

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA



**AISLAMIENTO DE FALLAS A PARTIR DE
MEDICIONES DE ENTRADA-SALIDA**

**POR
ING. IVON ELENA LEAL LEAL**

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA ELÉCTRICA**

SEPTIEMBRE 2016

**UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN
FACULTAD DE INGENIERÍA MECÁNICA Y ELÉCTRICA
SUBDIRECCIÓN DE ESTUDIOS DE POSGRADO**



**AISLAMIENTO DE FALLAS A PARTIR DE
MEDICIONES DE ENTRADA-SALIDA**

**POR
ING. IVON ELENA LEAL LEAL**

**COMO REQUISITO PARCIAL PARA OBTENER EL GRADO DE
MAESTRÍA EN CIENCIAS DE LA INGENIERÍA ELÉCTRICA**

SEPTIEMBRE 2016

Universidad Autónoma de Nuevo León
Facultad de Ingeniería Mecánica y Eléctrica
Subdirección de Estudios de Posgrado

Los miembros del comité de tesis recomendamos que la tesis “Aislamiento de fallas a partir de mediciones de entrada-salida”, realizada por el alumno Ing. Ivon Elena Leal Leal, con número de matrícula 1457032, sea aceptada para su defensa como requisito parcial para obtener el grado de Maestría en Ciencias de la Ingeniería Eléctrica.

El Comité de Tesis



Dr. Efraín Alcorta García

Asesor



Dr. David Alejandro Díaz Romero
Revisor



Dr. César Martínez Torres
Revisor

Vo. Bo.



Dr. Simón Martínez Martínez
Subdirector de Estudios de Posgrado

San Nicolás de los Garza, Nuevo León, a 1 de septiembre 2016

ÍNDICE GENERAL

Agradecimientos	x
Resumen	xi
1. Introducción	1
1.1. Hipótesis	3
1.2. Objetivos	3
1.2.1. Generales	3
1.2.2. Particulares	3
1.3. Metodología	4
2. Preliminares	5
2.1. Estado del arte	5
2.2. Conceptos básicos en el Diagnóstico de Fallas	7
2.3. Generación residual	10
2.3.1. Espacio de Paridad	10
2.3.2. Observador de Diagnóstico (DO)	14

2.4. Identificación de sistemas	15
2.4.1. El proceso de identificación	17
2.4.2. Identificación por subespacios	18
3. Generación de residuos directamente de datos	20
3.1. Descripción del capítulo	20
3.2. Generación de residuos	21
3.2.1. Modelos de datos de entrada-salida	21
3.2.2. Representación del Kernel	25
3.2.3. Generación del residuo	26
3.2.4. Identificación del SKR	27
3.2.5. Ejemplo 1	29
3.3. Diseño de observadores para la detección de fallas directamente de datos	31
3.3.1. Construcción de un generador de residuos (Observador) basa- do en un vector de paridad	31
3.3.2. Ejemplo 2	34
3.4. Detección de fallas incipientes en transformadores (Aplicación)	36
3.4.1. Introducción	36
3.4.2. Enfoque basado en datos para la detección de fallas incipientes en transformadores	38
3.4.3. Simulación	39

4. Aislamiento de fallas a partir de mediciones	44
4.1. Descripción del capítulo	44
4.2. Esquema de observadores generalizados (GOS)	45
4.3. Enfoque para el aislamiento de fallas a partir de mediciones	46
4.3.1. Aislamiento de fallas	46
4.3.2. Propuesta de solución	47
4.3.3. Descripción del sistema	49
4.3.4. Justificación matemática	50
5. Ejemplo de aplicación	54
5.1. Descripción del sistema	54
5.2. Experimentos planteados	56
5.3. Resultados	58
5.3.1. Escenario 1	58
5.3.2. Escenario 2	58
5.3.3. Escenario 3	59
5.4. Discusión	60
6. Conclusiones y Trabajo a futuro	61

ÍNDICE DE FIGURAS

2.1. Esquema de Diagnóstico de Fallas	8
2.2. Esquema espacio de paridad	14
2.3. Sistema dinámico	15
2.4. Proceso de identificación	16
3.1. Sistema de tres tanques	30
3.2. Sistema de tres tanques	34
3.3. Residuo sin falla	35
3.4. Residuo con falla (6000s)	35
3.5. Conexión del transformador trifásico	39
3.6. Tres columnas del transformador trifásico	40
3.7. Corrientes de entrada	41
3.8. Corrientes de salida	41
3.9. Residuo sin fallas (condiciones nominales)	41
3.10. Corrientes de entrada con falla	42
3.11. Corrientes de salida con falla	43

3.12. Residuo con falla	43
4.1. Diagrama esquemático del GOS	45
4.2. Desacoplo de fallas	47
4.3. Detección de fallas	48
4.4. Residuo desacoplado de la falla f_1	49
5.1. Banco experimental - AMIRA DR300	55
5.2. Esquema simplificado del DR300	55
5.3. Datos nominales	56
5.4. Respuesta en ausencia de fallas	58
5.5. Respuesta a falla de actuador	59
5.6. Respuesta a falla de sensor	59

LISTA DE ACRÓNIMOS

PCA : Principal Component Analysis (Análisis del componente principal).

PLS : Partial Least Squares (Mínimos cuadrados parciales).

DO : Diagnostic Observer (Observador de diagnóstico).

FDI : Fault Detection and Isolation (Detección y localización de fallas).

ARX : AutoRegressive with eXternal input (Autorregresivo con entrada exógena).

ARMAX : Average Model with eXternal input (Autorregresivo de media variable con entrada exógena).

OE : Output Error (Error de la Salida).

LTI : Linear Time-Invariant (Lineal invariante en el tiempo).

SKR : Stable Kernel Representation (Representación estable del Kernel).

LCF : Left Coprime Factorization (Factorización Coprima Izquierda).

SVD : Singular Value Descomposition (Descomposición de valores singulares).

GOS : Generalized Observer Scheme (Esquema de observadores generalizados).

AGRADECIMIENTOS

Agradecimientos

Agradezco:

A Dios, por darme la sabiduría necesaria para llegar hasta aquí y por llenar mi vida de dicha y bendiciones.

A mi asesor, el Dr. Efraín Alcorta García, mi más amplio agradecimiento por haber creído en mí y por su disposición para dirigir en todo momento el presente trabajo de tesis. Cuya experiencia y educación han sido mi fuente de motivación.

A mis padres, Adrian Leal Villarreal y Maria Elena Leal Garza, les agradezco de todo corazón su apoyo incondicional, su guía y su confianza en la realización de mis sueños. Soy afortunada por contar siempre con su amor, comprensión y ejemplo. Este logro es para ustedes.

A Yahaira Leal, Adriana Leal, Violeta Leal y Luis Galván, con mucho cariño, por la compañía y el apoyo que me brindan y por los sueños que hemos compartido.

A mis amigos, Karen, Alejandro, Oscar y Poncho, que siempre estuvieron a un lado mio para ayudarme, escucharme, aconsejarme y en muchas ocasiones guiarme.

Y a todas aquellas personas que de una u otra forma, colaboraron o participaron en la realización de esta investigación, hago extensivo mi más sincero agradecimiento.

RESUMEN

Ing. Ivon Elena Leal Leal.

Candidato para obtener el grado de Maestría en Ciencias de la Ingeniería Eléctrica.

Universidad Autónoma de Nuevo León.

Facultad de Ingeniería Mecánica y Eléctrica.

Título del estudio: AISLAMIENTO DE FALLAS A PARTIR DE MEDICIONES DE ENTRADA-SALIDA.

Número de páginas: 66.

OBJETIVOS Y MÉTODO DE ESTUDIO: La presente tesis tiene como objetivo general desarrollar un algoritmo para el aislamiento de fallas, en donde el requerimiento consiste en utilizar solamente información sobre las mediciones de entrada-salida del sistema.

Como metodología se tiene realizar una revisión de la bibliografía referente a la generación de residuos a partir de datos de un sistema, los cuales están inspirados en métodos basados en observadores. Se prosigue con proponer un enfoque que nos permita tener residuos desacoplados de ciertas fallas.

CONTRIBUCIONES Y CONCLUSIONES: Un punto importante en este trabajo fue demostrar que el aislamiento de fallas puede ser realizado directamente usando datos

de entrada y salida del proceso, para esto se propone un enfoque basado en datos medidos para el aislamiento de fallas en sistemas muestreados, mediante un algoritmo de identificación.

La propuesta de solución para el problema de aislamiento de fallas con generadores de residuos basados en observadores diseñados a partir de datos, esta inspirado en la idea utilizada en los métodos de diagnóstico basados en redes neuronales, en los cuales existe una primera fase de entrenamiento en la que se selecciona las ponderaciones de la red neuronal y una segunda fase en la que se aplica la red neuronal diseñada en el diagnóstico de fallas. De hecho, la metodología estándar de diseño de observadores basados en datos sigue estas dos fases. A diferencia del algoritmo disponible en la literatura, en este trabajo se propone utilizar mediciones con una determinada falla, para así poder diseñar un observador sin sensibilidad a la falla presente en los datos del sistema. Utilizando información adecuada es posible construir generadores de residuos para lograr aislar un conjunto de fallas. El método propuesto es justificado técnicamente mediante experimentos realizados en un equipo de laboratorio DR300 de la marca AMIRA®. En donde los resultados en simulación obtenidos permiten afirmar que el aislamiento es satisfactorio.

Se verificó que es posible la detección de fallas a partir de datos mediante la utilización de un ejemplo de aplicación en un transformador, con lo que se realizó la redacción de un artículo *“Data-driven approach to Observer-based incipient fault detection in Transformer”* que fue aceptado para el IEEE/PES Transmission and Distribution Conference and Exposition Latin America (IEEE/PES T&D LA 2016). Y gracias a los resultados de investigación que arrojó este tema de tesis, se tiene otro artículo *“Aislamiento de Fallas en Sistemas Lineales Discretos a partir de Mediciones”* para el Congreso Nacional de Control Automático 2016 (AMCA 2016).

Firma del asesor: _____

Dr. Efraín Alcorta García

CAPÍTULO 1

INTRODUCCIÓN

Una falla debe ser entendida como un cambio indeseable en el sistema, que tiende a degradar el desempeño del mismo.

El diagnóstico de fallas se ha consolidado en los últimos años debido al intenso trabajo realizado por la comunidad de diagnóstico, motivados por las exigencias de seguridad y confiabilidad de la industria. Una de las técnicas ampliamente reportadas en la literatura hace uso de observadores de la salida [1]. Una dificultad es que muchos de los métodos desarrollados hacen uso de un modelo matemático del proceso, el cual en algunos casos no es posible de obtener fácilmente, además incluyen un análisis matemático que presenta considerable complejidad.

La idea básica de la detección y aislamiento de fallas basados en modelos es el uso de la redundancia analítica, es decir, redundancia obtenida mediante el uso de un modelo matemático del sistema en consideración, con el fin de obtener señales que detectan fallas, que se denominan residuos [1]. Una forma de materializar la redundancia analítica es a través de observadores, los residuos se obtienen como la diferencia entre una salida de medición menos un estimado de ellos. La señal residual debe seguir siendo analizada con el fin de determinar si existe una falla en el sistema supervisado.

La manera más común de generación de residuos es a través de un observador.

Idealmente el residuo será cero cuando no se presente falla y diferente de cero en presencia de falla y no en otro caso, esto es cierto en el contexto de un conocimiento perfecto del sistema y de un escenario libre de perturbaciones. Cuando cualquier tipo de ruido o perturbación está presente dentro del sistema, es necesario considerar una cota o umbral para los residuos, a partir del cual se considera que se ha producido una falla, la intención de utilizar dicho umbral es disminuir (y eventualmente eliminar) las falsas alarmas, ver por ejemplo [2], [3].

Bajo ciertas condiciones, el residuo puede ser totalmente desacoplado de algunas fallas (o perturbaciones). En general se maneja la detección de fallas directamente de datos, con robustez frente a ruido y perturbaciones. Para el aislamiento de fallas, aunque se presentan enfoques de solución, estos están basados en las matrices del sistema y no directamente de los datos.

Este trabajo está enfocado en el problema de aislamiento de fallas utilizando generadores de residuos basados en observadores que son diseñados utilizando mediciones entrada-salida del sistema a ser supervisado. La base del trabajo está reportada en [4] así como en los antecedentes de diagnóstico de fallas basados en modelos [3].

Los métodos basados en datos se han desarrollado para sistemas lineales de tiempo discreto [4], así como para sistemas de tiempo continuo [5].

La propuesta de solución para el problema de aislamiento de fallas con generadores de residuos basados en observadores diseñados a partir de datos está inspirado en la idea utilizada en los métodos de diagnóstico basados en redes neuronales, en los cuales existe una primera fase de entrenamiento en la que se selecciona las ponderaciones de la red neuronal y una segunda fase en la que se aplica la red neuronal diseñada en el diagnóstico de fallas. De hecho, la metodología estándar de diseño de observadores basados en datos sigue estas dos fases. A diferencia del algoritmo disponible en la literatura, en este trabajo se propone utilizar mediciones con una determinada falla, para así poder diseñar un observador sin sensibilidad a la falla pre-

sente en los datos del sistema. Utilizando información adecuada es posible construir generadores de residuos para lograr aislar un conjunto de fallas. El método propuesto es justificado técnicamente y verificado adicionalmente mediante experimentos realizados en un equipo de laboratorio DR300 de la marca AMIRA®.

1.1 HIPÓTESIS

Es posible detectar y aislar fallas en sistemas lineales discretos, utilizando como única información disponible mediciones de entrada y salida del sistema.

1.2 OBJETIVOS

1.2.1 GENERALES

Desarrollar un algoritmo para el aislamiento de fallas, en donde el requerimiento consiste en utilizar solamente información sobre las mediciones de entrada-salida del sistema.

1.2.2 PARTICULARES

El desglose del objetivo general es el siguiente:

- Rehacer los resultados existentes en la literatura para la generación residual directamente de datos.
- Probar los resultados existentes con un ejemplo de aplicación.

- Proponer una metodología simple para la obtención de residuos desacoplados mediante una cancelación geométrica.
- Desarrollo del algoritmo basado en mediciones para el aislamiento de fallas en sistemas muestreados.
- Verificación del enfoque mediante programación y prueba con diferentes datos.

1.3 METODOLOGÍA

La estrategia propuesta para alcanzar el objetivo general (y los objetivos particulares) es la siguiente:

- Se realizará una revisión de la bibliografía referente a la generación de residuos a partir de datos, los cuales están inspirados en métodos basados en observadores.
- Seleccionar el algoritmo que servirá de base en nuestra propuesta. Se pretende re-hacer los resultados obtenibles mediante este algoritmo.
- Revisar técnicas de identificación de sistemas a partir de datos (Identificación por subespacios).
- Proponer un algoritmo que permita obtener residuos desacoplados de ciertas fallas.
- Programación y prueba del algoritmo con diferentes datos.
- Reporte de resultados.

CAPÍTULO 2

PRELIMINARES

2.1 ESTADO DEL ARTE

Todo sistema físico está sujeto a cambios en sus parámetros, los cuales modifican el comportamiento para el cual fueron diseñados, por esto, la detección y el aislamiento de fallas son un aspecto importante a considerar en los procesos industriales, que permiten mejorar el funcionamiento de éstos. Los métodos de detección y desacoplo han ido evolucionando acorde con la aparición de nuevas tecnologías que permiten su implementación.

