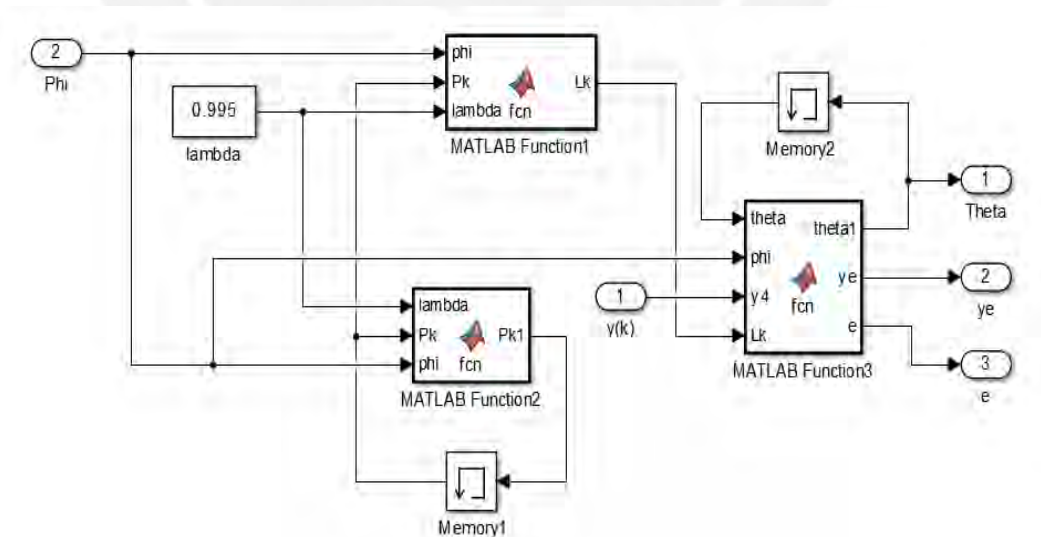


Figura 3.16. Bloque Estimator de Parámetros.

Los bloques *MATLAB Function* en su interior están calculando respectivamente.

```

1 function Lk = fcn(phi,Pk,lambda)
2
3 - Lk = Pk*phi/(lambda + phi'*Pk*phi);

```

Figura 3.17. MATLAB Function 1.

$$L(k) = R(k)^{-1} \Phi(k) = \frac{P(k-1)\Phi(k)}{\lambda(k) + \Phi^T(k)P(k-1)\Phi(k)}$$

```

1 function Pk1 = fcn(lambda,Pk,phi)
2
3 - Pk1 = 1/lambda*(Pk-Pk*phi*phi'*Pk/(lambda + phi'*Pk*phi));

```

Figura 3.18. MATLAB Function 2.

$$P(k) = \frac{1}{\lambda(k)} \left[P(k-1) - \frac{P(k-1)\Phi(k)\Phi^T(k)P(k-1)}{\lambda(k) + \Phi^T(k)P(k-1)\Phi(k)} \right]$$

```

1 function [thetal,ye,e] = fcn(theta,phi,y4,Lk)
2
3 - ye = phi'*theta;
4 - e = y4-ye;
5 - thetal = theta + Lk*e;

```

Figura 3.19. MATLAB Function 3.

$$\hat{\theta}(k) = \hat{\theta}(k-1) + L(k) (y(k) - \hat{y}(k))$$

En la Figura 3.20, se puede observar como los parámetros estimados convergen rápidamente hacia sus valores nominales.

Las líneas azules son los valores nominales de los parámetros del amortiguador, y las líneas verdes son los valores de los parámetros

estimados. Se observa que los parámetros estimados convergen a sus valores nominales en aproximadamente 0.1 segundos.

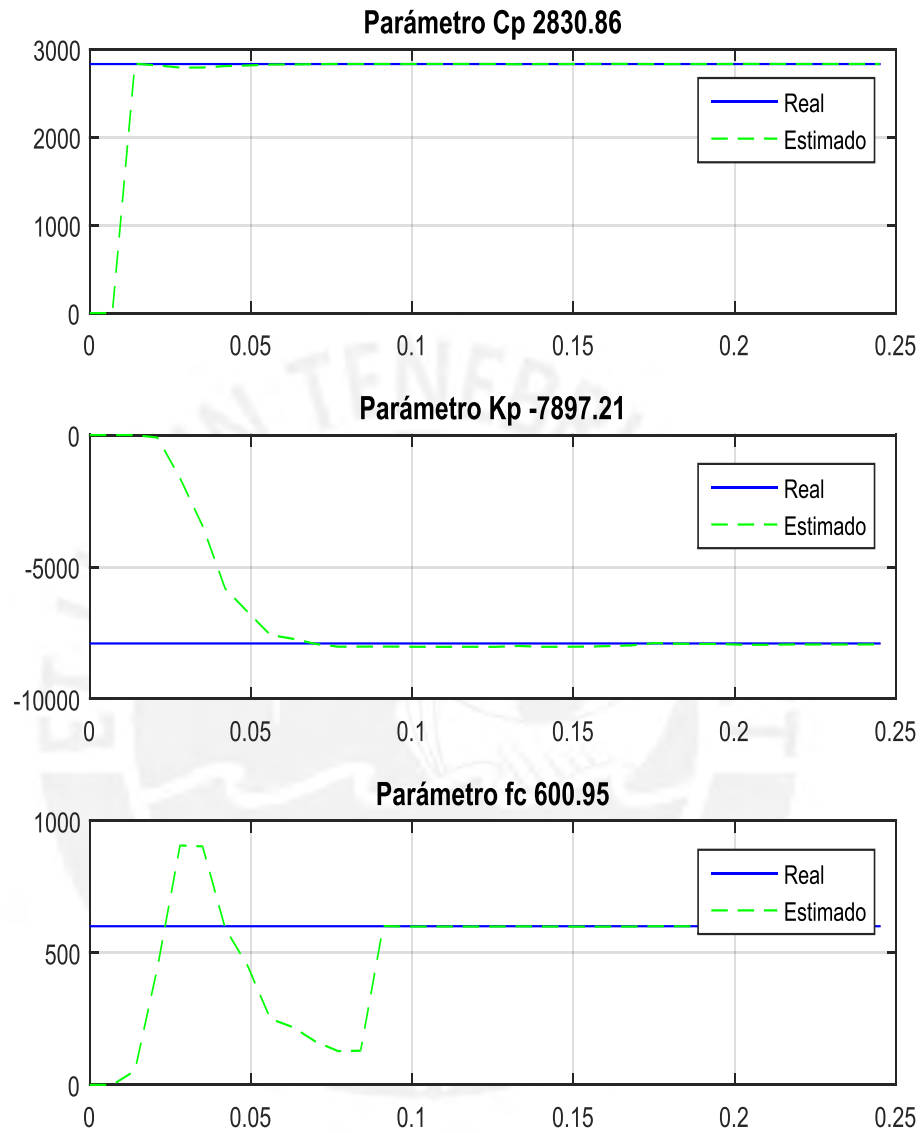


Figura 3.20. Parámetros estimados.

3.6.1. Obtención de Residuales de la Estimación Paramétrica

El valor estimado se resta y se divide con su valor nominal para obtener un valor porcentual de error de estimación.

$$r_{\hat{C}_p} = \left(\frac{C_p - \hat{C}_p}{C_p} \right) \times 100\% \quad (3.61)$$

$$r_{\hat{K}_p} = \left(\frac{K_p - \hat{K}_p}{K_p} \right) \times 100\% \quad (3.62)$$

$$r_{\hat{f}_c} = \left(\frac{1 - \hat{f}_c}{1} \right) \times 100\% \quad (3.63)$$

Con esto se consigue que si los parámetros están bien estimados y el sistema está libre de fallas los residuales serán igual a cero, como se observa en la Figura 3.21.




Figura 3.21. Residuales de la estimación paramétrica.

Los tres residuales son iguales a cero, lo que indica que se está estimando bien los parámetros y no ha ocurrido ninguna falla.

A continuación, se simula una falla multiplicativa ocurrida a partir del segundo 10. Se considera una disminución del 10% del coeficiente de

amortiguamiento viscoso C_p , esto indicaría que hay una fuga del líquido MR, ver Figura 3.22.




Figura 3.22. Falla paramétrica, disminución del 10% de C_p .

Como se observa, los tres parámetros son sensibles a la falla pero sólo el parámetro estimado C_p mantiene el error; los otros dos convergen a cero después de aproximadamente 4 segundos de haber ocurrido la falla.

Para el diagnóstico, el rango de variación de C_p se estableció entre -5% y -30%. La variación mínima se definió con el fin de evitar falsas alarmas de falla para variaciones menores de C_p . Y la variación máxima es el valor antes de que el sistema se vuelva inestable.

Las fallas aditivas en los sensores pueden generar errores al momento de estimar los parámetros, esto ocasionaría que nuestro sistema de estimación paramétrica arroje valores falsos. Para evitar un diagnóstico erróneo se trabajará con el promedio del valor estimado actual y los cuatro valores estimados pasados, esto para cada parámetro.

3.7. Diseño de una Red Neuronal para Aislar Fallas

Después de obtener los residuales y analizar su comportamiento ante determinadas fallas, se procede al diseño de una red neuronal para poder llevar a cabo el aislamiento.