En sus inicios los sistemas de detección de fallas, analizaban y diagnosticaban en base a redundancia física, es decir, en el uso de los elementos repetidos del sistema. Estos nos permiten, por medio de comparaciones del funcionamiento, tomar decisiones sobre la presencia de fallas. Sin embargo, debe tenerse claro que la utilización de elementos repetidos en un sistema no puede ser llevada a la práctica siempre (costo, tamaño y peso) [6].

A principios de la década de los 70 fue introducido el concepto de redundancia analítica, la cual está basada en el conocimiento del modelo matemático del sistema en cuestión así como de las señales de entrada y salida del sistema [6], en el contexto de sistemas lineales invariantes en el tiempo, muchos enfoques han sido propuestos

[1], entre los que destacan los métodos basados en observadores.

El diagnóstico de fallas consiste en la detección, localización e identificación de fallas. Para métodos basados en modelos, el diagnóstico se realiza a través del diseño de señales que dependen idealmente solo de las fallas, las cuales son llamadas residuos. La evaluación de estas señales, mediante comparación con un valor de umbral, implica un segundo paso. Finalmente, la información sobre las fallas es extraída para completar el diagnóstico mediante la identificación de la falla.

Los métodos basados en datos históricos del proceso, son utilizados debido a su relativa simplicidad y eficiencia, tales como: métodos basados en redes neuronales, en lógica difusa y en inteligencia artificial [7]. Existen otras propuestas inspiradas en técnicas procedentes de la estadística, tales como PCA y PLS [3].

En la actualidad los métodos utilizados para la obtención de residuos a partir de datos de entrada y salida del proceso están en desarrollo, estos métodos combinan las ventajas de los métodos de diagnóstico basados en modelos con los que están basados en datos. Existe una técnica basada en observadores para la generación de residuos a partir de datos, presentada en [4].

En esta tesis se presenta un enfoque para el aislamiento de fallas a partir de datos, dicho enfoque se basa en observadores de salida para la generación de un residuo desacoplado de las *fallas* de no interés, el cual hace uso del algoritmo presentado en [4], este utiliza un método de identificación, con el cual se calculan las matrices del observador, para después aislar fallas mediante la utilización de datos sin falla y con falla del proceso.

2.2 CONCEPTOS BÁSICOS EN EL DIAGNÓSTICO DE FALLAS

Una *falla* es comprendida en general como el cambio de un parámetro fuera de los márgenes de tolerancia.

Tipos de fallas:

- ***Fallas multiplicativas.*** Una falla multiplicativa se representa mediante un término en el cuál se está multiplicando al estado o a la entrada (cambio en el parámetro del sistema).
- ***Fallas aditivas.*** Una falla aditiva es aquella que afecta al sistema manifestándose como una entrada adicional.

Clasificación de fallas por dependencia temporal:

- ***Abrupta.*** Es la que se manifiesta como un cambio repentino y puede ser modelado mediante una función escalón.
- ***Incipiente.*** Es la que va aumentando su nivel paulatinamente en el tiempo, el cambio manifestado puede ser modelado mediante una función tipo rampa.
- ***Intermitente.*** Es cuando la falla aparece y desaparece sin un patrón determinado.

Clasificación de fallas por el lugar de origen:

- ***Fallas en los sensores.*** Estas fallas actúan directamente sobre las mediciones del proceso.
- ***Fallas en los actuadores.*** Estas fallas causan cambios en el actuador.

- **Fallas en los componentes.** Estas fallas se usan para indicar un mal funcionamiento en los componentes internos del proceso.

El diagnóstico de fallas es necesario por las siguientes razones:

- **Seguridad.** Las fallas pueden ocasionar accidentes.
- **Economía.** Las fallas pueden producir pérdidas económicas.
- **Preservación del desempeño.** Algunas veces, preservar el desempeño del sistema es el objetivo, pues este esta directamente afectando a seres humanos.

El diagnóstico de fallas consiste en:

- **Detección de fallas.** Sólo dice si ocurrió la falla y, de ser así, el tiempo en el que ocurrió.
- **Localización de fallas.** Consiste en ubicar dónde ocurrió la falla (actuador, sensor o componente).
- **Identificación de Fallas.** Se determina el tamaño, tipo o naturaleza de la falla.

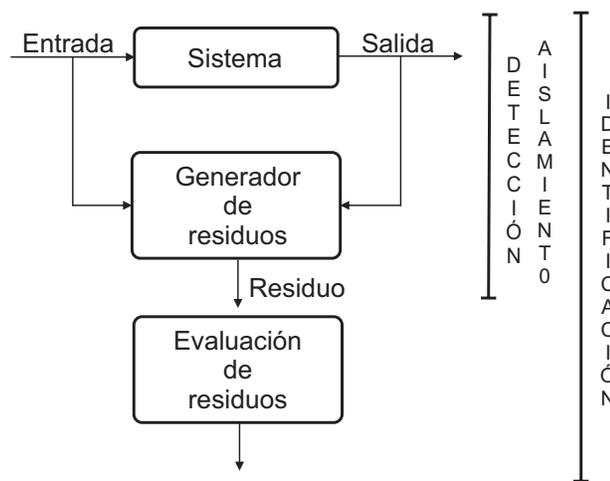


Figura 2.1: Esquema de Diagnóstico de Fallas

Pasos para el diagnóstico de fallas:

- **Generación de residuos.** Obtención de señales, llamadas residuos, con información sobre fallas. De manera ideal un residuo será cero si no hay fallas presentes, y diferente de cero de otra forma.
- **Evaluación de residuos.** Es la extracción de la información sobre la falla.

El **residuo** es un indicador de falla. Algunas propiedades deseables para el residuo son las siguientes:

- Tener valores cercanos a cero para los modos de operación normal.
- Que algún residuo alcance valores diferentes de cero para los modos de operación con fallas.
- Ser muy sensibles a fallas.
- Responder rápidamente a posibles fallas

Existen ciertos aspectos para evaluar la eficiencia de las distintas técnicas de detección de fallas. Los más importantes en este trabajo son:

- Rapidez de la detección.
- Sensibilidad frente a fallas incipientes.

En función de elegir la técnica de detección de fallas más adecuada, lo que se quiere evitar son:

- Falsas alarmas por unidad de tiempo.
- Fallas que no se detectan.
- Identificación incorrecta de fallas.

2.3 GENERACIÓN RESIDUAL

En un esquema de diagnóstico de fallas basado en modelos, la generación de residuos corresponde a la etapa del cálculo de las diferencias entre las variables medidas y las estimadas mediante cada modelo, observador o filtro presente en el esquema.

Los esquemas de diagnóstico de fallas presentados en esta sección incluyen dos técnicas de generación de residuos [8]:

- Observadores.
- Ecuaciones de Paridad.

Este trabajo utilizará ambas técnicas para la construcción de un generador de residuos basado en datos.

2.3.1 ESPACIO DE PARIDAD

La esencia de este enfoque es derivar las llamadas relaciones de paridad. Es ampliamente aceptado gracias a su simplicidad computacional y a su fácil implementación. El espacio de paridad para sistemas dinámicos fue desarrollado en [9]. La idea es construir un conjunto de ecuaciones que dependan solo de variables medibles y a las cuales se les pueda revisar su paridad (consistencia).

El *espacio de paridad* establece la consistencia del modelo con las mediciones en una ventana de tiempo. En este trabajo utilizaremos la siguiente descripción [3].

Considerando un sistema dinámico en tiempo discreto

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) \\ y(k) &= Cx(k) + Du(k)\end{aligned}\tag{2.1}$$

donde $x(0)$ es la condición inicial de dimensión n , $x(k)$ es el vector de estado de dimensión n , $u(k)$ es el vector de entradas de dimensión m y $y(k)$ es el vector de salida de dimensión p .

Si se consideran fallas aditivas:

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) + E_d d(k) + E_f f(k) \\ y(k) &= Cx(k) + Du(k) + F_d d(k) + F_f f(k) \end{aligned} \quad (2.2)$$

donde $d(k)$ es el vector de perturbaciones, $f(k)$ es el vector de fallas, Las matrices A , B , C , D , E_d , E_f , F_d y F_f son constantes, conocidas y de dimensiones apropiadas. Suponer que el par (A, C) es observable y que $\text{rango}(C) = p$.

Considerar un atraso de s instantes de tiempo discreto de al menos el mismo tamaño que el orden del sistema ($s \geq n$) y representar la salida del sistema para este valor.

Con el propósito de construir el generador de residuos suponemos primero que $d(k) = 0$ y $f(k) = 0$. Expresando la ecuación de salida con un atraso de tiempo s , cuyo valor máximo depende del índice de observabilidad del sistema:

$$\begin{aligned} y(k-s) &= Cx(k-s) + Du(k-s) \\ y(k-s+1) &= Cx(k-s+1) + Du(k-s+1) \\ &= CAx(k-s) + CBu(k-s) + Du(k-s+1) \end{aligned}$$

Aplicando este procedimiento de forma recursiva se obtiene la representación de salida para el tiempo actual k .

$$\begin{aligned} y(k-s+2) &= CA^2x(k-s) + CABu(k-s) + CBu(k-s+1) + Du(k-s+2) \\ &\vdots \\ y(k) &= CA^s x(k-s) + CA^{s-1} Bu(k-s) + \dots + CBu(k+1) + Du(k) \end{aligned}$$

Se definen los vectores:

$$u_s(k) = \begin{bmatrix} u(k-s) \\ \vdots \\ u(k) \end{bmatrix}; \quad y_s(k) = \begin{bmatrix} y(k-s) \\ \vdots \\ y(k) \end{bmatrix} \quad (2.3)$$

y se considera la matriz (matriz de observabilidad extendida)

$$\Gamma_s = \begin{bmatrix} C \\ \vdots \\ CA^s \end{bmatrix}$$

Con la matriz asociada a los parámetros de Markov de la entrada a la salida

$$H_{u,s} = \begin{bmatrix} D & 0 & \cdots & 0 \\ CB & D & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}B & \cdots & CB & D \end{bmatrix}$$

se puede escribir el conjunto de ecuaciones desarrolladas en forma compacta como:

$$y(k) = \Gamma_s x(k-s) + H_{u,s} u_s(k) \quad (2.4)$$

La ecuación (2.4) es conocida como la relación de paridad. Note que los vectores de entradas $u_s(k)$ y de salidas $y_s(k)$ se forman con las mediciones y se suponen conocidas. Las matrices Γ_s y $H_{u,s}$ son constantes y formadas con las matrices del sistema, las cuales se suponen conocidas. La única variable desconocida es $x(k-s)$.

La idea básica de la relación de paridad es utilizar el hecho de que $s \geq n$ entonces el $\text{rango}(\Gamma_s) = n$ es menor que el número de renglones de Γ_s , con lo que existe al menos un vector renglón $\nu_s \neq 0$ de dimensiones $(s+1)p$ tal que

$$\nu_s \Gamma_s = 0 \quad (2.5)$$

El generador de residuos basado en relaciones de paridad es construido por:

$$r(k) = \nu_s (y_s(k) - H_{u,s} u_s(k)) \quad (2.6)$$

Los vectores que satisfacen (2.5) son llamados vectores de paridad. El conjunto de vectores de paridad que satisfacen

$$P_s = \{\nu_s | \nu_s \Gamma_s = 0\} \quad (2.7)$$

es llamado espacio de paridad de orden s -ésimo.

Para ver el efecto de $f(k)$ y $d(k)$ en el generador de residuos (2.6) ahora se remueve la restricción utilizada. Definiendo

$$f_s(k) = \begin{bmatrix} f(k-s) \\ \vdots \\ f(k) \end{bmatrix}; \quad d_s(k) = \begin{bmatrix} d(k-s) \\ \vdots \\ d(k) \end{bmatrix} \quad (2.8)$$

$$H_{f,s} = \begin{bmatrix} F_f & 0 & \cdots & 0 \\ CF_f & F_f & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}F_f & \cdots & CF_f & F_f \end{bmatrix} \quad (2.9)$$

$$H_{d,s} = \begin{bmatrix} F_d & 0 & \cdots & 0 \\ CE_d & F_d & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}E_d & \cdots & CE_d & F_d \end{bmatrix} \quad (2.10)$$

Entonces las ecuaciones para $y_s(k)$ puede escribirse como:

$$y_s(k) = \Gamma_s x(k-s) + H_{u,s} u_s(k) + H_{f,s} f_s(k) + H_{d,s} d_s(k) \quad (2.11)$$

El generador de residuos queda como:

$$r_s(k) = \nu_s((H_{f,s} f_s(k) + H_{d,s} d_s(k))), \quad \nu_s \in P_s \quad (2.12)$$

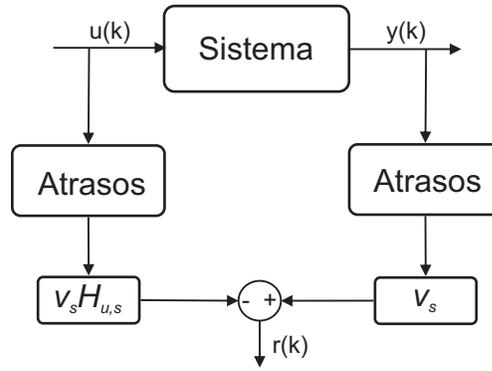


Figura 2.2: Esquema espacio de paridad

2.3.2 OBSERVADOR DE DIAGNÓSTICO (DO)

El DO es gracias a su estructura flexible y similaridad al observador de Luenberger uno de los generadores de residuos mas investigados [4].

Este generador de residuo es un observador de salida descrito por:

$$\begin{aligned} z(k+1) &= A_d z(k) + B_d u(k) + L_d y(k) \\ r(k) &= G_d y(k) - C_d z(k) - D_d u(k) \end{aligned} \quad (2.13)$$

donde $z \in \mathfrak{R}^s$, s denota el orden del observador.

Asumiendo que $G_{yu}(z) = C(zI - A)^{-1}B + D$, entonces A_d , B_d , L_d , D_d , C_d y G_d junto con la matriz $T \in \mathfrak{R}^{s \times n}$ tienen que satisfacer las condiciones de Luenberger,

1. A_d es estable
2. $TA - A_d T = L_d C$, $B_d = TB - L_d D$
3. $G_d C - C_d T = 0$, $D_d = G_d D$

con lo que el sistema (2.13) proporciona un vector residual, es decir

$$\forall u, x(0), \lim_{k \rightarrow \infty} r(k) = 0$$

Este esquema de observador de diagnóstico es equivalente a un Observador de orden reducido, lo que es deseable y útil para su aplicación en línea.

2.4 IDENTIFICACIÓN DE SISTEMAS

Un *sistema* es toda realidad en la que interactúan variables de diferentes tipos para producir señales observables. Las señales observables que son de interés para el observador se denominan salidas del sistema, mientras que las señales que pueden ser manipuladas libremente por dicho observador son las entradas del mismo. El resto de las señales que influyen en la evolución de las salidas pero no pueden ser manipuladas por el observador se denominan perturbaciones o fallas.

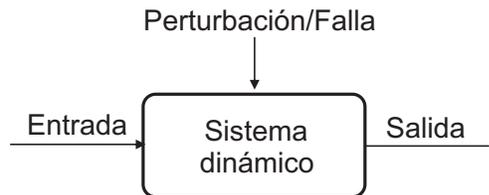


Figura 2.3: Sistema dinámico

Cuando es necesario conocer el comportamiento de un sistema en determinadas condiciones y ante determinadas entradas, se puede recurrir a la experimentación sobre dicho sistema y a la observación de sus salidas. Sin embargo, en muchos casos la experimentación puede resultar compleja o incluso imposible de llevar a cabo, lo que hace necesario trabajar con algún tipo de representación que se aproxime a la realidad, y a la que se conoce como modelo. Básicamente, un modelo es una

herramienta que permite predecir el comportamiento de un sistema sin necesidad de experimentar sobre él.

Las técnicas de control actuales requieren de modelos matemáticos cada vez mas exactos para el análisis y el diseño. En algunos casos, los modelos no pueden ser obtenidos de forma sencilla a partir de las leyes físicas que rigen el proceso, por lo que se recurre a la identificación de sistemas.

Podemos definir la identificación de sistemas como el “arte” de crear modelos matemáticos sencillos y precisos para sistemas complejos a partir de series temporales de observaciones ruidosas [10] .

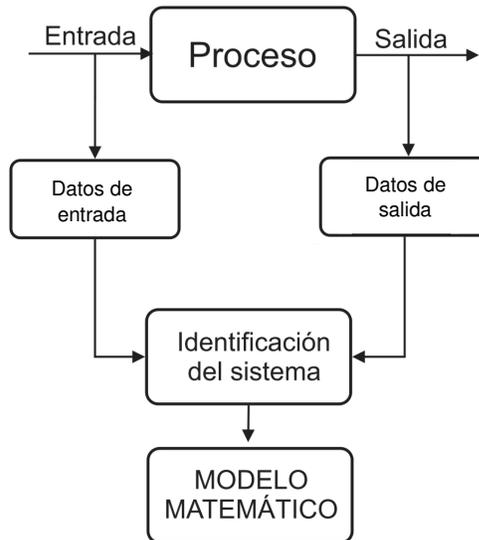


Figura 2.4: Proceso de identificación

En la literatura han sido propuestos numerosos métodos lineales como solución al proceso de identificación. Éstos son simples, como por ejemplo ARX, ARMAX y OE, los cuales se basan en la optimización de parámetros, es decir, los parámetros del sistema se obtienen minimizando una función de costo conveniente.

2.4.1 EL PROCESO DE IDENTIFICACIÓN

En términos generales, el proceso de identificación comprende los siguientes pasos:

1. **Obtención de datos de entrada-salida.** Para ello se debe excitar el sistema mediante la aplicación de una señal de entrada y registrar la evolución de sus entradas y salidas durante un intervalo de tiempo.
2. **Tratamiento previo de los datos registrados.** Los datos registrados están generalmente acompañados de ruidos indeseados u otro tipo de imperfecciones que puede ser necesario corregir antes de iniciar la identificación del modelo. Se trata, por tanto, de “preparar” los datos para facilitar y mejorar el proceso de identificación.
3. **Elección de la estructura del modelo.** Si el modelo que se desea obtener es un modelo paramétrico, se debe determinar la estructura deseada para dicho modelo. Este punto se facilita en gran medida si se tiene un cierto conocimiento sobre las leyes físicas que rigen el proceso.
4. **Obtención de los parámetros del modelo.** A continuación se procede a la estimación de los parámetros de la estructura que mejor ajustan la respuesta del modelo a los datos de entrada-salida obtenidos experimentalmente.
5. **Validación del modelo.** El último paso consiste en determinar si el modelo obtenido satisface el grado de exactitud requerido para la aplicación en cuestión. Si se llega a la conclusión de que el modelo no es válido, se deben revisar los siguientes aspectos como posibles causas:
 - a) El conjunto de datos de entrada-salida no proporciona suficiente información sobre la dinámica del sistema.
 - b) La estructura escogida no es capaz de proporcionar una buena descripción del modelo.

- c) El criterio de ajuste de parámetros seleccionado no es el más adecuado.

2.4.2 IDENTIFICACIÓN POR SUBESPACIOS

Los métodos de subespacios son una familia de algoritmos de identificación de sistemas en el espacio de estados basados en técnicas de proyección lineal [11].

Los enfoque basado en técnicas de subespacios tiene las siguientes características:

- Combina herramientas de teoría de sistemas, álgebra lineal numérica y geometría (proyecciones).
- No se requiere de procedimientos iterativos de optimización, lo que implica que no hay problema con mínimos locales, convergencia e inicialización.
- Provee modelos confiables de sistemas LTI multivariables directamente de datos entrada-salida.
- No se requiere de una realización particular (forma canónica) lo cual mejora el condicionamiento numérico.
- Se requiere una capacidad computacional modesta en comparación co los métodos tradicionales de error de predicción.

El estudio de las técnicas basadas en subespacios permitirá adquirir las bases necesarias para realizar la implementación de algoritmos para el diagnóstico de fallas basado en datos.

2.4.2.1 FORMULACIÓN DEL PROBLEMA

Los modelos matemáticos a obtener mediante técnicas de identificación de sistemas basadas en subespacios tienen la siguiente forma

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) + \omega(k) \\y(k) &= Cx(k) + Du(k) + v(k)\end{aligned}\tag{2.14}$$

Con la covarianza de las secuencias de ruido definidas como

$$E \left[\begin{pmatrix} \omega(g) \\ v(g) \end{pmatrix} \begin{pmatrix} \omega(q)^T & v(q)^T \end{pmatrix} \right] = \begin{pmatrix} Q & S \\ S^T & R \end{pmatrix} \delta_{gq} \geq 0 \tag{2.15}$$

donde g es diferente de q pero cuando δ_{gq} es igual a 1 entonces g es igual a q . Los vectores $v(k) \in \mathfrak{R}^p$ y $\omega(k) \in \mathfrak{R}^n$ contienen las señales no observadas, $v(k)$ es denominado ruido en la medición y $\omega(k)$ ruido en el proceso, cuyas sucesiones son consideradas con promedio igual a cero, es decir, como ruido blanco en estado estacionario, ecuación (2.15).

El primer paso en los métodos de subespacio es estimar el subespacio expandido por las columnas de la matriz de observabilidad extendida (2.4), de allí el nombre.

Las distintas técnicas difieren en la forma en que la matriz de observabilidad extendida es estimada y en cómo es usada para estimar las matrices del sistema.

De modo que el problema de identificación puede formularse como:

Dado el conjunto de datos de entrada y salida, determinar el orden del sistema n y las matrices A , B , C y D que mejor ajusten los datos en algún sentido bien definido.

Una buena presentación de este método puede encontrarse en [11], donde viene explicado con detalle el desarrollo de este algoritmo.

En este trabajo se identificarán las matrices del DO en lugar de identificar directamente las matrices del sistema (2.14).

CAPÍTULO 3

GENERACIÓN DE RESIDUOS DIRECTAMENTE DE DATOS

3.1 DESCRIPCIÓN DEL CAPÍTULO

Este capítulo utiliza la filosofía basada en modelos para obtener residuos directamente de datos.

La generación de residuos es fundamental para el diagnóstico de fallas. Es la base para la construcción exitosa de un sistema para la detección y localización de fallas (FDI).

El primer objetivo es identificar el SKR para sistemas lineales variantes en el tiempo, conocido también como el LCF, sirve como una forma de modelo para la dinámica de entrada y salida de un sistema y como una herramienta de análisis y síntesis para sistemas dinámicos.

Se presenta un esquema para la generación de residuos basados en observador, éste trabaja con datos de entrada y salida muestreados [4] y después se tiene un ejemplo de aplicación de dicho algoritmo, para esto se utilizaron datos nominales y con falla de un transformador.

3.2 GENERACIÓN DE RESIDUOS

3.2.1 MODELOS DE DATOS DE ENTRADA-SALIDA

Con el objetivo de conectar modelos analíticos y datos del proceso, se introducirá el siguiente modelo de datos entrada-salida.

Considerando el sistema lineal invariante en el tiempo:

$$\begin{aligned} x(k+1) &= Ax(k) + Bu(k) + w(k) \\ y(k) &= Cx(k) + Du(k) + v(k) \end{aligned} \quad (3.1)$$

donde $u(k) \in \mathfrak{R}^m$, $y(k) \in \mathfrak{R}^p$ y $x(k) \in \mathfrak{R}^n$, $w(k) \in \mathfrak{R}^n$ y $v(k) \in \mathfrak{R}^p$ denotan secuencias de ruido que tienen una distribución normal y son estadísticamente independientes de $u(k)$ y $x(0)$. Y asumimos que el proceso (3.1) es controlable y observable.

Sea $\omega(k) \in \mathfrak{R}^\xi$ un vector de datos. Introduciremos las siguientes notaciones

$$\omega_s(k) = \begin{bmatrix} \omega(k-s) \\ \vdots \\ \omega(k) \end{bmatrix} \in \mathfrak{R}^{(s+1)\xi} \quad (3.2)$$

$$\Omega_k = [\omega(k) \cdots \omega(k+N-1)] \in \mathfrak{R}^{\xi \times N} \quad (3.3)$$

$$\Omega_f = [\omega_s(k) \cdots \omega_s(k+N-1)] \in \mathfrak{R}^{(s+1)\xi \times N} \quad (3.4)$$

donde s representa el retardo y puede ser definido por el usuario ($s > n$) y N denota el número de datos muestreados utilizados para la construcción del bloque. En este estudio $\omega(k)$ puede ser $y(k)$, $x(k)$, $u(k)$, $w(k)$, $v(k)$ y ξ representa n , p ó m dados en (3.1).

El modelo de datos entrada-salida es descrito por

$$Y_f = \Gamma_s X_{k-s} + H_{u,s} U_f + H_{w,s} W_f + V_f \in \mathfrak{R}^{(s+1)p \times N} \quad (3.5)$$

$$\Gamma_s = \begin{bmatrix} C \\ \vdots \\ CA^s \end{bmatrix} \in \mathfrak{R}^{(s+1)p \times n} \quad (3.6)$$

$$H_{u,s} = \begin{bmatrix} D & 0 & \cdots & 0 \\ CB & D & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}B & \cdots & CB & D \end{bmatrix} \in \mathfrak{R}^{(s+1)p \times (s+1)m} \quad (3.7)$$

$$H_{w,s} = \begin{bmatrix} 0 & 0 & \cdots & 0 \\ C & 0 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1} & \cdots & C & 0 \end{bmatrix} \in \mathfrak{R}^{(s+1)p \times (s+1)m} \quad (3.8)$$

3.2.1.1 MATRICES DE DATOS

Matrices de Hankel. Los datos de entrada y salida del sistema, se pueden organizar a modo de obtener lo que se conoce como matrices o bloques de Hankel [11].

Sea U_p, Y_f, U_f, Y_p los conjuntos de datos. Los subíndices p y f en las variables denotan respectivamente el pasado y el futuro, de las salidas o entradas del sistema.

Las matrices de Hankel para los datos de salida son

$$Y_p = \begin{bmatrix} y(k-2s-1) & y(k-2s) & \cdots & y(k-2s+N-2) \\ y(k-2s) & y(k-2s+1) & \cdots & y(k-2s+N-1) \\ \vdots & \vdots & \vdots & \vdots \\ y(k-s-1) & y(k-s) & \cdots & y(k-s+N-2) \end{bmatrix} \quad (3.9)$$

$$Y_f = \begin{bmatrix} y(k-s) & y(k-s-1) & \cdots & y(k-s+N-1) \\ y(k-s-1) & y(k-s+2) & \cdots & y(k-s+N) \\ \vdots & \vdots & \vdots & \vdots \\ y(k) & y(k+1) & \cdots & y(k+N-1) \end{bmatrix} \quad (3.10)$$

de la misma manera se forman las matrices de datos de entrada U_p , $y U_f$ y las matrices de ruido W_p , W_f , V_p y V_f . Estas matrices se forman como en (3.4).

Mediante programación se calcula el bloque de Hankel de un vector de datos. Para su inicialización requiere un conjunto de datos los cuales pueden ser expresados como un vector fila o columna, El número de filas que posee el bloque se expresa con k y el número de datos que se toman para la construcción del bloque se determina con N .

- El número de filas (k) es un índice definido por el usuario que es lo suficientemente grande, es decir, por lo menos debería ser mayor que el orden máximo del sistema que se quiere representar, $k > n$.
- El número de columnas (N) es típicamente igual a $(Ndat - 1) - 2k + 1$. lo que implica que todas las muestras de datos son usadas.

Acomodando las matrices de Hankel pasadas y futuras como

$$Z_p = \begin{bmatrix} U_p \\ Y_p \end{bmatrix} \quad Z_f = \begin{bmatrix} U_f \\ Y_f \end{bmatrix} \quad (3.11)$$

La ecuación (3.5) puede ser formulada como

$$Z_f = \begin{bmatrix} I & 0 \\ H_{u,s} & \Gamma_s \end{bmatrix} \begin{bmatrix} U_f \\ X_{k-s} \end{bmatrix} + \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix} \quad (3.12)$$

Con el fin de extraer la información del sistema de los conjuntos de datos Z_f y U_f , la influencia de los últimos términos de la ecuación (3.12) pueden ser

eliminados o compensados. para este propósito, las llamadas variables instrumentales pueden ser aplicadas, las cuales utilizan la independencia estadística de los ruidos para compensar los efectos del ruido [12]. A raíz de estos supuestos, el ruido del “pasado” y “futuro” debe ser estadísticamente independiente. Por lo tanto, Z_p podría ser elegido como variable instrumental para eliminar los efectos del ruido que contiene la ecuación (3.12).

Definimos

$$H = \begin{bmatrix} Z_p \\ Z_f \end{bmatrix} \quad (3.13)$$

Descomposición RQ. Por medio de la descomposición RQ de los datos del proceso, el cálculo se ejecutara de una forma numéricamente robusta y fiable [13].

Considerando las matrices de datos como un arreglo de columnas rectangulares, se puede aplicar la descomposición de matrices rectangulares RQ, para obtener una matriz inferior triangular de datos y una matriz triangular superior de ceros.

$$\begin{bmatrix} Z_p \\ U_f \\ Y_f \end{bmatrix} = \begin{bmatrix} R_{11} & 0 & 0 \\ R_{21} & R_{22} & 0 \\ R_{31} & R_{32} & R_{33} \end{bmatrix} \begin{bmatrix} Q_1 \\ Q_2 \\ Q_3 \end{bmatrix} \quad (3.14)$$

donde

$R_{11} \in \mathfrak{R}^{(km+kp) \times (km+kp)}$, $R_{21} \in \mathfrak{R}^{km \times (km+kp)}$, $R_{22} \in \mathfrak{R}^{km \times km}$, $R_{31} \in \mathfrak{R}^{kp \times (km+kp)}$, $R_{32} \in \mathfrak{R}^{kp \times km}$, $R_{33} \in \mathfrak{R}^{kp \times kp}$ son matrices triangulares inferiores.; $Q_1 \in \mathfrak{R}^{(km+kp) \times N}$, $Q_2 \in \mathfrak{R}^{km \times N}$, $Q_3 \in \mathfrak{R}^{kp \times N}$ son matrices ortogonales.