El modelo elegido es la *red backpropagation*, que no es más que una arquitectura perceptrón multicapa con entrenamiento backpropagation.

3.7.1. Diseño de patrones de entrenamiento

El primer paso a seguir es establecer la forma de los patrones. Estos estarán conformados por 6 entradas (in_i) a la red. Se ha decidido trabajar con dos estados estimados por los observadores de entradas desconocidas: el desplazamiento de la masa suspendida \hat{z}_s y el desplazamiento de la masa no suspendida \hat{z}_{us} . Por lo tanto cada patrón está conformado como se muestra en la Tabla 3.2.

Tabla 3.2. Conformación de patrones para red neuronal.

in_1	\hat{z}_s del observador 01: z_{sUI01}
in_2	\hat{z}_s del observador 02: z_{sUI02}
in_3	la resta $z_{sUI01} - z_{sUI02}$
in_4	\hat{z}_{us} del observador 01: z_{usUI01}
in_5	\hat{z}_{us} del observador 02: z_{usUI02}
in_6	la resta $z_{usUI01} - z_{usUI02}$

Se tienen 6 patrones que representan:

- Falla positiva en el sensor de velocidad de la masa suspendida.
- Falla negativa en el sensor de velocidad de la masa suspendida.
- Falle positiva en el sensor de velocidad de la masa no suspendida.
- Falla negativa en el sensor de velocidad de la masa no suspendida.

- Falla positiva en el sensor deflexión de la suspensión.
- Falla negativa en el sensor de deflexión de la suspensión.

Los patrones para el entrenamiento de la red fueron conseguidos con el valor promedio de cada estado estimado ante la simulación de cada falla. Además, para un mejor entrenamiento estos valores se multiplicaron por un factor igual a 100. Los patrones conformados se muestran en la siguiente tabla.

Tabla 3.3. Patrones de entrenamiento.

	in_1	in_2	in_3	in_4	in_5	in_6
Patrón1	3.61	0	3.62	3.68	0	3.65
Patrón2	-3.61	0	-3.62	-3.68	0	-3.65
Patrón3	-7.68	4.0	-11.68	-7.73	3.99	-11.73
Patrón4	7.68	-4.0	11.68	7.73	-3.99	11.73
Patrón5	0	-1.12	1.12	0	-1.2	1.21
Patrón6	0	1.12	-1.12	0	1.21	-1.2

3.7.2. Salidas Deseadas

Se recomienda que las salidas estén conformadas por vectores con valores entre 0 y 1. Además, estos vectores deben ser ortogonales para evitar la confusión de la red.

Entonces, las salidas serán vectores de dimensión igual al número de fallas que se desea aislar. La Tabla 3.4 muestra los patrones con sus respectivas entradas para la red y las salidas que se desean obtener para cada patrón.

Tabla 3.4. Patrones entrada-salida para entrenamiento Backpropagation.

	ENTRADAS						SALIDAS					
Patrón1	3.61	0	3.62	3.68	0	3.65	1	0	0	0	0	0
Patrón2	-3.61	0	-3.62	-3.68	0	-3.65	0	1	0	0	0	0
Patrón3	-7.68	4.0	-11.68	-7.73	3.99	-11.73	0	0	1	0	0	0
Patrón4	7.68	-4.0	11.68	7.73	-3.99	11.73	0	0	0	1	0	0
Patrón5	0	-1.12	1.12	0	-1.2	1.21	0	0	0	0	1	0
Patrón6	0	1.12	-1.12	0	1.21	-1.2	0	0	0	0	0	1

3.7.3. Capas intermedias y funciones de activación

Se tiene el número de entradas y salidas de la red. Ahora se debe establecer el número de capas intermedias y el número de neuronas intermedias.

Se empezó con una capa intermedia y 10 neuronas intermedias, posteriormente se logró concluir que para un buen aislamiento se necesitan 100 neuronas intermedias. Las funciones de activación son tipo lineales, tanto a la entrada como a la salida. Para el caso de las neuronas intermedias se consideran funciones sigmoideas del tipo 1 en donde además se buscará el centro (c) y la pendiente (a) para cada neurona.

$$f(x) = \frac{1}{1 + e^{-\frac{m-c}{a}}}$$

Es necesario recordar que no hay una teoría exacta que indique cuántas neuronas ni qué funciones de activación deben tener. Todo se debe establecer por medio de prueba y error.

3.7.4. Entrenamiento de la red neuronal

El objetivo del entrenamiento es encontrar los pesos sinápticos que le permitan a la red aislar las 6 fallas de manera eficiente.

$$w_{jk} = w_{jk} - \eta \frac{dJ}{dw_{jk}}$$

$$v_{ij} = v_{ij} - \eta \frac{dJ}{dv_{ij}}$$

$$a_j = a_j - \eta_a \frac{dJ}{da_j}$$

$$c_j = c_j - \eta_c \frac{dJ}{dc_j}$$

Para empezar, se debe escoger pesos iniciales que pueden ser aleatorios muy pequeños o nulos.

La matriz de pesos v_{ij} tendrá tantas filas como el número de neuronas de entrada (6), y tantas columnas como el número de neuronas intermedias.

La matriz de pesos w_{jk} deberá tener igual número de filas como neuronas intermedias, y tantas columnas como neuronas de salida (6).

Se deben probar los valores de eta (η , η_a y η_c) que garanticen una rápida convergencia del error a cero. Los valores recomendados son: 0.01, 0.001, se deberá probar estos valores.

El número de iteraciones se establece en 5 000. En la Figura 3.23 se observa el error de entrenamiento para un eta igual a 0.01 con 10 neuronas intermedias.

La Tabla 3.5 resume las pruebas que se hicieron. Con lo que se concluye que 100 neuronas resulta mejor para el entrenamiento; además, el valor eta adecuado es 0.001. El error de entrenamiento para este caso se observa en la Figura 3.24.




Figura 3.23. Error de entrenamiento $\eta=0.01$ con 10 neuronas intermedias.

Tabla 3.5. Error de entrenamiento.

Eta η	Número de neuronas intermedias		
	10	20	50
0.1	1.2007	1.103	1.029
0.01	1.1074	1.087	0.986
0.001	1.0169	1.0636	0.8070

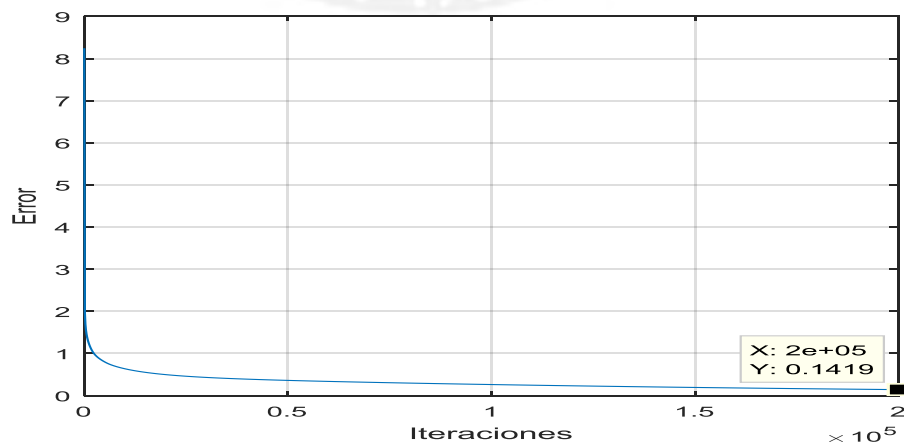


Figura 3.24. Error de entrenamiento $\eta=0.001$, 100 neuronas intermedias.

3.8. Pruebas y Resultados

El sistema de diagnóstico de fallas funcionará en tres etapas. La primera dedicada a detectar desconexiones de sensores; esto se logra al observar si las salidas estimadas son diferentes a las salidas medidas por los sensores. Si las salidas medidas son igual a cero entonces los residuales serán igual a la salida estimada.

La segunda etapa detecta fugas en el amortiguador MR. Se monitorea los tres residuales obtenidos por el sistema de estimación paramétrica, si existe alguna fuga dos residuales serán igual a cero y el tercero mantendrá un offset de la misma magnitud de la falla. Para un mejor aislamiento se trabaja con el promedio del valor actual y los 4 valores anteriores de cada parámetro estimado. Para indicar una falla paramétrica, el promedio de C_p deberá ser diferente de cero y los otros dos promedios correspondientes a K_p y f_c se mantendrán en cero.

Por último, la tercera etapa se encarga de detectar y aislar fallas aditivas en los sensores. Aquí se hace uso de la red neuronal como ya se indicó en la sección anterior.

El programa se detalla en el Anexo B. El sistema de diagnóstico arroja un código K que indica la falla ocurrida. En la Tabla 3.6 se indican los códigos que corresponden a cada falla.

Los códigos K del 1 al 7 indican fallas por desconexión de sensores, para este caso se pueden diagnosticar fallas múltiples de desconexión, es decir cuando sea más de un sensor el que haya sufrido una desconexión.

La falla multiplicativa por fuga en el amortiguador está indicada por $K=8$. También tenemos un código que indica que el sistema está trabajando en condiciones normales $K=9$.

Por último los códigos K del 10 al 15, indican fallas aditivas positivas y negativas en los sensores del sistema.

Tabla 3.6. Código K de fallas diagnosticadas.