El cálculo real de la descomposición RQ se realiza mediante la transpuesta de la descomposición QR. Dicha descomposición proporciona matrices de datos que también son útiles para la obtención de residuos [14].

3.2.2 REPRESENTACIÓN DEL KERNEL

3.2.2.1 FACTORIZACIÓN COPRIMA IZQUIERDA (LFC)

Se sabe que el par $(\hat{M}(z), \hat{N}(z))$ con

$$\begin{aligned}\hat{M} &= I - C(zI - A + LC)^{-1}L \\ \hat{N} &= D + C(zI - A + LC)^{-1}(B - LD)\end{aligned}\quad (3.15)$$

construyen el LCF para (2.1), es decir

$$y(z) = \hat{M}(z)\hat{N}(z)u(z) \quad (3.16)$$

Una propiedad fundamental de el LCF es que en el caso sin fallas y sin ruido

$$r(z) \triangleq \begin{bmatrix} -\hat{N}(z) & \hat{M}(z) \end{bmatrix} \begin{bmatrix} u(z) \\ y(z) \end{bmatrix} = 0, \quad \forall u \quad (3.17)$$

Dado el sistema (2.1), que es un sistema lineal estable K conducido por $u(z)$, este puede representarse mediante

$$r(z) = K \begin{bmatrix} u(z) \\ y(z) \end{bmatrix} = 0, \quad \forall u \quad (3.18)$$

es llamada la representación estable del Kernel (SKR). Es claro que en el sistema $[-\hat{N}(z) \quad \hat{M}(z)]$ define el SKR.

3.2.2.2 REALIZACIÓN BASADA EN DATOS DEL SKR

Dado el sistema formado por (2.1), la matriz $K_{d,s}$ es llamada la realización basada en datos del SKR, si para algún entero s ,

$$r(k) = K_{d,s} \begin{bmatrix} u_s(k) \\ y_s(k) \end{bmatrix} = 0, \quad \forall u_s(k), x(0) \quad (3.19)$$

Dejando que U , Y denoten el conjunto de datos disponibles de las entradas y salidas del proceso y asumiendo que las medidas del ruido del proceso tienen media cero y una distribución normal, tenemos que

$$K_{d,s} \begin{bmatrix} U \\ Y \end{bmatrix} \sim N(0, \Sigma_{res}), \quad \forall U \quad (3.20)$$

así, el diseño de la detección de fallas directamente de datos es formulada como: encontrar $K_{d,s}$ y Σ_{res} usando los datos del proceso disponibles.

Una vez que $K_{d,s}$ y Σ_{res} son identificadas, la generación de residuos (en línea) puede ser realizada en la forma

$$r(k) = K_{d,s} \begin{bmatrix} u_s(k) \\ y_s(k) \end{bmatrix} = 0 \quad (3.21)$$

con $u_s(k)$ y $y_s(k)$ denotando los datos de entrada y salida del proceso en el intervalo $[k-s, k]$.

$$\text{Donde } u_s(k) = \begin{bmatrix} u(k-s) \\ \vdots \\ u(k) \end{bmatrix} \text{ y } y_s(k) = \begin{bmatrix} y(k-s) \\ \vdots \\ y(k) \end{bmatrix}.$$

Están formadas como en (3.2) y representan la primer columna de las matrices futuras $U_f \in \mathfrak{R}^{(s+1)m \times N}$ y $Y_f \in \mathfrak{R}^{(s+1)p \times N}$ como se muestra en (3.4).

3.2.3 GENERACIÓN DEL RESIDUO

Este esquema de generación de residuos se basa en la identificación directamente de datos del SKR como se describe en (3.21). Para este fin reescribimos (3.5) de la siguiente manera

$$\begin{bmatrix} U_f \\ Y_f \end{bmatrix} = \Psi_s \begin{bmatrix} U_f \\ X_{k-s} \end{bmatrix} + \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix}, \quad \Psi_s = \begin{bmatrix} I & 0 \\ H_{u,s} & \Gamma_s \end{bmatrix} \quad (3.22)$$

Ya que $\Psi_s \in \mathfrak{R}^{(s+1)(p+m) \times (n+(s+1)m)}$ y para $s > n$, $(s+1)(p+m) > n + (s+1)m$, entonces existe Ψ_s^\perp de modo que

$$\Psi_s^\perp \Psi_s = 0, \quad \Psi_s^\perp \in \mathfrak{R}^{((s+1)p-n) \times (s+1)(p+m)}$$

$$\Psi_s^\perp \begin{bmatrix} U_f \\ Y_f \end{bmatrix} = \Psi_s^\perp \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix} \quad (3.23)$$

En otras palabras, Ψ_s^\perp es la realización directamente de datos del SKR $K_{d,s}$ y con esto se construye el generador de residuos.

3.2.4 IDENTIFICACIÓN DEL SKR

Ahora, estudiaremos la cuestión de identificar, definiendo

$$K_{d,s} = \Psi_s^\perp$$

Note que Z_p no está correlacionado con W_f , V_f , por lo tanto se tiene

$$\frac{1}{N-1} \begin{bmatrix} U_f \\ Y_f \end{bmatrix} Z_p^T \approx \Psi_s \begin{bmatrix} U_f \\ X_{k-s} \end{bmatrix} Z_p^T \quad (3.24)$$

Asumiendo que $\begin{bmatrix} U_f \\ X_f \end{bmatrix} Z_p^T$ es de rango completo, tenemos

$$\Psi_s^\perp \Psi_s = 0 \iff \Psi_s^\perp \begin{bmatrix} U_f \\ Y_f \end{bmatrix} \frac{Z_p^T}{N-1} \quad (3.25)$$

Ahora realizando la Descomposición de Valores Singulares (SVD)

$$\begin{bmatrix} U_f \\ Y_f \end{bmatrix} \frac{Z_p^T}{N-1} = \begin{bmatrix} U_1 & U_2 \end{bmatrix} \begin{bmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \end{bmatrix} \begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} \quad (3.26)$$

lleva a

$$\Sigma_2 \approx 0, \quad \Psi_s^\perp = U_2^T \in \mathfrak{R}^{((s+1)p-n) \times (s+1)(m+p)}.$$

$$\text{Sea } K_{d,s} = \Psi_s^\perp = \begin{bmatrix} \Psi_{s,u}^\perp & \Psi_{s,y}^\perp \end{bmatrix}, \quad \Psi_{s,y}^\perp \in \mathfrak{R}^{((s+1)p-n) \times (s+1)p}.$$

es evidente que

$$\Psi_{s,y}^\perp \Gamma_s = 0, \quad \Psi_{s,u}^\perp = \Psi_{s,y}^\perp H_{u,s} \quad (3.27)$$

Así, $\Psi_{s,y}^\perp = \Gamma_s^\perp$ es el llamado subespacio de paridad. Por medio de la identificación de la representación del kernel Ψ_s^\perp , un vector residual puede ser generado de la siguiente manera.

$$r(k) = \Psi_{s,y}^\perp y_s(k) + \Psi_{s,u}^\perp u_s(k) = \Psi_s^\perp \begin{bmatrix} u_s(k) \\ y_s(k) \end{bmatrix} \quad (3.28)$$

Usando los datos del proceso U_f y Y_f Es posible estimar la matriz de covarianza como sigue

$$\Psi_s^\perp \begin{bmatrix} u_s(k) \\ y_s(k) \end{bmatrix} = \Psi_{s,y}^\perp (H_{w,s} W_f + V_f) \implies \Sigma_{res} = \frac{1}{N-1} \Psi_s^\perp \begin{bmatrix} u_s(k) \\ y_s(k) \end{bmatrix} \left(\Psi_s^\perp \begin{bmatrix} u_s(k) \\ y_s(k) \end{bmatrix} \right)^T \quad (3.29)$$

Con la descomposición RQ hecha en (3.14) se obtiene lo siguiente [15]

$$\begin{bmatrix} U_f \\ Y_f \end{bmatrix} = \begin{bmatrix} R_{21} & R_{22} \\ R_{31} & R_{32} \end{bmatrix} \begin{bmatrix} Q_1 \\ Q_2 \end{bmatrix} + \begin{bmatrix} 0 \\ R_{33} Q_3 \end{bmatrix} \quad (3.30)$$

$$R_{33} Q_3 = H_{w,s} W_f + V_f \quad (3.31)$$

Finalmente tenemos

$$\Psi_s^\perp \begin{bmatrix} R_{21} & R_{22} \\ R_{31} & R_{32} \end{bmatrix} = 0 \iff \Psi_s^\perp \Psi_s = 0 \quad (3.32)$$

$$\Psi_s^\perp \begin{bmatrix} U_f \\ Y_f \end{bmatrix} = \Psi_{s,y}^\perp (H_{w,s} W_f + V_f) = \Psi_{s,y}^\perp R_{33} Q_3 \quad (3.33)$$

$$\Sigma_{res} = \frac{\Psi_{s,y}^\perp R_{33} Q_3 (\Psi_{s,y}^\perp R_{33} Q_3)^T}{N-1} = \frac{\Psi_{s,y}^\perp R_{33} R_{33}^T (\Psi_{s,y}^\perp)^T}{N-1} \quad (3.34)$$

3.2.4.1 ALGORITMO 1 (GENERACIÓN DE RESIDUOS MEDIANTE LA IDENTIFICACIÓN BASADA EN DATOS DEL SKR)

1. *Colectar los datos del proceso* Z_p, U_f, Y_f .
2. *Realizar la descomposición-RQ* (3.14).
3. *Hacer el SVD* (2.6) *y calcular* $K_{d,s} = \Psi_s^\perp = U_2^T$.
4. *Calcular* $\Sigma_{res} = \frac{\Psi_{s,y}^\perp R_{33} R_{33}^T (\Psi_{s,y}^\perp)^T}{N-1}$.

En esta sección se presentaron algunos conceptos básicos y los primeros esquemas y algoritmos de diseño para el diagnóstico de fallas a partir de datos. [4]

3.2.5 EJEMPLO 1

3.2.5.1 SISTEMA DE TRES TANQUES

Para demostrar que mediante la aplicación del Algoritmo 1 podemos obtener un residuo que es cero en ausencia de fallas, utilizaremos como ejemplo un sistema de tres tanques [3]. En este sistema dos bombas independientes llenan los tanques de los extremos. Los tres tanques están interconectados y el tercer tanque solo tiene salida del líquido como el que se muestra en la Figura 3.1.

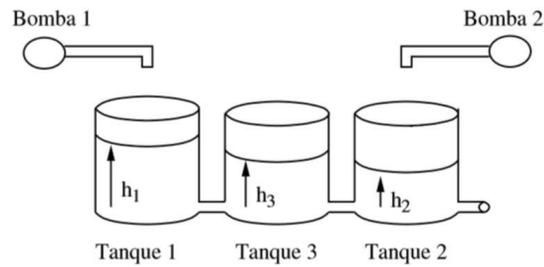


Figura 3.1: Sistema de tres tanques

Las entradas son el flujo proveniente de las bombas 1 y 2 en tanto que las salidas son los niveles de cada tanque.

3.2.5.2 RESULTADOS DE SIMULACIÓN

Con el fin de obtener datos, se simuló el sistema linealizado discreto de este proceso y de ahí se tomaron datos de entrada y salida con los que se obtuvieron los siguientes resultados (Utilizando datos nominales).

Residuo

res =

```
1.0e-08 *  
-0.0928  
0.2138  
-0.1590  
0.1605  
-0.0332  
-0.0104  
0.0000  
0.0000  
-0.0000
```

Covarianza del residuo

```

cov_res =

1.0e-26 *
  0.0513    0.0053    0.0110   -0.0090   -0.0082    0.0001   -0.0000   -0.0000    0.0000
  0.0053    0.0704   -0.0053    0.0072   -0.0056   -0.0016    0.0000   -0.0000    0.0000
  0.0110   -0.0053    0.1587    0.0539    0.0259    0.0072   -0.0000    0.0000    0.0000
 -0.0090    0.0072    0.0539    0.1340    0.0175    0.0191   -0.0000    0.0000   -0.0000
 -0.0082   -0.0056    0.0259    0.0175    0.0416    0.0056    0.0000    0.0000   -0.0000
  0.0001   -0.0016    0.0072    0.0191    0.0056    0.0316   -0.0000    0.0000   -0.0000
 -0.0000    0.0000   -0.0000   -0.0000    0.0000   -0.0000    0.0000   -0.0000   -0.0000
 -0.0000   -0.0000    0.0000    0.0000    0.0000    0.0000   -0.0000    0.0000   -0.0000
  0.0000    0.0000    0.0000   -0.0000   -0.0000   -0.0000   -0.0000   -0.0000    0.0000

```

con lo que se comprueba que el SKR obtenido nos da un residuo igual a cero en ausencia de fallas.

3.3 DISEÑO DE OBSERVADORES PARA LA DETECCIÓN DE FALLAS DIRECTAMENTE DE DATOS

3.3.1 CONSTRUCCIÓN DE UN GENERADOR DE RESIDUOS (OBSERVADOR) BASADO EN UN VECTOR DE PARIDAD

Inspirados por el hecho de que en el caso de los sistemas lineales invariantes en el tiempo una conexión entre el espacio de paridad (lazo abierto) y el observador de diagnóstico (lazo cerrado), cuando los valores propios de A_d son ceros, ambos sistemas tienen dinámicas idénticas [16], [3].