Código K	Falla Detectada	
1	Desconexión del sensor y_1 , sensor y_2 y sensor y_3	f_1
2	Desconexión del sensor y_1	f_2
3	Desconexión del sensor y_2	f_3
4	Desconexión del sensor y_3	f_4
5	Desconexión del sensor y_1 y sensor y_2	f_5
6	Desconexión del sensor y_1 y sensor y_3	f_6
7	Desconexión del sensor y_2 y sensor y_3	f_7
8	Fuga amortiguador MR	f_8
9	Normal funcionamiento	
10	Falla (+) positiva sensor y_1	f_9
11	Falla (-) negativa sensor y_1	f_{10}
12	Falla (+) positiva sensor y_2	f_{11}
13	Falla (-) negativa sensor y_2	f_{12}
14	Falla (+) positiva sensor y_3	f_{13}
15	Falla (-) negativa sensor y_3	f_{14}

La primera prueba que se realizó se trató de la desconexión de los tres sensores secuencialmente. Primero se desconectó el sensor y_1 a partir del segundo 20. Después, sensor y_2 se desconectó en el segundo 30. Finalizando con la desconexión del sensor y_3 en el segundo 40.

Según la Tabla 3.6 el código K que el sistema deberá mostrar es: 9 desde el inicio de la simulación hasta el segundo 20, que es cuando ocurre la desconexión del sensor y_1 y el indicador K será igual a 2, posteriormente a partir del segundo 30 se desconecta también el sensor y_2 , quedando desconectados los sensores y_1 y y_2 , lo cual es indicado por el código K igual a 5. Para finalizar, en el segundo 40 quedan desconectados los tres sensores, lo cual deberá ser indicado por $K=1$.

En la Figura 3.25, se observa los resultados de esta primera prueba, mostrando excelentes resultados del diagnóstico de estas fallas.




Figura 3.25. Desconexión de los tres sensores en diferentes tiempos.

El programa diagnosticó las fallas ocurridas y arrojó el código correspondiente según fueron ocurriendo las fallas.

En la Figura 3.26, se observan fallas por desconexión de los sensores y_2 y y_3 .




Figura 3.26. Desconexión de los sensores y_2 y y_3 .

En el segundo 30 el sensor y_2 se desconectó ($K=3$) seguido de una desconexión del sensor y_3 ($K=7$) en el segundo 40. Las mismas fallas ocurren para los sensores y_3 y y_1 en la Figura 3.27. Donde se puede observar la desconexión del sensor y_3 ($K=4$) a partir del segundo 20, y la posterior desconexión del sensor y_1 ($K=6$) a partir del segundo 30.




Figura 3.27. Desconexión de los sensores y_3 y y_1 .

Es posible notar que todas las fallas, respecto a desconexión de sensores, son perfectamente diagnosticadas.

En Figura 3.28 se simuló una falla por fuga del líquido MR en el amortiguador.

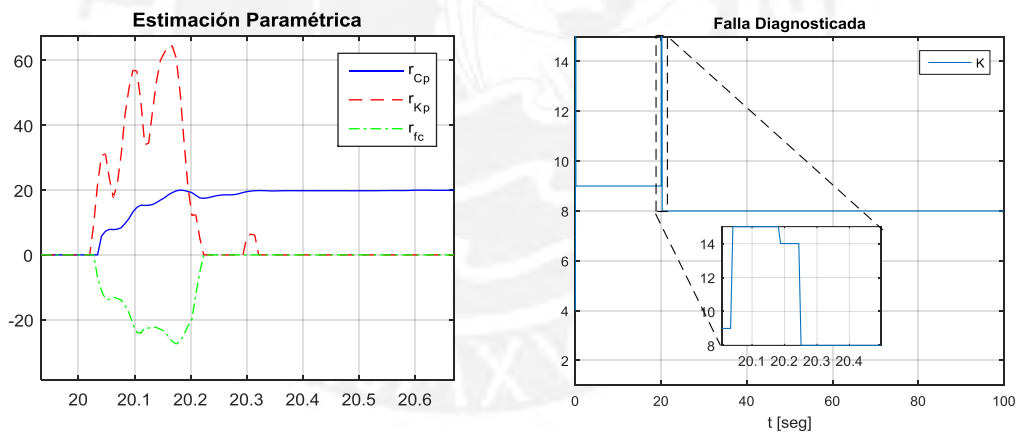


Figura 3.28. Fuga en el amortiguador MR.

La falla es del 20% del valor nominal de C_p . Se puede notar que al principio la falla es confundida con otra relacionada con el sensor y_3 ($K=15$), pero después de pocos segundos el sistema logra diagnosticar correctamente la falla ocurrida ($K=8$). Esto se debe al tiempo de convergencia necesario de la estimación de los parámetros. Es posible mejorar esto modificando el factor

de olvido, aunque el sistema se volvería más sensible al ruido de medición, el factor elegido es 0.95.

A continuación se muestra el diagnóstico de fallas aditivas en los sensores de la suspensión. Para demostrar el desempeño de la red neuronal diseñada, se simularán fallas con diferentes magnitudes de las que se usaron para el entrenamiento de la red.

Para fallas aditivas en el sensor y_1 , se simuló la falla como un escalón en el segundo 10, con una magnitud de ± 0.01 y otro con ± 0.02 . En la Figura 3.29 se aprecia el resultado. A la derecha se observa cómo responden las entradas a la red neuronal, que para el estado estimado \hat{z}_s son: in_1 línea roja; in_2 línea verde y in_3 línea negra. Y para \hat{z}_s son: in_4 línea roja; in_5 línea verde; in_6 línea negra para \hat{z}_{us} .




Figura 3.29. Falla positiva menor en el sensor y_1 .

Se puede observar que la falla es rápidamente detectada aunque con un diagnóstico no muy preciso (indica $K=14$ al principio). El correcto diagnóstico de la falla ocurre algunas décimas de segundo después (indica $K=10$ después de 0.45s), demostrando así, que el sistema logra diagnosticar correctamente la falla. Lo mismo sucede para una falla negativa en este mismo sensor.

En la Figura 3.30 se puede observar el diagnóstico de una falla negativa para el sensor y_1 .

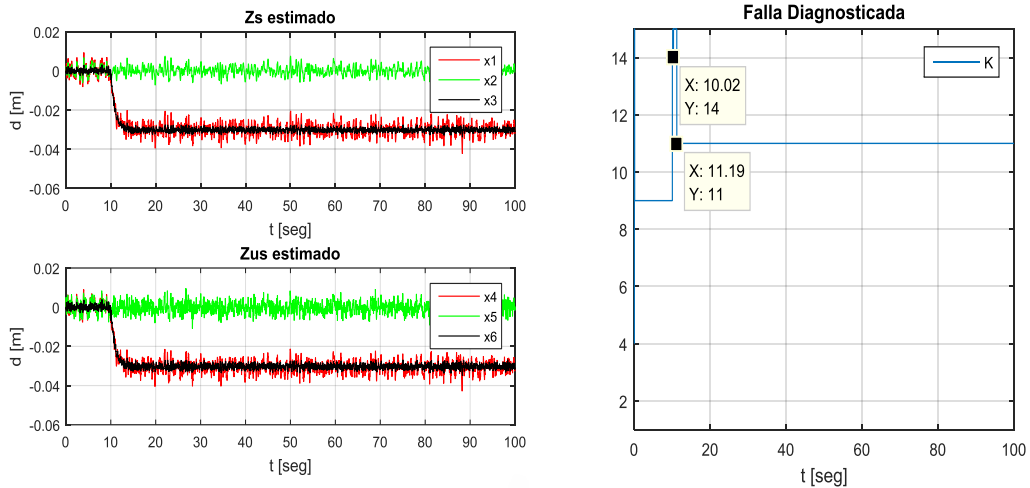


Figura 3.30. Falla negativa menor en el sensor y_1 .

Como en el caso anterior la detección es rápida, aunque el correcto diagnóstico sucede algunos instantes después.

Ahora se prueba con un valor mayor al de entrenamiento, como se aprecia en la Figura 3.31.




Figura 3.31. Falla positiva mayor en el sensor y_1 .

Para una magnitud mayor a la de entrenamiento, la falla es diagnóstica más rápidamente que los casos anteriores. Para el caso de una magnitud mayor negativa, el diagnóstico es mucho más rápido como se aprecia en la Figura 3.32

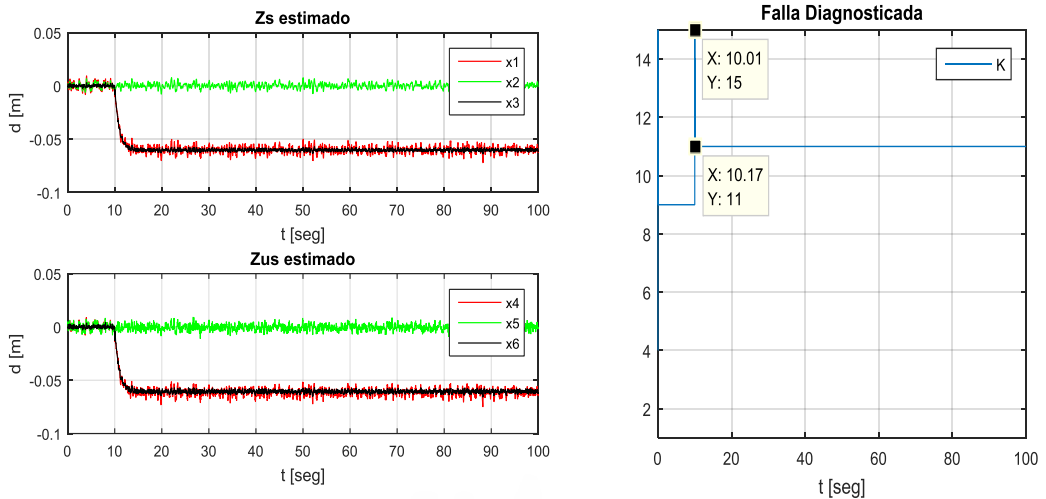


Figura 3.32. Falla negativa mayor en el sensor y_1 .

Para las fallas en el sensor y_2 , se probó con un escalón de magnitud ± 0.025 y otro de ± 0.05 . En la Figura 3.33 se observa la simulación de la falla en el segundo 10.




Figura 3.33. Falla positiva en el sensor y_2 .

En este caso el correcto diagnóstico es un poco más lento que en los dos casos anteriores. A continuación en la Figura 3.34 se muestra el resultado del diagnóstico para una falla negativa en el sensor y_2 .

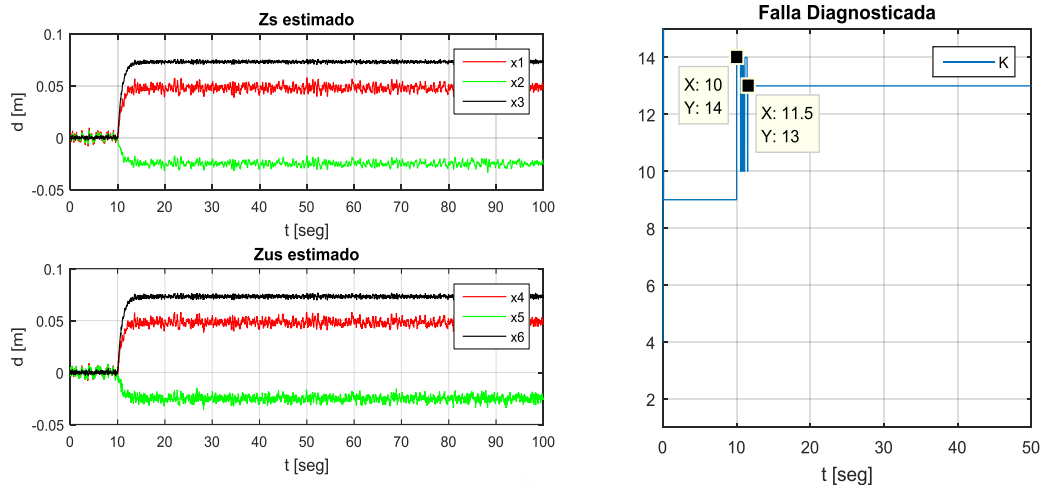


Figura 3.34. Falla negativa en el sensor y_2 .

Para una falla negativa de una magnitud de -0.025 , el correcto diagnóstico se logra después de 1.5 segundos. Para una magnitud mayor el tiempo de diagnóstico es menor, como se puede ver en la Figura 3.35.




Figura 3.35. Falla positiva mayor en el sensor y_2 .

En la Figura 3.36, se puede ver que para una magnitud negativa mayor el tiempo de diagnóstico también es menor.




Figura 3.36. Falla negativa mayor en el sensor y_2 .

Para las fallas en el sensor y_3 , se probó con un escalón de ± 0.001 y uno de ± 0.002 .

Para una magnitud menor positiva, el sistema de diagnóstico, solo detecta la falla por algunos instantes ya que esta magnitud es muy pequeña, como se puede observar en la Figura 3.37.




Figura 3.37. Falla positiva menor en el sensor y_3 .

Lo mismo ocurre para una falla negativa menor, como se ve en la Figura 3.38.




Figura 3.38. Falla negativa menor en el sensor y_3 .

Para magnitudes mayores se obtienen mejores resultados, como se puede observar en las Figuras 3.39 y 3.40.

Para magnitudes positivas mayores, el tiempo de diagnóstico es de 1.34 segundos.




Figura 3.39. Falla positiva mayor en el sensor y_3 .

En el caso de magnitudes negativas mayores, el tiempo de diagnóstico es mayor como se ve en la Figura 3.40.

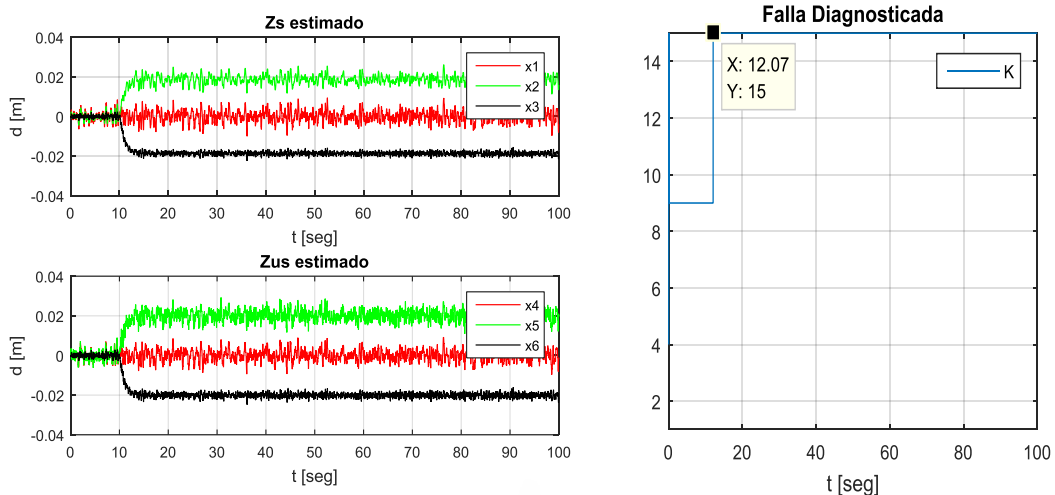


Figura 3.40. Falla negativa mayor en el sensor y_3 .

Se ha podido observar que las fallas que mejor son diagnosticadas son las de desconexión de los sensores, mientras que las fallas paramétricas son detectadas después de transcurrido algún instante. Esto debido al tiempo de convergencia de la estimación de los parámetros cuando ocurre un cambio. Y por último, las fallas aditivas en los sensores tardan un poco más en ser detectadas y aisladas. Esto se debe a que los estados estimados demoran en converger a su valor correspondiente según la falla ocurrida, los filtros pasa altas intervienen bastante en este tiempo de convergencia, pero se debe mencionar que estos fueron seleccionados de tal manera que el ruido no afecte demasiado a la estimación, sin tampoco perder la dinámica de los estados estimados. En el transcurso de este tiempo es que la red neuronal confunde los patrones con un estado normal de funcionamiento o con otro tipo de falla.

Con el fin de evaluar la robustez del sistema de diagnóstico de fallas, se realizaron pruebas para observar el efecto de incertidumbre del valor de la masa suspendida (m_s) y del coeficiente de rigidez del neumático K_t .

Se consideró una masa suspendida 50% más pesada y otra 50% menos pesada que la nominal, y en el caso del coeficiente de rigidez del neumático, se consideró un K_t 20% mayor y un K_t 20% menor.

En la Figura 3.41, se pueden observar los resultados de las pruebas para todas las fallas cuando la masa suspendida es igual a $1.5m_s$.