Considere el modelo del proceso (2.1) y el vector de paridad

$$\alpha_s = [\alpha_{s,0} \ \alpha_{s,1} \ \dots \ \alpha_{s,s}] \in \mathfrak{R}^{(s+1)p}, \quad \alpha_s \begin{bmatrix} C \\ CA \\ \vdots \\ CA^s \end{bmatrix} = 0$$

donde $\alpha_{s,i} \in \mathfrak{R}^p$, $i = 0, 1, \dots, s$. ha sido demostrado en [3] que las matrices

$$A_d = \begin{bmatrix} 0 & 0 & \dots & 0 \\ 1 & 0 & \dots & 0 \\ \vdots & \ddots & \ddots & \vdots \\ 0 & \dots & 1 & 0 \end{bmatrix} \in \mathfrak{R}^{s \times s}, \quad L_d = - \begin{bmatrix} \alpha_{s,0} \\ \alpha_{s,1} \\ \vdots \\ \alpha_{s,s-1} \end{bmatrix} \quad (3.35)$$

$$T = \begin{bmatrix} \alpha_{s,1} & \alpha_{s,2} & \dots & \alpha_{s,s-1} & \alpha_{s,s} \\ \alpha_{s,2} & \dots & \dots & \alpha_{s,s} & 0 \\ \vdots & \dots & \dots & \vdots & \vdots \\ \alpha_{s,s} & 0 & \dots & \dots & 0 \end{bmatrix} \begin{bmatrix} C \\ CA \\ \vdots \\ CA^{s-1} \end{bmatrix} \in \mathfrak{R}^{s \times n} \quad (3.36)$$

resuelven las ecuaciones de Luenberger

$$TA - A_dT = L_dC \quad (3.37)$$

$$C_dT = G_dC, \quad C_d = [0 \ \dots \ 0 \ 1] \in \mathfrak{R}^s, \quad G_d = \alpha_{s,s} \in \mathfrak{R}^p$$

Una aplicación directa de este resultado es la construcción de un generador de residuos basado en observador para el vector de paridad dado α_s , como sigue

$$\begin{aligned} z(k+1) &= A_d z(k) + B_d u(k) + L_d y(k) \in \mathfrak{R}^s, & B_d &= TB - L_d D \\ r(k) &= G_d y(k) - C_d z(k) - D_d u(k) \in \mathfrak{R}, & D_d &= G_d D \end{aligned} \quad (3.38)$$

Note que

$$\begin{bmatrix} B_d \\ D_d \end{bmatrix} = \begin{bmatrix} \alpha_{s,0} & \alpha_{s,1} & \dots & \alpha_{s,s-1} & \alpha_{s,s} \\ \alpha_{s,1} & \dots & \dots & \alpha_{s,s} & 0 \\ \vdots & \dots & \dots & \vdots & \vdots \\ \alpha_{s,s} & 0 & \dots & \dots & 0 \end{bmatrix}$$

$$= \begin{bmatrix} \alpha_s H_{u,s}(:, 1 : m) \\ \alpha_s H_{u,s}(:, m + 1 : 2m) \\ \vdots \\ \alpha_s H_{u,s}(:, sm + 1 : (s + 1)m) \end{bmatrix} \quad (3.39)$$

Las ecuaciones (3.35), (3.38) y (3.39), permiten una construcción directa del generador de residuos dado en (3.38) usando una fila de Ψ_s^\perp , la cual llamamos ψ_s^\perp

$$\psi_s^\perp = [\psi_{s,u}^\perp \quad \psi_{s,y}^\perp] \quad (3.40)$$

Ya que $\psi_{s,y}^\perp = \alpha_s$ es un vector de paridad y

$$\psi_{s,u}^\perp = -\psi_{s,y}^\perp H_{u,s}$$

tenemos, además de A_d , C_d dadas en (3.35) y (3.39), B_d , D_d , G_d , L_d formadas en términos de $\psi_{s,u}^\perp$ y $\psi_{s,y}^\perp$:

$$L_d = - \begin{bmatrix} \psi_{s,y}^\perp(1 : p) \\ \vdots \\ \psi_{s,y}^\perp((s-1)p + 1 : sp) \end{bmatrix}, G_d = \psi_{s,y}^\perp(sp + 1 : (s+1)p) \quad (3.41)$$

$$B_d = - \begin{bmatrix} \psi_{s,u}^\perp(1 : m) \\ \vdots \\ \psi_{s,u}^\perp((s-1)m + 1 : sm) \end{bmatrix}, D_d = -\psi_{s,u}^\perp((sm + 1 : (s+1)m)) \quad (3.42)$$

3.3.1.1 ALGORITMO 2 (DISEÑO DE UN SISTEMA PARA LA GENERACIÓN DE RESIDUOS BASADO EN OBSERVADOR)

1. *Correr Algoritmo 1 con $\Psi_{s,y}^\perp$, $\Psi_{s,u}^\perp$ como salidas .*
2. *Formar B_d , D_d , G_d , L_d de acuerdo a (3.41) y (3.42).*
3. *Construir el generador de residuos (3.38) .*

Motivados por el hecho de que el generador de residuos visto en la sección anterior es configurado en lazo abierto, por lo que es menos robusto e implica más carga computacional, se presentó, en esta sección, un enfoque para la construcción de un sistema para el diagnóstico de fallas basado en observador con la ayuda del SKR (Ψ_s^\perp) dado en el Algoritmo 1. Como se sabe el generador de residuos basado en observador está configurado en lazo cerrado con la señal residual retroalimentada y los cálculos involucrados son realizados en forma recursiva, por lo que presentan alta robustez y demandan menos carga computacional.

3.3.2 EJEMPLO 2

3.3.2.1 SISTEMA DE TRES TANQUES

Para demostrar que mediante la aplicación del Algoritmo 2 podemos detectar fallas, utilizaremos como ejemplo un sistema de tres tanques [3]. En este sistema dos bombas independientes llenan los tanques de los extremos. Los tres tanques están interconectados y el tercer tanque solo tiene salida del líquido como el que se muestra en la Figura 3.2.

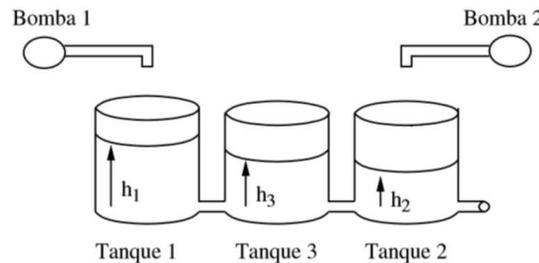


Figura 3.2: Sistema de tres tanques

Las entradas son el flujo proveniente de las bombas 1 y 2 en tanto que las salidas son los niveles de cada tanque.

3.3.2.2 RESULTADOS DE SIMULACIÓN

Con el fin de obtener datos, se simuló el sistema linealizado discreto de este proceso y de ahí se tomaron datos de entrada y salida con los que se obtuvieron los siguientes resultados.

Tendremos como falla una fuga en el tanque 3. El tiempo de muestreo es de 1s.

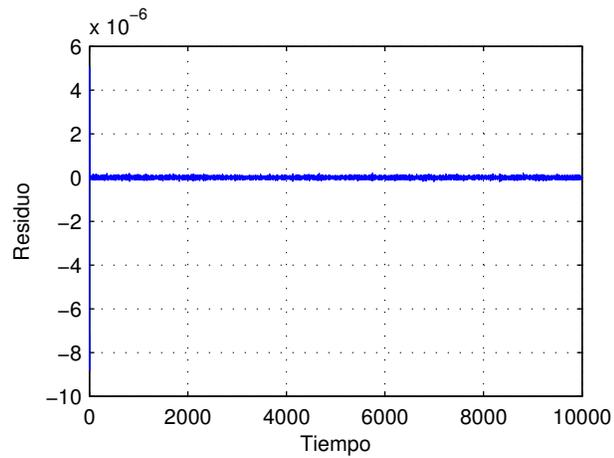


Figura 3.3: Residuo sin falla

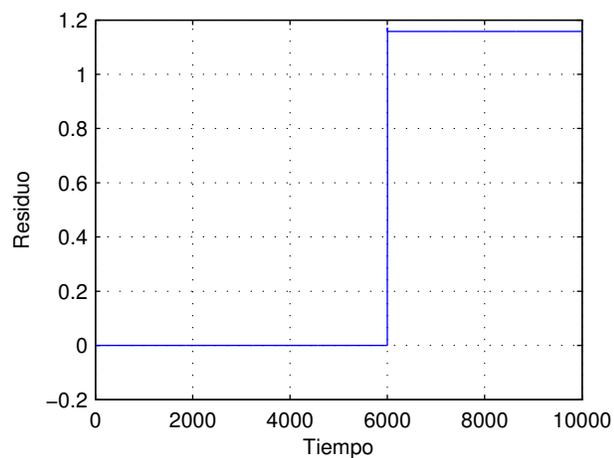


Figura 3.4: Residuo con falla (6000s)

3.4 DETECCIÓN DE FALLAS INCIPIENTES EN TRANSFORMADORES (APLICACIÓN)

La detección de fallas incipientes en transformadores representa una cuestión muy importante para el mantenimiento y para evitar posibles fallas. Existen muchos enfoques para la detección de fallas incipientes fuera de línea a partir de mediciones, y sólo pocos consideran la posibilidad de realizar el diagnóstico en línea. En esta sección se realiza un diagnóstico de fallas incipientes en línea a partir de mediciones eléctricas. En donde se utilizan las corrientes junto con el algoritmo 2 presentado en este capítulo para diseñar el observador de diagnóstico. El observador es además utilizado para supervisar el comportamiento del transformador. Los resultados de simulación muestran la viabilidad del enfoque propuesto.

3.4.1 INTRODUCCIÓN

Un componente esencial de un sistema de alimentación es el transformador eléctrico. Las fallas en los transformadores pueden causar graves daños a la transmisión y distribución de la energía eléctrica. La motivación de detectar fallas en transformadores sigue dos direcciones principales: una es para proteger la red de posibles daños al ocurrir la falla [17] y la otra es detectar la falla en una etapa temprana, es decir, la detección de fallas incipientes. La información de una falla incipiente podría ser utilizada para el mantenimiento, así como para evitar posibles daños.

Muchos enfoques para la detección de fallas incipientes disponibles en la literatura son para la aplicación fuera de línea, es decir, cuando el transformador no está en funcionamiento. Hay muchos enfoques para la detección de fallas en los transformadores. Básicamente se pueden agrupar en dos conjuntos principales: enfoques fuera de línea y en línea. Los enfoques fuera de línea prueban el rendimiento del

transformador cuando no está en uso. En algunos casos es necesario desconectar las terminales del transformador para realizar la prueba. Ejemplos de estos enfoques son el análisis del gas disuelto en aceite [18], el análisis de la respuesta a la frecuencia [19], el ensayo de impulsos, así como algunas de sus variantes [20].

El método más extendido para la detección de fallas y la protección de los transformadores en línea se basa en el llamado principio de corriente de protección diferencial [21]. Nótese, sin embargo, que este enfoque se basa en el procesamiento de señales y en un modelo parcial (estático) del comportamiento del transformador, es decir, solo los valores de estado estacionario son considerados. Esto hace a el enfoque de protección diferencial sensible a fallas externas, con un comportamiento no lineal del transformador y con corrientes de entrada.

Un enfoque alternativo para la detección de fallas en línea en transformadores se basa en un modelo obtenido a partir de datos de medición. La principal ventaja es que la dinámica no lineal se puede tener en cuenta, es decir, en este caso el modelo del transformador es en realidad no lineal, sin embargo a causa de la metodología basada en datos, el cálculo del aniquilador implica una proyección y algunos de los efectos no lineales también se proyectan a un espacio nulo. Otra ventaja es que las corrientes de entrada no producen falsas alarmas. Ejemplos de estos métodos son los enfoques basados en redes neuronales, según lo reportado en [22]. Nótese que en este caso se requiere un cierto entrenamiento con los datos nominales (sin falla) del transformador.

En cierto sentido, el enfoque propuesto hace uso de algunas ideas generalmente utilizadas por redes neuronales, ya que los datos nominales se utilizan para obtener una especie de modelo para el comportamiento nominal. En lugar de redes neuronales se utilizan proyecciones y filtrado lineal para obtener señales residuales.

Enfoques más analíticos utilizan modelos no lineales basados en ecuaciones diferenciales no lineales de un transformador. Una idea interesante ha sido reportada en [22], [23] y [24] en la que se combinan las ecuaciones de voltaje a fin de obtener

una ecuación diferencial que contiene términos solamente lineales, pero teniendo en cuenta (implícitamente) el comportamiento no lineal.

Sin embargo, como se reporta en [25] se requiere que la ecuación diferencial resultante sea asintóticamente estable. Puede ser demostrado que la ecuación lineal resultante de [23] y [24] sólo son críticamente estable y que no satisfacen los requerimientos. Recientemente en [26] se han propuesto enfoques que satisfacen los requisitos de estabilidad. Los enfoques consideran ecuaciones diferenciales no lineales, así como la correspondiente constante de Lipschitz de las no linealidades.

Esta sección utiliza un enfoque para la detección de fallas que combina los métodos basados en datos y observadores para la detección de fallas incipientes en un transformador eléctrico. Una ventaja del enfoque es que no se requiere explícitamente el modelo matemático del transformador, en lugar de eso los métodos basados en datos son utilizados para obtener el diseño del observador de diagnóstico. En una segunda etapa, el observador de diagnóstico diseñado es utilizado para monitoriar en tiempo real un transformador eléctrico. En cierto sentido, el procedimiento propuesto utiliza algunas ideas de los enfoques basados en redes neuronales, pero en combinación con métodos más clásicos basados en modelos. El enfoque es lo suficientemente sensible para detectar fallas incipientes. Un ejemplo se utiliza para mostrar los resultados.

3.4.2 ENFOQUE BASADO EN DATOS PARA LA DETECCIÓN DE FALLAS INCIPIENTES EN TRANSFORMADORES

El modelo del transformador es utilizado con el fin de obtener los datos de entrada y salida necesarios para las simulaciones, se han tomado de [27], [28]. El modelo del transformador utilizado se basa en un circuito magnético.

El enfoque propuesto consiste en usar datos de entrada y salida sin fallas del

transformador para diseñar un observador de monitoreo. El observador representan el comportamiento nominal y, en consecuencia, puede indicar cada posible mal funcionamiento del transformador, es decir, el observador realiza una prueba de consistencia de los datos de entrada y salida medidos.

Note que el enfoque propuesto ha sido desarrollado para sistemas lineales, sin embargo, el modelo del transformador es en realidad no lineal. Sin embargo, a causa de la metodología basada en datos, el cálculo numérico de el aniquilador implica una proyección y algunos de los efectos no lineales también se proyectan a un espacio nulo. La cancelación de algunas de las no linealidades podría ser posible si es que se están produciendo en un canal de entrada.

3.4.3 SIMULACIÓN

Para probar el enfoque propuesto se utiliza la simulación de un transformador.

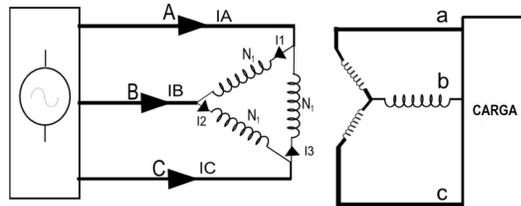


Figura 3.5: Conexión del transformador trifásico

3.4.3.1 DATOS DEL MODELO DEL TRANSFORMADOR USADO EN LA SIMULACIÓN

Se consideran los datos de entrada-salida de un transformador trifásico con los siguientes parámetros:

$$\text{Reluctancia de dispersión: } \begin{bmatrix} 1 & 1 & 1 & 0.537 & 0.537 & 0.537 \end{bmatrix}$$

Áreas transversales: $\begin{bmatrix} 1 & 1 & 1 & 1.16 & 1.16 \end{bmatrix}$

Vueltas devanado: $\begin{bmatrix} 1.732 & 1.732 & 1.732 & 1 & 1 & 1 \end{bmatrix}$

Restricciones curva de saturación: $\begin{bmatrix} 0.7 & 754 & 0.95 \end{bmatrix}$

Matriz de resistencias:

$$\begin{bmatrix} 0.0015 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.0015 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.0015 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.0015 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.0015 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.0015 \end{bmatrix}$$

Todos los parámetros se dan en p.u. Todos los parámetros son de las columnas y los yugos, los valores de dispersión de reluctancias son para las columnas entre devanados, ver Figura 3.6.

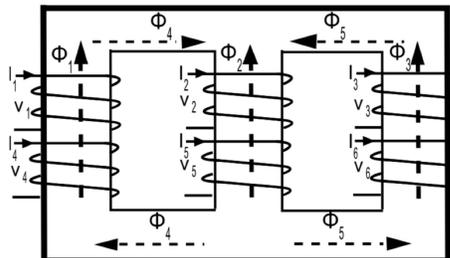


Figura 3.6: Tres columnas del transformador trifásico

3.4.3.2 RESULTADOS

Como datos de entrada tenemos las corrientes primarias y como datos de salida las corrientes secundarias. Las gráficas de los datos de entrada y salida se pueden encontrar en la figura 3.7 y 3.8.