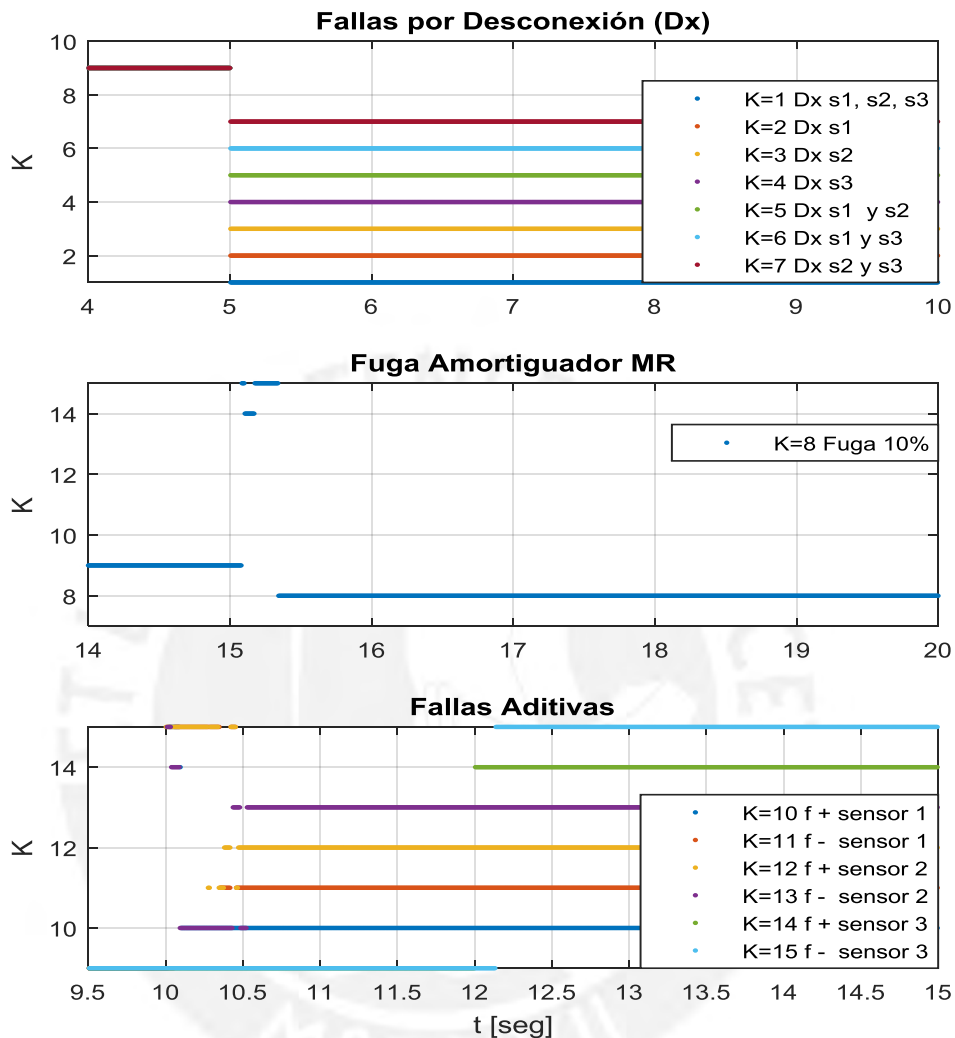


Figura 3.41. Diagnóstico de fallas para $1.5m_s$.

Se puede ver como el sistema diagnostica correctamente todas las fallas indicando el código de falla K correspondiente. Unas fallas son diagnosticadas mayor rapidez que otras.

Las fallas por desconexión de sensores se simularon a partir del segundo 5. Se puede observar que todas las fallas por desconexión son diagnosticadas correctamente. La falla por fuga del líquido MR se simuló a partir del segundo 15 y como se puede ver, se logra diagnosticar correctamente

después de aproximadamente 0.5 segundos. El diagnóstico de las fallas aditivas tiene las mismas características que para el caso de la masa nominal. Estas fallas se simularon a partir del segundo 10.

Los resultados de los tres casos restantes se muestran las Figuras 3.42, 3.43 y 3.44.

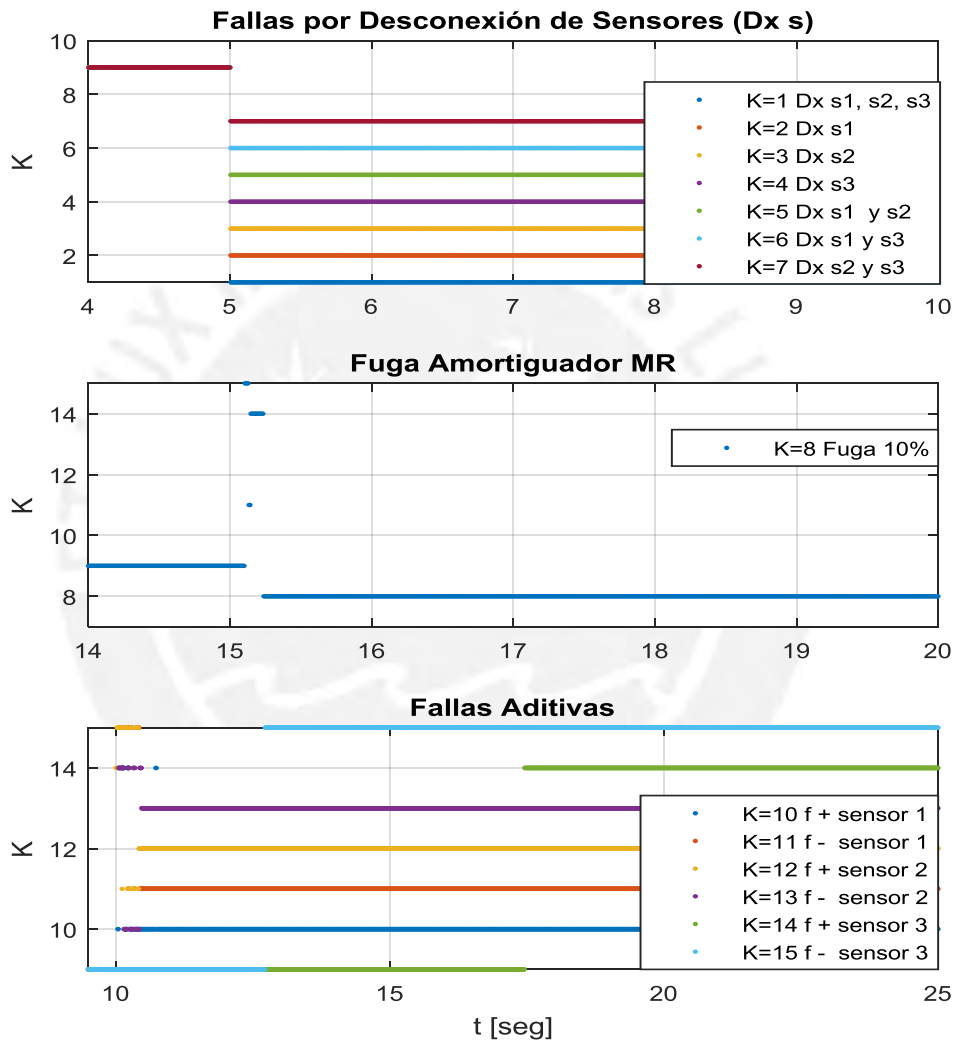


Figura 3.42. Diagnóstico de fallas para una masa $0.5m_s$.

Se puede observar que el diagnóstico de las fallas por desconexión sigue siendo perfectamente eficiente. El diagnóstico de las demás fallas se realiza correctamente como en los casos anteriores.

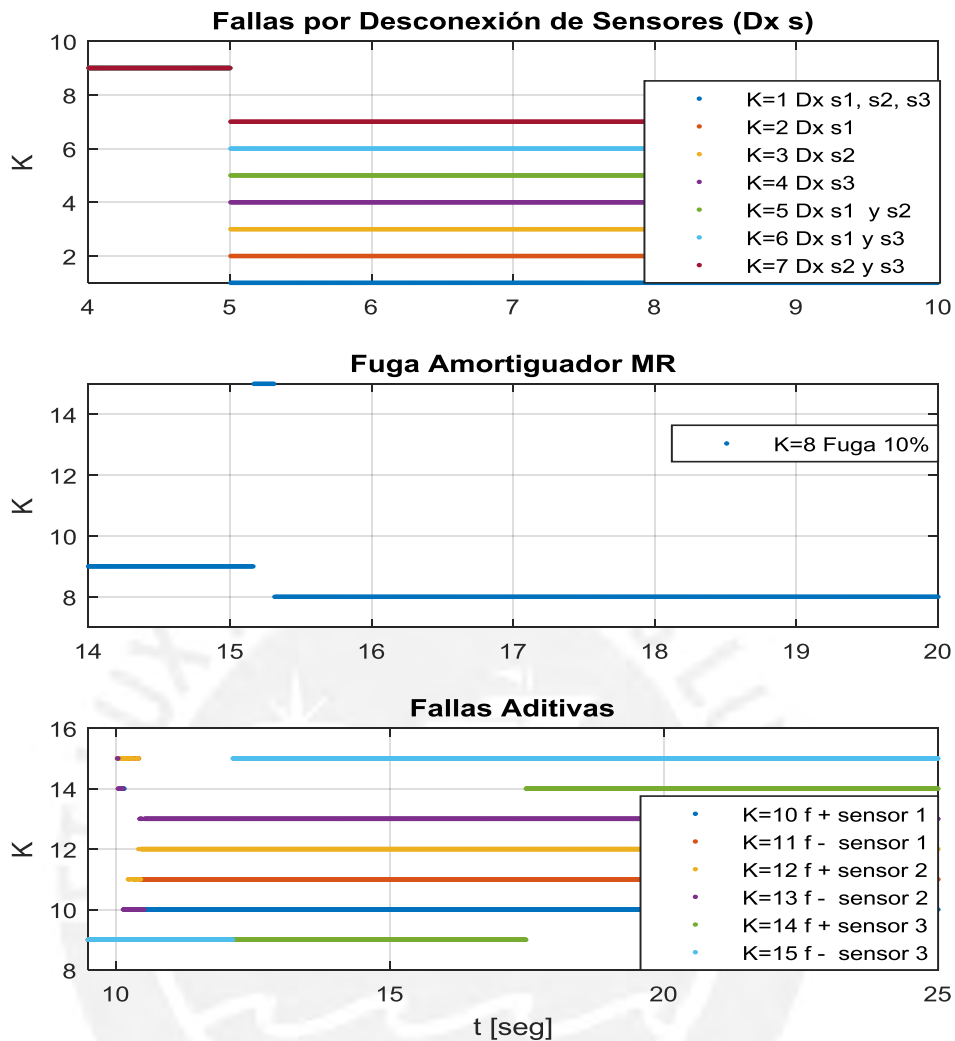


Figura 3.43. Diagnóstico de fallas para $1.2K_t$.