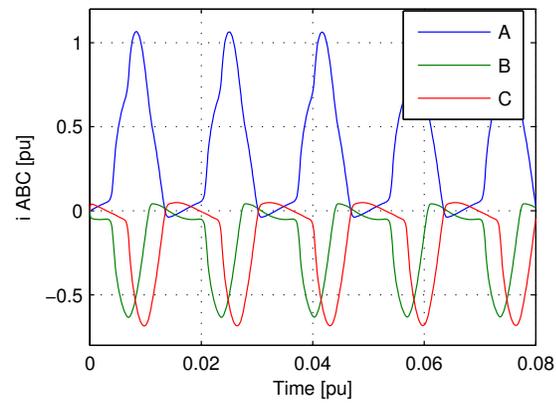


Figura 3.7: Corrientes de entrada

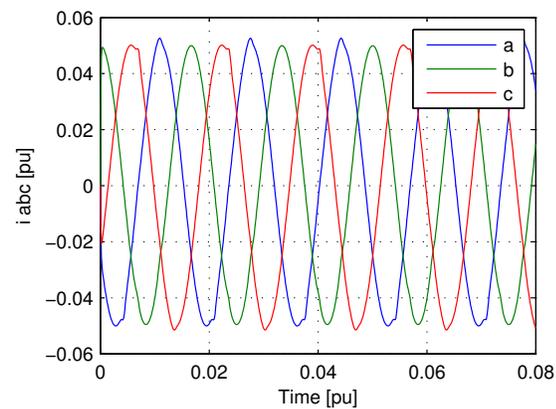


Figura 3.8: Corrientes de salida

El residuo correspondiente sin falla se puede ver en la figura 3.9.

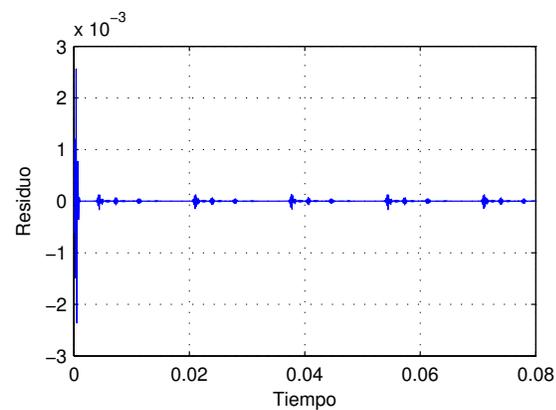


Figura 3.9: Residuo sin fallas (condiciones nominales)

Los picos que se observan en el residuo de la figura (3.9) se deben a las no linealidades del sistema, sin embargo el residuo es prácticamente cero, dicho comportamiento es el esperado.

Ahora con el fin de simular una falla por envejecimiento se utilizaron los datos nominales del sistema y los datos con falla del sistema, estos datos fueron tomados en un punto en donde la falla por envejecimiento ya estaba presente por lo que se simuló la falla como una falla abrupta, la cual se manifiesta como un cambio repentino, y no como una falla incipiente la cual va creciendo gradualmente (las fallas por envejecimiento son fallas incipientes) ,como trabajo futuro se pretende determinar la falla incipiente mínima que se puede detectar utilizando este enfoque.

El efecto de la falla en la señal de entrada-salida puede ser revisado en las figuras 3.10 y 3.11, respectivamente.

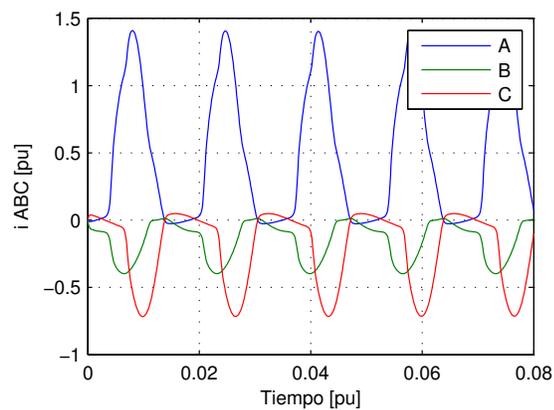


Figura 3.10: Corrientes de entrada con falla

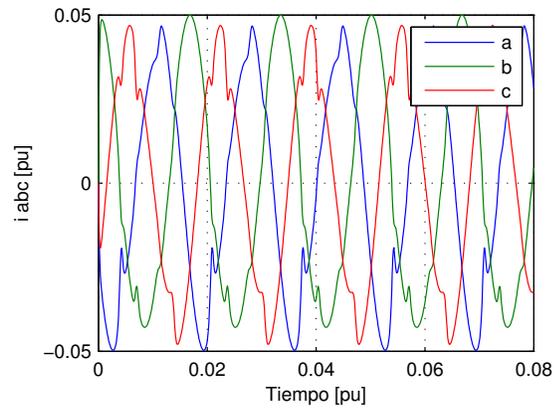


Figura 3.11: Corrientes de salida con falla

En la figura 3.12 se puede observar el residuo cuando se tiene una falla causada por envejecimiento.

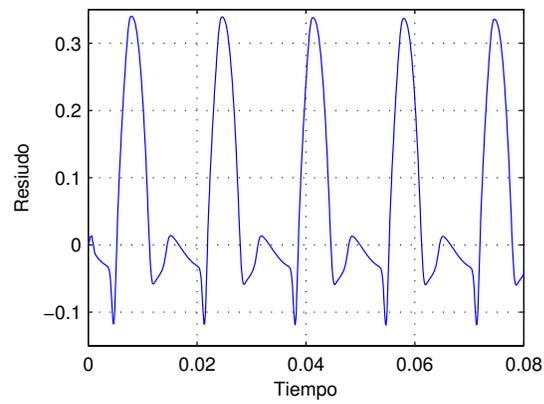


Figura 3.12: Residuo con falla

CAPÍTULO 4

AISLAMIENTO DE FALLAS A PARTIR DE MEDICIONES

4.1 DESCRIPCIÓN DEL CAPÍTULO

El diagnóstico de fallas en procesos dinámicos es un área de creciente interés. Una gran cantidad de resultados para análisis y diseño de esquemas de diagnóstico se encuentran disponibles en la literatura especializada. Recientemente aparece un resultado relacionado con la detección de fallas para sistemas cuyo modelo matemático no es conocido de antemano. Sin embargo, un problema sin resolver consiste en diseñar un algoritmo para el diagnóstico de fallas basado en observadores cuando solo se dispone de mediciones. Un enfoque de solución a este problema es propuesto en este capítulo, el cual es obtenido sobre el supuesto de que diferentes conjuntos de mediciones están disponibles para el diseño. Además de una justificación técnica de los resultados obtenidos. Experimentos son utilizados para mostrar las bondades del algoritmo propuesto.

4.2 ESQUEMA DE OBSERVADORES GENERALIZADOS (GOS)

En el presente diseño, para poder discernir entre diferentes fallas, se va a utilizar un grupo de residuos estructurados que van a ser generados por un grupo o banco de observadores, los cuales van a ser diseñados con el objetivo de que cada residuo se comporte de forma diferente para una falla, de forma que un residuo sea sensible e insensible a algunas fallas. Por lo tanto cuando una falla ocurre, algunos residuos se verán afectados, mientras que otros no [1]. En este GOS cada observador utiliza todas las entradas y salidas, como se muestra en la figura 4.2, donde se obtienen residuos como resultado de la comparación de las salidas reales del sistema y las estimaciones realizadas con cada observador. Una vez obtenidos los residuos se generan las firmas características de cada falla (Matriz de incidencia de fallas).

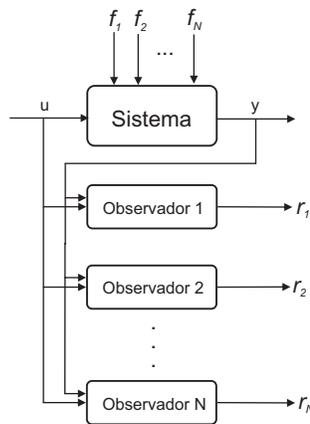


Figura 4.1: Diagrama esquemático del GOS

La utilidad de este arreglo de residuos esta en que facilita el aislamiento o identificación de la falla que se presente. En la Tabla 6.1 se muestra un ejemplo de una tabla de N residuos, para un universo de N fallas, con desacoplamiento de ciertas fallas de interés.

	Falla 1 (f_1)	Falla 2 (f_2)	...	Falla M (f_N)
Residuo 1 (r_1)	\emptyset	\checkmark		\checkmark
Residuo 2 (r_2)	\checkmark	\emptyset		\checkmark
\vdots			\ddots	
Residuo N (r_N)	\checkmark	\checkmark		\emptyset

Tabla 4.1: Matriz de incidencia de fallas

donde “ \emptyset ” representa que el residuo fue diseñado insensible a la falla correspondiente, mientras que el símbolo “ \checkmark ” representa sensibilidad a la falla.

Aquí el primer residuo (r_1) es sensible a todas las fallas excepto a la primera (f_1), el segundo residuo (r_2) es sensible a todas las fallas excepto a la segunda (f_2), y así sucesivamente, es decir

$$r_1 = q_1(f_2, f_3, \dots, f_N)$$

$$r_2 = q_2(f_1, f_3, \dots, f_N)$$

$$\vdots$$

$$r_N = q_N(f_1, f_2, \dots, f_{N-1})$$

Por último, se realiza una evaluación del residuo mediante una decisión lógica apropiada, con la que se toma una decisión final.

4.3 ENFOQUE PARA EL AISLAMIENTO DE FALLAS A PARTIR DE MEDICIONES

4.3.1 AISLAMIENTO DE FALLAS

El aislamiento de fallas es el proceso mediante el cual se va a eliminar la dependencia de una falla respecto de otras fallas y perturbaciones.

Suponiendo que tenemos dos posibles fallas f_1 y f_2 , se puede diseñar un generador de residuos sensible a las fallas (f_2) pero robusto a una falla, en este caso a f_1 , ver Figura 4.2.

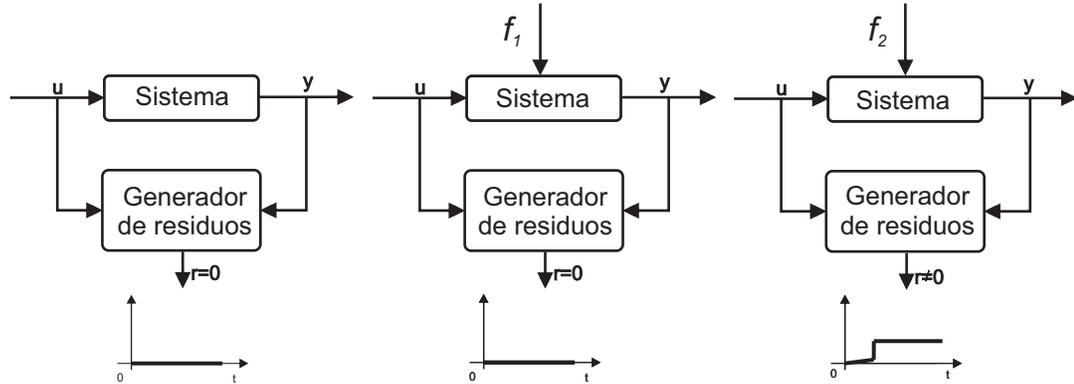


Figura 4.2: Desacoplo de fallas

Para el aislamiento se va a utilizar como ayuda la teoría anteriormente expuesta, el esquema de observadores generalizados.

4.3.2 PROPUESTA DE SOLUCIÓN

Un resultado bien conocido es el hecho de que la parte más significativa del aislamiento de fallas se alcanza desde la manera en la que diseñan los generadores de residuos. Es decir, si el diseño de un residuo no considera la posibilidad de aislar fallas, el aislamiento posterior, en la evaluación así como en la identificación de fallas se vuelve muy complicado, y frecuentemente se hace imposible.

Cuando se utilizan métodos basados en modelos, el desacoplo de fallas con fines de robustez y/o aislamiento, se realiza previo a la obtención del generador de residuos o bien, de manera simultánea. Esto nos inspira a reflexionar acerca del momento adecuado, durante el diseño, en el que es mejor poder incorporar estrategias para lograr el aislamiento de fallas. Adicionalmente se requiere información sobre las fallas,

es decir, si no contamos con las matrices de distribución de fallas ni el modelo del sistema, algo se requiere para ser trabajado y alcanzar los resultados buscados, es por eso que necesitamos conocer los datos con falla del sistema para obtener un residuo aislado de dicha falla.

Tomando ideas de la comunidad de redes neuronales, se propone la idea de utilizar información del efecto de una falla sobre la salida del sistema y después de otra falla. Es decir, se propone el uso de tantos juegos de datos de un sistema como el número de fallas más uno. La idea es explicada con el siguiente ejemplo conceptual.

Suponer que tenemos dos posibles fallas f_1 y f_2 que pueden afectar a un sistema.

Primero, el enfoque presentado en [29] utiliza los datos del sistema discreto sin falla para generar un residuo y poder detectar la falla, este residuo es sensible a cualquier falla como se muestra en la Figura 4.3(b).

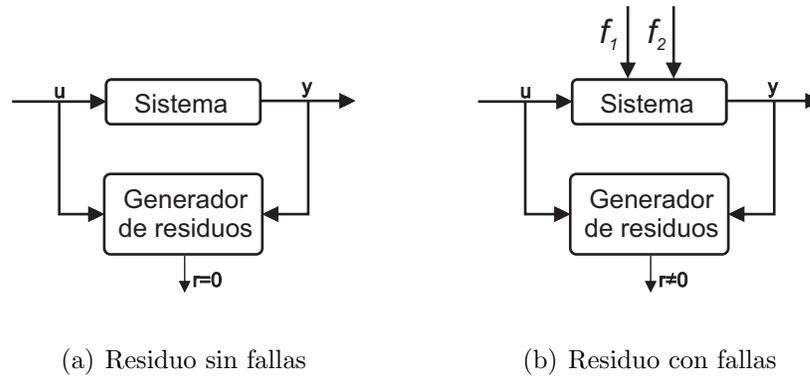
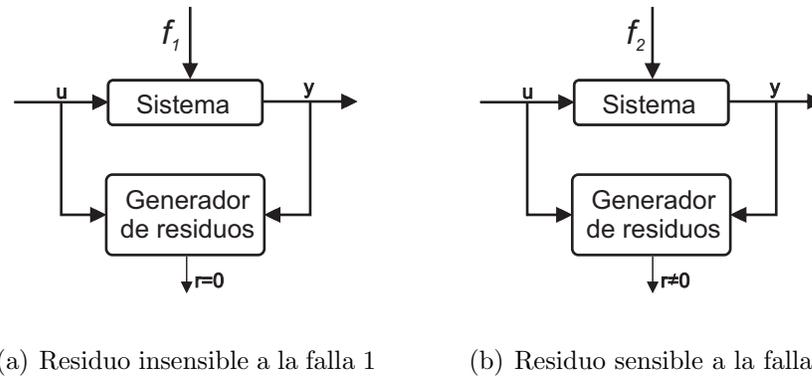


Figura 4.3: Detección de fallas

donde ante la ausencia de fallas el residuo permanece en cero, ver Figura 4.3(a) y diferente de cero al detectar alguna de las fallas, ver Figura 4.3(b).

La información sobre las fallas debe de ser procesada de tal forma que se obtengan las características de robustez requeridas. Siguiendo el ejemplo, las mediciones en las cuales esta presente la falla f_1 (con $f_2 = 0$) permiten obtener un generador

de residuos 1, el cual es insensible a la primera falla, ver figura 4.4(a) pero sensible a las demás fallas, por ejemplo la falla f_2 , ver figura 4.4(b).



(a) Residuo insensible a la falla 1

(b) Residuo sensible a la falla 2

Figura 4.4: Residuo desacoplado de la falla f_1

Así mismo, las mediciones en las cuales esta presente solo el efecto de la segunda falla f_2 (con $f_1 = 0$) posibilita el diseño de un generador de residuos 2 insensible a la falla f_2 . El resultado es resumido a continuación:

Resultado Dado mediciones entrada-salida afectadas por una falla. Entonces es posible el diseño de un generador de residuos robusto a esa falla mientras se mantiene sensible a otras fallas utilizando solamente datos.

Prueba: Sea ψ_s^\perp un aniquilador izquierdo que cancela el canal de influencia de la i -ésima falla, de tal forma que el generador de residuos no es dependiente de la magnitud de la falla. Por lo tanto se requiere de magnitud suficiente para que el proceso de obtención del espacio nulo izquierdo sea numéricamente viable.

4.3.3 DESCRIPCIÓN DEL SISTEMA

Aunque las plantas usualmente son continuas, el diagnóstico de fallas es realizado normalmente con datos muestreados. Por lo tanto solo plantas discretas (discre-

tizadas) son consideradas en este capítulo. Se considera el siguiente sistema en donde el efecto de las fallas que queremos detectar o desacoplar están de forma aditiva.

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) + E\bar{f}(k) + Gf(k) \\y(k) &= Cx(k) + Du(k) + F\bar{f}(k) + Jf(k)\end{aligned}\tag{4.1}$$

donde $x(k)$ es el vector de estados de dimensión n , $u(k)$ es el vector de entradas de dimensión m , $\bar{f}(k)$ es el vector de la falla desacoplada de dimensión l , $f(k)$ es el vector de fallas de dimensión l_f y las matrices A , B , C , D , E , F , G , y J son constantes, conocidas y de dimensiones apropiadas.

4.3.4 JUSTIFICACIÓN MATEMÁTICA

Se toman los datos de entrada-salida nominales y con falla (de la falla que se quiere aislar, en este caso fallas aditivas) para la construcción del observador.

Y suponiendo que la falla no ocurre desde el principio, si no en algún instante de tiempo. Consideramos el sistema LTI:

$$\begin{aligned}x(k+1) &= Ax(k) + Bu(k) + E\bar{f}(k) + w(k) \\y(k) &= Cx(k) + Du(k) + F\bar{f}(k) + v(k)\end{aligned}\tag{4.2}$$

donde $u(k) \in \mathfrak{R}^m$, $y(k) \in \mathfrak{R}^p$ y $x(k) \in \mathfrak{R}^n$, $w(k) \in \mathfrak{R}^n$ y $v(k) \in \mathfrak{R}^p$ denotan secuencias de ruido que tienen una distribución normal y son estadísticamente independientes de $u(k)$ y $x(0)$. Y asumimos que el proceso (4.2) es controlable y observable.

El modelo de datos entrada-salida es descrito por

$$Y_f = \Gamma_s X_{k-s} + H_{u,s} U_f + H_{\bar{f},s} \bar{F}_f + H_{w,s} W_f + V_f\tag{4.3}$$

$$\Gamma_s = \begin{bmatrix} C \\ \vdots \\ CA^s \end{bmatrix} \quad (4.4)$$

$$H_{u,s} = \begin{bmatrix} D & 0 & \cdots & 0 \\ CB & D & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}B & \cdots & CB & D \end{bmatrix} \quad (4.5)$$

$$H_{w,s} = \begin{bmatrix} 0 & 0 & \cdots & 0 \\ C & 0 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1} & \cdots & C & 0 \end{bmatrix} \quad (4.6)$$

$$H_{\bar{f},s} = \begin{bmatrix} F & 0 & \cdots & 0 \\ CE & F & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}E & \cdots & CE & F \end{bmatrix} \quad (4.7)$$

Este esquema de generación de residuos esta basada en la identificación directamente de datos del SKR, lo que se pretende eliminar la dependencia de la condición del vector de estado y de las variable de no interés $\bar{f}(k)$. Para este fin reescribimos (4.3) de la siguiente manera

$$\begin{aligned} \begin{bmatrix} U_f \\ Y_f \end{bmatrix} &= \begin{bmatrix} I & 0 & 0 \\ H_{u,s} & H_{\bar{f},s} & \Gamma_s \end{bmatrix} \begin{bmatrix} U_f \\ \bar{F}_f \\ X_{k-s} \end{bmatrix} + \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix} \\ \begin{bmatrix} U_f \\ Y_f \end{bmatrix} &= \Psi_s \begin{bmatrix} U_f \\ \bar{F}_f \\ X_{k-s} \end{bmatrix} + \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix} \\ \Psi_s^\perp \begin{bmatrix} U_f \\ Y_f \end{bmatrix} &= \Psi_s^\perp \Psi_s \begin{bmatrix} U_f \\ \bar{F}_f \\ X_{k-s} \end{bmatrix} + \Psi_s^\perp \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix} \end{aligned}$$

$$\Psi_s^\perp \begin{bmatrix} U_f \\ Y_f \end{bmatrix} = \Psi_s^\perp \begin{bmatrix} 0 \\ H_{w,s}W_f + V_f \end{bmatrix} \quad (4.8)$$

donde la parte derecha de la ecuación (4.8) es utilizada para implementación y la parte izquierda para el análisis. Permitiendo generar un residuo

$$r(k) = \Psi_s^\perp \begin{bmatrix} U_f \\ Y_f \end{bmatrix} = 0 \quad (4.9)$$

el cual solamente es sensible a las fallas de interés $f(k)$. Y se obtienen las matrices del observador de la misma manera que en la detección, con una fila de la matriz Ψ_s^\perp .

Después de la construcción del observador, se considera el siguiente modelo de entrada-salida (correspondiente al sistema mostrado en la ecuación (4.2)), el cual tiene fallas que se quieren aislar $\bar{f}(k)$ y fallas que se quieren detectar $\bar{f}(k)$.

$$Y_f = \Gamma_s X_{k-s} + H_{u,s}U_f + H_{\bar{f},s}\bar{F}_f + H_{f,s}F_f \quad (4.10)$$

las matrices son definidas en las ecuaciones (4.4), (4.5), (4.6), (4.7) y donde

$$H_{f,s} = \begin{bmatrix} J & 0 & \cdots & 0 \\ CG & J & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}G & \cdots & CG & J \end{bmatrix} \quad (4.11)$$

de donde el calculo de Ψ_s^\perp implica que si una falla \bar{f} esta presente en las mediciones entrada salida, entonces el efecto de esta falla sera eliminada del residuo. Esto se logra mientras que el residuo se mantiene sensible a otras fallas $f(k)$. Es claro que esto ocurrirá siempre que dos fallas no estén afectando el mismo canal (es decir, si las falla no están acopladas).

4.3.4.1 ALGORITMO 4 (DISEÑO DEL i -ÉSIMO GENERADOR DE RESIDUOS ROBUSTO A LA i -ÉSIMA FALLA.)

1. *Obtener mediciones entrada-salida del sistema asegurandose que la i -ésima falla (con magnitud suficiente) esta afectando al sistema.*
2. *Formar las matrices U_f y Y_f (Matrices Hankel futuras).*
3. *Obtener ψ_s^\perp satisfaciendo la ecuación (4.9).*
4. *Determinar las matrices del i -ésimo generador de residuos siguiendo las ecuaciones (3.35), (3.36), (3.41) y (3.42).*

CAPÍTULO 5

EJEMPLO DE APLICACIÓN

Con la finalidad de mostrar las ventajas del algoritmo propuesto se realizó una aplicación de este a un prototipo de laboratorio. El equipo seleccionado no representa la clase de sistemas para los cuales se hace necesario el proceder con un enfoque basados en datos, pues el modelo es bien conocido. Sin embargo, sirve ahora para mostrar las ideas del algoritmo propuesto. Por otro lado, a pesar de la característica de linealidad que se le atribuye al sistema, debido a la electrónica del *drive* que trae el equipo, la linealidad solo se puede observar en una zona de trabajo específica.

5.1 DESCRIPCIÓN DEL SISTEMA

El sistema considerado es un motor de corriente directa con una carga variable. La carga es incluida mediante un generador de imanes permanentes acoplado al motor y al que se le puede incluir un perfil de carga arbitrario mediante una señal. El equipo es mostrado en la figura (5.1).

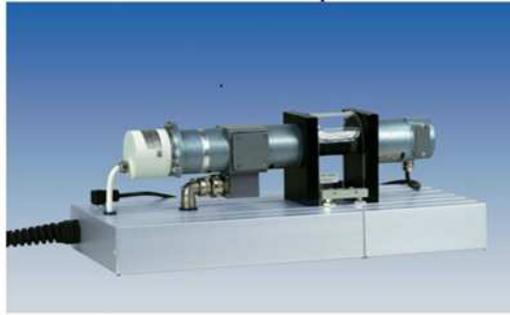


Figura 5.1: Banco experimental - AMIRA DR300

El esquemático del motor puede ser visto en la Figura (5.2). En este diagrama no aparece el drive ni la electrónica relacionada con la generación de la carga.

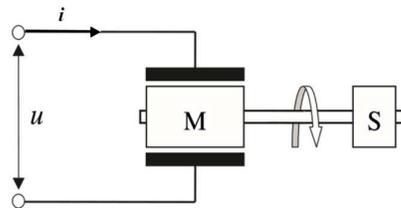


Figura 5.2: Esquema simplificado del DR300

La señal de entrada es el voltaje suministrado, Figura 5.3(a). En tanto que las salidas son la velocidad angular del eje del motor y la corriente de armadura, Figura 5.3(b). El equipo dispone de un lazo de control proporcional integral que puede ser utilizado opcionalmente, o bien, se puede utilizar algún controlador externo. El perfil con el que la carga opera sobre el sistema puede también ser configurado mediante un arreglo resistivo interno o bien mediante una señal externa.

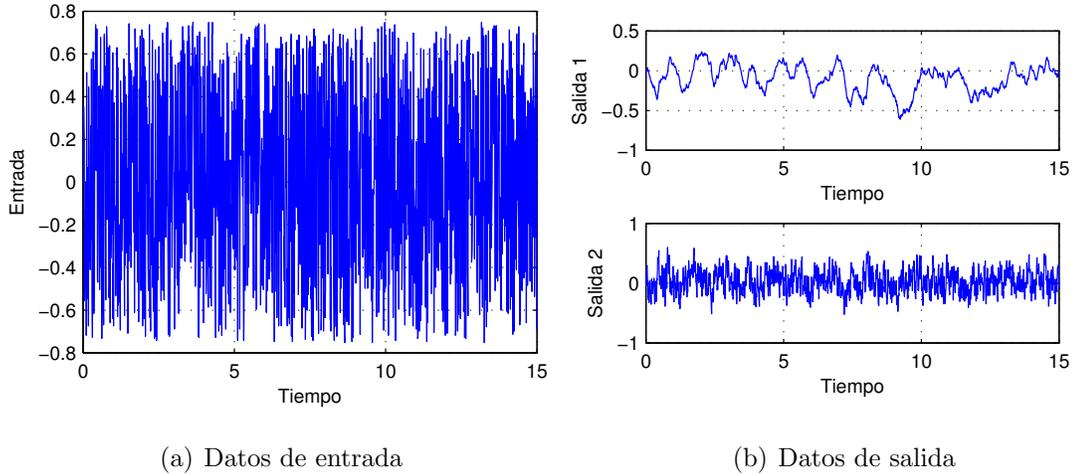


Figura 5.3: Datos nominales

Para fines de los experimentos realizados se utilizó LabView junto con un MyRio. Se utilizó el sistema sin controlador, es decir, en lazo abierto.

Se consideran dos posibles fallas, una falla aditiva de actuador (la falla se considera en el drive) y una falla aditiva en un sensor. Las fallas son incluidas por software.

5.2 EXPERIMENTOS PLANTEADOS

El sistema tiene $m = 1$ entrada y $p = 2$ salidas y su orden es $n = 2$, el tiempo de muestreo es $Tm = 0.01s$, se utilizaron 1500 datos para la simulación con $N = 1489$ y $s = 5$.

Para obtener los datos con falla se simularon dos fallas aditivas donde se le sumo una magnitud de 1.34 al vector de salidas y de entradas después del instante de muestreo 800 (8s).

Con la finalidad de mostrar que el procedimiento propuesto puede ser usado efectivamente para el aislamiento de fallas, es decir, para la construcción de un

banco de residuos que permiten el aislamiento de fallas, se establecieron los siguientes escenarios de prueba.

Escenario	Descripción
1	Sistema sin falla
2	Falla en actuador
3	Falla en sensor

Se diseñaron dos residuos, el primero robusto a la falla en el actuador, y el segundo residuo robusto a la falla en el sensor. Como fue mencionado con anterioridad, el diseño de un residuo robusto a una falla determinada requiere de datos en los cuales esté presente la falla en cuestión. Uno puede en un equipo de laboratorio obtener los datos. Esto puede ser manejado como una desventaja del método propuesto. Sin embargo, es importante destacar que no se requiere reproducir una falla de manera exacta, sino que mas bien se requiere de aplicar una señal en el canal en donde se encuentra el elemento a ser supervisado. Esto posibilita la aplicación del método.

El diseño completo para este ejemplo brinda como resultado dos residuos, cada uno sensible a una posible falla mientras que es robusto a la otra. Las características del generador de residuos diseñado, se pueden apreciar en la siguiente tabla:

	f_1 (act.)	f_2 (sensor)
r_1	\emptyset	\checkmark
r_2	\checkmark	\emptyset

Donde “ \emptyset ” representa que el residuo fue diseñado insensible a falla correspondiente, mientras que el símbolo “ \checkmark ” representa sensibilidad a la falla.

Los vectores de paridad utilizados para el diseño de los generadores de residuos son:

$$\begin{aligned}\psi_{s,y}^\perp 1 &= [0.0470 \quad -0.5371 \quad -0.0081 \quad -0.1038 \quad -0.0032 \quad 0.2766 \quad 0.0234 \quad 0.3979 \quad 0.0250 \quad 0.3220 \quad 0.0729 \quad 0.3919] \\ \psi_{s,y}^\perp 2 &= [0.0079 \quad -0.5490 \quad 0.0021 \quad -0.0743 \quad -0.0142 \quad 0.2842 \quad 0.0332 \quad 0.3139 \quad -0.0278 \quad 0.0171 \quad 0.0077 \quad 0.0008]\end{aligned}$$

5.3 RESULTADOS

Primero es necesario una fase de diseño de generadores de residuos con la robustez requerida, es decir, dos generadores de residuos, uno con robustez a la falla en el actuador, el cual es denominado r_1 y otro con robustez a la falla en el sensor, denominado r_2 . El diseño esta basado en conjuntos de datos con la incidencia de fallas descrita con anterioridad.

5.3.1 ESCENARIO 1

Residuos evaluando datos sin fallas.