Es necesario mencionar la importancia de la robustez del sistema ante la incertidumbre de algunos parámetros, ya que, los modelos matemáticos nunca son tan precisos, además, estos parámetros escogidos (masa suspendida y coeficiente rígido del neumático) son los que presentan una mayor posibilidad de variar.

La masa suspendida está sujeta a la carga que representan todos los ocupantes más el chasis del vehículo, es así que la cantidad de pasajeros siempre puede ser diferente.

Respecto al coeficiente de rigidez del neumático, este podría variar en caso que el neumático sufra una pérdida de presión por falta de aire. Es por ello que el sistema deberá ser insensible a este cambio.

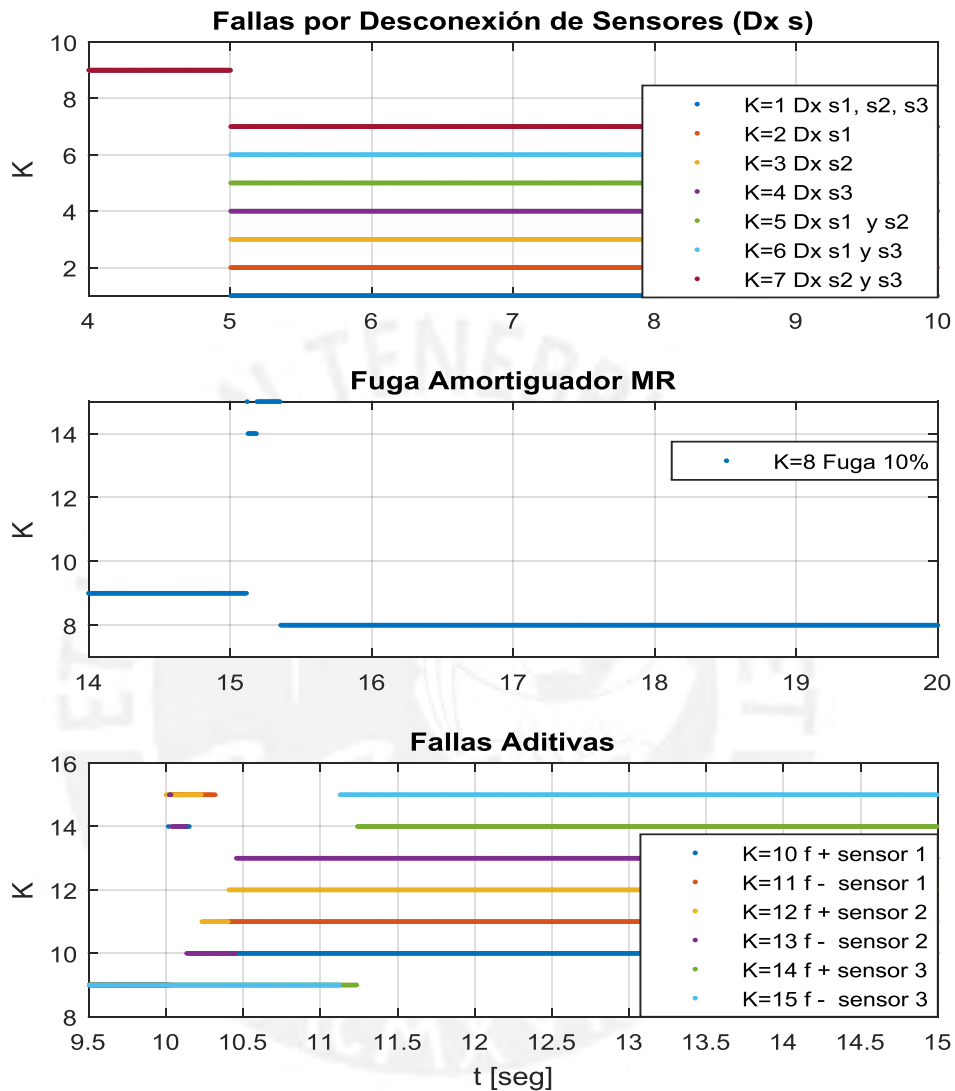


Figura 3.44. Diagnóstico de fallas para $0.8K_t$.

Con estas cuatro pruebas se demuestra que el sistema es capaz de realizar el diagnóstico de todas las fallas consideradas en este trabajo a pesar de la incertidumbre de estos dos parámetros.

Resumiendo los resultados obtenidos se presenta la Tabla 3.7, donde se puede observar las fallas que se han logrado diagnosticar y los residuales usados para ello. El símbolo “✓” indica que el correspondiente residual se

usó para diagnosticar las respectivas fallas. Los símbolos “+” y “-” indican que los correspondientes residuales aumentan o disminuyen, según sea el caso, ante determinadas fallas.

Tabla 3.7. Matriz de Firma de Fallas

Residuales		Fallas Diagnosticadas													
		f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8	f_9	f_{10}	f_{11}	f_{12}	f_{13}	f_{14}
UIO	r_{11}														
	r_{12}	✓	✓	✓	✓	✓	✓	✓							
	r_{13}	✓	✓	✓	✓	✓	✓	✓							
	r_{21}	✓	✓	✓	✓	✓	✓	✓							
	r_{22}														
	r_{23}														
	in_1									(+)	(-)	(-)	(+)		
	in_2											(+)	(-)	(-)	(+)
	in_3									(+)	(-)	(-)	(+)	(+)	(-)
	in_4									(+)	(-)	(-)	(+)		
	in_5											(+)	(-)	(-)	(+)
	in_6									(+)	(-)	(-)	(+)	(+)	(-)
Est. Par.	r_{C_p}							✓							
	r_{K_p}							✓							
	r_{f_c}							✓							

Como se puede observar, para diagnosticar fallas por desconexión de sensores (de f_1 hasta f_7) se usan los residuales del banco de observadores de estradas desconocidas, el aislamiento de las fallas se realiza mediante reglas “if – else”.

La fuga en el amortiguador magneto-reológico no era posible ser diagnosticada por medio de los residuales de los observadores. Así que, el subsistema de estimación paramétrica completó la labor del sistema de diagnóstico de fallas. Para ello se utilizó los tres residuales obtenidos de los parámetros estimados.

Para el caso de las fallas aditivas en los sensores, se usó los estados estimados por los observadores, a los cuales previamente se los filtró para evitar el efecto driff. Los estados estimados presentaban patrones distintos ante determinadas fallas, así que estos se usaron para que la red neuronal pudiera aislar la falla correctamente.

4. PROPUESTA DE IMPLEMENTACIÓN

4.1. Introducción

En el presente capítulo, se plantea una propuesta de implementación para simulaciones prácticas del sistema de diagnóstico de fallas, para ello se propone la construcción de un banco de pruebas. A continuación, se detalla el software y hardware que será necesario implementar.

4.2. Hardware

La parte del hardware está conformado por los actuadores que se necesitan. Dado el caso que el banco de pruebas necesita ser excitados por un perfil de carretera, este será producido por un motor DC lineal el cual recibe una señal generada desde un ordenador.

4.2.1. Actuadores

a) **Amortiguador Magneto-reológico:** Para construir un banco de pruebas para una suspensión semi-activa el elemento principal es el amortiguador MR.

El modelo del actuador utilizado en este texto representa a un amortiguador fabricado por *Lord Corporation*. El amortiguador es rellenado con un fluido magneto-reológico y posee una longitud de 215mm cuando se encuentra extendido, el cual cuenta con una carrera de 25mm. El cilindro principal tiene un diámetro de 38mm y aloja al pistón, al circuito magnético, un acumulador y 50mL de fluido MR. El campo magnético producido en el amortiguador es generado por un pequeño electroimán situado en la cabeza del pistón. La corriente para el electroimán es suministrada por un controlador de corriente lineal funcionando con 120VAC, el cual genera una corriente de 0 – 1 A, la cual es proporcional a un voltaje DC de entrada aplicado en un rango de 0 – 3 V. El pico de potencia requerida es menor de 10 W.

Este controlador de corriente transforma el voltaje aplicado (0 – 2.25 V) a una proporcional, corriente alta (0 – 1 A), señal de baja tensión. Este señal es aplicada al fluido MR para generar la fuerza de salida, la cual puede llegar

a 3000 N. La fuerza es estable sobre un amplio rango de temperatura (variando menos del 10% en un rango de -40°).

b) Actuador de Excitación:

Para la excitación vertical de la rueda se conecta un motor eléctrico lineal a la placa base de la rueda. De acuerdo con el principio de un motor eléctrico de tres fases sin escobillas, se genera una fuerza directamente proporcional a la corriente que mueve la barra, que incorpora los imanes permanentes.



Figura 4.1. Motor lineal para la excitación de la carretera (Koch et al, 2010).

4.2.2. Sensores

Los sensores necesarios para poder implementar el banco de pruebas son:

a) **Acelerómetros:** Tanto para el control Sky-hook como para la estimación de los estados y los parámetros del amortiguador es necesario conocer las velocidades de la masa suspendida y la masa no suspendida. Estas velocidades se pueden conseguir por medio de la integración de la medición de las aceleraciones.

Los acelerómetros capacitivos tienen la característica de poder medir aceleraciones desde 0Hz hasta varios cientos de Hz, por lo que se suelen emplear para aplicaciones de baja o muy baja frecuencia, aunque cuentan con muy buena resistencia a posibles picos de aceleración.