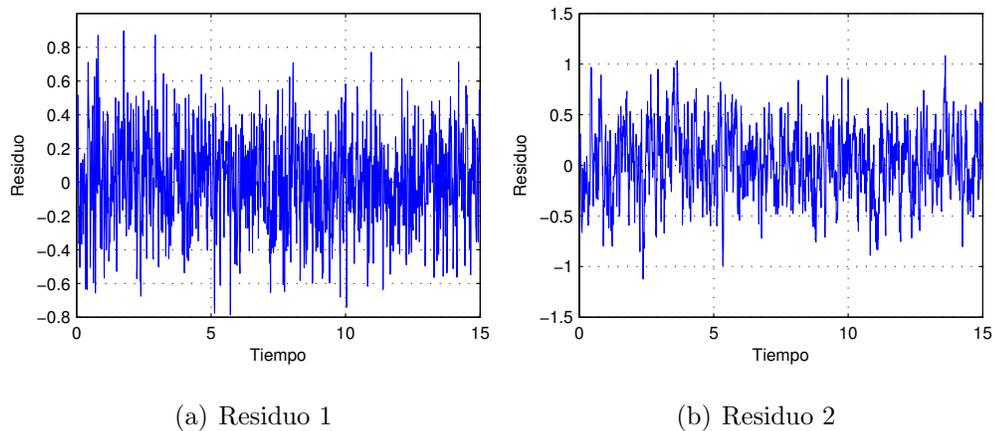


Figura 5.4: Respuesta en ausencia de fallas

En este escenario podemos observar que el residuo prácticamente permanece en cero, dicho resultado es el esperado cuando no hay fallas presentes en el sistema.

5.3.2 ESCENARIO 2

Residuos evaluando datos con falla en actuador.

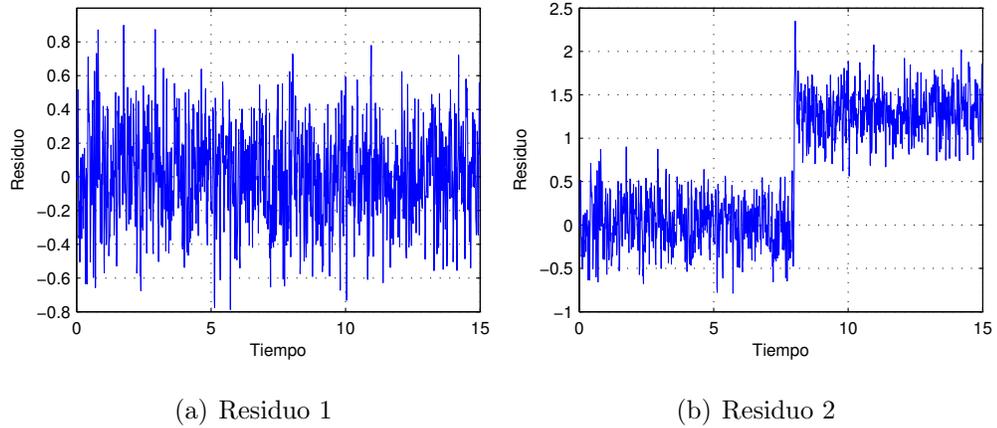


Figura 5.5: Respuesta a falla de actuador

Se puede apreciar que el residuo 1 es insensible a la falla 1, mientras que el residuo 2 es sensible a dicha falla.

5.3.3 ESCENARIO 3

Residuos evaluando datos con falla en sensor.

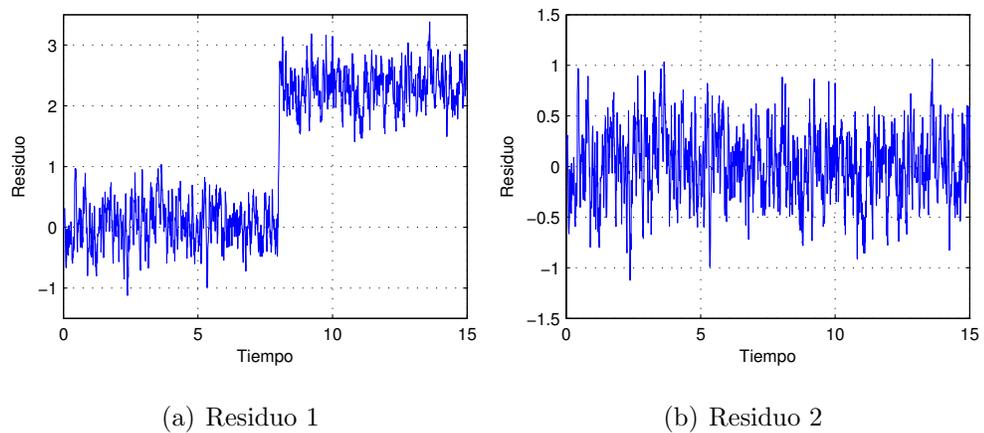


Figura 5.6: Respuesta a falla de sensor

A diferencia del residuo 2, aquí se puede apreciar que el residuo 1 es insensible

a la falla 1, mientras que el residuo 2 es sensible a dicha falla.

Con los tres escenarios vistos en este capítulo se puede concluir que el algoritmo propuesto para el aislamiento de fallas funciona.

5.4 DISCUSIÓN

Se discute primeramente el aspecto operativo del método propuesto. La primera cuestión relacionada con el método propuesto es la disponibilidad de las señales requeridas para realizar el diseño de los generadores de residuos con diferentes características de robustez. Estas señales pueden ser obtenidas inyectando una señal en el canal donde está el instrumento/componente que se desea supervisar.

Alternativamente se puede identificar un modelo a partir de mediciones entrada-salida del sistema en ausencia de fallas. En el caso de actuadores y sensores es posible introducir una señal en cada actuador y sensor (uno a la vez) para obtener el conjunto de mediciones entrada-salida con diferentes situaciones de falla.

Enseguida, el algoritmo tiene pocas posibilidades de ajuste. Uno de ellos es el tamaño de los bloques en las matrices de Hankel. En general se requiere que el tamaño de los bloques debe ser mayor que el orden del sistema a ser considerado.

En la figura 5.4 se pueden apreciar los resultados de aplicar mediciones entrada-salida del sistema cuando no hay falla. Se observa que la magnitud del residuo no es cero, pero está cercano a cero. Es claro que un umbral con valor de ± 1 puede evitar alarmas falsas. El efecto de la falla sobre el residuo diseñado robusto puede ser discriminado mediante la evaluación. Algo semejante ocurre cuando la falla en el sensor se manifiesta, como se puede ver en la figura 5.6. En este caso se aplica también el mismo criterio para evaluar los residuos (comparación con un valor de umbral y discriminación por tiempo que el residuo se mantiene sobre el valor de umbral).

CAPÍTULO 6

CONCLUSIONES Y TRABAJO A FUTURO

Se presentó uno de los enfoques más utilizados para el diagnóstico de fallas basados en datos [30], uno de los objetivos consistió en utilizar dicho algoritmo para la detección de fallas incipientes en transformadores. Se muestra que el esquema propuesto es eficaz en la detección de fallas incipientes incluso si no hay un modelo matemático explícito del transformador utilizado. Los resultados obtenidos permiten demostrar que es posible detectar fallas aunque el sistema sea no lineal, y que se pueden obtener residuos sensibles ante fallas incipientes, lo que muestra una buena aplicación del algoritmo. Como trabajo futuro se pretende determinar la falla incipiente mínima que se puede detectar utilizando este enfoque.

Un punto importante en este trabajo fue demostrar que el aislamiento de fallas puede ser realizado directamente usando datos de entrada y salida del proceso, para esto se propone un enfoque de diseño para el aislamiento de fallas directamente de datos en donde los resultados en simulación obtenidos permiten afirmar que el aislamiento es satisfactorio.

El problema de aislamiento de fallas en sistemas para los cuales no se conoce un modelo es considerado. Inspirados en procedimientos utilizados en redes neuronales, donde datos en situaciones específicas de un sistema son utilizadas para entrenar las redes. Básicamente se utilizó esta idea para lograr el diseño con características

de robustez determinadas. Se mostró como la idea tiene sustento en la teoría de identificación por subespacios. Se concluye que la idea de diseño para aislamiento de fallas puede ser aplicada con éxito a sistemas alrededor de un punto de operación, o bien a sistemas que son lineales. Una cuestión importante es que para efecto de diseñar los residuos, no se requiere información de diferentes magnitudes de una misma falla, sino que solo se requiere que tenga magnitud suficiente para que su manifestación ayude a cancelar el efecto durante el diseño del generador de residuos. Naturalmente, el método funcionará mejor si los datos utilizados para el diseño de generadores de residuos son obtenidos con señales de entrada con la característica de excitación persistente.

Se verificó que es posible la detección de fallas a partir de datos mediante la utilización de un ejemplo de aplicación en un transformador, con lo que se realizó la redacción de un artículo “*Data-driven approach to Observer-based incipient fault detection in Transformer*” que fue aceptado para el IEEE/PES Transmission and Distribution Conference and Exposition Latin America (IEEE/PES T&D LA 2016). Y gracias a los resultados de investigación que arrojó este tema de tesis, se tiene otro artículo “*Aislamiento de Fallas en Sistemas Lineales Discretos a partir de Mediciones*” para el Congreso Nacional de Control Automático 2016 (AMCA).

La metodología utilizada para el diagnóstico de fallas a partir de datos, se encuentra todavía en una etapa inicial, es por ello que trabajo futuro se requiere en el sentido de lograr identificación de fallas así como en los detalles de diseño, tales como la selección mas adecuada del tamaño de los bloques de las matrices de Hankel.

BIBLIOGRAFÍA

- [1] P. M. Frank. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy: A survey and some new results. *Automatica*, 26(3):459–474, 1990.
- [2] J. Chen and R. J. Patton. *Robust model-based fault diagnosis for dynamic systems*, volume 3. Springer Science & Business Media, 2012.
- [3] S. X. Ding. *Model-based fault diagnosis techniques: design schemes, algorithms, and tools*. Springer Science & Business Media, 2008.
- [4] S. X. Ding. *Data-driven design of fault diagnosis and fault-tolerant control systems*. Springer, 2014.
- [5] P. Zhang and S. X. Ding. A model-free approach to fault detection of continuous-time systems based on time domain data. *International Journal of Automation and Computing*, 4(2):189–194, 2007.
- [6] E. Alcorta-Garcia. Detectando fallas mediante redundancia analítica. *Ingenierías*, 4(11):43, 2001.
- [7] B. Huang, Koeppen-Seliger, P. M. Frank, P. Amann, E. Alcorta Garcia. Knowledge- and data-based models for fault diagnosis. *Systems Analysis Modelling Simulation*, 35(1):25–44, 1999.
- [8] R. Isermann. *Fault-diagnosis systems: an introduction from fault detection to fault tolerance*. Springer Science & Business Media, 2006.

-
- [9] E. Y. Chow and A. S. Willsky. Analytical redundancy and the design of robust failure detection systems. *Automatic Control, IEEE Transactions on*, 29(7):603–614, 1984.
- [10] L. Ljung. System identification: theory for the user. *Englewood Cliffs*, 1987.
- [11] P. Van Overschee and B. L. De Moor. *Subspace identification for linear systems: Theory implementation applications*. Springer Science & Business Media, 2012.
- [12] and X. Xie S. Yin, S. X. Ding and H.Luo. A review on basic data-driven approaches for industrial process monitoring. *IEEE Transactions on Industrial Electronics*, 61(11):6418–6428, 2014.
- [13] B.Huang and R. Kadali. *Dynamic modeling, predictive control and performance monitoring: A data-driven subspace approach*. Springer, 2008.
- [14] S. X. Ding. Data-driven design of model-based fault diagnosis systems. *IFAC Proceedings Volumes*, 45(15):840–847, 2012.
- [15] S. J. Qin. An overview of subspace identification. *Computers & chemical engineering*, 30(10):1502–1513, 2006.
- [16] S. X. Ding, E. L. Ding, and T. Jeinsch. A numerical approach to optimization of fdi systems. In *Decision and Control, 1998. Proceedings of the 37th IEEE Conference on*, volume 1, pages 1137–1142. IEEE, 1998.
- [17] O. Ozgonenel and E. Kilic. Modeling and real-time fault identification in transformers. *Journal of the Franklin Institute*, 345(3):205–225, 2008.
- [18] M. Duval. A review of faults detectable by gas-in-oil analysis in transformers. *Electrical Insulation Magazine, IEEE*, 18(3):8–17, 2002.
- [19] J. W. Kim, B. Park, S. Ch. Jeong, S. W. Kim, and P. G. Park. Fault diagnosis of a power transformer using an improved frequency-response analysis. *Power Delivery, IEEE Transactions on*, 20(1):169–178, 2005.

-
- [20] K. S. Pandey and L. Satish. Multiresolution signal decomposition: a new tool for fault detection in power transformers during impulse tests. *Power Delivery, IEEE Transactions on*, 13(4):1194–1200, 1998.
- [21] A. Guzman, S. Zocholl, G. Benmouyal, and H. Altuve. A current-based solution for transformer differential protection. ii. relay description and evaluation. *Power Delivery, IEEE Transactions on*, 17(4):886–893, 2002.
- [22] A. G. Phadke and J. S. Thorp. A new computer-based flux-restrained current-differential relay for power transformer protection. *Power Apparatus and Systems, IEEE Transactions on*, (11):3624–3629, 1983.
- [23] K. Inagaki, M. Higaki, Y. Matsuii, K. Kurita, M. Suzuki, K. Yoshida, and Maeda T. Digital protection method for power transformers based on an equivalent circuit composed of inverse inductance. *Power Delivery, IEEE Transactions on*, 3(4):1501–1510, 1988.
- [24] T. S. Sidhu and M. S. Sachdev. Online identification of magnetizing inrush and internal faults in three-phase transformers. *Power Delivery, IEEE Transactions on*, 7(4):1885–1891, 1992.
- [25] M. Kinnaert, R. Hanus, and Ph. Arte. Fault detection and isolation for unstable linear systems. *Automatic Control, IEEE Transactions on*, 40(4):740–742, 1995.
- [26] E. Alcorta-Garcia, C. Elizondo-González, C. Perez-Rojas, and A. Avalos-Gonzalez. A lmi observer-based approach to fault detection in electrical transformers. In *System of Systems Engineering, 2007. SoSE'07. IEEE International Conference on*, pages 1–5. IEEE, 2007.
- [27] J. R. Espinoza and C. Perez-Rojas. Modeling transformers with internal faults based on magnetic circuit. part i: Models. In *North American Power Symposium (NAPS), 2011*, pages 1–6. IEEE, 2011.

-
- [28] J. R. Espinoza, C. Perez-Rojas, and S. Garcia-Martinez. Modeling transformer with incipient faults using magnetic circuit. In *IEEE RVP 2012*, Acapulco, Mexico, July 2012. IEEE.
- [29] S. X. Ding, Y. Yang, Y. Zhang, and L. Li. Data-driven realizations of kernel and image representations and their application to fault detection and control system design. *Automatica*, 50(10):2615–2623, 2014.
- [30] S. X. Ding. Data-driven design of monitoring and diagnosis systems for dynamic processes: A review of subspace technique based schemes and some recent results. *Journal of Process Control*, 24(2):431–449, 2014.