Existen acelerómetros capacitivos que están completamente sellados, por lo que son muy insensibles a interferencias y radiaciones electromagnéticas.

La mayoría incorporan electrónica que les permite obtener una alta sensibilidad, con una baja deriva térmica y gran linealidad.

Para la aceleración de la masa suspendida, se podría usar un sensor con un rango de medición de $\pm 5g$, y para la aceleración de la masa no suspendida un sensor con un rango de $\pm 25g$.



Figura 4.2. Acelerómetro capacitivo.

b) **Sensor de Deflexión:** Este sensor es necesario para la estimación paramétrica, se puede usar un LVDT que tiene un buen desempeño y no es muy sensible al ruido.

Los LVDT son sensores inductivos, en este caso es necesario uno especialmente diseñado para su montaje en el interior de cilindros, característica por la cual estos equipos tienen que ser muy robustos y soportar presiones y temperaturas elevadas.



Figura 4.3. Sensor LVDT.

c) **Sensor de Fuerza:** Conocer la fuerza del amortiguador también es necesario para la estimación paramétrica, para estos se puede usar una célula de carga.

Una celda de carga es un transductor que convierte fuerza en una salida eléctrica medible. Aunque hay muchas variedades de celdas de carga, las celdas de carga a base de calibrador de tensión son el tipo usado más frecuentemente.



Figura 4.4. Célula de carga tracción/compresión.

d) **Sensor de Corriente:** La corriente aplicada al amortiguador es necesario para alimentar a los observadores y para calcular la fuerza interna que ejerce el amortiguador MR. esta corriente puede ser medida por medio de un transductor de efecto hall.

Los sensores de corriente de lazo abierto son capaces de proporcionar una tensión de salida proporcional a la corriente medida sin utilizar ningún control de realimentación. El dispositivo de tamaño compacto con bajo consumo de energía es adecuado para circuitos alimentados por batería, como en este caso el sistema del vehículo.



Figura 4.5. Transductor de efecto Hall.

4.2.3. Microcontrolador

El programa será implementado en un microcontrolador con la capacidad suficiente para procesar los datos a una velocidad mayor de 141 Hz que es la frecuencia de muestreo de las variables.

4.3. Software

El algoritmo del sistema de diagnóstico de fallas tendrá un diagrama de flujo como se muestra en la Figura 4.6 y se detalla a continuación.

- 1) Se inicializa el programa cargando los parámetros del modelo de la suspensión semi-activa. Estos parámetros se pueden conseguir previamente con un proceso de identificación paramétrica.
- 2) Se establecen las condiciones iniciales. Los estados iniciales de los observadores se establecen iguales a cero. Además los vectores que son útiles en el subsistema de estimación paramétrica también deberán inicializarse con valores iguales a cero.
- 3) Se deben cargar los pesos sinápticos que se consiguieron en el entrenamiento de la red neuronal.
- 4) Se leen las variables medidas por los sensores. Además de las mediciones de los sensores es necesario conocer la variable de control, como se explicó antes esta variable es calculada para cada observador y para la estimación paramétrica ya que no puede ser medida directamente.
- 5) A continuación se estiman los estados con los cuales se consiguen las salidas estimadas para luego obtener los residuales. También se estiman los parámetros del amortiguador para obtener los otros 3 residuales.
- 6) Se verifica si existe alguna falla por desconexión.
- 7) Se verifica si existe alguna falla paramétrica por fuga en el amortiguador MR.
- 8) Se verifica si existe alguna falla aditiva en los sensores.
- 9) Se indica la falla en la pantalla del conductor.
- 10) Se vuelve al paso 4.

La configuración final del sistema de diagnóstico de fallas trabajando con el banco de pruebas de la suspensión semi-activa se muestra en la Figura 4.7.

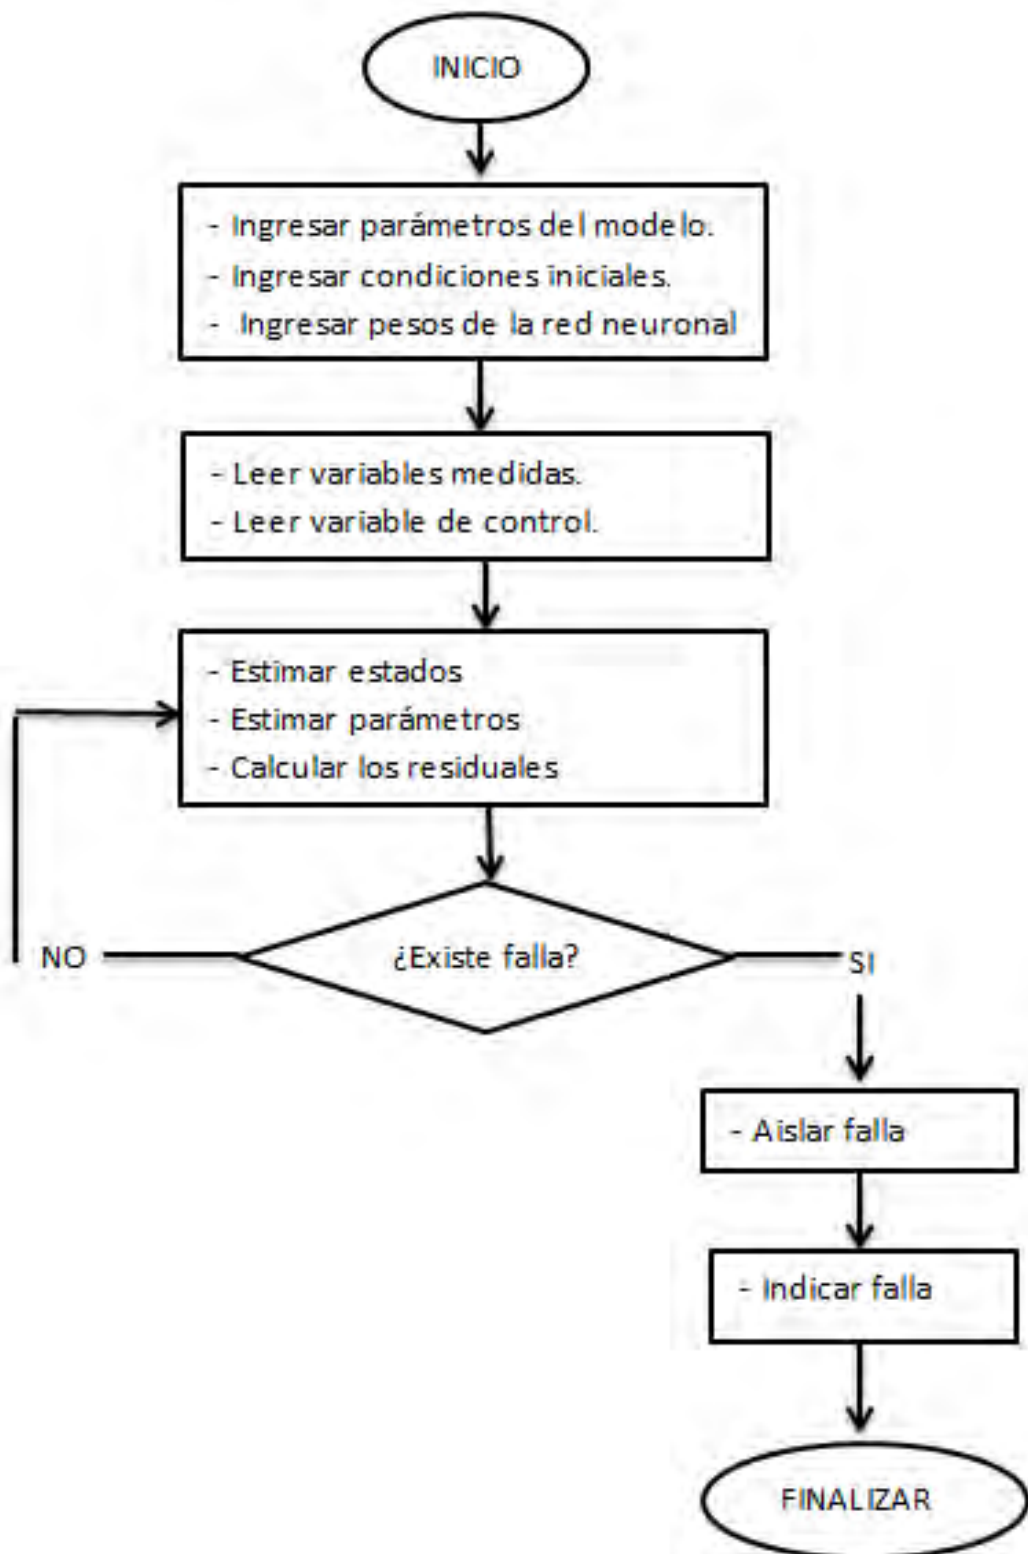


Figura 4.6. Diagrama de flujo del sistema de diagnóstico de fallas.




Figura 4.7. Diagrama de funcionamiento del sistema de diagnóstico de fallas.

5. CONCLUSIONES

Tres métodos fueron desarrollados para trabajar de manera complementaria con la finalidad de diagnosticar fallas en la suspensión semi-activa de un vehículo. Las fallas consideradas fueron de tres tipos: desconexión de sensores, fugas en el amortiguador MR y fallas aditivas en los sensores.

Se diseñó un controlador sky-hook para la suspensión semi-activa. Un análisis del desempeño mediante simulaciones concluyó que la suspensión semi-activa posee una mejor actuación en comparación con una suspensión pasiva.

Se realizó el diseño de un banco de observadores con el que se logró desacoplar al sistema del perfil de carretera, obteniendo buenas estimaciones de los estados de la suspensión. Se concluyó que mediante los residuales generados por la comparación de las salidas estimadas y las salidas medidas se lograron diagnosticar siete fallas por desconexión de sensores.

Para evitar el efecto drift en los estados estimados por los observadores se diseñaron filtros pasa altas.


Se diseñó un subsistema de estimación paramétrica para detectar una fuga en el amortiguador MR. El factor de olvido se eligió logrando un equilibrio entre el tiempo de convergencia de los parámetros estimados y la sensibilidad del sistema ante el ruido.

Se realizó el diseño de una red neuronal que tiene como entradas los estados estimados por los observadores y con la que se logró detectar correctamente seis fallas aditivas simples en los sensores, incluso ante la presencia de ruido de medición.

Mediante pruebas de simulación se pudo comprobar que el sistema es robusto para una variación de $\pm 50\%$ de la masa suspendida, y una variación de $\pm 20\%$ del coeficiente de rigidez del neumático.

Recomendaciones

- Se podría mejorar el desempeño del sistema de diagnóstico de fallas al modificar los filtros pasa altas empleados en los observadores, tal que, los estados estimados converjan más rápidamente para formar los patrones de falla.
- Se podría reducir el tiempo que tarda el sistema en diagnosticar la fuga en el amortiguador MR ajustando el factor de olvido, verificando que el sistema no se vuelva muy sensible al ruido.
- Para trabajos futuros, se debería estudiar la manera de incluir el diagnóstico de una falla relacionada con el neumático. Diagnosticar esta falla es importante ya que la rigidez del neumático ayuda al vehículo a mantener la estabilidad.



6. REFERENCIAS

Anh Lam Do, (2006). Approche LPV pour la Commande Robuste de la Dynamique des Vehicules: Amelioration Conjointe du Confort et de la Securite.

Corriga G., Sanna S., Usai G. (1991). An Optimal Tandem Active-Passive Suspension System for Road Vehicles with Minimum Power Consumption. *IEEE Transactions on Industrial Electronics*, 38(3).

Ekoru, J., Dahunsi O., Pedro, J. (2011). PID Control of a Nonlinear Half-car Active Suspension System Via Force Feedback. *IEEE AFRICON Conference*, 1-6.

Ersanilli V.E., Reeve P.J., Burnham K.J., King P. J. (2009). A Continuous-Time Model-Based Tyre Fault Detection Algorithm Utilising a Kalman State Estimator Approach. *Advanced Control and Diagnosis*.

Fischer D. and Isermann R. (2004). Mechatronic Semi-active and Active Vehicle Suspension. *Control Engineering Practice*, 12: 1353–1367.

Fischer D., Kaus E., Isermann R. (2003). Fault Detection for an Active Vehicle Suspension. *Proceedings of the American Control Conference*, 4377-4382.

Guo S., Yang S., Pan C. (2006). Dynamic Modeling of Magnetorheological Damper Behaviors. *Journal of Intelligent Material Systems and Structures*, 17: 3-14.

Hedrick J. K., Rajamani R., Yi K. (1994). Observer Design for Electronic Suspension Applications. *Vehicle System Dynamics: International Journal of Vehicle Mechanics and Mobility*, 23: 413-440.

Hernandez-Alcantara D., Morales-Menendez R., Amezquita-Brooks L. (2015). Fault Detection for Automotive Shock Absorber. *Journal of Physics: Conference Series*, 659, 012037.

Hernandez-Alcantara D., Tudon-Martinez J.-Martinez J., Amezquita-Brooks L., Vivas-Lopez C., Morales-Menendez R. (2014). State Observers for Semi-

Active Suspensions: Experimental Results. *IEEE Conference on Control Applications*, 53-58.

Hilera J., Martínez V. (2000). *Redes Neuronales Artificiales, Fundamentos, Modelos y Aplicaciones*. Alfaomega. México.

Hurel J., Mandow A., Garcia A. (2013). Los Sistema de Suspensión Activa y Semiactiva: Una Revisión.

Isermann R. (2002). *Mechatronic Systems: Fundamentals*, first edition, Springer, Darmstadt, Germany.

Isermann R. (2006). *Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance*. Springer.

Isermann R. and Münchhof M. (2011). *Identification of Dynamic Systems: An Introduction with Applications*. Springer.

John C. Dixon (2007). *The shock absorber handbook*, second edition, Professional Engineering Publishing Ltd and John Wiley and Sons Ltd, England.

Koch G., Pellegrini E., Spirk S., Lohmann B. (2010). Design and Modeling of a Quarter-Vehicle Test Rig for Active Suspension Control. *Technical Reports on Automatic Control*, 5.

Lozoya-Santos J., Morales M., Ramirez M., Niño E. (2009). Frequency and Current Effects in a MR Damper. *International Journal of Vehicle Autonomous Systems*, 7(3/4): 121–140.

Lozoya-Santos J., Tudon-Martinez J. M., Morales M., Ramirez M., Molina G. (2012a). Fault Detection for Automotive MR Damper. *14th IFAC Symposium on Information Control Problems in Manufacturing*, 1023-1028.

Lozoya-Santos J., Morales R., Ramirez R., Tudon J., Sename O., Dugard L. (2012b). Magneto-Rheological Damper - An Experimental Study. *Journal of Intelligent Material Systems and Structures*, 23 (11): 1213-1232.

Lozoya-Santos J., Morales R., Tudón J., Sename O., Dugard L., Ramirez R. (2011). Control Strategies for an Automotive Suspension with a MR Damper. *18th IFAC World Congress*, Milan, Italy.

Martín del Brío B., Sanz-Molina A. (2007). *Redes Neuronales y Sistemas Borros*. Alfaomega. 3era edición. México.

Min-Sang S., Seung-Bok C., Kum-Gil S. (2011), Control strategies for Vehicle Suspension System Featuring Magnetorheological (MR) Damper. *Vibration Analysis and Control – New Trends and Developments*.

Morales-Menendez R., Lozoya-Santos J., Hernandez-Alcantara D., Koenig D. (2013). Fault Detection in Automotive Semi-active Suspension: Experimental Results. *SAE World Congress & Exhibition*, vol 2013.

Odendaal H. and Jones T., (2014). Actuator Fault Detection and Isolation: An Optimized Parity Space Approach. *Control Engineering Practice*, 26: 222–232.

Rengifo C. (1999) Identificación de Sistemas en Lazo Cerrado, Universidad del Valle Facultad de Ingeniería Escuela de Ingeniería Eléctrica Y Electrónica Santiago de Cali.

Rizvi H., Abid M., Qayyum khan A. (2013). Actuator Fault Diagnosis and Isolation in Vehicle Active Suspension System. *IEEE 9th International Conference on Emerging Technologies*. 15-26.

Ryba L. (2012). Vehicle Parameters Estimation and Semi-active Suspension Control.

Sapiński B. and Filuś J., (2003). Analysis of Parametric Models of MR Linear Damper. *Journal of Theoretical and Applied Mechanics*, 41(2): 215-240, Warsaw.

Savaresi S., Poussot-Vassal C., Spelta C., Sename O., Dugard L. (2010). *Semi-active Suspension Control Design for Vehicles*, Elsevier, England.

Sayers M. and Karamihis S. (1998). *The Little book of Profiling: Basic Information about Measuring and Interpreting Road Profiles*. University of Michigan.

Sfaihi B. and Boubaker O. (2004). Full Order Observer Design for Linear System with Unknown Inputs. *IEEE International Conference on Industrial Technology*.

Shahram Azadi and Abbas Soltani. (2009). Fault detection of vehicle suspension system using wavelet analysis. *Vehicle System Dynamics: International Journal of Vehicle Mechanics and Mobility*, 47(4): 403-418.

Simani S., Fantuzzi C, Patton R. (2002). *Model-Based Fault Diagnosis in Dynamic Systems Using Identification Techniques*. Springer-Verlag.

Tyan F., Hong Y. F., Tu S. H., Jeng W. S. (2009). Generation of Random Road Profile. *Journal of Advanced Engineering*, 4(2): 1373-1378.

Varrier S., Vivas-Lopez C., Lozoya-Santos J., Tudon-Martinez J., Koenig D., Martinez J., Morales-Mendendez R., (2013), Applicative Fault Tolerant Control for Semi-Active Suspension System: Preliminary Results. *European Control Conference*, Zürich, Switzerland.

Xubin-Song (1999). *Design of Adaptive Vibration Control Systems with Application of Magneto-Rheological Dampers*. Virginia Polytechnic Institute and state University Blacksburg, Virginia EE.UU.

Yu-mei Liu, Xiao-ning Cao, Jian Su, Qiang Guo, Feng-ying, LU, Li cui. (2009). Suspension System Fault Diagnosis Method Based on Fuzzy Mathematics. *9th International Conference on Electronic Measurement & Instruments IEEE*, 210-214.